



Universidade do Estado do Rio de Janeiro

Centro de Tecnologia e Ciências

Instituto de Matemática e Estatística

Danilo Pinheiro Furtado

**Método de aprendizado profundo autossupervisionado  
para deblending de dados sísmicos marítimos**

Rio de Janeiro

2024

Danilo Pinheiro Furtado

**Método de aprendizado profundo autossupervisionado para deblending de dados sísmicos marítimos**



Dissertação apresentada como requisito parcial para obtenção do título de Mestre, ao programa de Pós-Graduação em Ciências Computacionais, da Universidade do Estado do Rio de Janeiro.

Orientadores: Prof. Dr. Gilson A. Ostwald Pedro da Costa  
Prof. Dr. Guilherme Lucio Abelha Mota

Rio de Janeiro

2024

CATALOGAÇÃO NA FONTE  
UERJ/REDE SIRIUS/BIBLIOTECA CTC/A

F992

Furtado, Danilo Pinheiro.

Método de aprendizado profundo autossupervisionado para debrending de dados sísmicos marítimos/ Danilo Pinheiro Furtado. - 2024.

112 f.: il.

Orientadores: Gilson Alexandre Ostwald Pedro da Costa, Guilherme Lucio Abelha Mota

Dissertação (Mestrado em Ciências Computacionais) - Universidade do Estado do Rio de Janeiro, Instituto de Matemática e Estatística.

1. Sismologia - Processamento de dados - Teses. 2. Linguagem de máquina - Teses. 3. Redes neurais (Computação) - Teses. I. Costa, Gilson Alexandre Ostwald Pedro da. II. Mota, Guilherme Lúcio Abelha. III. Universidade do Estado do Rio de Janeiro. Instituto de Matemática e Estatística. IV. Título.

CDU 004

Patricia Bello Meijinhos CRB7/5217 - Bibliotecária responsável pela elaboração da ficha catalográfica

Autorizo, apenas para fins acadêmicos e científicos, a reprodução total ou parcial desta dissertação, desde que citada a fonte.

---

Assinatura

---

Data

Danilo Pinheiro Furtado

**Método de aprendizado profundo autossupervisionado para deblending de dados sísmicos marítimos**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre, ao programa de Pós-Graduação em Ciências Computacionais, da Universidade do Estado do Rio de Janeiro.

Aprovada em 23 de outubro de 2024.

Banca Examinadora:

---

Prof. Dr. Gilson A. Ostwald Pedro da Costa (Orientador)  
Instituto de Matemática e Estatística - UERJ

---

Prof. Dr. Guilherme Lucio Abelha Mota (Orientador)  
Instituto de Matemática e Estatística - UERJ

---

Prof. Dr. Alexandre Gonçalves Evsukoff  
COPPE/UFRJ

---

Prof. Dr. Dário Augusto Borges Oliveira  
FGV EMAp

---

Prof. Dr. Lisandro Lovisolo  
Departamento de Engenharia Eletrônica e de Telecomunicações - UERJ

Rio de Janeiro

2024

## AGRADECIMENTOS

Agradeço aos meus pais, Francisco Pinheiro (Chico da Compesa) e Rita Farias, por sempre me incentivarem a seguir o caminho do aperfeiçoamento através dos estudos e por respeitarem as minhas decisões, mesmo nem sempre concordando com elas.

Agradeço imensamente à Izabelle Andrade, minha esposa e companheira, que sempre me incentivou apesar do alto preço que teve que pagar pela minha ausência durante o período dedicado à realização deste trabalho. Ao meu filho, Lucas, registro aqui o meu agradecimento e pedido de perdão pelo tempo em que não pude me dedicar a você tanto quanto deveria e gostaria.

Agradeço aos meus orientadores Prof. Dr. Gilson Costa e Prof. Dr. Guilherme Abelha pela paciência, compreensão, incentivo e suporte à realização deste projeto. Suas ideias, sugestões e revisões foram fundamentais para o resultado final deste trabalho.

Agradeço à minha irmã, Daniela, e minha sobrinha, Júlia Vitória, por todo o apoio e torcida mesmo à distância.

Agradeço ao meu cunhado, Abílio, às minhas cunhadas, Débora e Gabrielle, e minha sogra, Sônia Selma, pelo apoio e pelos momentos de descontração tão importantes durante esta jornada.

Agradeço aos amigos da gerência de Aquisição Geofísica pela amizade, companheirismo e incentivo durante a realização deste trabalho. Em especial, aos gerentes Guilherme Canha e Cláudio Falcão pelo suporte e incentivo de sempre.

Agradeço à PETROBRAS pelo apoio financeiro e pela liberação parcial para dedicação a este trabalho.

Agradeço a todos os professores do PPG-CCOMP por compartilharem seus conhecimentos durante as disciplinas. Em especial, às professoras Dra. Cristiane Faria e Dra. Diana Sasaki que me indicaram a este programa de pós-graduação e dividiram comigo a autoria da minha primeira publicação em um periódico.

Agradeço aos colegas do PPG-CCOMP, especialmente aos membros do Laboratório de Processamento Gráfico pelo compartilhamento de experiências e ajuda mútua. Principalmente, Yago, Matheus e Vinícius, que foram meus contemporâneos mais próximos.

Agradeço a todos os que compartilharam códigos e dados públicos que foram utilizados direta ou indiretamente neste trabalho.

Agradeço aos membros da banca, Prof. Dr. Alexandre Evsukoff, Prof. Dr. Dário Oliveira e Prof. Dr. Lisandro Lovisolo pelas críticas construtivas e sugestões.

E por último, mas não menos importante, gostaria de agradecer a todas as pessoas que, de forma direta ou indireta, contribuíram para a realização deste trabalho.

## RESUMO

FURTADO, Danilo Pinheiro. **Método de aprendizado profundo autossupervisionado para deblending de dados sísmicos marítimos**. 2024. 112 f. Dissertação (Mestrado em Ciências Computacionais) – Instituto de Matemática e Estatística, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2024.

A aquisição sísmica convencional requer um intervalo de tempo entre disparos longo o suficiente para registrar todos os eventos de interesse e evitar a interferência entre sinais de fontes sucessivas. Isto causa limitações tanto do ponto de vista operacional quanto da amostragem espacial dos dados. A fim de superar essas limitações, foi introduzido o conceito de aquisição sísmica *blended* ou aquisição com fontes simultâneas. Nesta técnica, dois ou mais pontos de tiro são disparados em um tempo mais curto, permitindo a interferência entre os dados de fontes sucessivas. No entanto, os benefícios trazidos por esta técnica vêm associados a um ruído de interferência sísmica que deve ser tratado durante o processamento dos dados. Essa etapa do processamento sísmico é conhecida como *deblending*. Recentemente, técnicas baseadas em aprendizado profundo têm sido aplicadas a diversos problemas da área de Geofísica. Como em uma aquisição sísmica *blended* apenas estarão disponíveis dados que sofreram interferência de tiros consecutivos, o uso de métodos de *deblending* envolvendo aprendizado supervisionado é limitado, uma vez que este tipo de método necessita de dados limpos, sem efeito de interferência, para o treinamento. Por esse motivo, o presente trabalho propõe a utilização do método autossupervisionado Trace2Trace para o processo de *deblending* de dados sísmicos marítimos. O método foi implementado utilizando redes neurais convolucionais com arquiteturas U-NET, *No-downscale* CNN (NDCNN) e RES-NDCNN. A validação do método foi realizada por meio da comparação dos resultados obtidos, em termos das métricas razão sinal-ruído (SNR) e NRMSE, com o método de *deblending* supervisionado e com o método de *deblending* por inversão esparsa, empregando a transformada de Fourier 2D janelada e o algoritmo FISTA. Nesta etapa de validação, foram avaliados os efeitos da arquitetura, da função objetivo e do procedimento de pós-processamento em experimentos realizados usando bases de dados sintéticos e reais. O método proposto usando a arquitetura RES-NDCNN apresentou melhores resultados do que as outras arquiteturas avaliadas. Após definição da arquitetura, analisou-se o efeito dos desvios aleatórios adicionados aos tempos entre disparos (*dither times*) sobre os resultados, bem como a capacidade de generalização da rede quando aplicada a uma base de dados diferente da utilizada para o treinamento. Os resultados obtidos com o método proposto são comparáveis aos publicados na literatura em condições similares e superam o método de *deblending* por inversão esparsa para *dither times* no intervalo  $[-0,5, 0,5]$  s.

**Palavras-chave:** Dados sísmicos. Deblending. Aprendizado autossupervisionado. Redes neurais convolucionais. Aprendizado profundo.

## ABSTRACT

FURTADO, Danilo Pinheiro. **A Self-supervised deep learning method for marine seismic data deblending**. 2024. 112 f. Dissertação (Mestrado em Ciências Computacionais) – Instituto de Matemática e Estatística, Universidade do Estado do Rio de Janeiro, Rio de Janeiro, 2024.

Conventional seismic acquisition requires a time interval between shots long enough to record all events of interest and avoid interference between signals from successive shots. This causes a limitation both from the spatial data sampling point of view and the operational one. In order to overcome these limitations, the concept of blended seismic acquisition, also known as simultaneous sources acquisition, was introduced. In this technique, two or more shot points are fired with a shorter time between shots, allowing interference between data from different sources. However, the benefits brought by this technique are associated with seismic interference noise (blending noise) that must be treated in data processing. This seismic processing step is known as deblending. Recently, deep learning based techniques have been applied to several problems in geophysics. Since in a blended seismic acquisition there is no blending noise-free data available, the use of deblending methods involving supervised learning is limited, once this kind of method needs clean data to be used as targets for training. For this reason, this work proposes the use of the Trace2Trace self-supervised method for marine seismic data deblending. The method was implemented with different convolutional neural networks architectures such as U-NET, No-downscale CNN (NDCNN) and RES-NDCNN. The method was validated by comparing the results obtained in terms of the signal-to-noise ratio (SNR) and NRMSE metrics with the supervised deblending method as well as the sparse inversion deblending method, using the 2D windowed Fourier transform and the FISTA algorithm. In this stage, the effects of the architecture, the objective function and the post-processing procedure were evaluated in experiments performed on both synthetic and field datasets. The proposed method using the RES-NDCNN architecture showed better results than the other ones evaluated. After choosing the architecture, the effect of the random time shifts added to the time intervals between shots (dither times) on the results was analyzed, as well as the network's ability to generalize when applied to a database other than the one used for training. The results obtained by the proposed method are comparable to those reported in literature under similar conditions and outperform the sparse inversion deblending method for dither times in the  $[-0.5, 0.5]$  s range.

**Keywords:** Seismic data. Deblending. Self-supervised learning. Convolutional neural networks. Deep learning.

## LISTA DE ILUSTRAÇÕES

Figura 1 - Tecnologias de aquisição sísmica marítima . . . . .	21
Figura 2 - Representação esquemática de uma aquisição sísmica <i>blended</i> . . . . .	23
Figura 3 - Representação do dado sísmico referente a uma linha de navegação como um tensor tridimensional . . . . .	24
Figura 4 - Ilustração de um operador de <i>blending</i> 2D $\mathbf{T}_r$ e sua aplicação a um painel de receptor comum, gerando um traço sísmico <i>blended</i> . . . . .	26
Figura 5 - Sismogramas originais, para um dado adquirido de forma convenci- onal, e <i>pseudoblended</i> no domínio do canal comum (à esquerda) e do tiro comum (à direita) . . . . .	28
Figura 6 - Número de publicações sobre aprendizado de máquina por ano de 2010 a 2021 . . . . .	32
Figura 7 - Algoritmos de aprendizado de máquina mais usados para aplicações de processamento sísmico . . . . .	33
Figura 8 - Representação de uma arquitetura MLP . . . . .	39
Figura 9 - Função de ativação ReLU . . . . .	41
Figura 10 - Função de ativação <i>Leaky</i> ReLU . . . . .	41
Figura 11 - Função de ativação sigmoide . . . . .	42
Figura 12 - Ilustração de uma operação de convolução 2D . . . . .	44
Figura 13 - Comparação entre uma camada totalmente conectada e uma camada convolucional . . . . .	45
Figura 14 - Métodos para redução de escala de mapas de ativação . . . . .	47
Figura 15 - Camada de convolução transposta com um <i>kernel</i> $2 \times 2$ e <i>stride</i> 1 . . . . .	48
Figura 16 - Atenuação de ruídos em dados sísmicos através de aprendizado su- pervisionado . . . . .	50
Figura 17 - Atenuação de ruídos em dados sísmicos através de aprendizado au- tossupervisionado Noise2Noise. . . . .	51
Figura 18 - Ilustração do processo de subamostragem por traços adjacentes do método Trace2Trace . . . . .	53
Figura 19 - Esquema de amostragem empregada no método Trace2Trace . . . . .	54
Figura 20 - Esquema de treinamento para o método de <i>Deblending</i> Autossuper- visionado Trace2Trace . . . . .	55
Figura 21 - Esquema de treinamento para o método de <i>Deblending</i> Autossuper- visionado Trace2Trace usando a função objetivo alternada . . . . .	56
Figura 22 - Esquema de treinamento para o método de <i>Deblending</i> supervisionado . . . . .	57
Figura 23 - Algoritmo FISTA . . . . .	59
Figura 24 - Arquitetura U-NET proposta por Liu et al. (2022) . . . . .	61
Figura 25 - Arquitetura No Downscale CNN (NDCNN) . . . . .	62

Figura 26 - Arquitetura RES-NDCNN . . . . .	63
Figura 27 - Modelo de velocidades sísmicas do campo de Volve usado para modelagem da base de dados sintéticos . . . . .	65
Figura 28 - Sismogramas da base de dados Volve sintético nos domínios do canal comum (CCG) e tiro comum (CSG) . . . . .	66
Figura 29 - Esquema do levantamento marítimo <i>streamer</i> 2D Mobil AVO <i>Viking Graben</i> linha 12 . . . . .	67
Figura 30 - Sismogramas da base de dados Mobil AVO nos domínios do canal comum (CCG) e tiro comum (CSG) . . . . .	67
Figura 31 - Histograma dos desvios temporais usados para construção do operador de <i>blending</i> com <i>dither times</i> no intervalo $[-1,0, 1,0]$ s . . . . .	68
Figura 32 - Sismogramas da base de dados Volve sintético nos domínios no canal comum (CCG) e tiro comum (CSG) antes e depois dos processos de <i>blending</i> e <i>pseudodeblending</i> . . . . .	69
Figura 33 - Sismogramas da base de dados Mobil AVO nos domínios no canal comum (CCG) e tiro comum (CSG) antes e depois dos processos de <i>blending</i> e <i>pseudodeblending</i> . . . . .	69
Figura 34 - Ilustração do volume de dados sísmicos Mobil AVO <i>Viking Graben</i> linha 12 separado em conjuntos de treinamento e teste . . . . .	71
Figura 35 - Exemplo de um par de <i>patches</i> usado no treinamento supervisionado	71
Figura 36 - Fluxo de treinamento das redes neurais profundas . . . . .	72
Figura 37 - Exemplo de um par de <i>patches</i> , extraído da base de dados Mobil AVO, usado no treinamento autossupervisionado Trace2Trace . . . . .	73
Figura 38 - Resultado do <i>deblending</i> autossupervisionado Trace2Trace usando a arquitetura U-NET e treinada com a função objetivo alternada L1 . . . . .	81
Figura 39 - Resultado do <i>deblending</i> autossupervisionado Trace2Trace usando a arquitetura RES-NDCNN e treinada com a função objetivo alternada L1 . . . . .	82
Figura 40 - Resultado do <i>deblending</i> pelo método de inversão esparsa . . . . .	83
Figura 41 - Resultado do <i>deblending</i> autossupervisionado Trace2Trace usando a arquitetura U-NET e treinada com a função objetivo alternada L1 . . . . .	87
Figura 42 - Resultado do <i>deblending</i> autossupervisionado Trace2Trace usando a arquitetura RES-NDCNN e treinada com a função objetivo alternada L1 . . . . .	88
Figura 43 - Resultado do <i>deblending</i> pelo método de inversão esparsa . . . . .	89
Figura 44 - Resultado da aplicação do método <i>Deblending</i> T2T usando <i>dither times</i> no intervalo $[-2,0, 2,0]$ s . . . . .	91
Figura 45 - Resultado do <i>deblending</i> pelo método de inversão esparsa usando <i>dither times</i> no intervalo $[-2,0, 2,0]$ s . . . . .	92

Figura 46 - Resultado da aplicação do método <i>Deblending</i> T2T usando <i>dither times</i> no intervalo [-1,0, 1,0] s . . . . .	93
Figura 47 - Resultado do <i>deblending</i> pelo método de inversão esparsa usando <i>dither times</i> no intervalo [-1,0, 1,0] s . . . . .	94
Figura 48 - Resultado da aplicação do método <i>Deblending</i> T2T usando <i>dither times</i> no intervalo [-0,5, 0,5] s . . . . .	95
Figura 49 - Resultado do <i>deblending</i> pelo método de inversão esparsa usando <i>dither times</i> no intervalo [-0,5, 0,5] s . . . . .	96
Figura 50 - Resultado da aplicação do método <i>Deblending</i> T2T, treinado com dados da base Mobil AVO e aplicado aos dados da base Volve Sintético	99
Figura 51 - Resultado da aplicação do método <i>Deblending</i> T2T, treinado com dados da base Volve Sintético e aplicado aos dados da base Mobil AVO100	

## LISTA DE TABELAS

Tabela 1 - Comparação entre as métricas de avaliação dos resultados obtidas para cada método de <i>deblending</i> e o <i>pseudodeblending</i> para a base de dados Volve Sintético. As melhores métricas obtidas para cada método são destacadas em negrito. Os segundos melhores resultados são destacados em itálico. . . . .	79
Tabela 2 - Comparação entre as métricas de avaliação dos resultados obtidas para cada método de <i>deblending</i> e o <i>pseudodeblending</i> para a base de dados Mobil AVO. As melhores métricas obtidas para cada método são destacadas em negrito. Os segundos melhores resultados são destacados em itálico. . . . .	84
Tabela 3 - Comparação entre as métricas de avaliação dos resultados obtidas para diferentes intervalos de <i>dither time</i> para os métodos <i>Deblending</i> Trace2Trace e Inversão Esparsa. . . . .	90
Tabela 4 - Valores da métrica razão sinal-ruído (SNR) obtidos nos experimentos de treinamento e teste cruzado entre diferentes bases de dados para o método <i>Deblending</i> T2T usando a arquitetura RES-NDCNN. . . .	97
Tabela 5 - Valores da métrica razão sinal-ruído (SNR) obtidos nos experimentos de treinamento e teste cruzado entre diferentes bases de dados para o método de <i>deblending</i> supervisionado usando a rede RES-NDCNN. . . .	98
Tabela 6 - Valores da métrica razão sinal-ruído (SNR) obtidos nos experimentos de treinamento e teste usando dados da base Mobil AVO submetidos a diferentes intervalos de <i>dither time</i> . . . . .	101

## LISTA DE SIGLAS

<b>CCUS</b>	<i>Carbon Capture, Utilization and Storage</i>
<b>FWI</b>	<i>Full Waveform Inversion</i>
<b>RTM</b>	<i>Reverse Time Migration</i>
<b>DL</b>	<i>Deep Learning</i>
<b>FISTA</b>	<i>Fast Iterative Shrinkage-Thresholding Algorithm</i>
<b>CSG</b>	<i>Common Shot Gather</i>
<b>CRG</b>	<i>Common Receiver Gather</i>
<b>CCG</b>	<i>Common Channel Gather</i>
<b>WFT2D</b>	<i>2D Windowed Fourier Transform</i>
<b>SPGL1</b>	<i>Spectral Projected Gradient L1</i>
<b>POCS</b>	<i>Projection onto Convex Sets</i>
<b>CNN</b>	<i>Convolutional Neural Networks</i>
<b>GRL</b>	<i>Global Residual Learning</i>
<b>MAE</b>	<i>Mean Absolute Error</i>
<b>SNR</b>	<i>Signal to Noise Ratio</i>
<b>MSE</b>	<i>Mean Squared Error</i>
<b>NRMSE</b>	<i>Normalized Root Mean-Squared Error</i>

## SUMÁRIO

	<b>INTRODUÇÃO</b>	15
1	<b>DESCRIÇÃO DO PROBLEMA</b>	20
2	<b>REVISÃO BIBLIOGRÁFICA</b>	31
2.1	Aplicações de Aprendizado de Máquina em Dados Sísmicos	31
2.2	<i>Deblending</i> de Dados Sísmicos	33
3	<b>FUNDAMENTAÇÃO TEÓRICA</b>	37
3.1	Redes Neurais	37
3.2	<b>Funções de Ativação</b>	40
3.2.1	<u>Rectified Linear Unit (ReLU)</u>	40
3.2.2	<u>Leaky Rectified Linear Unit (Leaky ReLU)</u>	41
3.2.3	<u>Sigmoide</u>	42
3.3	Redes Neurais Convolucionais	42
3.4	Redução de Escala	46
3.5	Convolução Transposta	47
3.6	Atenuação de Ruídos através de Aprendizado Supervisionado	48
3.7	Atenuação de Ruídos através de Aprendizado Autossupervisionado	50
4	<b>MÉTODO</b>	54
4.1	<i>Deblending</i> Autossupervisionado Trace2Trace	54
4.1.1	<u>Pós-processamento</u>	56
4.2	<i>Deblending</i> Supervisionado	57
4.3	<i>Deblending</i> por Inversão Esparsa	58
4.4	Arquiteturas de Redes Neurais Profundas	60
4.4.1	<u>U-NET</u>	60
4.4.2	<u>NDCNN</u>	61
4.4.3	<u>RES-NDCNN</u>	62
5	<b>PROCEDIMENTO EXPERIMENTAL</b>	64
5.1	<b>Bases de Dados</b>	65
5.1.1	<u>Volve Sintético</u>	65
5.1.2	<u>Mobil AVO Viking Graben</u>	66
5.2	<b>Preparação dos Dados</b>	68
5.2.1	<u>Blending e Pseudodeblending</u>	68
5.2.2	<u>Normalização dos Dados</u>	70
5.3	<b>Treinamento Supervisionado</b>	70
5.4	<b>Treinamento Autossupervisionado Trace2Trace</b>	72

5.5	<b>Funções Objetivo</b>	73
5.6	<b>Parametrização do Treinamento</b>	74
5.7	<b>Etapa de Teste</b>	74
5.8	<b><i>Deblending</i> por Inversão Esparsa - Implementação</b>	74
5.9	<b>Métricas</b>	75
5.9.1	<u>Razão Sinal-Ruído (SNR)</u>	75
5.9.2	<u>Raiz do Erro Quadrático Médio Normalizado (NRMSE)</u>	75
5.10	<b>Hardware</b>	76
5.11	<b>Software</b>	76
6	<b>RESULTADOS E DISCUSSÃO</b>	79
6.1	<b>Validação do Método</b>	79
6.1.1	<u>Volvo Sintético</u>	79
6.1.2	<u>Mobil AVO <i>Viking Graben</i></u>	84
6.2	<b>Análise do Efeito do <i>Dither Time</i></b>	90
6.3	<b>Avaliação da Capacidade de Generalização</b>	96
	<b>CONCLUSÃO</b>	102
	<b>TRABALHOS FUTUROS</b>	104
	<b>REFERÊNCIAS</b>	105

## INTRODUÇÃO

O método sísmico de reflexão pode ser considerado como uma das técnicas geofísicas mais relevantes devido ao grande número de levantamentos realizados, os detalhes e a acurácia da informação obtida, bem como o alto valor do investimento e do retorno associado. O que faz a sísmica de reflexão o método sísmico mais efetivo, especialmente para a indústria de óleo e gás, é o fato de que a imagem final obtida é de grande detalhe e alta resolução quando comparada com outras técnicas geofísicas de superfície (DONDURUR, 2018).

Embora a exploração de petróleo e gás represente a maior parte da atividade de aquisição sísmica, os levantamentos sísmicos também são úteis para qualquer tipo de exploração que necessite de um conhecimento detalhado da subsuperfície da Terra. Estes incluem a pesquisa sísmica profunda para explorar a estrutura do planeta Terra até um nível de algumas centenas de quilômetros e levantamentos superficiais para detectar riscos para a construção de edifícios (ABMA; FOSTER, 2021). Impulsionados pelo crescimento da transição energética, os dados sísmicos são cada vez mais utilizados para estudar a superfície rasa para instalação de parques eólicos (CHAMBERS; LOMASK, 2023) e monitoramento de sítios para Captura, Utilização e Armazenamento de Carbono (*Carbon Capture, Utilization and Storage - CCUS*)(OURABAH; CHATENAY, 2022).

O processo convencional de aquisição de dados sísmicos requer um intervalo de tempo entre disparos longo o suficiente para registrar todos os eventos de interesse e evitar a interferência entre sinais de fontes sucessivas. Isto causa uma limitação tanto do ponto de vista da amostragem espacial dos dados quanto do ponto de vista operacional.

A fim de superar essas limitações, foi introduzido o conceito de aquisição sísmica *blended* (BERKHOUT, 2008), ou aquisição com fontes simultâneas (BEASLEY; CHAMBERS; JIANG, 1998). Nesta técnica, dois ou mais pontos de tiro são disparados com um tempo entre disparos mais curto, permitindo a interferência entre os dados de fontes sucessivas.

A aquisição sísmica com fontes simultâneas tem sido uma tecnologia emergente, estimulando tanto a pesquisa geofísica quanto esforços comerciais. Os benefícios desta

metodologia são substanciais como um dado adquirido de forma mais rápida, mais econômica e sustentável ou mesmo a aquisição de dados com um menor intervalo espacial<sup>1</sup> entre disparos do que uma aquisição sísmica convencional.

No entanto, existem desafios associados a essa técnica. Muitas etapas do processamento sísmico tais como atenuação de reflexões múltiplas, inversão do campo de ondas Completo (*Full Waveform Inversion* - FWI) e migração reversa no tempo (*Reverse Time Migration* - RTM), entre outras, ainda dependem de volumes de dados sem interferência entre registros consecutivos. Sendo assim, um dos principais desafios para o uso de aquisições com fontes simultâneas é a recuperação de um dado sequencial convencional, ou seja, de um dado sem ruído de interferência sísmica (*blending noise*). Esse processo de recuperação é conhecido como separação de fontes e também chamado de *deblending* (WASON, 2017).

A fim de permitir a separação adequada dos registros durante o processamento sísmico, técnicas de codificação de fontes (*source-encoding techniques*) devem ser utilizadas na aquisição dos dados (MAHDAD; DOULGERIS; BLACQUIERE, 2011; WU; BLACQUIERE; GROENESTIJN, 2018). Nas aquisições marítimas, o método de codificação mais comum usa desvios temporais aleatórios adicionados aos tempos entre os disparos (*random time dithering*), pois quando os dados são reorganizados em domínios diferentes do domínio do tiro comum, a interferência entre os disparos aparece como um ruído incoerente, favorecendo a aplicação de técnicas de *deblending*. Neste método de codificação, os tempos de disparo exatos precisam ser registrados, pois essa informação é crucial para todas as técnicas de *deblending* (VELASQUES, 2020).

Atualmente, existem duas categorias principais de métodos convencionais para *deblending* de dados sísmicos na literatura: métodos baseados em atenuação de ruído (*denoising*) e métodos baseados em inversão.

Os primeiros métodos de *deblending* propostos baseavam-se em técnicas de atenuação de ruído para identificar e remover o ruído de interferência entre fontes. Embora vários desses métodos tenham produzido resultados promissores, os métodos de *deblending* mais

---

<sup>1</sup>Os intervalos espacial e temporal entre disparos estão relacionados pela velocidade do navio sísmico.

modernos usam técnicas de inversão. Tais técnicas envolvem a estimativa do dado separado, em algum domínio transformado onde o dado tenha uma representação esparsa, através da formulação do processo de *deblending* como um problema inverso. Como este se trata de um problema mal-posto<sup>2</sup>(*ill-posed*), em geral se faz necessário usar alguma forma de regularização para resolvê-lo (MONK, 2020). Os métodos de *deblending* baseados em atenuação de ruídos demandam, geralmente, menos recursos computacionais em comparação com métodos baseados em inversão. Entretanto, os resultados são extremamente dependentes da parametrização dos filtros utilizados, o que requer bastante tempo e experiência para otimização e ajuste manual desses parâmetros. Já os métodos baseados em inversão envolvem o uso tanto de transformadas quanto de algoritmos de inversão que demandam uso intenso de recursos computacionais, sobretudo em se tratando de dados sísmicos cujos volumes são da ordem de terabytes.

Recentemente, técnicas baseadas em Aprendizado Profundo (*Deep Learning* - DL) têm atraído a atenção da comunidade de Geofísica e têm sido aplicadas a diversos problemas da área, como interpolação de dados sísmicos (OLIVEIRA et al., 2018), atenuação e classificação de ruídos (BAARDMAN; TSINGAS, 2019; LIU et al., 2022), construção de modelos de velocidade (MULLER et al., 2023), dentre outros.

O crescimento do volume de dados e a necessidade de redução do tempo entre a aquisição e a entrega dos produtos finais, por um lado, bem como o crescente poder da capacidade computacional, por outro, fizeram com que o uso de métodos baseados em dados (*data-driven methods*) se tornassem extremamente atraentes para a indústria. Neste contexto, os métodos de aprendizado de máquina têm sido objeto de notáveis investimentos e desenvolvimentos testemunhados por um número exponencialmente crescente de publicações (ANJOM; VACCARINO; SOCCO, 2024).

É diante desse cenário de busca por soluções mais eficientes e eficazes baseadas em dados que o presente trabalho se propõe a investigar o processo de *deblending* de dados sísmicos marítimos por meio de diferentes arquiteturas de redes neurais profundas e da

---

<sup>2</sup>Um problema inverso é dito bem-posto, segundo a definição do matemático francês Jacques Hadamard, se existe solução, se esta solução é única e se a solução tem uma dependência contínua com os dados de entrada. Problemas inversos que não satisfazem alguma dessas condições são ditos problemas mal-postos (RICHTER, 2016).

aplicação de técnicas de aprendizado supervisionado e autossupervisionado.

Tendo em vista que em uma aquisição sísmica *blended* apenas estarão disponíveis dados que sofreram interferência de tiros consecutivos, o uso de métodos de *deblending* envolvendo aprendizado supervisionado é limitado, uma vez que este tipo de método necessita de dados limpos, sem efeito de interferência, para o treinamento. Por isso, são de fundamental importância a pesquisa e o desenvolvimento de métodos e algoritmos de *deblending* que usem estratégias de aprendizado autossupervisionado ou não-supervisionado.

Seguindo essa direção, este trabalho propõe a utilização do método autossupervisionado Trace2Trace (LIU et al., 2022), originalmente proposto para atenuação de ruído aleatório em imagens sísmicas, para o processo de *deblending* de dados sísmicos. O método foi implementado utilizando redes neurais convolucionais com arquiteturas U-NET, *No-downscale* CNN (NDCNN) e RES-NDCNN. A validação do método foi realizada por meio da comparação dos resultados obtidos, em termos das métricas razão sinal-ruído (SNR) e NRMSE, com o método de *deblending* supervisionado, envolvendo as mesmas arquiteturas, além do método tradicional de *deblending* por inversão esparsa, empregando a transformada de Fourier 2D janelada e o Algoritmo Rápido Iterativo de Achatamento e Limiarização (*Fast Iterative Shrinkage-Thresholding Algorithm* - FISTA) (BECK; TEBoulle, 2009). Nesta etapa de validação, foram avaliados os efeitos das arquiteturas selecionadas, da função objetivo e do procedimento de pós-processamento em experimentos realizados usando bases de dados sintéticos e reais. Após definição da arquitetura, analisou-se o efeito dos desvios aleatórios adicionados aos tempos entre disparos (*dither times*) sobre os resultados, bem como a capacidade de generalização da rede quando aplicada a uma base de dados diferente da utilizada para o treinamento.

O conteúdo do trabalho está estruturado da seguinte forma: O Capítulo 1 apresenta a descrição do problema de *deblending* de dados sísmicos. O Capítulo 2 apresenta os principais trabalhos disponíveis na literatura sobre *deblending* de dados sísmicos através de métodos convencionais e redes neurais profundas. O Capítulo 3 aborda os conceitos teóricos fundamentais para a compreensão dos métodos empregados e dos resultados obtidos. O Capítulo 4 descreve os métodos e arquiteturas das redes neurais utilizadas. As bases

de dados, procedimentos experimentais e métricas utilizadas nos experimentos realizados são apresentados no Capítulo 5. Os resultados obtidos são apresentados e discutidos no Capítulo 6. Por fim, são apresentadas as conclusões a respeito dos resultados obtidos e são discutidas as possibilidades de trabalhos futuros.

## 1 DESCRIÇÃO DO PROBLEMA

A aquisição de dados sísmicos é uma parte essencial do ciclo de exploração e produção de petróleo e gás. Levantamentos sísmicos são realizados em terra, zonas de transição e no mar, em águas rasas e profundas. O princípio básico consiste na emissão de um sinal acústico, gerado por uma fonte sísmica, impulsiva ou vibratória, e o registro do sinal refletido nas camadas geológicas em subsuperfície (BJORLYKKE, 2010).

No ambiente marinho, a energia sísmica é normalmente gerada usando arranjos de canhões de ar comprimido, rebocados por um navio, enquanto que na sísmica terrestre são utilizadas fontes explosivas ou caminhões vibradores. Um canhão de ar comprimido é um dispositivo que emite ar altamente pressurizado na água, tipicamente 2.000 psi a 5.000 psi. O volume de cada canhão de ar varia de 10 pol<sup>3</sup> a 250 pol<sup>3</sup> e o volume total de um arranjo varia de 1.000 pol<sup>3</sup> a 8.000 pol<sup>3</sup> (BJORLYKKE, 2010; DONDURUR, 2018).

O sinal acústico oriundo das reflexões nas camadas geológicas é detectado e registrado por diferentes tipos de sensores tais como hidrofones, que medem pressão, geofones, que medem velocidade de partícula, ou ainda acelerômetros, que medem aceleração.

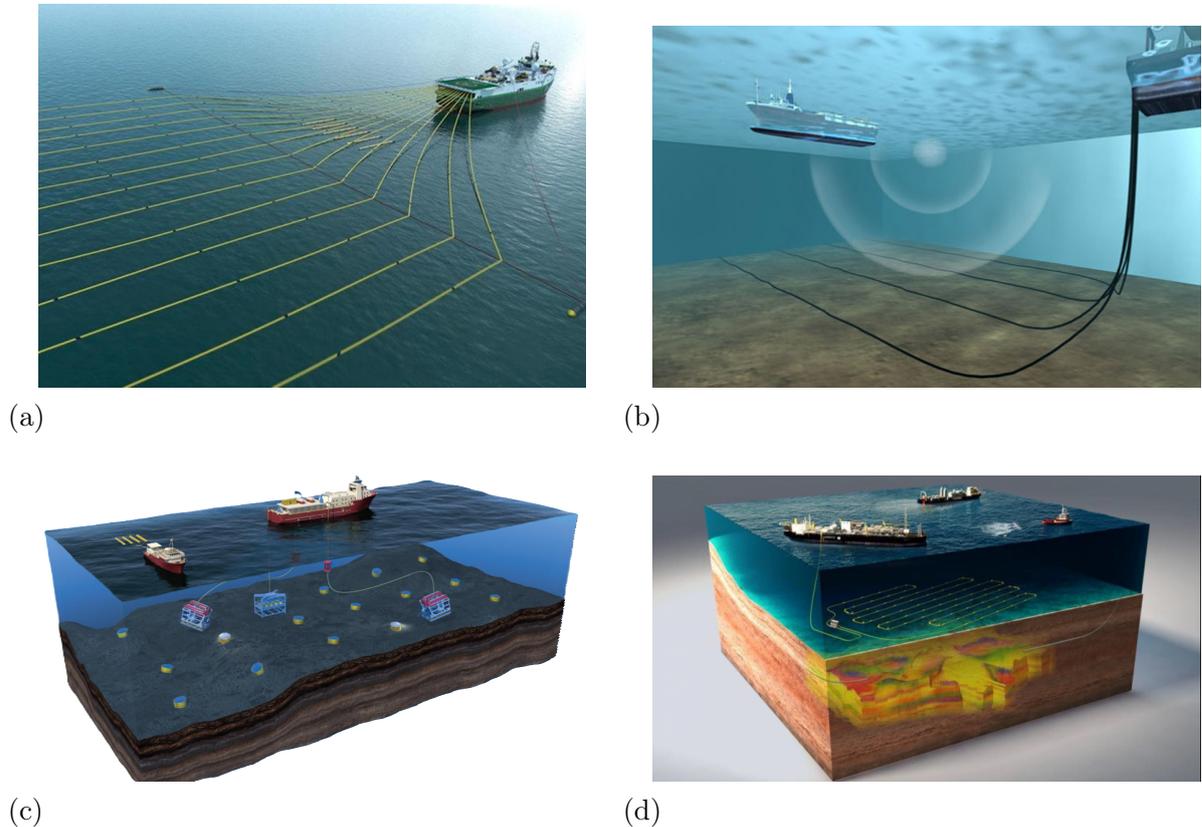
As principais tecnologias de aquisição sísmica marítima disponíveis no mercado, classificadas de acordo com o tipo de receptor são:

- **Streamers** - cabos compostos por receptores que são rebocados próximos da superfície do mar;
- **Ocean Bottom Cables (OBC)** - cabos compostos por receptores que são depositados temporariamente no fundo do mar;
- **Ocean Bottom Nodes (OBN)** - receptores autônomos temporariamente instalados no fundo do mar. Depois de registrar os dados sísmicos, os *nodes* precisam ser coletados para recarga de bateria e *download* dos dados antes de serem depositados em uma nova posição;
- **Permanent Reservoir Monitoring (PRM)** - receptores instalados permanentemente no fundo do mar, conectados por cabos às plataformas de produção de

petróleo e gás, que registram continuamente dados sísmicos passivos e ativos.

A Figura 1 mostra as diferentes tecnologias de aquisição sísmica no ambiente marinho.

Figura 1 – Tecnologias de aquisição sísmica marítima



Legenda: (a) - *Streamers*; (b) - *Ocean Bottom Cable (OBC)*; (c) - *Ocean Bottom Nodes (OBN)* e (d) - *Permanent Reservoir Monitoring (PRM)*.

Fonte: (a) - OpenPR (2022); (b) - Peak-Seismic (2024); (c) - Smythe (2017); (d) - Geospace (2024).

Independentemente da tecnologia utilizada, levantamentos sísmicos convencionais são projetados de forma que os tempos entre os disparos sejam suficientemente longos para evitar a interferência entre os registros de tiros consecutivos (BERKHOUT, 2008). Isto afeta diretamente a amostragem, a produtividade e os custos de um levantamento. Na prática, a relação entre o tempo e o intervalo espacial entre disparos é dada pela velocidade do navio sísmico. Por exemplo, para um intervalo espacial entre disparos de 25 m e velocidade de navio fonte de 5 nós, aproximadamente 2,5 m/s, o tempo máximo de registro limpo, isto é, sem interferência entre tiros consecutivos, é de 10 segundos. Para reduzir

esse intervalo entre disparos para 12,5m e manter o tempo máximo de registro limpo de 10s, seria necessário reduzir a velocidade do navio para a metade. Infelizmente, essa redução não é, em geral, operacionalmente viável, devido a presença de correntes marinhas que precisam ser balanceadas por uma maior velocidade do navio, a fim de manter a estabilidade dos cabos receptores e fontes sísmicas (VELASQUES, 2020).

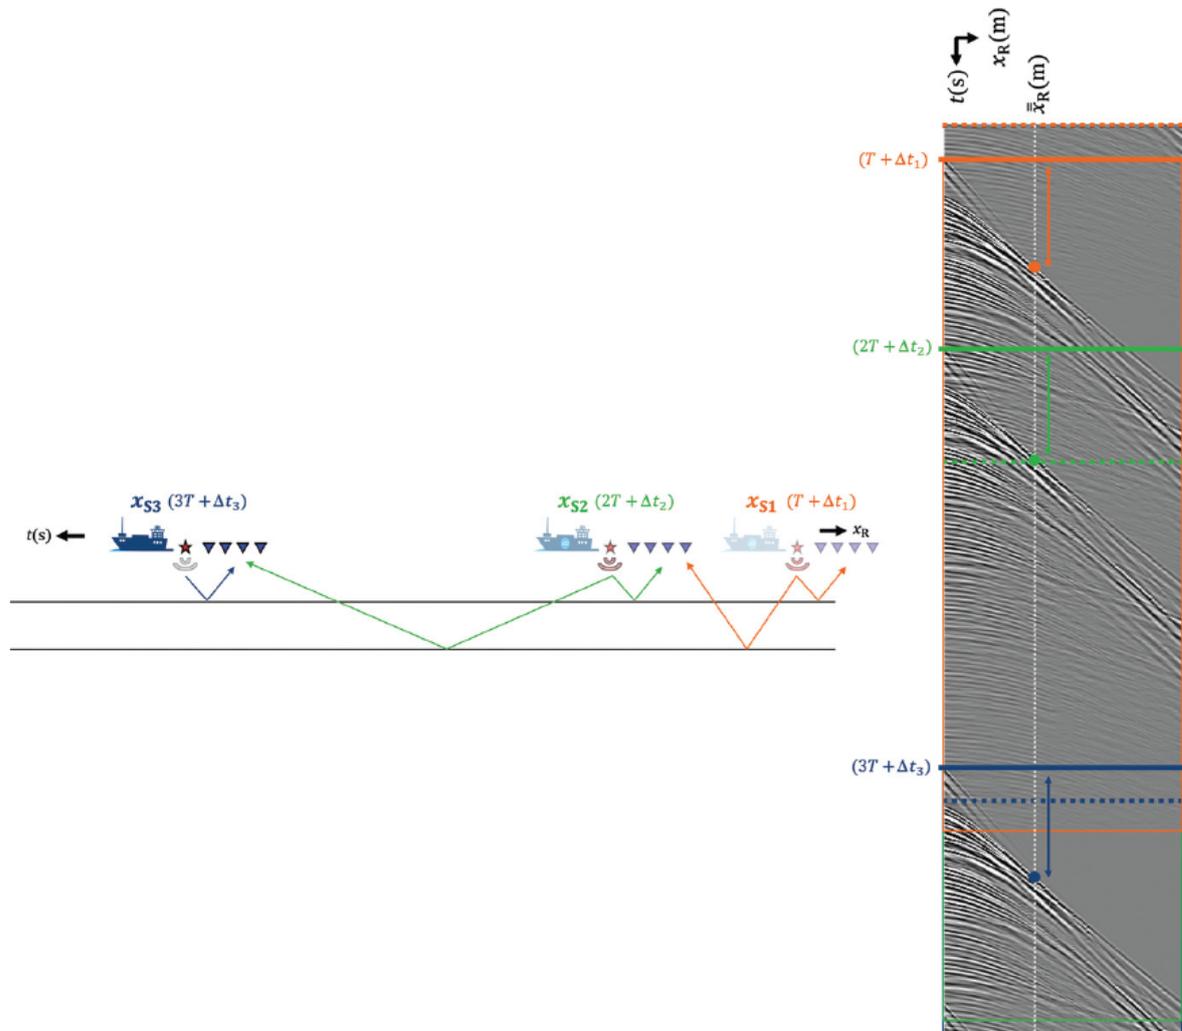
O custo de uma aquisição sísmica marítima é proporcional ao tempo necessário para adquirir o dado, que por sua vez, está relacionado à velocidade do navio sísmico. Quanto maior é a velocidade do navio sísmico, menor é o tempo total de aquisição, e portanto, menor o custo. Voltando ao exemplo anterior, caso a velocidade do navio fosse incrementada em 25% (3,125 m/s), mantendo-se o intervalo espacial entre tiros de 25 m, o tempo máximo de registro limpo seria reduzido para 8 s. Caso o tempo máximo necessário para registrar todos os eventos de interesse seja 10 s, do ponto de vista da aquisição sísmica convencional, esse aumento da velocidade do navio e, conseqüentemente, a redução proporcional do custo de aquisição não seria operacionalmente possível.

A fim de superar essas limitações, foram propostas diversas metodologias envolvendo aquisição de dados sísmicos usando fontes simultâneas (*simultaneous source acquisition*) ou quase-simultâneas, também conhecida como aquisição *blended* (BEASLEY; CHAMBERS; JIANG, 1998; BERKHOUT, 2008). Em princípio, a metodologia de fontes simultâneas consiste em disparar várias fontes em tempos quase simultâneos, ou seja, com um tempo entre disparos reduzido e aleatório, portanto, resultando em sobreposições entre registros de tiros consecutivos, em oposição à aquisição convencional (WASON, 2017).

A Figura 2 ilustra uma aquisição *blended* e um exemplo de sismograma correspondente. O navio rebocando uma fonte sísmica (estrela) e um cabo com receptores (triângulos) se desloca da direita para a esquerda registrando dados de três disparos consecutivos com intervalo entre disparos de  $T + \Delta t_i$ . As linhas horizontais tracejadas no sismograma representam os tempos nominais entre disparos  $T$  e as linhas sólidas representam os tempos reais considerando a adição de um desvio temporal aleatório conhecido  $\Delta t_i$  (*dither time*). O sinal sísmico oriundo da reflexão na interface mais profunda referente à fonte  $S_1$  interfere com os sinais referentes à fonte  $S_2$  refletidos em interfaces mais rasas. O mesmo

ocorre entre os registros das fontes  $S_2$  e  $S_3$ . No entanto, como o intervalo entre os disparos das fontes  $S_2$  e  $S_3$  é maior, menor é o nível de interferência entre esses registros.

Figura 2 – Representação esquemática de uma aquisição sísmica *blended*

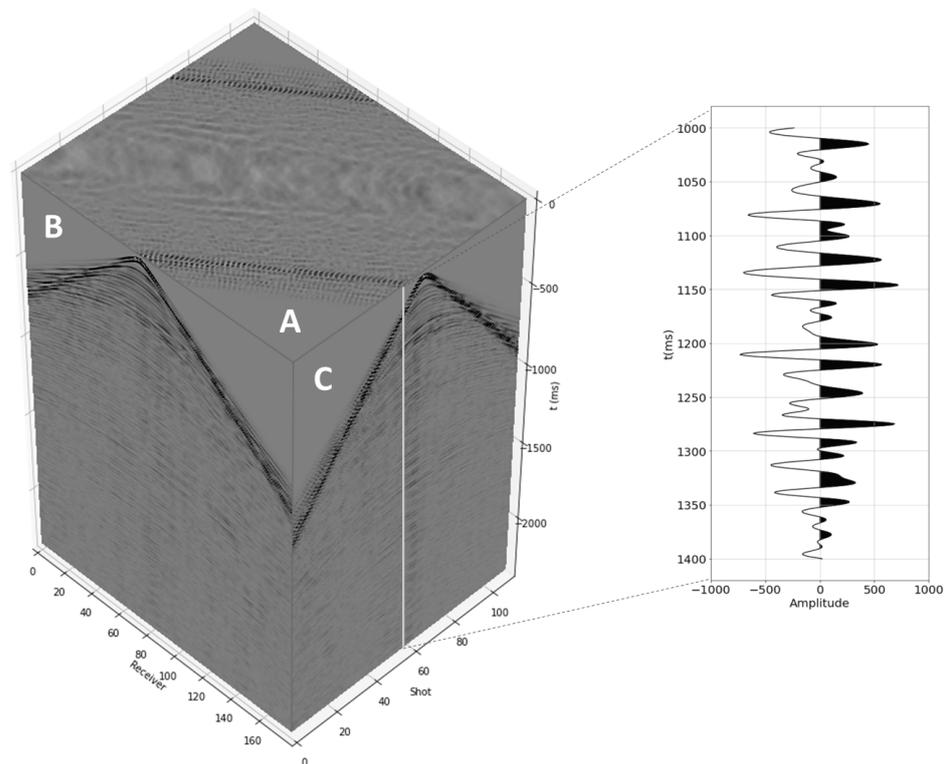


Fonte: Adaptado de Luiken, Ravasi e Birnie (2024).

Um levantamento sísmico marítimo é normalmente dividido em linhas de navegação (*sail lines*) compostas por vários pontos de tiro. Considerando uma linha de navegação como um conjunto de  $N_s$  pontos de tiro, onde para cada tiro,  $N_r$  receptores estavam ativos, e cada receptor registrou o sinal sísmico por um tempo  $t$ , com  $N_t$  amostras, pode-se representar o dado de uma linha de navegação como um tensor tridimensional de dimensões  $N_s \times N_r \times N_t$ . Cortes neste tensor representam sismogramas em diferentes domínios na forma matricial. Por exemplo, um corte de tempo constante (*time slice*) expressa os dados capturados a partir dos diversos tiros e por cada um dos receptores para um deter-

minado tempo  $t$ . Por outro lado, um sismograma no domínio do tiro comum (*Common Shot Gather* - CSG) contém os registros efetuados por todos os receptores ativos para um determinado tiro. Já um sismograma no domínio do receptor comum (*Common Receiver Gather* - CRG) contém todas as amostras registradas por um determinado receptor para todos os tiros. O CRG é normalmente utilizado nos casos de aquisições onde os receptores estão fixos, como por exemplo, nas tecnologias OBC, OBN e PRM. No caso em que os receptores se movem juntamente com a fonte, como é o caso da tecnologia *streamer*, este sismograma é chamado de domínio do canal comum (*Common Channel Gather* - CCG) (LUIKEN; RAVASI; BIRNIE, 2024). Por fim, cada coluna dos CRGs (ou CCGs) e CSGs representa um traço sísmico, conforme ilustrado na Figura 3.

Figura 3 – Representação do dado sísmico referente a uma linha de navegação como um tensor tridimensional



Legenda: A face A representa um corte de tempo constante, B reflete um sismograma no domínio do tiro comum e C um sismograma no domínio do receptor comum. A linha vertical clara na face C realça um exemplo de traço sísmico extraído a partir deste sismograma.

Fonte: O autor (2024).

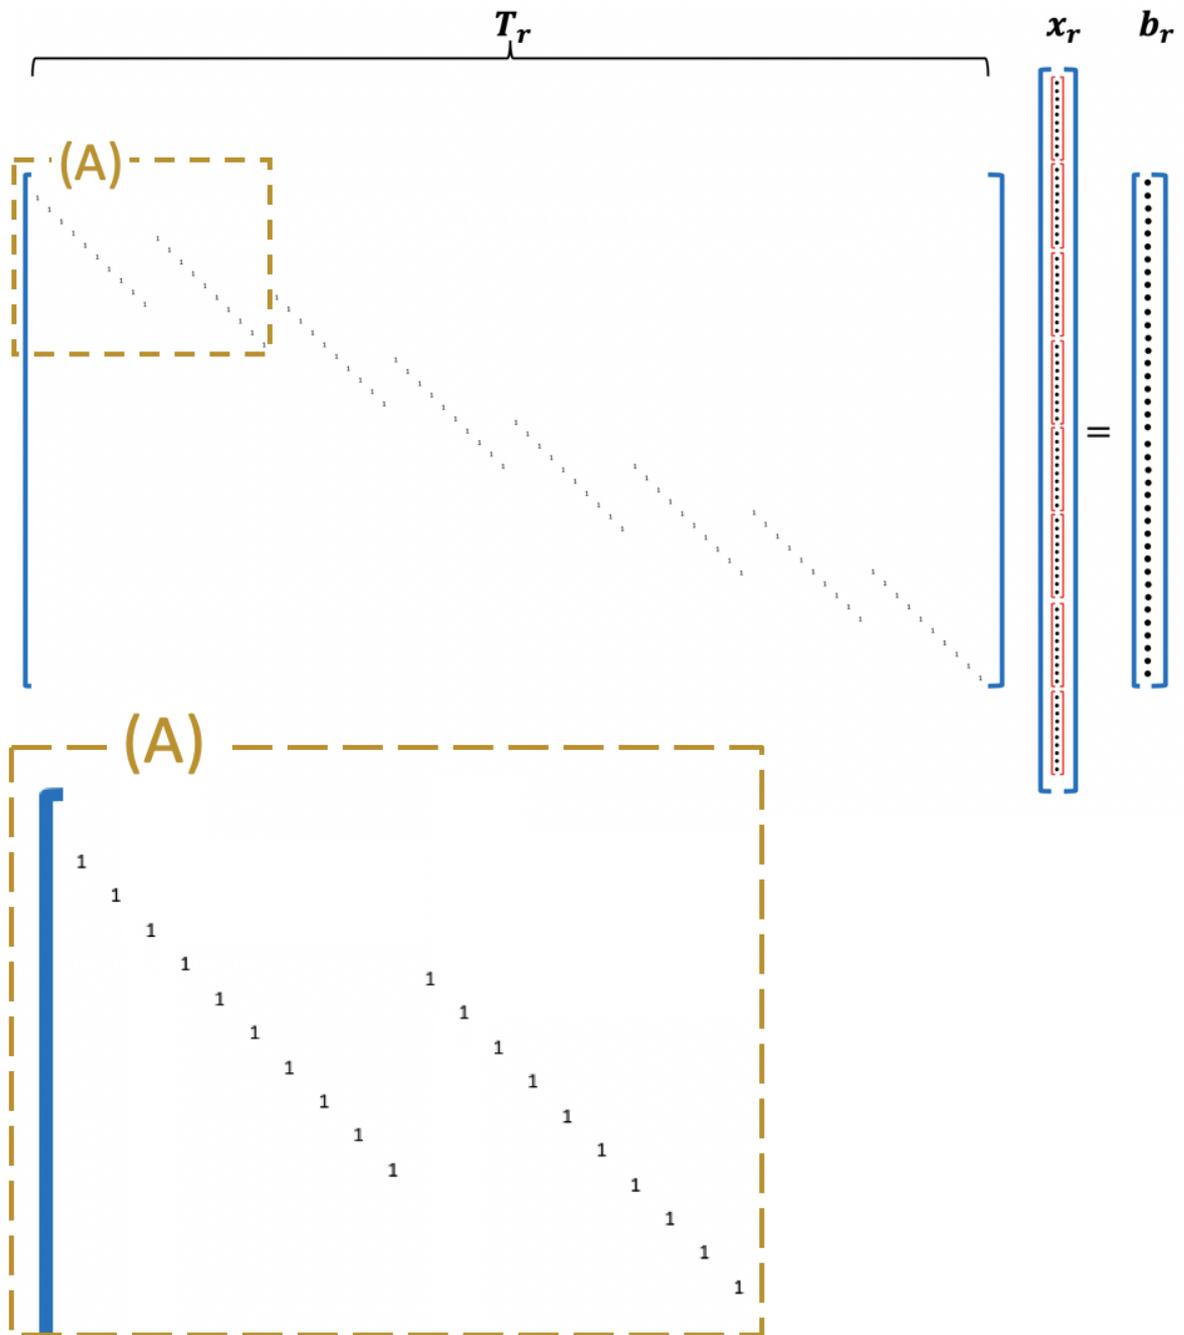
Um registro no domínio do receptor ou canal comum pode ser representado por uma matriz de ordem  $N_t$  (número de amostras temporais)  $\times$   $N_s$  (número de tiros). Podemos rearranjar os elementos desta matriz utilizando o operador  $\mathbf{vet}(\cdot)$ , que concatena as colunas da matriz uma a uma. Este procedimento produz o vetor coluna  $\mathbf{x}_r$  de dimensão  $N_s N_t$ , onde segmentos de  $\mathbf{x}_r$  são relacionados aos diferentes tiros registrados de forma convencional, ou seja, sem o efeito de interferência. O processo de *blending*, portanto, pode ser descrito como a aplicação de um operador  $\mathbf{T}_r$  em  $\mathbf{x}_r$ , capaz de combinar os segmentos de  $\mathbf{x}_r$ , gerando  $\mathbf{b}_r$ , o dado *blended*. Matematicamente, este processo pode ser representado pela Equação 1:

$$\mathbf{T}_r \mathbf{x}_r = \mathbf{b}_r \quad (1)$$

onde  $\mathbf{b}_r$ , o dado *blended* no domínio do receptor comum, corresponde a um vetor coluna de dimensão  $N_b < N_s N_t$  e  $\mathbf{T}_r$  é o operador de *blending* que corresponde a uma matriz de ordem  $N_b \times N_s N_t$ . Na prática,  $\mathbf{T}_r$  é uma matriz esparsa, onde alguns elementos apresentam valor igual a um, enquanto a maioria de seus elementos é de zeros. Em uma aquisição sísmica *blended* real, o operador de *blending* é construído a partir do registro preciso do tempo de cada disparo.

A Figura 4 ilustra o operador  $\mathbf{T}_r$  para um painel de receptor comum com 8 tiros e 10 amostras temporais. Observa-se que, na forma matricial, o operador de *blending* apresenta segmentos diagonais deslocados de acordo com os intervalos entre disparos. Para o caso de uma aquisição convencional, em que não ocorre interferência entre os disparos, o operador de *blending* seria representado por uma matriz diagonal ou identidade. No caso de uma aquisição *blended*, o operador de *blending* representa a forma de combinação dos registros de diferentes pontos de tiro consecutivos, para geração de um dado *blended* de tamanho reduzido. Portanto, o operador de *blending* pode ser visto como uma espécie de operador de compressão do dado sísmico.

Figura 4 – Ilustração de um operador de *blending* 2D  $\mathbf{T}_r$  e sua aplicação a um painel de receptor comum, gerando um traço sísmico *blended*



Legenda: A porção inferior mostra em detalhe algumas colunas do operador. Os elementos do operador não mostrados na figura têm valor nulo.

Fonte: Adaptado de Velasques (2020).

A Equação 1 utilizada na forma direta permite obter um dado *blended* a partir de um dado adquirido ou modelado de forma convencional. Esse processo, chamado de *blending* numérico (CHEN; FOMEL; HU, 2014; SUN et al., 2020b; CHENG et al., 2022), tem

seu uso é comumente encontrado na literatura para geração de dados *blended* para estudos de *benchmark* de algoritmos de *deblending*.

O processo inverso da operação de *blending*, mais conhecido como *deblending*, consiste em tentar recuperar o dado sem interferência entre tiros a partir do dado *blended*. Para isso, faz-se necessário resolver a Equação 1, possibilitando estimar  $\mathbf{x}_r$  a partir de  $\mathbf{b}_r$  e  $\mathbf{T}_r$ . Trata-se, uma vez que as dimensões de  $\mathbf{b}_r$  são menores que  $\mathbf{x}_r$ , de um sistema subdeterminado. Em geral, sistemas subdeterminados apresentam infinitas soluções. Uma solução possível é dada pelo método dos mínimos quadrados, que consiste em minimizar o quadrado da norma  $L_2$  :

$$\hat{\mathbf{x}} = \underset{\mathbf{x}}{\operatorname{argmin}} \|\mathbf{x}\|_2^2 \quad \text{s.t.} \quad \mathbf{T}_r \mathbf{x} = \mathbf{b}_r \quad (2)$$

e cuja solução analítica é dada por:

$$\hat{\mathbf{x}} = \mathbf{T}_r^\dagger \mathbf{b}_r = \mathbf{T}_r^H (\mathbf{T}_r \mathbf{T}_r^H)^{-1} \mathbf{b}_r \quad (3)$$

onde  $\mathbf{T}_r^H$  é a matriz conjugada transposta de  $\mathbf{T}_r$ , também chamada de operador adjunto ou conjugado hermitiano<sup>3</sup> e  $\mathbf{T}_r^\dagger = \mathbf{T}_r^H (\mathbf{T}_r \mathbf{T}_r^H)^{-1}$  é chamada de pseudoinversa de Moore-Penrose (OLVER; SHAKIBAN, 2018) do operador  $\mathbf{T}_r$ .

Por construção, o operador de *blending*  $\mathbf{T}_r$  apresenta linhas mutuamente ortogonais. Portanto, a matriz  $\mathbf{T}_r$  é dita semiortogonal, que é uma extensão da ortogonalidade para matrizes não quadradas (ZHANG, 2017). Assim, o operador  $\mathbf{T}_r$  apresenta a seguinte propriedade:

$$\mathbf{T}_r \mathbf{T}_r^H = \mathbf{I} \quad (4)$$

onde  $\mathbf{I}$  é a matriz identidade. Usando esta propriedade, a Equação 3 pode ser escrita como:

---

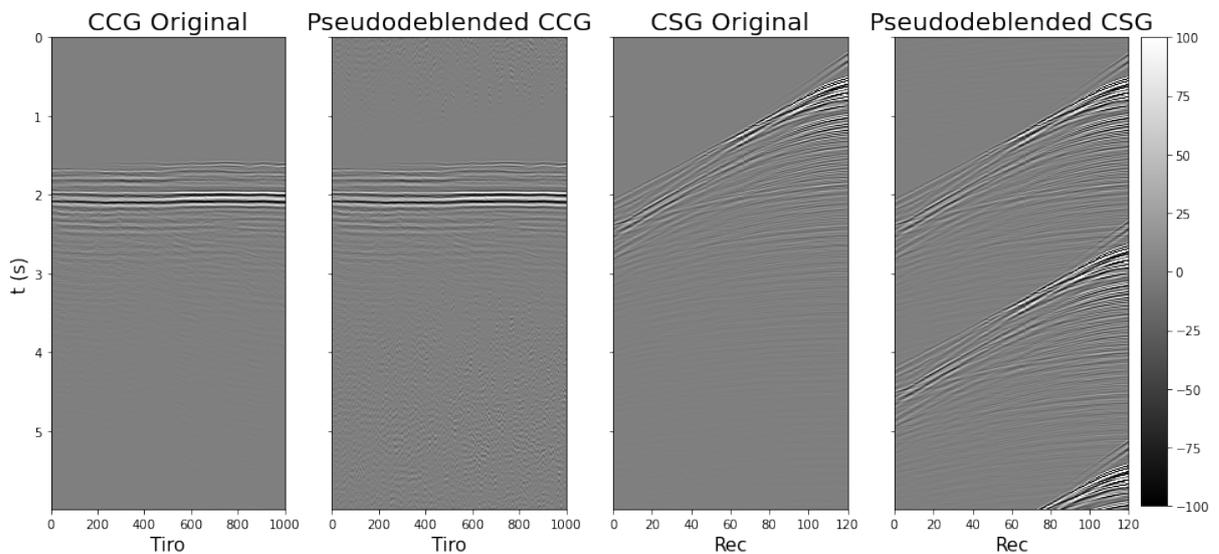
<sup>3</sup>No domínio espaço-tempo,  $\mathbf{T}_r$  é uma matriz real, logo  $\mathbf{T}_r^H = \mathbf{T}_r^T$ .

$$\begin{aligned}\hat{\mathbf{x}} &= \mathbf{T}_r^H (\mathbf{T}_r \mathbf{T}_r^H)^{-1} \mathbf{b}_r \\ \hat{\mathbf{x}} &= \mathbf{T}_r^H \mathbf{I} \mathbf{b}_r \\ \hat{\mathbf{x}} &= \mathbf{T}_r^H \mathbf{b}_r\end{aligned}\tag{5}$$

a solução dada pela Equação 5 é chamada de *pseudodeblending*.

A Figura 5 mostra a comparação entre sismogramas no domínio do canal e do tiro comum para um dado adquirido de forma convencional, sem efeito de interferência, e o dado *pseudodeblended* correspondente, obtido após o processo de *blending* numérico e *pseudodeblending*. O efeito do operador de *blending* consiste em misturar os registros de fontes consecutivas reduzindo as dimensões do dado. Portanto, a solução de *pseudodeblending* restaura as dimensões originais e desloca o dado temporalmente retornando à referência de tempo zero do dado original. No entanto, o processo de *pseudodeblending* não remove a interferência entre os tiros consecutivos e, portanto, o dado resultante é contaminado por um ruído chamado na literatura de ruído de *blending* (*blending noise*) (VELASQUES, 2020; SUN et al., 2020b; LUIKEN; RAVASI; BIRNIE, 2024).

Figura 5 – Sismogramas originais, para um dado adquirido de forma convencional, e *pseudodeblended* no domínio do canal comum (à esquerda) e do tiro comum (à direita)



Fonte: O autor (2024).

Vale ressaltar que a interferência causada pelo processo de *blending* apenas se apresenta como um ruído incoerente no domínio do receptor comum devido a técnica de *random time dithering*, que consiste na adição de desvios temporais aleatórios  $\Delta t_i$  (*dither times*) aos tempos entre disparos nominais  $T$  (ABMA; FOSTER, 2021). Caso os tempos entre disparos fossem regulares, tanto os sinais de interesse quanto o ruído de interferência seriam coerentes e indistinguíveis, dificultando assim o processo de *deblending*.

Entretanto, existem propostas de técnicas de aquisição com fontes simultâneas e algoritmos de *deblending* associados que usam padrões determinísticos e específicos de disparos. Um exemplo é a técnica *Seismic Apparition*, proposta por Robertsson, Amundsen e Pedersen (2016), em que uma segunda fonte sísmica alterna entre disparar simultaneamente com a primeira fonte ou disparar sozinha após um intervalo de tempo constante. Usando esse padrão de disparo, os autores mostram que é possível realizar o *deblending* dos dados no domínio da frequência-número de onda  $f-k$  até uma frequência limite determinada pelo espaçamento entre tiros.

Métodos de *deblending* baseados em técnicas para atenuação de ruído (*denoising*) partem do dado *pseudodeblended* e buscam atenuar o ruído de *blending* através da aplicação de filtros tais como filtros de mediana, filtros de predição de erro (*prediction error filters*), além de filtros nos domínios da frequência-número de onda  $f-k$  e *wavelet*.

Por outro lado, métodos de *deblending* baseados em inversão esparsa buscam resolver o problema considerando a restrição adicional de que o dado a ser recuperado seja esparsos em algum domínio transformado. Dessa forma, o método de inversão esparsa propõe a solução do seguinte problema de otimização conhecido como *basis pursuit* (ELAD, 2010):

$$\hat{\mathbf{s}} = \underset{\mathbf{s}}{\operatorname{argmin}} \|\mathbf{s}\|_1 \quad \text{s.t.} \quad \mathbf{T}_r \mathbf{S}^H \mathbf{s} = \mathbf{b}_r \quad (6)$$

onde  $\mathbf{s} = \mathbf{S}\mathbf{x}$  representa o dado esparsos em algum domínio transformado e  $\mathbf{S}$  e  $\mathbf{S}^H$  representam o operador direto e inverso dessa transformada, respectivamente. Para casos mais realistas, envolvendo dados com a presença de ruído, a igualdade  $\mathbf{T}_r \mathbf{S}^H \mathbf{s} = \mathbf{b}_r$  deve ser substituída por  $\|\mathbf{T}_r \mathbf{S}^H \mathbf{s} - \mathbf{b}_r\|_2 \leq \epsilon$ , onde  $\epsilon$  é um termo de tolerância que ajusta do nível de ruído permitido na solução (VELASQUES, 2020). Essa variação do problema *basis*

*pursuit*, representada pela Equação 7, é chamada na literatura de *basis pursuit denoising* (ELAD, 2010).

$$\hat{\mathbf{s}} = \underset{\mathbf{s}}{\operatorname{argmin}} \|\mathbf{s}\|_1 \quad \text{s.t.} \quad \|\mathbf{T}_r \mathbf{S}^H \mathbf{s} - \mathbf{b}_r\|_2 \leq \epsilon \quad (7)$$

Após obter a solução da Equação 6, o dado *deblended* no domínio original deve ser recuperado através da aplicação da transformada inversa por meio da Equação 8.

$$\hat{\mathbf{x}} = \mathbf{S}^H \hat{\mathbf{s}} \quad (8)$$

Dentre as transformadas disponíveis, destacam-se na literatura o uso da Transformada de Fourier Janelada 2D (*2D Windowed Fourier Transform - WFT2D*) (ABMA et al., 2015), transformada Curvelet (MANSOUR et al., 2012; WASON, 2017; VELASQUES, 2020), transformada Radon (IBRAHIM; SACCHI, 2014) e transformada Seislet (CHEN; FOMEL; HU, 2014).

Os problemas de otimização representados pelas Equações 6 e 7 podem ser resolvidos numericamente por diversos algoritmos encontrados na literatura, tais como o Algoritmo Rápido Iterativo de Achatamento e Limiarização (*Fast Iterative Shrinkage-Thresholding Algorithm - FISTA*) (BECK; TEOULLE, 2009), Gradiente Espectral Projetado L1 (*Spectral Projected Gradiente L1 - SPGL1*) (BERG; FRIEDLANDER, 2009) e Projeção em Conjuntos Convexos (*Projection onto Convex Sets - POCS*) (ABMA; KABIR, 2006), dentre outros. Uma questão ainda não resolvida é que tipo de algoritmo de inversão esparsa é necessário para produzir os melhores resultados de *deblending* (ABMA; FOSTER, 2021)

Atualmente, os métodos dessas duas categorias estão incorporando técnicas baseadas em aprendizado profundo, através da utilização de redes neurais convolucionais treinadas de modo supervisionado e autossupervisionado, buscando obter soluções de *deblending* mais computacionalmente eficientes e eficazes.

## 2 REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta a revisão bibliográfica do trabalho. A Seção 2.1 apresenta o quadro e tendência gerais a respeito da utilização de técnicas de aprendizado de máquina em dados sísmicos. Na Seção 2.2, são apresentados os trabalhos que tratam do problema de *deblending* de dados sísmicos usando tanto algoritmos convencionais quanto técnicas de aprendizado profundo.

### 2.1 Aplicações de Aprendizado de Máquina em Dados Sísmicos

Anjom, Vaccarino e Socco (2024) fizeram uma revisão completa de trabalhos relacionados à aplicação de técnicas de aprendizado de máquina em dados sísmicos. O uso de técnicas de aprendizado de máquina para processamento sísmico e interpretação expandiu exponencialmente nos últimos 10 anos. A Figura 6 mostra o número de publicações envolvendo aplicações de técnicas de aprendizado de máquina em dados sísmicos por ano, entre os anos de 2010 e 2021, de acordo com as maiores bases de dados da área SEG<sup>4</sup> e EAGE<sup>5</sup>, em comparação com aplicações em todos os outros campos da ciência, de acordo com a plataforma Scopus. Segundo esta revisão, 56% das publicações são relacionadas ao tema de processamento sísmico e destes, 52% tratam de etapas de pré-processamento, tais como atenuação de ruídos (22%), interpolação de traços (11%), marcação de primeira quebra (9%), separação de eventos (6%) e controle de qualidade (4%). A Figura 7 mostra que dentre as técnicas de aprendizado de máquina utilizadas para solução de problemas de processamento sísmico, destacam-se as Redes Neurais Convolucionais (*Convolutional Neural Networks* - CNN).

Sobre a utilização de técnicas de aprendizado de máquina para processamento de dados sísmicos, Hou e Messud (2021) reforçam que o processamento sísmico exige padrões muito elevados para a preservação e extração de fidelidade do sinal, devido a maioria dos sinais de interesse serem extremamente fracos nos dados brutos. Qualquer dano causado por uma etapa de processamento pode ser amplificado em etapas posteriores

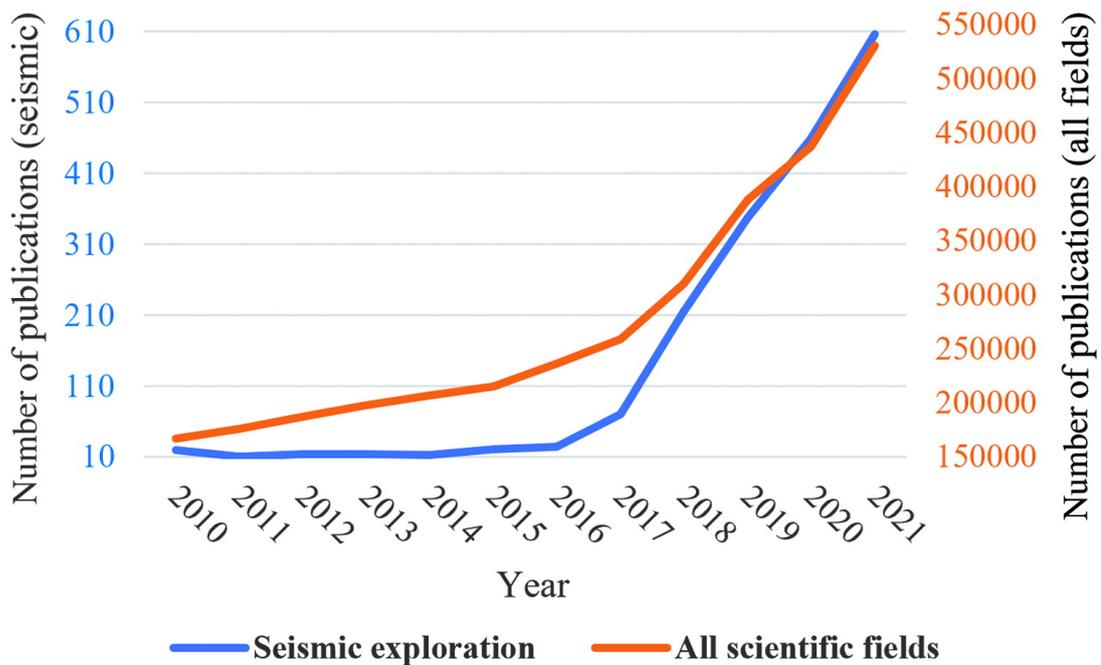
---

<sup>4</sup>Society of Exploration Geophysicists

<sup>5</sup>European Association of Geoscientists and Engineers

devido à natureza não linear dos algoritmos de inversão. Além disto, os resultados finais processados são qualitativa e quantitativamente analisados por equipes multidisciplinares para apoiar decisões de negócios que requerem alto padrão de precisão. Apontam ainda que existem questões práticas que precisam ser mais abordadas, como a seleção apropriada de dados de treinamento, quantificação de incertezas e interpretabilidade dos modelos. Na visão dos autores, as técnicas de aprendizado de máquina não substituirão a experiência humana ou os algoritmos geofísicos, mas a abordagem conjunta pode resultar em soluções mais robustas e eficientes.

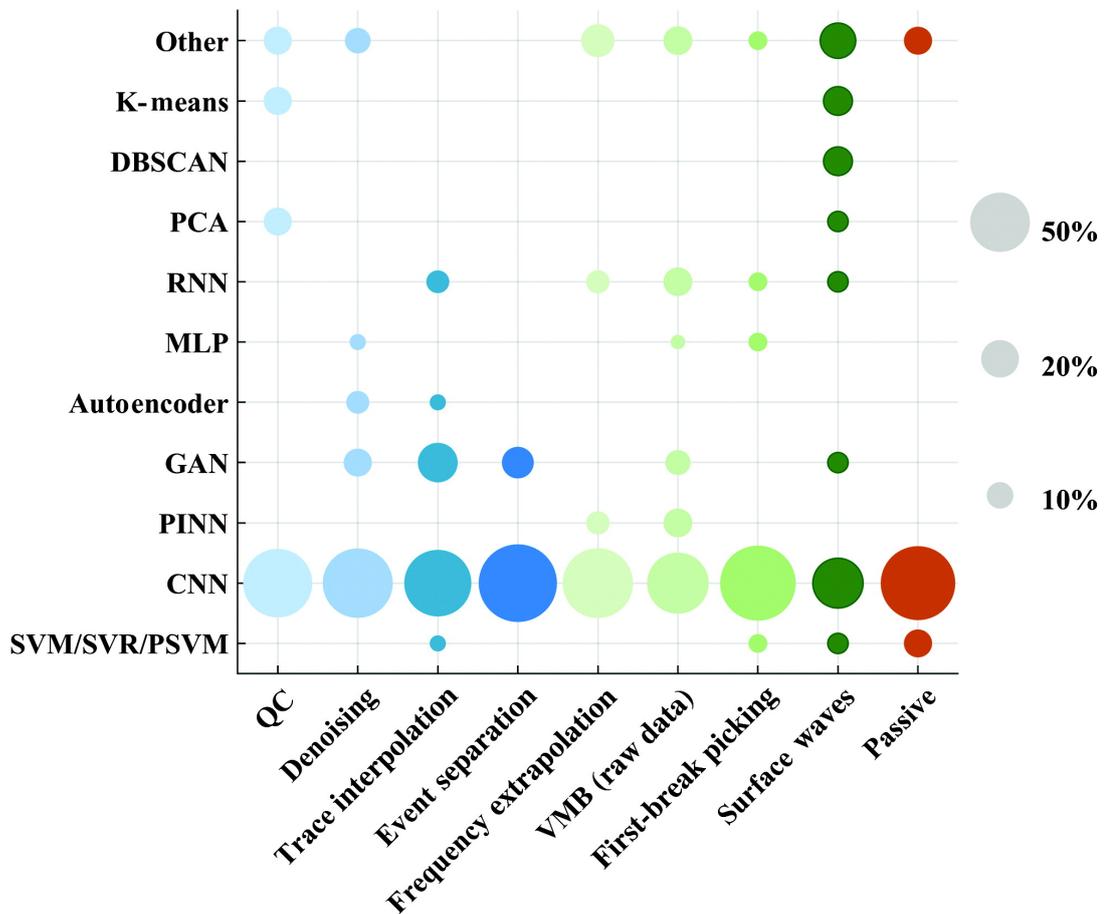
Figura 6 – Número de publicações sobre aprendizado de máquina por ano de 2010 a 2021



Legenda: O número de publicações sobre aprendizado de máquina relacionada com a exploração sísmica é apresentada em azul. A curva em laranja mostra o número de publicações para as aplicações em todas as outras áreas científicas, de acordo com a plataforma Scopus.

Fonte: Anjom, Vaccarino e Socco (2024).

Figura 7 – Algoritmos de aprendizado de máquina mais usados para aplicações de processamento sísmico



Legenda: Os três círculos cinzas mostram a relação entre o tamanho do círculo e suas frações nas aplicações.

Fonte: Anjom, Vaccarino e Socco (2024).

## 2.2 *Deblending* de Dados Sísmicos

O conceito de aquisição sísmica com o uso de fontes simultâneas foi inicialmente proposto para levantamentos sísmicos terrestres com o uso de fontes vibratórias devido ao controle da assinatura de fonte, o que permitiu o uso de técnicas de codificação dos *sweeps*<sup>6</sup>. Uma revisão dos principais métodos pode ser encontrada em Bagaini (2006).

Beasley, Chambers e Jiang (1998) propuseram o uso simultâneo de fontes em posições diferentes em sísmica marítima. Hampson, Stefani e Herkenhoff (2008) elaboraram mais este conceito e introduziram a ideia do uso de pequenos desvios aleatórios no tempo en-

<sup>6</sup>Varredura em frequência realizada por uma fonte vibratória.

tre disparos (*random time dithering*). Nessas circunstâncias, um registro no domínio do tiro comum (*common shot gather*) apresentará dois campos de onda coerentes vindos da contribuição das duas fontes. Por outro lado, no domínio do receptor comum (*common receiver gather*), em que traços sucessivos vêm de diferentes tiros, haverá uma superposição de um campo de onda coerente e um ruído incoerente, devido às fontes secundárias (HAMPSON; STEFANI; HERKENHOFF, 2008).

Berkhout (2008) estendeu o conceito de fontes simultâneas para aquisição sísmica *blended*, que significa o registro contínuo das respostas de múltiplas fontes que se sobrepõem no tempo. Além disso, formalizou matematicamente o processo de *blending* como uma operação matricial.

Existem duas categorias principais de métodos convencionais para *deblending* de dados sísmicos encontradas na literatura: métodos baseados em inversão e métodos baseados em atenuação de ruído (*denoising*) ou filtragem.

Mahdad, Doulgeris e Blacquiere (2011) propuseram um método iterativo de subtração preditiva que estima o campo de ondas das fontes secundárias usando filtros no domínio da frequência-número de onda ( $f-k$ ) e subtrai o ruído de interferência (*blending noise*) do campo de ondas primário. Mahdad, Doulgeris e Blacquiere (2012) investigaram o uso de diferentes métodos de filtragem usando filtros de mediana e filtros usando a transformada Radon linear.

Pesquisas recentes têm revelado a superioridade dos métodos de *deblending* por algoritmos de inversão (ABMA et al., 2015). Tais métodos usam algoritmos de inversão que operam em algum domínio onde o dado sísmico seja esparso. Destacam-se na literatura o uso da transformada de Fourier 2D janelada (ABMA et al., 2015), transformada Radon (IBRAHIM; SACCHI, 2014), transformada Seislet (CHEN; FOMEL; HU, 2014) e transformada Curvelet (MANSOUR et al., 2012; WASON, 2017; VELASQUES, 2020).

Conforme discutido na seção anterior, na última década, houve um crescimento exponencial do uso de técnicas de aprendizado de máquina aplicadas à solução de problemas de processamento de dados sísmicos. O primeiro trabalho utilizando redes neurais convolucionais para classificação e atenuação de ruído de *blending* em dados sísmicos foi proposto

por Baardman e Tsingas (2019). As redes foram treinadas de forma supervisionada usando dados reais que passaram por *blending* numérico.

Richardson e Feller (2019) usaram uma U-Net, com uma arquitetura ResNet34 como *encoder*, treinada de forma supervisionada usando dados sintéticos<sup>7</sup>, mas aplicada para *deblending* de dados reais adquiridos no Mar do Norte. Os autores reportaram um resultado em termos da razão sinal-ruído (SNR) média do dado *deblended* de 16,5 dB. Por sua vez, Matharu et al. (2020) usaram a arquitetura *Denoising CNN* (DnCNN), proposta por Zhang et al. (2017) para atenuação de ruídos em imagens naturais, treinada de forma supervisionada usando apenas dados reais que passaram pelo processo de *blending* numérico. Os autores obtiveram um resultado em termos de SNR de 14,52 dB. Analogamente, Sun et al. (2020b) propuseram uma arquitetura de rede neural convolucional para *deblending* de dados sísmicos sem o uso de redução de escala (*no downscaling*) com o intuito de preservar o máximo possível do contexto geológico durante a remoção do ruído de interferência, além de reduzir uma potencial perda de precisão e desfoque do sinal (*blurring*).

Zu et al. (2020) adaptaram o método de *deblending* iterativo, proposto por Mahdad, Doulgeris e Blacquiere (2011), substituindo os passos de filtragem no domínio frequência-número de onda  $f-k$  pela saída de uma rede neural convolucional, treinada de modo supervisionado, usando dados sintéticos que passaram por *blending* numérico. Os autores obtiveram resultados em termos de SNR de 25,7 dB, no caso do *deblending* de dados sintéticos, e apenas 5,3 dB no caso da aplicação em dados reais. Usando essa mesma proposta iterativa, Wang et al. (2021a) desenvolveram um método de *deblending* baseado no treinamento de uma U-NET usando dados sintéticos e no uso de técnicas de *Transfer Learning* para aplicação em dados reais. Os autores reportaram um resultado de SNR médio de 26,47 dB, no caso do *deblending* de dados sintéticos e 16,5 dB para os dados reais. Estes resultados mostram que a estratégia de treinamento usando dados sintéticos e aplicação em dados reais resulta em perdas significativas de desempenho na tarefa de *deblending*.

Xu et al. (2022) propuseram um método de *deblending* baseado no *framework Plug-*

---

<sup>7</sup>Dados sísmicos sintéticos são gerados através da simulação computacional do processo de aquisição sísmica por meio da solução numérica da equação da onda em um modelo de subsuperfície.

*and-Play*<sup>8</sup>, originalmente proposto por Venkatakrisnan, Bouman e Wohlberg (2013), que integra uma rede neural convolucional, treinada para atenuação de ruído de forma supervisionada, ao algoritmo de inversão ADMM<sup>9</sup> (BOYD et al., 2011). Os autores mencionaram um resultado de 24,46 dB de SNR em dados reais.

Todos os trabalhos citados anteriormente usaram a estratégia de treinamento supervisionado. Isto implica na utilização de dados adquiridos ou modelados de forma convencional submetidos ao processo de *blending* numérico, como dados de entrada, e dados limpos, sem o efeito de interferência, como alvos para o treinamento. Vale ressaltar que em uma situação real, de uma aquisição sísmica *blended*, apenas estarão disponíveis dados que sofreram interferência de tiros consecutivos. Portanto, são de fundamental importância a pesquisa e o desenvolvimento de métodos e algoritmos de *deblending* que usem estratégias de aprendizado autossupervisionado ou não-supervisionado.

O trabalho de Wang et al. (2021b) segue nessa direção e propõe um esquema de aprendizado autossupervisionado, baseado no método Noise2Void (KRULL; BUCHHOLZ; JUG, 2019; LAINE et al., 2019), eliminando assim a necessidade do uso de dados sísmicos limpos como alvos para o treinamento. O método autossupervisionado Noise2Void, proposto originalmente para atenuação de ruído em imagens naturais e biomédicas, seleciona múltiplos pixels de uma imagem ruidosa e os substitui por pixels adjacentes. Essa imagem resultante é usada como entrada no treinamento de uma rede U-NET e a imagem ruidosa original é usada como alvo.

Recentemente, Luiken, Ravasi e Birnie (2024) propuseram um algoritmo de *deblending* que combina uma rede neural convolucional treinada de modo autossupervisionado, inspirada na metodologia Noise2Void (KRULL; BUCHHOLZ; JUG, 2019; LAINE et al., 2019), com um *framework* de inversão do tipo *Plug-and-Play* (VENKATAKRISHNAN; BOUMAN; WOHLBERG, 2013). Os autores reportaram um SNR médio de 23,0 dB no caso de *deblending* de dados reais.

---

<sup>8</sup>A ideia original do *framework Plug-and-Play* (VENKATAKRISHNAN; BOUMAN; WOHLBERG, 2013) consiste em substituir um dos passos intermediários do algoritmo de inversão ADMM por um algoritmo de atenuação de ruído.

<sup>9</sup>*Alternating Direction Method of Multipliers.*

### 3 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, serão apresentados os principais conceitos sobre redes neurais e atenuação de ruído através de aprendizado supervisionado e autossupervisionado. O conteúdo relacionado aos fundamentos de redes neurais e redes convolucionais utilizou como base as referências Goodfellow, Bengio e Courville (2016), Roberts, Yaida e Hanin (2022) e Prince (2023).

#### 3.1 Redes Neurais

O componente mais básico da rede neural é o neurônio. Vagamente inspirado no comportamento dos neurônios biológicos, o neurônio artificial consiste essencialmente de duas operações simples:

- A pré-ativação  $z_i$  de um neurônio é uma combinação linear de sinais recebidos  $s_j$  onde cada sinal é ponderado por um peso  $W_{ij}$  e somado a um termo de viés (*bias*)  $b_i$  de acordo com a Equação 9;

$$z_i(\mathbf{s}) = b_i + \sum_{j=1}^{n_{in}} W_{ij} s_j \quad \text{para } i = 1, \dots, n_{out} \quad (9)$$

- Cada neurônio então dispara ou não de acordo com o valor da pré-ativação  $z_i$  e produz uma ativação  $\sigma_i = \sigma(z_i)$ . A função  $\sigma(z)$  é chamada de função de ativação e age independentemente em cada componente do vetor de preativação.

Tomados em conjunto, esses  $n_{out}$  neurônios formam uma camada, que recebe um vetor  $n_{in}$ -dimensional de sinais  $s_j$  e produz o vetor  $n_{out}$ -dimensional de ativações  $\sigma_i$ . Com essa perspectiva coletiva, uma camada é parametrizada por um vetor de vieses  $b_i$  e uma matriz de pesos  $W_{ij}$ , onde  $i = 1, \dots, n_{out}$  e  $j = 1, \dots, n_{in}$ , junto com uma função de ativação fixa  $\sigma(z)$  (ROBERTS; YAIDA; HANIN, 2022).

Com esses componentes, pode-se organizar muitos neurônios em uma camada e, em seguida, empilhar sequencialmente muitas dessas camadas de modo que as ativações de saída dos neurônios em uma camada se tornem os sinais de entrada para os neurônios

em alguma outra camada. A organização dos neurônios e seu padrão de conexões é conhecido como arquitetura da rede neural. A arquitetura de rede neural mais simples baseada neste princípio de empilhamento de camadas de muitos neurônios é chamada de *Multilayer Perceptron* - MLP. A MLP também é chamada de rede totalmente conectada, ou *Fully Connected Network* - FCN, reforçando o fato de que cada neurônio em uma dada camada  $\ell$  tem conexão com todos os neurônios da camada  $\ell + 1$ .

A MLP é recursivamente definida através do conjunto de equações:

$$\begin{aligned} z_i^{(1)}(x_\alpha) &= b_i^{(1)} + \sum_{j=1}^{n_0} W_{ij}^{(1)} x_{j;\alpha} \quad \text{para } i = 1, \dots, n_1 \\ z_i^{(\ell+1)}(x_\alpha) &= b_i^{(\ell+1)} + \sum_{j=1}^{n_\ell} W_{ij}^{(\ell+1)} \sigma(z_j^{(\ell)}(x_\alpha)) \quad \text{para } i = 1, \dots, n_{\ell+1}; \quad \ell = 1, \dots, L - 1 \end{aligned} \tag{10}$$

que descrevem uma rede com  $L$  camadas, com cada camada  $\ell$  composta por  $n_\ell$  neurônios. O dado de entrada é representado por um conjunto  $\mathcal{D}$  de vetores  $n_0$ -dimensionais  $\mathcal{D} = \{x_{i;\alpha}\}_{\alpha=1, \dots, N_{\mathcal{D}}}$ . O índice  $\alpha$  é referente à cada amostra do conjunto de dados de entrada com  $N_{\mathcal{D}}$  elementos, e o índice  $i = 1, \dots, n_0$  é referente às componentes do vetor de entrada. A Figura 8 ilustra um exemplo de MLP com  $L = 4$  camadas, com dimensão de entrada  $n_0 = 4$  e de saída  $n_4 = 1$ .

O número de camadas  $L$  define a profundidade da rede e o número de neurônios em cada camada  $n_\ell$  define as larguras das camadas. As camadas intermediárias  $\ell = 1, \dots, L - 1$  são chamadas de camadas ocultas, uma vez que as pré-ativações e as ativações dos neurônios dessas camadas não fazem parte da saída da rede. A profundidade e as larguras das camadas ocultas são hiperparâmetros de arquitetura que definem a forma da rede, enquanto os valores de  $n_0$  e  $n_L$  são definidos pelas dimensões de entrada e saída, respectivamente. Em particular, as pré-ativações computadas pela rede na última camada, dadas por:

$$f(\theta; x) = z^{(L)}(x) \tag{11}$$

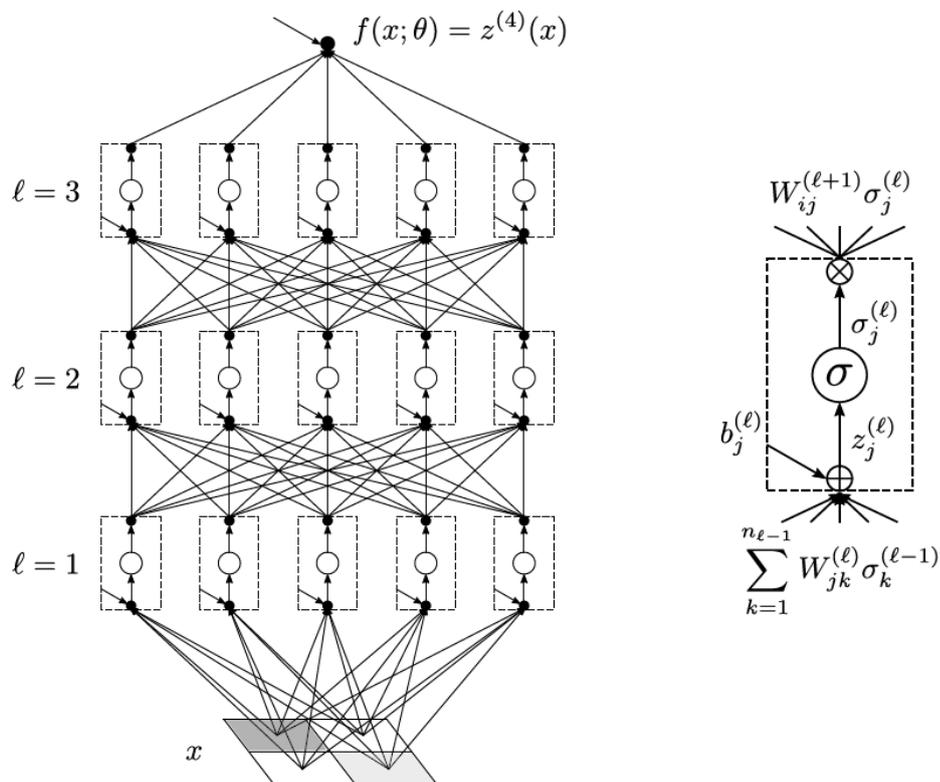
servem como uma função aproximadora do mapeamento entre os sinais de entrada e saída

da rede, com seus parâmetros ajustáveis do modelo  $\theta$  sendo a união dos vieses e pesos de todas as camadas. É conveniente pensar essa união de parâmetros como um vetor explícito cujas componentes cobrem todos os parâmetros do modelo. Neste caso, a dimensão de  $\theta$ , e, portanto, o total de parâmetros do modelo é dado por:

$$P = \sum_{\ell=1}^L (n_{\ell} + n_{\ell}n_{\ell-1}) \quad (12)$$

que escala quadraticamente com as larguras das camadas da rede e linearmente com a profundidade.

Figura 8 – Representação de uma arquitetura MLP



Legenda: Representação de uma arquitetura MLP com  $L = 4$  camadas (à esquerda), com dimensão de entrada  $n_0 = 4$  e de saída  $n_4 = 1$ . As três camadas ocultas têm cinco neurônios cada. Estrutura detalhada de cada neurônio (à direita) que pondera os sinais pelos pesos e adiciona o viés para produzir a pré-ativação, gera a ativação a partir da pré-ativação e multiplica a ativação pelo peso da próxima camada.

Fonte: Roberts, Yaida e Hanin (2022).

O procedimento de ajuste dos parâmetros do modelo é chamado de algoritmo de

aprendizado. Esse ajuste é realizado por meio de um algoritmo de otimização. Os algoritmos de otimização mais utilizados nas aplicações de aprendizado profundo são os métodos que envolvem a descida do gradiente (*gradient descent*), como o *Stochastic Gradient Descent* - SGD (RUDER, 2016) e o *Adaptive Moment Estimation* - ADAM (KINGMA; BA, 2015). O que permite o uso desses métodos para o treinamento de redes neurais é o algoritmo de retropropagação, do inglês *backpropagation* (RUMELHART; HINTON; WILLIAMS, 1986), que computa de forma eficiente o gradiente da função objetivo com respeito aos pesos e vieses da rede.

## 3.2 Funções de Ativação

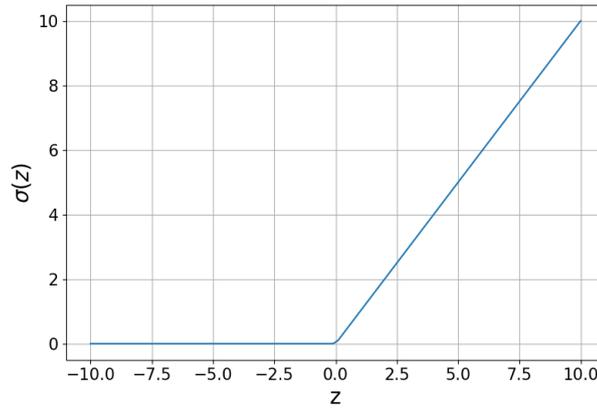
Conforme discutido na seção anterior, a função de ativação é responsável pela decisão se um neurônio é ativado ou não de acordo com o valor de pré-ativação. As funções de ativação criam uma relação não linear entre os dados de entrada e saída da rede. O empilhamento de muitas camadas de neurônios com essas funções de ativação não lineares acumula a não linearidade, permitindo que tais redes neurais profundas possam expressar funções altamente complexas (ROBERTS; YAIDA; HANIN, 2022). Nesta seção serão descritas as funções de ativação presentes nas arquiteturas de rede utilizadas neste trabalho.

### 3.2.1 Rectified Linear Unit (ReLU)

A função de ativação *Linear Rectified Unit* (ReLU), dada pela Equação 13, é a função de ativação mais usada em redes neurais profundas (ROBERTS; YAIDA; HANIN, 2022). A Figura 10 mostra o gráfico da função ReLU.

$$\sigma(z) = \text{ReLU}(z) = \begin{cases} 0, & \text{se } z < 0 \\ z, & \text{se } z \geq 0 \end{cases} \quad (13)$$

Figura 9 – Função de ativação ReLU



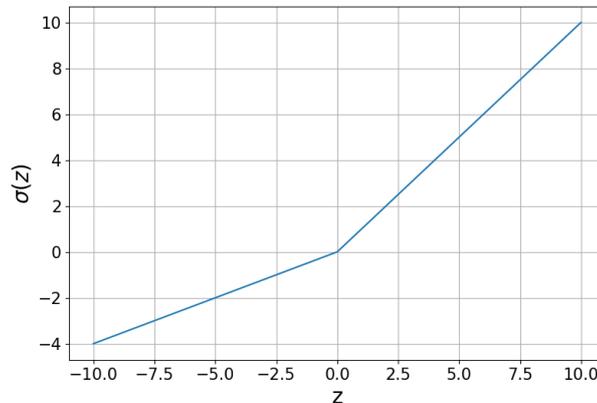
Fonte: O autor (2024).

### 3.2.2 Leaky Rectified Linear Unit (Leaky ReLU)

A função de ativação *Leaky Linear Rectified Unit (Leaky ReLU)* é uma variação da ReLU que introduz uma inclinação linear para valores de pré-ativação negativos. A função *Leaky ReLU* é dada pela Equação 14:

$$\sigma(z) = LReLU(z) = \begin{cases} \alpha z, & \text{se } z < 0 \\ z, & \text{se } z \geq 0 \end{cases} \quad (14)$$

onde  $\alpha$  é uma constante positiva. A Figura 10 mostra o gráfico da função *Leaky ReLU* usando  $\alpha = 0,4$ .

Figura 10 – Função de ativação *Leaky ReLU*

Fonte: O autor (2024).

O uso da função de ativação ReLU pode causar um problema chamado de desligamento de neurônios (*dead neurons*). No caso em que a pré-ativação para uma função de ativação ReLU é negativa, a saída será zero, fazendo com que o gradiente também seja zero. Se, em vez disso, a *Leaky ReLU* for usada, o gradiente nunca será zero e esse problema é evitado (SUN et al., 2020b).

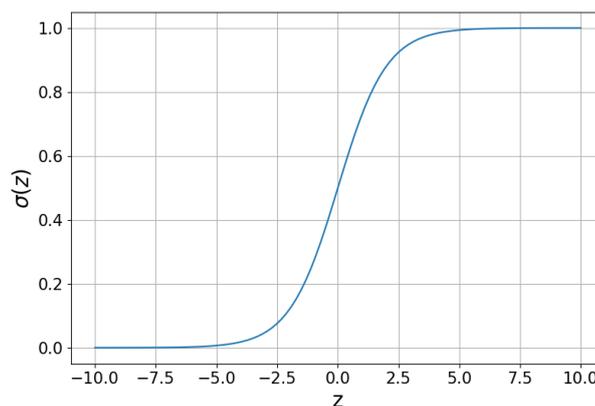
### 3.2.3 Sigmoide

A função de ativação sigmoide é uma função logística dada pela Equação 15.

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (15)$$

A função sigmoide é contínua e preserva informações sobre a magnitude da pré-ativação, principalmente no intervalo próximo de  $z = 0$  onde a função é quase linear. Fora desta faixa, a função comprime fortemente essas informações, saturando para  $\sigma(z) = 1$  quando  $z \rightarrow \infty$  e para  $\sigma(z) = 0$  quando  $z \rightarrow -\infty$ . A Figura 11 mostra o gráfico da função sigmoide.

Figura 11 – Função de ativação sigmoide



Fonte: O autor (2024).

## 3.3 Redes Neurais Convolucionais

Redes neurais convolucionais, em inglês *Convolutional Neural Networks* (CNNs) (LECUN et al., 1989), são um tipo particular de rede neural para processamento de dados que possuem estrutura de tensores. Tais dados incluem séries temporais, representadas

como um tensor unidimensional com amostras em intervalos de tempo regulares, e dados de imagem, que podem ser representados como um tensor bi- ou tridimensional de pixels.

Redes convolucionais foram extremamente bem-sucedidas em aplicações práticas. A nomenclatura indica que a rede é baseada em uma operação matemática chamada convolução. Redes convolucionais são simplesmente redes neurais que modelam a operação de convolução no lugar da multiplicação matricial em pelo menos uma de suas camadas (GOODFELLOW; BENGIO; COURVILLE, 2016).

A convolução é uma operação matemática entre duas funções definida pela Equação 16, no caso contínuo, e pela Equação 17 no caso discreto e unidimensional.

$$(x * w)(t) := \int_{-\infty}^{\infty} x(\tau)w(t - \tau)d\tau \quad (16)$$

$$(x * w)[n] = \sum_{m=-\infty}^{\infty} x[m]w[n - m] \quad (17)$$

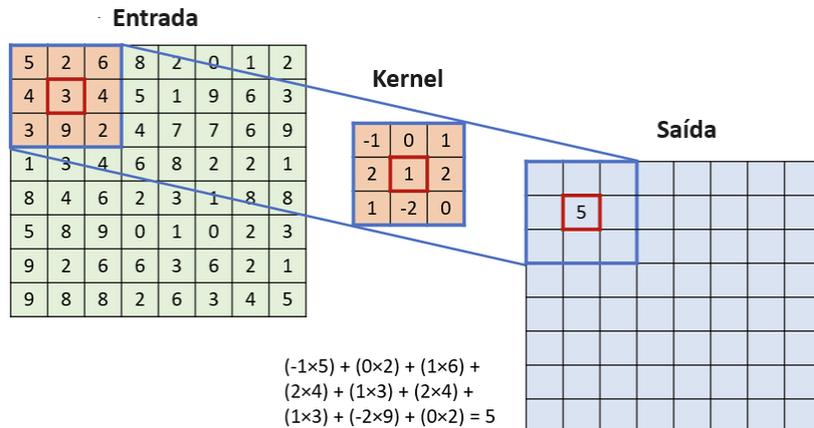
Para funções discretas de suporte finito e no caso 2D, a operação de convolução é definida pela Equação 18 (GONZALEZ; WOODS, 2017).

$$(x * w)[n, m] = \sum_{i=-a}^a \sum_{m=-b}^b x[i, j]w[n - i, m - j] \quad (18)$$

No contexto de redes neurais, a função  $x$  é frequentemente chamada de entrada e a função  $w$  de *kernel*. O resultado dessa operação é denominado mapa de características (*feature map*) ou canal. A Figura 12 exemplifica a operação de convolução 2D.

A rigor, a operação representada pela Figura 12 se trata de uma correlação cruzada e não de uma convolução, na qual os elementos do *kernel* seriam rotacionados em relação à entrada. Independentemente disso, esta definição (incorreta) é a convenção usual em aprendizado de máquina (PRINCE, 2023).

Figura 12 – Ilustração de uma operação de convolução 2D



Fonte: Podareanu et al. (2019).

Podemos pensar na camada convolucional como um tipo particular de camada MLP, onde muitos pesos, elementos dos *kernels* das camadas convolucionais, são definidos como zero e os valores dos pesos restantes são ainda compartilhados entre vários neurônios diferentes. Isso significa que as camadas convolucionais estão realmente dentro da classe de funções descritíveis usando camadas MLP. Para uma camada convolucional 2D, a equação de iteração para o MLP é substituída por:

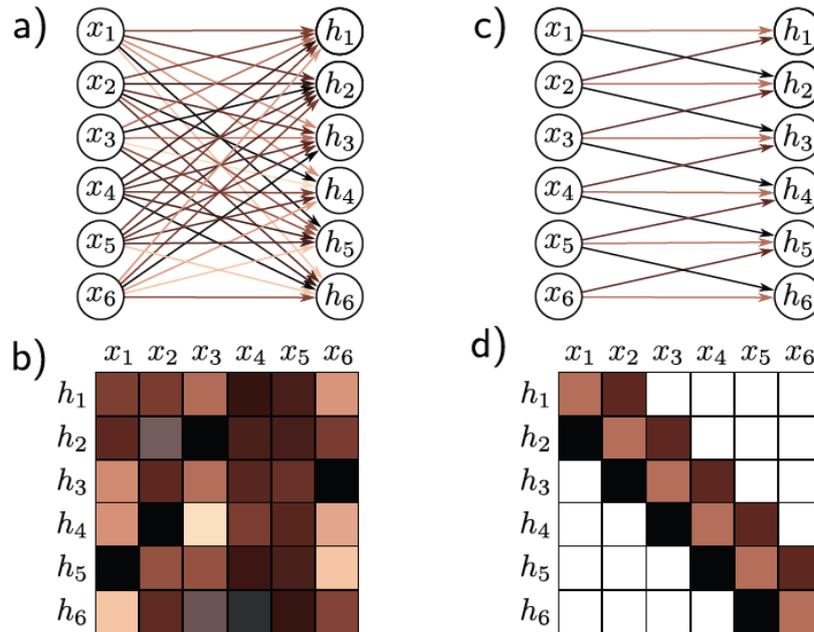
$$z_{i,(c,d)}^{(\ell+1)}(x_\alpha) = b_i^{(\ell+1)} + \sum_{j=1}^{n_\ell} \sum_{c'=-k}^k \sum_{d'=-k}^k W_{ij}^{(\ell+1)} \sigma(z_{j,(c+c',d+d')}^{(\ell)}(x_\alpha)) \quad (19)$$

onde em  $z_{i,(c,d)}^{(\ell+1)}(x_\alpha)$ , o primeiro índice  $i$  é um índice de canal, o par de índices  $(c, d)$  é um índice bidimensional espacial e o número  $k$ , mantido aqui com uma constante fixa para cada camada, determina o tamanho da janela convolucional ou as dimensões dos *kernels* (ROBERTS; YAIDA; HANIN, 2022).

A Figura 13 mostra uma comparação entre uma camada totalmente conectada e uma camada convolucional. A camada totalmente conectada (Figura 13-a) possui um peso conectando cada entrada  $x_i$  a cada neurônio oculto  $h_i$ . Por isso, a matriz de pesos associada (Figura 13-b) possui 36 pesos relacionando as seis entradas aos seis neurônios. A camada convolucional com tamanho de *kernel* igual a três, possui apenas três pesos (Figura 13-c). A matriz de pesos associada (Figura 13-d) é um caso especial da matriz da

camada totalmente conectada onde muitos pesos são nulos e outros são repetidos (mesma cor indica o mesmo valor, branco indica peso zero).

Figura 13 – Comparação entre uma camada totalmente conectada e uma camada convolucional



Fonte: Modificado de Prince (2023).

De modo geral, cada camada convolucional (CC) possui um conjunto de filtros, que por sua vez, são compostos por *kernels*. Os filtros possuem dimensões  $(h, w, D)$ , onde  $(h, w)$  são as dimensões dos *kernels* e  $D$  é igual ao número de canais do dado de entrada. Os *kernels* são normalmente matrizes quadradas, apesar de não haver restrições formais que impeçam o uso de matrizes retangulares ou de tensores de uma ou três dimensões. Os *kernels* possuem dimensões estabelecidas durante o processo de concepção da arquitetura, cada um de seus elementos em geral consiste em um valor real. Uma CC implementa o processo análogo ao deslizamento de seus filtros sobre o tensor proveniente da camada anterior de forma a modelar a operação de convolução. O comprimento do passo, conhecido como *stride*, é um parâmetro definido durante a concepção da arquitetura da rede. Se o *stride* for igual a um, os *kernels* se deslocarão uma amostra entre cada cálculo. Além disto, para cada *kernel*, é gerado um mapa de características 2D. Desta forma, a profundidade do volume da saída de uma camada convolucional é igual ao número de filtros em

cada camada.

Existem três razões principais pelas quais as CC são favoráveis para o processamento de imagens. A primeira é que as elas escalam bem com o aumento do tamanho da imagem (GOODFELLOW; BENGIO; COURVILLE, 2016). Assim, os pesos em uma CC não são dependentes do tamanho do volume de entrada, isto significa que com o aumento do tamanho do volume de entrada, o número de pesos permanecerá o mesmo. Portanto, mesmo para grandes volumes de entrada, as CC são computacionalmente eficientes. A segunda razão é devido à visão espacial. Como as CC consistem em filtros que deslizam pelos dados de entrada, elas podem detectar bordas, formas ou padrões presentes e conjuntos de pixels contíguos. Por fim, as operações de convolução são invariantes a translação, desta forma, uma mesma feição local em um mapa de ativação será realçada da mesma forma independente da posição de ocorrência da feição. Em resumo, camadas convolucionais processam cada região local da imagem de forma independente, usando parâmetros compartilhados por toda a imagem. Elas usam menos parâmetros do que camadas totalmente conectadas, exploram as relações espaciais entre pixels próximos e não precisam reaprender a interpretação dos pixels em todas as posições (PRINCE, 2023).

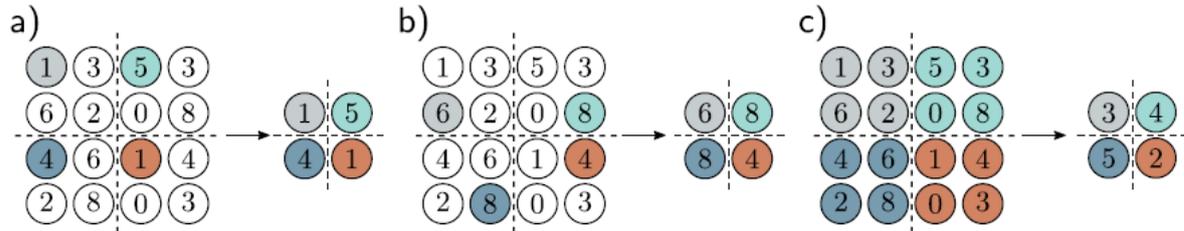
### 3.4 Redução de Escala

O objetivo das técnicas de redução de escala, também chamadas de *downscaling* ou *downsampling*, é criar uma imagem ou mapa de ativação de dimensões menores do que a entrada, mas que ainda contém os elementos estruturais e informações mais importantes, descartando os detalhes finos que não seriam utilizados efetivamente nas camadas subsequentes para a tarefa final do modelo.

Existem duas abordagens principais para redução da escala de um mapa de ativações 2D. Aqui, consideramos o caso mais comum de redução de ambas as dimensões por um fator de dois. Primeiro, podemos simplesmente subamostrar o mapa de entrada, selecionando uma amostra em cada janela de tamanho  $2 \times 2$ , com passo dois (Figura 14-a). O segundo método é a operação de *pooling*, que consiste na aplicação de uma janela móvel que desliza sobre a entrada e retorna o maior valor dentro da janela, no caso do *pooling*

máximo (Figura 14-b), ou a média aritmética dos valores da janela, no caso do *pooling* médio (Figura 14-c).

Figura 14 – Métodos para redução de escala de mapas de ativação



Legenda: (a) - Subamostragem. O mapa de ativações original de dimensões  $4 \times 4$  é reduzido para  $2 \times 2$ ; (b) - *Pooling* máximo. Seleciona os valores máximos em janelas de tamanho  $2 \times 2$ ; (c) - *Pooling* médio. Calcula os valores médios em janelas de tamanho  $2 \times 2$ . Todos os métodos ilustrados usaram *stride* dois.

Fonte: Modificado de Prince (2023).

Um importante hiperparâmetro das redes neurais convolucionais é o passo (*stride*) que a janela móvel executa durante as operações de convolução ou *pooling*. Quanto maior o *stride* menor será a dimensão espacial do resultado.

O processo de redução de escala induz uma invariância à pequenas translações da entrada. Se a entrada for deslocada em um pixel, muitos destes valores máximos permanecem os mesmos. Para todas as abordagens, a redução de escala é realizada separadamente para cada canal, então a saída tem dimensões reduzidas, mas o mesmo número de canais (PRINCE, 2023).

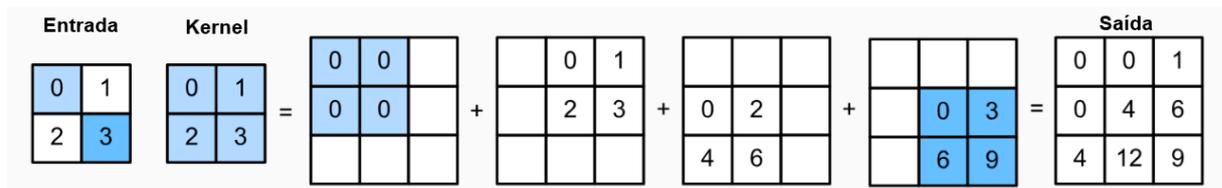
### 3.5 Convolução Transposta

A camada de convolução transposta é um tipo de camada de rede neural que executa a operação oposta de uma camada convolucional tradicional, aumentando efetivamente as dimensões dos mapas de características de entrada.

A camada convolucional transposta utiliza uma técnica semelhante à operação de convolução, mas ao contrário, com o objetivo de aprender uma função de aumento de dimensionalidade (*upsampling*). Enquanto uma convolução padrão reduz as dimensões espaciais da entrada através da aplicação de seus filtros, a convolução transposta aplica

filtros de uma forma que expande as dimensões. Em uma camada convolucional os elementos do *kernel* agem como pesos que multiplicam a entrada em cada locação. Já na camada de convolução transposta, a entrada é tratada como pesos que são multiplicados pelos valores dos *kernels* (Figura 15). Os filtros na camada convolucional transposta são aprendidos durante o treinamento, semelhante às camadas convolucionais tradicionais.

Figura 15 – Camada de convolução transposta com um *kernel*  $2 \times 2$  e *stride* 1



Fonte: Modificado de Zhang et al. (2020).

A camada de convolução transposta ajuda na recuperação de informações espaciais perdidas durante operações de redução da dimensionalidade, permitindo que a rede gere resultados detalhados e de maior resolução.

### 3.6 Atenuação de Ruídos através de Aprendizado Supervisionado

Dados sísmicos são inevitavelmente contaminados por ruídos e sinais não sísmicos originados a partir das mais variadas fontes, tais como, ondas do mar, vento, tráfego, ruído instrumental, ruído elétrico, entre outros (BUSSON, 2022). Os ruídos nos dados sísmicos podem ser classificados como coerentes, que apresentam coerência espacial (reflexões múltiplas, interferência sísmica, etc.), e incoerentes ou aleatórios (*swell noise*, ruído de vento, etc.) (DONDURUR, 2018). A atenuação de ruídos é um problema clássico e sempre foi um desafio na prática de processamento de dados sísmicos (WANG et al., 2023).

O dado sísmico pode ser considerado como uma superposição entre sinais úteis e ruídos

$$\mathbf{x} = \mathbf{y} + \mathbf{n} \quad (20)$$

onde  $\mathbf{x}$  representa o dado sísmico bruto,  $\mathbf{y}$  representa o sinal útil e  $\mathbf{n}$  representa genericamente

mente os ruídos<sup>10</sup>, incluindo os coerentes e incoerentes.

Vários métodos de aprendizado de máquina foram originalmente propostos para atenuação de ruídos em imagens naturais ou biomédicas e depois foram adaptados para imagens sísmicas. Por exemplo, a arquitetura *Denoising* CNN (DnCNN), proposta por Zhang et al. (2017) para atenuação de ruído gaussiano em imagens naturais, foi utilizada por Zheng, Yuan e Si (2020) para atenuação de ruídos lineares em dados sísmicos e por Zhao et al. (2019) para atenuação de ruídos de baixa frequência em dados sísmicos adquiridos no deserto. Sun et al. (2020a) propuseram uma variação da U-NET, originalmente proposta por Ronneberger, Fischer e Brox (2015) para segmentação de imagens médicas, para atenuação de interferência sísmica.

Essas aplicações usaram dados de treinamento pareados, ou seja, dados limpos e ruídos, e a estratégia de aprendizado supervisionado. A atenuação de ruídos através de aprendizado supervisionado consiste em encontrar o melhor mapeamento  $\mathbf{y} \approx f_{\theta}(\mathbf{x})$  entre o dado bruto de entrada ( $\mathbf{x}$ ) e o sinal útil ( $\mathbf{y}$ ), dado sem ruído, usado como alvo no treinamento, através da solução do problema de otimização dado pela Equação 21.

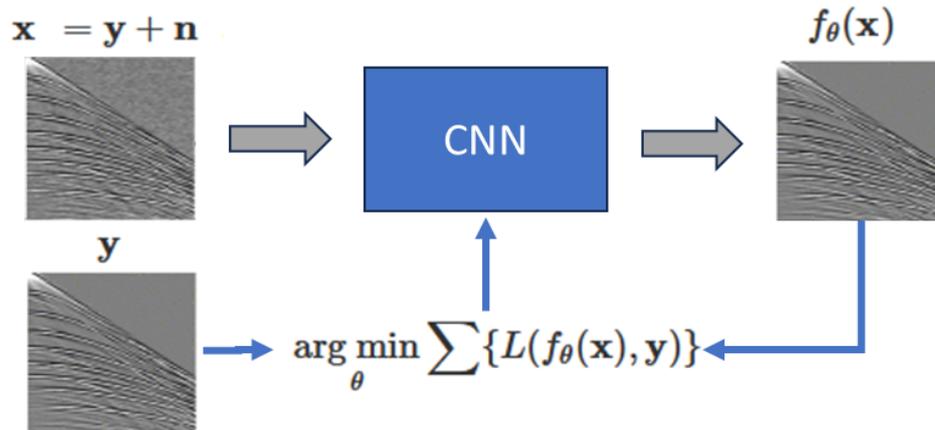
$$\hat{\theta} = \arg \min_{\theta} \sum_i \{L(f_{\theta}(\mathbf{x}_i), \mathbf{y}_i)\} \quad (21)$$

A função  $L(\cdot)$  representa a função objetivo ou função de perda (*Loss function*) usada no treinamento. O objetivo a ser alcançado durante o treinamento é obter os valores dos parâmetros ótimos  $\hat{\theta}$  que ajustem a função  $f_{\theta}(\cdot)$  de forma a minimizar a função objetivo  $L(f_{\theta}(\mathbf{x}_i), \mathbf{y}_i)$  em função dos dados de treinamento  $\{\mathbf{x}_i, \mathbf{y}_i\}$ . No caso do treinamento de uma CNN, os parâmetros  $\hat{\theta}$  representam os pesos e vieses das camadas convolucionais da rede utilizada. A Figura 16 ilustra o processo de treinamento supervisionado de uma CNN para atenuação de ruídos em dados sísmicos.

---

<sup>10</sup>Aqui consideramos o conceito generalizado de ruído como tudo aquilo que não seja sinal útil e que se deseja remover ou atenuar através do processamento dos dados. Inclui, portanto, ruídos de diferentes origens, além do ruído de *blending*.

Figura 16 – Atenuação de ruídos em dados sísmicos através de aprendizado supervisionado



Fonte: O autor (2024).

### 3.7 Atenuação de Ruídos através de Aprendizado Autossupervisionado

Na prática, obter dados sísmicos reais realmente limpos é bastante desafiador. Portanto, a falta de dados limpos tem sido uma das principais desvantagens para o uso de métodos de atenuação de ruídos baseados em aprendizado supervisionado. Esse tipo de limitação tem motivado o desenvolvimento de técnicas que empreguem aprendizado não-supervisionado ou autossupervisionado para a tarefa de atenuação de ruídos em imagens e dados sísmicos.

O paradigma do aprendizado autossupervisionado é considerado uma ponte entre a aprendizagem supervisionada e a aprendizagem não-supervisionada. As tarefas de aprendizado autossupervisionado são divididas em duas categorias: tarefas de pretexto e tarefas verdadeiras (*downstream tasks*). O primeiro tipo de tarefa emprega aprendizagem supervisionada para aprender representações, com rótulos ou alvos gerados a partir dos próprios dados. Quando esse aprendizado estiver concluído, o modelo aplica as representações aprendidas anteriormente às tarefas subsequentes (RANI et al., 2023).

Seguindo essa linha, Lehtinen et al. (2018) propuseram o método Noise2Noise, partindo da hipótese de que uma rede neural poderia ser treinada para atenuar ruídos aleatórios

em imagens usando apenas pares de imagens ruidosas, ou seja, duas realizações da mesma imagem com ruídos diferentes.

Este método de atenuação de ruídos através de aprendizado autossupervisionado baseia-se nas seguintes premissas:

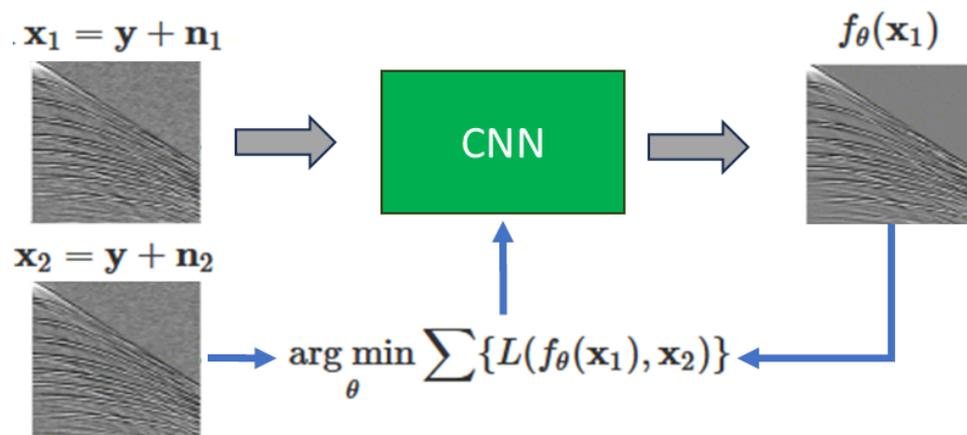
1. a entrada e o alvo de treinamento apresentam o mesmo sinal útil coerente;
2. a entrada e o alvo de treinamento apresentam ruídos independentes.

Quando as premissas são satisfeitas, o problema de otimização que representa o treinamento supervisionado (Equação 21) pode ser reescrito baseado no método Noise2Noise:

$$\hat{\theta} = \arg \min_{\theta} \sum_i \{L(f_{\theta}(\mathbf{x}_{1,i}), \mathbf{x}_{2,i})\} \quad (22)$$

onde  $\mathbf{x}_{1,i} = \mathbf{y}_i + \mathbf{n}_{1,i}$  e  $\mathbf{x}_{2,i} = \mathbf{y}_i + \mathbf{n}_{2,i}$  representam pares de imagens ruidosas usadas como entrada e alvo, respectivamente. A Figura 17 ilustra o processo de treinamento autossupervisionado Noise2Noise de uma CNN para atenuação de ruídos em dados sísmicos.

Figura 17 – Atenuação de ruídos em dados sísmicos através de aprendizado autossupervisionado Noise2Noise.



Fonte: O autor (2024).

Considerando uma função objetivo do tipo  $L_2$  e representando a saída da rede  $f_{\theta}(\mathbf{x}_1)$  como  $\hat{\mathbf{y}}$ , pode-se escrever a função objetivo da Equação 22 como:

$$\begin{aligned}
L_2(\hat{\mathbf{y}}, \mathbf{y} + \mathbf{n}_2) &= \frac{1}{N} \sum_{i=1}^N [\mathbf{y}_i + \mathbf{n}_{2,i} - \hat{\mathbf{y}}_i]^2 \\
&= \frac{1}{N} \sum_{i=1}^N \{[\mathbf{y}_i - \hat{\mathbf{y}}_i]^2 + 2\mathbf{n}_{2,i}[\mathbf{y}_i - \hat{\mathbf{y}}_i] + \mathbf{n}_{2,i}^2\} \\
&= L_2(\hat{\mathbf{y}}, \mathbf{y}) + \sigma(\mathbf{n}_2)^2 + \frac{2}{N} \sum_{i=1}^N \mathbf{n}_{2,i}[\mathbf{y}_i - \hat{\mathbf{y}}_i]
\end{aligned} \tag{23}$$

o primeiro termo da Equação 23 se trata da função objetivo do caso supervisionado ( $L_2(\hat{\mathbf{y}}, \mathbf{y})$ ). O segundo termo é a variância do ruído ( $\sigma(\mathbf{n}_2)^2$ ), que é independente dos parâmetros  $\theta$  do modelo. O terceiro termo tende a zero quando  $N$  é grande o suficiente e quando o ruído incoerente e o sinal são independentes e apresentam média zero.

Portanto, em princípio, o uso de imagens ruidosas como alvo no treinamento não alteraria a capacidade de aprendizado da rede. Consequentemente, o treinamento seguindo a metodologia Noise2Noise seria equivalente ao treinamento supervisionado.

Embora a metodologia Noise2Noise possa usar apenas pares de dados ruidosos para treinamento, esses pares de dados precisam atender à premissa de que eles têm o mesmo sinal. Para a prospecção sísmica, uma das formas de obter dados sísmicos com sinais semelhantes seria realizar múltiplas aquisições repetidas dos mesmos pontos de tiro e receptor no mesmo levantamento. No caso da aquisição de dados sísmicos marítimos, essa estratégia não é operacionalmente viável e certamente aumentaria o custo da aquisição. Portanto, é um desafio obter pares de treinamento ruidosos suficientes, o que limitaria a aplicação da metodologia Noise2Noise na tarefa de atenuação de ruídos em dados sísmicos (SHAO et al., 2022).

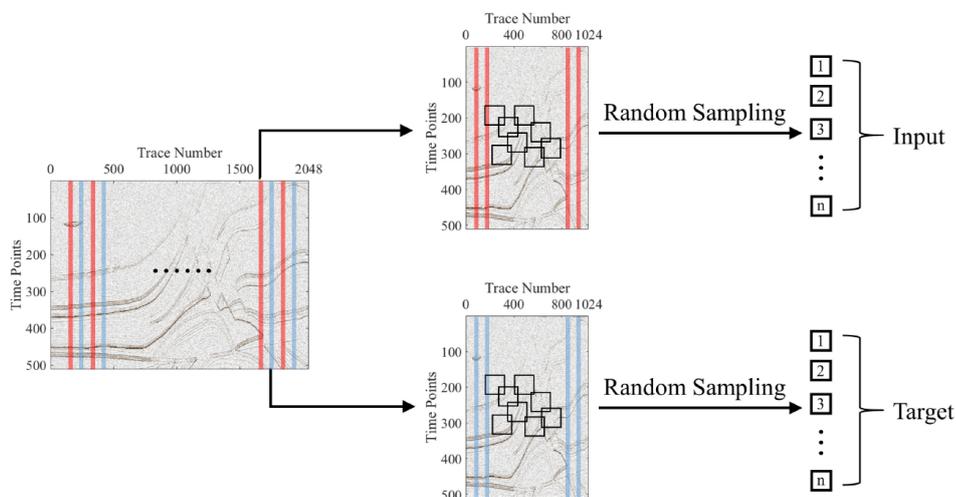
Com o intuito de superar essa limitação, Liu et al. (2022) propuseram uma estratégia para geração de pares de dados sísmicos ruidosos a partir de traços sísmicos adjacentes. O método, posteriormente chamado na literatura de Trace2Trace (SONG et al., 2023), é baseado na continuidade lateral dos dados sísmicos, e consiste na utilização de traços ímpares e pares como entrada e alvo no processo de treinamento de redes neurais, respectivamente.

O método Trace2Trace é baseado nas seguintes premissas:

1. Sinais de traços sísmicos adjacentes são espacialmente correlacionados;
2. Ruído aleatório é espacialmente independente e imprevisível.

Considerando essas premissas, o método propõe a geração de pares de amostras para treinamento obtidas apenas a partir de imagens sísmicas<sup>11</sup> ruidosas. A estratégia de amostragem consiste em separar os dados do conjunto de treinamento em traços sísmicos pares e ímpares, criando assim subconjuntos de dados para serem usados como entrada e alvo, respectivamente. A Figura 18 ilustra esse processo. Esses pares de dados são, então, utilizados para treinamento das redes, de forma análoga ao método Noise2Noise, seguindo a mesma estratégia apresentada na Seção 3.7 (Figura 17). Os trabalhos de Liu et al. (2022) e (SONG et al., 2023) trataram apenas da atenuação de ruído aleatório em imagens sísmicas.

Figura 18 – Ilustração do processo de subamostragem por traços adjacentes do método Trace2Trace



Legenda: O processo de subamostragem por traços adjacentes do método Trace2Trace parte de uma imagem sísmica ruidosa e a separa em traços sísmicos ímpares (em vermelho) e pares (em azul). Cada subconjunto é, então, dividido em *patches* que serão utilizados como entrada e alvo para o treinamento.

Fonte: Liu et al. (2022).

<sup>11</sup>Imagens sísmicas são geradas a partir de dados sísmicos e da aplicação de métodos de imageamento, tais como migração reversa no tempo (RTM) e inversão do campo de ondas completo (FWI).

## 4 MÉTODO

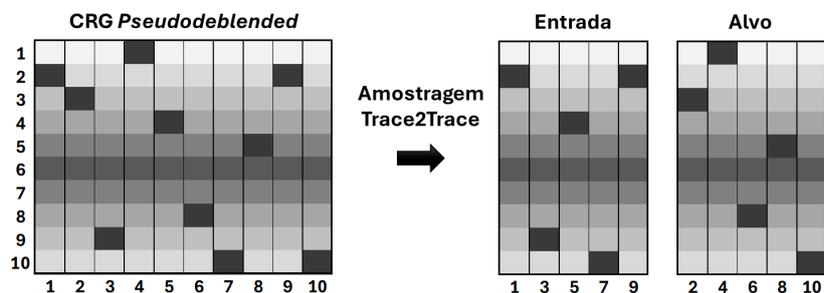
No presente capítulo, são apresentados os métodos empregados e propostos no trabalho, bem como são descritas as arquiteturas das redes neurais profundas utilizadas.

### 4.1 *Deblending* Autossupervisionado Trace2Trace

O método de *Deblending* Autossupervisionado Trace2Trace consiste na proposta principal deste trabalho em utilizar o método Trace2Trace, proposto originalmente por Liu et al. (2022) para atenuação de ruído aleatório em imagens sísmicas, para o processo de *deblending* de dados sísmicos.

No método de *deblending* aqui proposto, as imagens sísmicas ruidosas são substituídas por dados sísmicos *pseudodeblended* no domínio do receptor comum (CRG) ou canal comum (CCG). Como os sinais úteis em traços sísmicos adjacentes nesse domínio apresentam coerência espacial e o ruído de *blending*, por outro lado, apresenta-se de forma espacialmente incoerente, as premissas do método Trace2Trace são, em princípio, satisfeitas e o método pode ser aplicado ao processo de *deblending*. A Figura 19 ilustra o processo de amostragem por traços sísmicos adjacentes empregado para geração de pares de dados para treinamento e a Figura 20 mostra o processo de treinamento segundo o método de *Deblending* Autossupervisionado Trace2Trace.

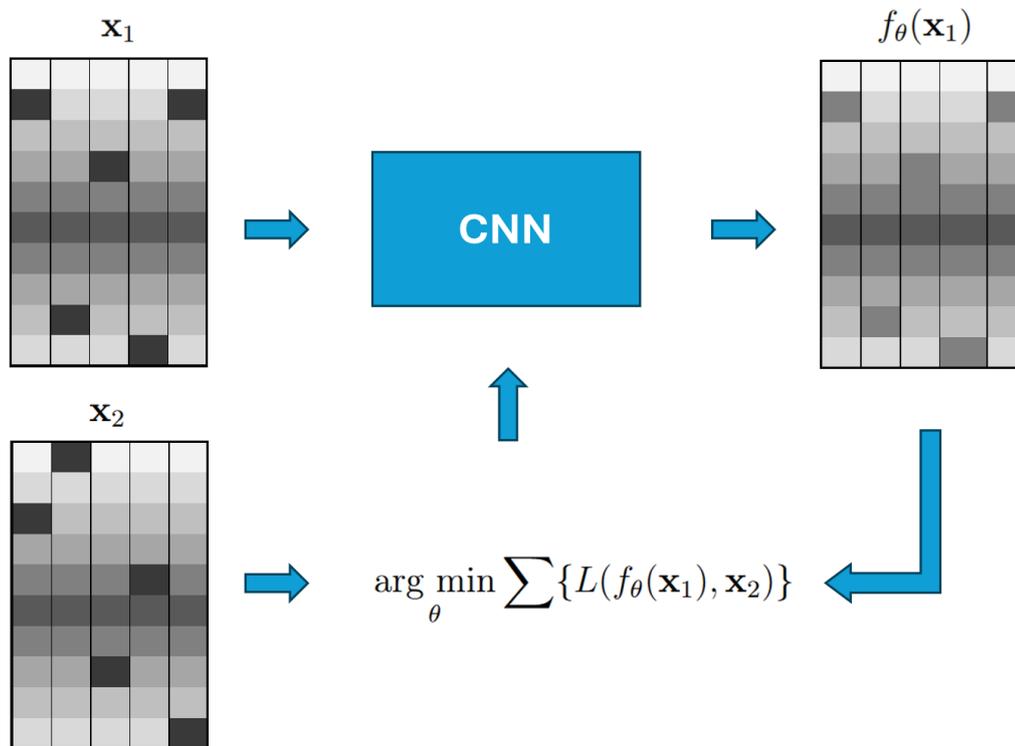
Figura 19 – Esquema de amostragem empregada no método Trace2Trace



Legenda: O ruído de *blending* é representado pelos quadrados pretos, cuja cor diverge das amostras vizinhas e não apresenta coerência espacial entre os traços sísmicos (colunas do dado de entrada). As linhas representam fatias de tempo constante.

Fonte: O autor (2024).

Figura 20 – Esquema de treinamento para o método de *Deblending* Autossupervisionado Trace2Trace

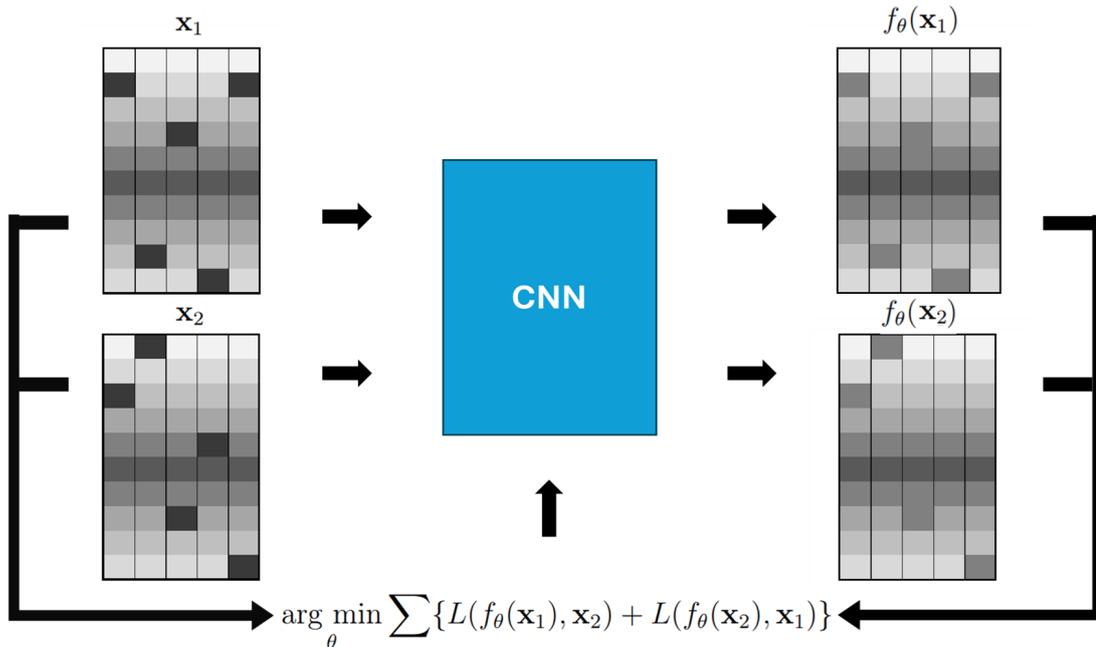


Fonte: O autor (2024).

Como o par de amostras ruidosas usadas para treinamento representam o mesmo dado limpo subjacente, ambas as amostras podem ser usadas tanto como entrada quanto como alvo. Isto implica, portanto, que os termos  $\mathbf{x}_1$  e  $\mathbf{x}_2$ , podem ser permutados na função objetivo a ser minimizada durante o treinamento. Em um trabalho envolvendo a aplicação do método Noise2Noise para atenuação de ruído em imagens de microscopia eletrônica, Calvarons (2021) propôs que ambos os termos da função objetivo  $L(f_\theta(\mathbf{x}_1), \mathbf{x}_2)$  e  $L(f_\theta(\mathbf{x}_2), \mathbf{x}_1)$  poderiam contribuir igualmente para o treinamento e chamou esta variação do método de *alternating* Noise2Noise. O mesmo raciocínio pode ser aplicado ao método de *Deblending* Trace2Trace aqui proposto. O uso simultâneo de ambas amostras dos pares de dados de treinamento como entrada e alvo, e vice-versa, pode ser representado pelo problema de regressão dado pela Equação 24. A Figura 21 ilustra este processo de treinamento. A função objetivo resultante será chamada no texto de função objetivo alternada. A minimização conjunta dos dois termos da função objetivo alternada introduz, portanto, um vínculo de consistência no processo de *deblending* usando o método Trace2Trace.

$$\hat{\theta} = \arg \min_{\theta} \sum_i \{L(f_{\theta}(\mathbf{x}_{1,i}), \mathbf{x}_{2,i}) + L(f_{\theta}(\mathbf{x}_{2,i}), \mathbf{x}_{1,i})\} \quad (24)$$

Figura 21 – Esquema de treinamento para o método de *Deblending* Autossupervisionado Trace2Trace usando a função objetivo alternada



Fonte: O autor (2024).

#### 4.1.1 Pós-processamento

O dado *deblended* predito pela rede treinada usando o método de *Deblending* Autossupervisionado Trace2Trace foi submetido a uma etapa de pós-processamento, que segue o que foi proposto no trabalho de Luiken, Ravasi e Birnie (2024). Esta etapa tem como objetivo aproximar o dado *deblended* do dado original, trazendo de volta ao dado feições e ruídos diferentes do ruído de interferência, que porventura tenham sido removidos durante o processo de *deblending*. Em outras palavras, o objetivo desta etapa de pós-processamento é isolar o efeito do processo de *deblending*.

Este processo consiste na solução do seguinte problema inverso:

$$\hat{\mathbf{y}}_{\text{pp}} = \hat{\mathbf{y}} + \underset{\mathbf{d}}{\operatorname{argmin}} \frac{1}{2} \|\mathbf{T}_r(\hat{\mathbf{y}} + \mathbf{d}) - \mathbf{b}_r\|_2^2 \quad (25)$$

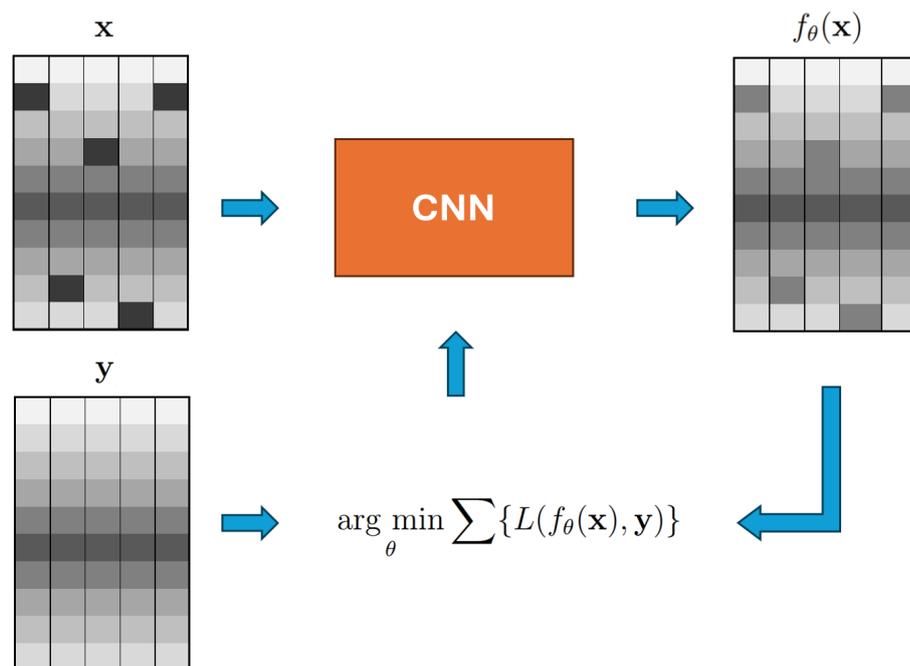
onde  $\mathbf{T}_r$  é o operador de *blending*,  $\mathbf{b}_r$  é o dado *blended*,  $\hat{\mathbf{y}}$  e  $\hat{\mathbf{y}}_{pp}$  representam o dado *deblended* antes e depois da etapa de pós-processamento, e  $\mathbf{d}$  representa o termo que se deseja adicionar ao dado *deblended* de modo que o resíduo em relação ao dado *blended* seja mínimo no sentido dos mínimos quadrados.

Este problema pode ser resolvido através do algoritmo iterativo LSQR (PAIGE; SAUNDERS, 1982), indicado para solução de problemas de mínimos quadrados envolvendo matrizes grandes e esparsas. Este algoritmo é analiticamente equivalente ao método dos gradientes conjugados, mas possui propriedades numéricas mais favoráveis.

#### 4.2 *Deblending* Supervisionado

O método de *Deblending* Supervisionado consiste no treinamento de redes neurais profundas de modo supervisionado para *deblending* de dados sísmicos. De maneira análoga à estratégia de atenuação de ruídos apresentada na Seção 3.6 (Figura 16), neste método, o treinamento das redes necessita de amostras pareadas de dados sísmicos no domínio do receptor ou canal comum com e sem o efeito do ruído de *blending*. A Figura 22 ilustra o processo de treinamento para o método de *Deblending* supervisionado.

Figura 22 – Esquema de treinamento para o método de *Deblending* supervisionado



Fonte: O autor (2024).

Para se obter esses pares de dados, deve-se partir de um dado sísmico sintético ou adquirido de forma convencional, realizar o processo de *blending* numérico, por meio da Equação 1, e executar o processo de *pseudodeblending* usando a Equação 5.

O uso de um método de *deblending* supervisionado neste trabalho tem como objetivo principal fornecer uma base de comparação com o método autossupervisionado proposto.

### 4.3 *Deblending* por Inversão Esparsa

Para comparação com os resultados obtidos pelos métodos que utilizam aprendizado profundo, também foi executado o processo de *deblending* por inversão esparsa. Este tipo de método busca resolver o problema de *deblending* considerando a restrição adicional de que o dado a ser recuperado seja esparsos em algum domínio transformado.

Os problemas de otimização representados pelas Equações 6 e 7 são equivalentes ao problema de mínimos quadrados com termo de regularização L1, dado pela Equação 26, mais conhecido como *Least Absolute Shrinkage and Selection Operator* (LASSO) (TIBSHIRANI, 1996):

$$\hat{\mathbf{s}} = \underset{\mathbf{s}}{\operatorname{argmin}} \frac{1}{2} \|\mathbf{b}_r - \Phi \mathbf{s}\|_2^2 + \lambda \|\mathbf{s}\|_1 \quad (26)$$

onde  $\mathbf{s} = \mathbf{S}\mathbf{x}$  representa o dado no domínio transformado,  $\Phi = \mathbf{T}_r \mathbf{S}^H$  representa o operador composto pelo operador de *blending* e o operador da transformada,  $\mathbf{b}_r$  é o dado *blended* e  $\lambda$  é o parâmetro de regularização.

Neste trabalho, o método de *deblending* por inversão esparsa foi implementado usando a transformada de Fourier 2D janelada (WFT2D) e o algoritmo de inversão esparsa FISTA (BECK; TEBoulLE, 2009), mesma combinação utilizada por Luiken, Ravasi e Birnie (2024).

O algoritmo FISTA (*Fast Iterative Shrinkage-thresholding Algorithm*) (BECK; TEBoulLE, 2009) é uma variação da classe de algoritmos *Iterative Shrinkage-thresholding Algorithms* (ISTA) que apresenta uma taxa de convergência aprimorada. Os algoritmos ISTA resolvem problemas LASSO a partir de um procedimento iterativo no qual a solução procurada é calculada por:

$$\mathbf{s}^{k+1} = S_{\lambda/L}(\mathbf{s}^k - \frac{1}{L}\Phi^H(\mathbf{b}_r - \Phi\mathbf{s}^k)) \quad (27)$$

em que  $1/L$  é uma constante que define o tamanho do passo adequado,  $S_{\lambda/L}$  é o operador de *soft thresholding*, dado pela Equação 28, e  $k$  é o número da iteração.

$$S_{\lambda/L}(x) = \text{sign}(x)\max\{|x| - \lambda/L, 0\} \quad (28)$$

A melhora na taxa de convergência existente no FISTA se deve a uma modificação na Equação 27. Em vez de utilizar a estimativa do passo anterior ( $\mathbf{s}^k$ ), é utilizada uma combinação linear  $\mu^k$  da estimativa atual e anterior ( $\mathbf{s}^{k+1}$  e  $\mathbf{s}^k$ ). As parcelas relevantes dessas estimativas no cálculo de  $\mu^k$  são definidas pela constante  $t_k$ , atualizada a cada iteração (PRADO; GUARNERI, 2018). O pseudocódigo do algoritmo FISTA é apresentado na Figura 23.

Figura 23 – Algoritmo FISTA

---

**Algoritmo 1: FISTA**

---

**Entrada:**  $\Phi$ ,  $\mathbf{b}_r$ ,  $\lambda$ ,  $L$ ,  $\epsilon$

**Saída:**  $\mathbf{s}^{k+1}$

**início**

$k = 1, t^k = 1, \mathbf{s}^k = \mathbf{0}, \mathbf{r}^k = \mathbf{b}_r, \mu^k = \mathbf{0}$

**enquanto**  $\|\mathbf{r}^k\|_2 > \epsilon$  **faça**

$\mathbf{s}^{k+1} = S_{\lambda/L}(\mu^k - \frac{1}{L}\Phi^H(\mathbf{b}_r - \Phi\mu^k))$

$t^{k+1} = \frac{1 + \sqrt{1 + 4(t^k)^2}}{2}$

$\mu^{k+1} = \mathbf{s}^{k+1} + \frac{t^k - 1}{t^{k+1}}(\mathbf{s}^{k+1} - \mathbf{s}^k)$

$\mathbf{r}^{k+1} = \mathbf{b}_r - \Phi\mathbf{s}^{k+1}$

$k = k + 1$

**fim**

**fim**

---

Fonte: Beck e Teboulle (2009).

Após obtenção da solução, o dado *deblended* no domínio original deve ser recuperado através da aplicação da transformada inversa por meio da Equação 29.

$$\hat{\mathbf{x}} = \mathbf{S}^H \hat{\mathbf{s}} \quad (29)$$

#### 4.4 Arquiteturas de Redes Neurais Profundas

Os métodos descritos nas Seções 4.1 e 4.2 são independentes da arquitetura de rede utilizada. Juntamente com o método Trace2Trace, Liu et al. (2022) propuseram uma variação da arquitetura U-NET para atenuação de ruído aleatório em imagens sísmicas. Logo, uma vez que o método de *deblending* proposto na Seção 4.1 se trata de uma nova aplicação do método Trace2Trace, é natural a escolha da mesma arquitetura proposta no trabalho original.

Além da arquitetura U-NET, foi avaliada a possibilidade de substituição desta por outra rede convolucional que já tivesse sido utilizada para a tarefa de *deblending* de dados sísmicos. Dentre as opções propostas na literatura, a rede *No-downscaling* CNN (NDCNN), proposta por Sun et al. (2020b), foi selecionada por ter sido originalmente concebida para esse fim, além de ter uma estrutura que não envolve redução de escala dos dados, diferentemente da U-NET, como descrito na próxima seção.

##### 4.4.1 U-NET

Originalmente proposta por Ronneberger, Fischer e Brox (2015) para segmentação de imagens biomédicas, a arquitetura U-NET é composta por um estágio *encoder*, responsável por extrair propriedades importantes do dado de entrada por meio de operações de redução de escala, e um ramo *decoder*, responsável por reconstruir o dado processado.

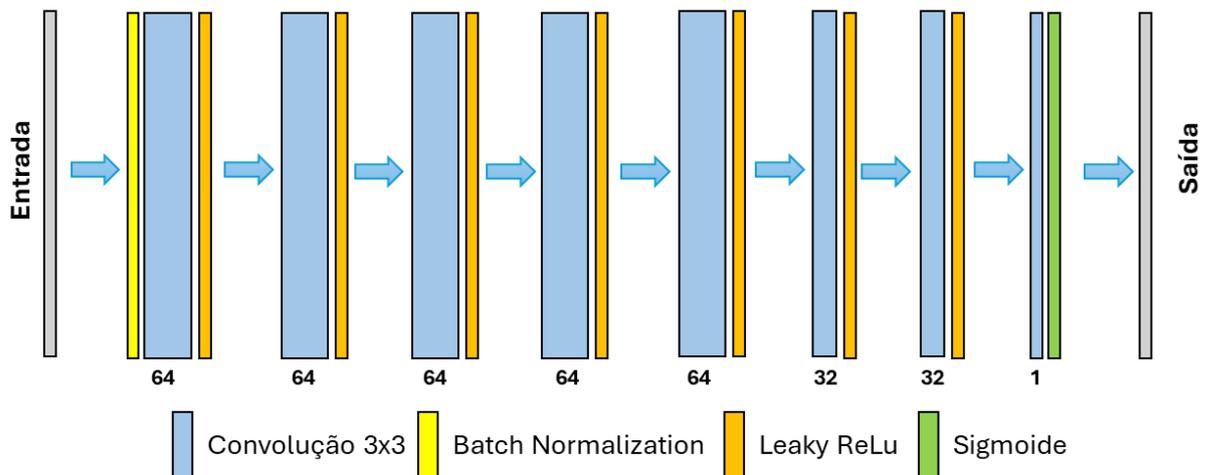
Uma característica importante da arquitetura U-NET é a conexão existente entre o *encoder* e o *decoder*, também chamada de *skip connection*. Essas conexões fazem com que a rede aprenda características de várias escalas por meio da combinação entre informações locais e globais (RONNEBERGER; FISCHER; BROX, 2015). As *skip connections* utilizadas na U-NET são aplicadas através da operação de concatenação, que consiste no empilhamento dos mapas de ativação e conseqüentemente no aumento do número de canais da imagem de saída da camada. A operação de concatenação preserva informações



a evitar o problema do desligamento de neurônios com valores de ativação negativos. Aqui, utilizamos o valor de 0,4 para o parâmetro de inclinação negativa. Além disso, a operação de *batch normalization* é usada na parte inicial da rede para padronização dos dados de entrada. Esta técnica contribui para evitar o problema de desaparecimento ou explosão do gradiente, assim como soluções presas em mínimos locais. Matematicamente, o *batch normalization* é realizado calculando a média ( $\mu$ ) e o desvio padrão ( $\sigma$ ) dos dados de entrada ( $x$ ) em cada *batch* separadamente e, em seguida, utilizando esses parâmetros para padronizar os dados através da Equação 30.

$$z = \frac{x - \mu}{\sigma} \quad (30)$$

Figura 25 – Arquitetura No Downscale CNN (NDCNN)



Fonte: O autor (2024).

#### 4.4.3 RES-NDCNN

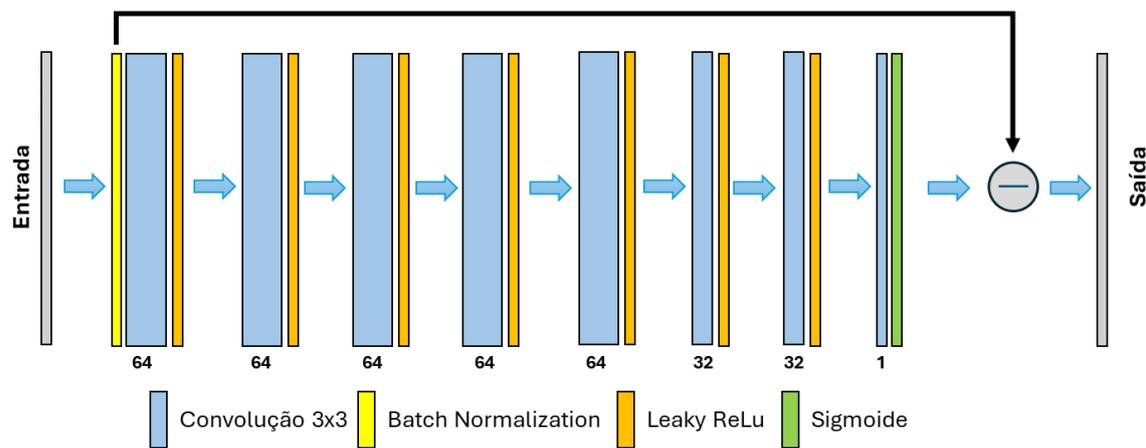
A arquitetura RES-NDCNN, proposta originalmente neste trabalho, é uma variação da rede NDCNN acrescida de uma conexão residual global.

O mecanismo de Aprendizagem Residual Global (*Global Residual Learning* - GRL), proposto por Zhang (2017), é uma variação das conexões residuais utilizadas originalmente na arquitetura RESNET (HE et al., 2016). Nesse caso, a conexão é feita entre a entrada e a

saída da rede, conforme ilustrado na Figura 26. A estratégia GRL remove implicitamente o conteúdo desejado do espaço latente nas camadas ocultas da rede. Logo, a rede apenas aprende a diferença entre a entrada ( $x$ ) e a saída desejada ( $y$ ):  $y = x - R(x)$ , onde  $R(x)$  é aprendido (BUSSON, 2022).

No caso da tarefa de *deblending*,  $R(x)$  representa o ruído de interferência presente no dado de entrada (*pseudodeblended*) e, portanto, o uso da estratégia GRL busca facilitar o aprendizado e a atenuação ou remoção do ruído de *blending*.

Figura 26 – Arquitetura RES-NDCNN



Fonte: O autor (2024).

## 5 PROCEDIMENTO EXPERIMENTAL

Os experimentos realizados neste trabalho foram agrupados em três categorias: validação do método de *deblending* proposto, análise do efeito do *dither time* e avaliação da capacidade de generalização.

A validação do método de *Deblending* Autossupervisionado Trace2Trace foi realizada comparando os resultados obtidos em duas bases de dados com os métodos de *Deblending* Supervisionado e *Deblending* por Inversão Esparsa. Além disso, foram avaliados os efeitos da arquitetura utilizada, da função objetivo e do procedimento de pós-processamento. Após esta etapa, a configuração que apresentou melhores resultados foi mantida para os experimentos seguintes.

Em seguida, o método proposto foi utilizado em dados com diferentes intervalos de *dither time* a fim de se avaliar o efeito destes sobre os resultados de *deblending* alcançados. Mais uma vez, os resultados do método proposto foram comparados aos obtidos com o *Deblending* por Inversão Esparsa.

Por fim, foram executados experimentos com o intuito de avaliar a capacidade de generalização do método proposto. Primeiramente, avaliou-se o efeito da aplicação do método em uma base de dados diferente da usada para o treinamento da rede, mantendo-se o mesmo intervalo de *dither time*. Em seguida, analisou-se o efeito da variação do intervalo de *dither time* entre os dados de treinamento e teste, mantendo-se a mesma base de dados.

Neste capítulo são apresentados os principais componentes dos experimentos realizados. São apresentadas as bases de dados, as etapas de preparação dos dados, os procedimentos e parâmetros utilizados para treinamento e teste das redes, as métricas utilizadas para avaliação dos resultados, bem como as configurações de *hardware* e *software* utilizadas nos experimentos.

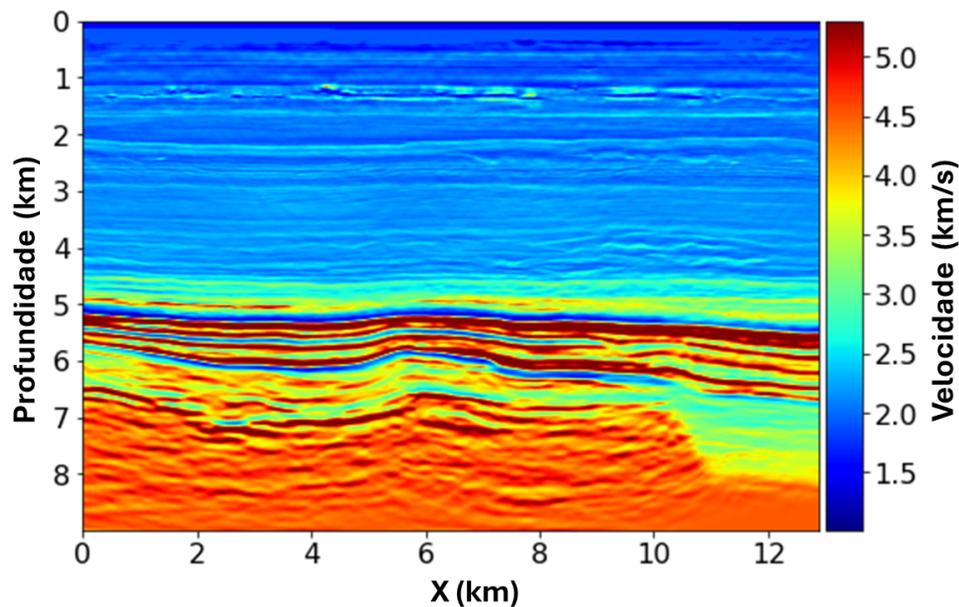
## 5.1 Bases de Dados

### 5.1.1 Volve Sintético

A base de dados sísmicos sintéticos Volve Sintético foi modelada a partir de um modelo de velocidades sísmicas de alta resolução do campo de Volve, localizado no Mar do Norte, disponibilizado por Ravasi (2022). O campo de Volve foi desativado em 2016 e os dados históricos de subsuperfície e produção foram disponibilizados pela empresa Equinor e parceiros para fins de pesquisa e desenvolvimento (EQUINOR, 2018).

Uma linha sísmica 2D com tecnologia *streamer* foi modelada com  $N_s = 891$  tiros, na profundidade de 15m, com espaçamento entre fontes de 10m e um cabo com  $N_r = 100$  receptores, com intervalo espacial de 40m e profundidade de 20m, além de  $N_t = 1.500$  amostras temporais, totalizando um tempo de registro de 6,0s. A Figura 27 mostra o modelo de velocidades usado na modelagem.

Figura 27 – Modelo de velocidades sísmicas do campo de Volve usado para modelagem da base de dados sintéticos

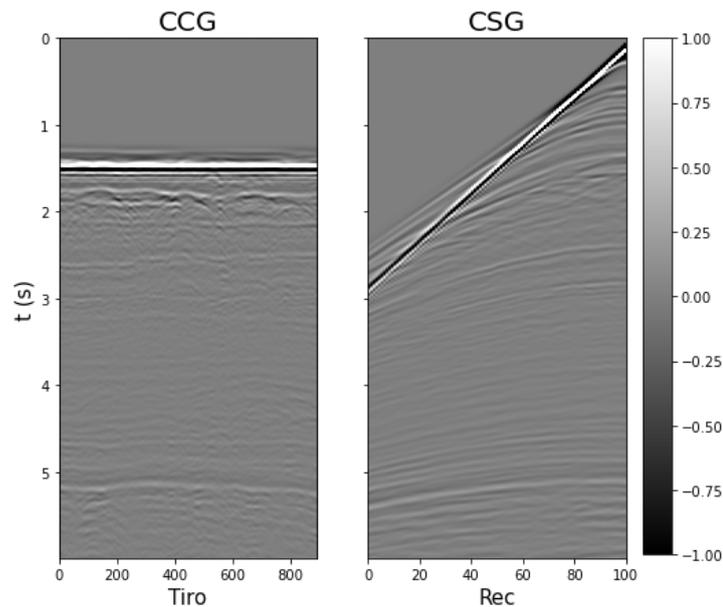


Fonte: O autor (2024).

A modelagem sísmica foi realizada por meio do pacote Python Devito (LUPORINI et al., 2020; LOUBOUTIN et al., 2019), usando o método de diferenças finitas e discretização da equação da onda acústica de segunda ordem no tempo e no espaço. Quanto maior

é a ordem da discretização (ordem de aproximação das derivadas), maior é a acurácia da modelagem (menor erro numérico) e maior é o custo computacional em termos de memória e tempo de processamento (FICHTNER, 2011). Para os propósitos deste trabalho, a aproximação de segunda ordem foi suficiente. O detalhamento do processo de modelagem sísmica pelo método de diferenças finitas está fora do escopo deste trabalho. Para aprofundamento neste tema, sugerimos as referências Bording e Lines (1997) e Fichtner (2011). A Figura 28 mostra exemplos de sismogramas modelados nos domínios do canal comum (CCG) e tiro comum (CSG).

Figura 28 – Sismogramas da base de dados Volve sintético nos domínios do canal comum (CCG) e tiro comum (CSG)



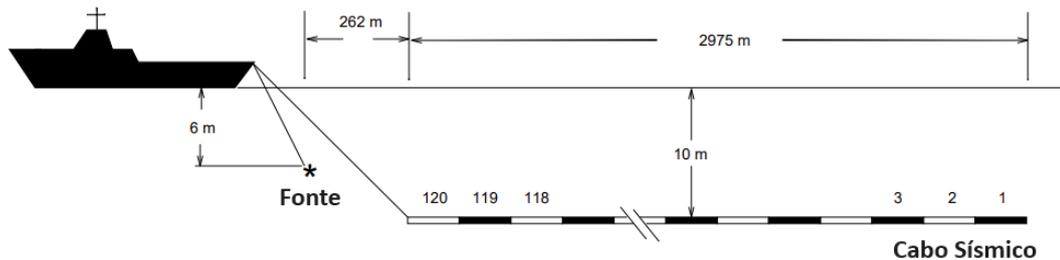
Fonte: O autor (2024).

### 5.1.2 Mobil AVO *Viking Graben*

A base de dados Mobil AVO *Viking Graben* linha 12 (SEG, 2021) é composta por dados sísmicos marítimos 2D adquiridos no Mar do Norte com tecnologia *streamer* e disponibilizada gratuitamente pela SEG. O dado é composto por  $N_s = 1.001$  tiros,  $N_r = 120$  receptores e  $N_t = 1.500$  amostras temporais, adquiridas com intervalo de amostragem de 4 ms, totalizando um tempo de registro de 6,0 s. Os intervalos entre tiros e entre receptores são de 25 m. O afastamento da fonte do tiro e o receptor mais próximo é de

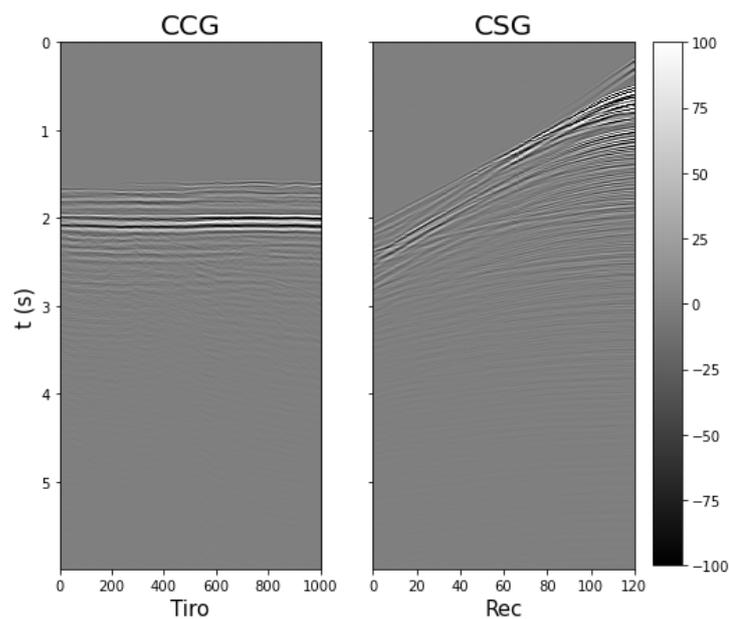
262 m e o afastamento mais distante 3.237 m. A profundidade nominal do cabo é de 10 m e a profundidade do arranjo de fonte é de 6 m. O arranjo de fonte sísmica consiste em 24 canhões de ar comprimido e oito sobressalentes, com volume total de 3.650 pol<sup>3</sup>. A lâmina d'água ao longo da linha sísmica é bastante constante, cerca de 350 m. A Figura 29 ilustra um esquema com os principais parâmetros de aquisição da linha sísmica e a Figura 30 mostra exemplos de sismogramas nos domínios do canal comum (CCG) e tiro comum (CSG).

Figura 29 – Esquema do levantamento marítimo *streamer* 2D Mobil AVO *Viking Graben* linha 12



Fonte: Keys e Foster (2012).

Figura 30 – Sismogramas da base de dados Mobil AVO nos domínios do canal comum (CCG) e tiro comum (CSG)



Fonte: O autor (2024).

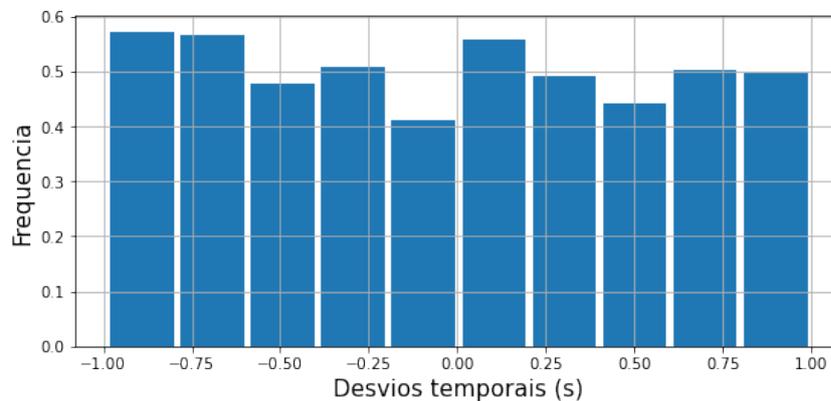
## 5.2 Preparação dos Dados

### 5.2.1 *Blending e Pseudodeblending*

O dado sísmico bruto da base Mobil AVO *Viking Graben* linha 12 no formato SEG-Y<sup>12</sup> foi lido, através do pacote Python Segyio, e carregado em um tensor 3D de dimensões  $1.001 \times 120 \times 1.500$ . Já os dados da base Volve Sintético, modelados por meio do pacote Devito, foram carregados em um tensor 3D de dimensões  $891 \times 100 \times 1.500$ .

Como os dados utilizados foram adquiridos ou modelados considerando uma aquisição sísmica convencional, o processo de *blending* foi realizado numericamente usando a Equação 1. Os operadores de *blending* foram construídos usando o pacote Python PyLops (RAVASI; VASCONCELOS, 2020) e considerando um tempo entre disparos de 3,0 s acrescido de um desvio temporal aleatório (*random time dither*) selecionado uniformemente no intervalo  $\Delta t_i \sim [-1,0, 1,0]$  s. A Figura 31 mostra o histograma da distribuição destes desvios temporais. Além deste, foram também utilizados *dither times* nos intervalos  $[-2,0, 2,0]$  s e  $[-0,5, 0,5]$  s. Em seguida, o dado *blended* foi submetido ao processo de *pseudodeblending* por meio da Equação 5. As Figuras 32 e 33 mostram sismogramas das bases de dados Volve sintético e Mobil AVO, respectivamente, antes e depois dos processos de *blending* e *pseudodeblending*.

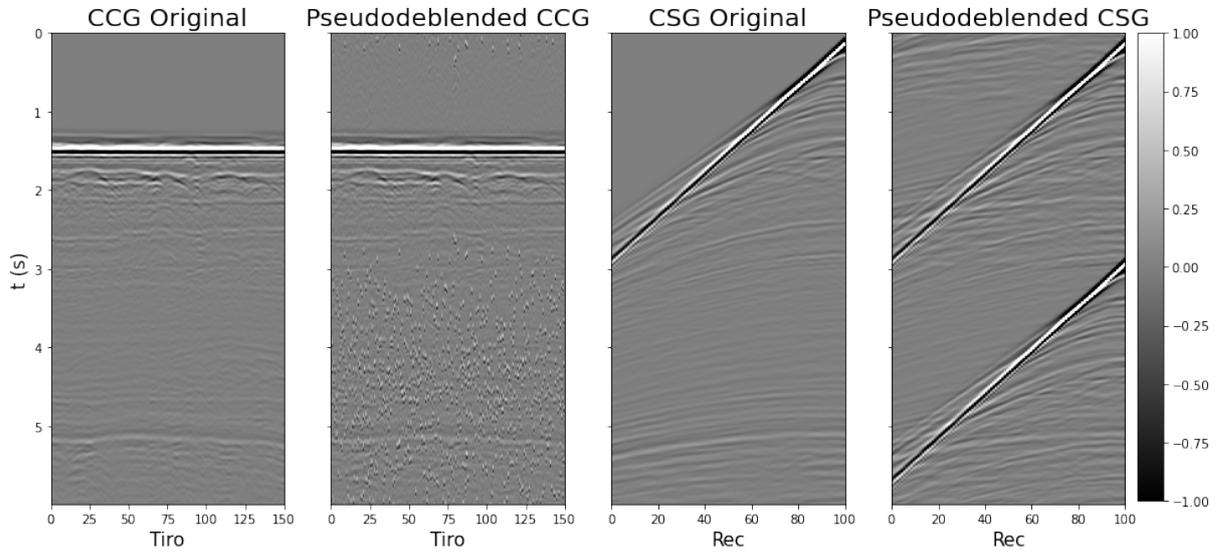
Figura 31 – Histograma dos desvios temporais usados para construção do operador de *blending* com *dither times* no intervalo  $[-1,0, 1,0]$  s



Fonte: O autor (2024).

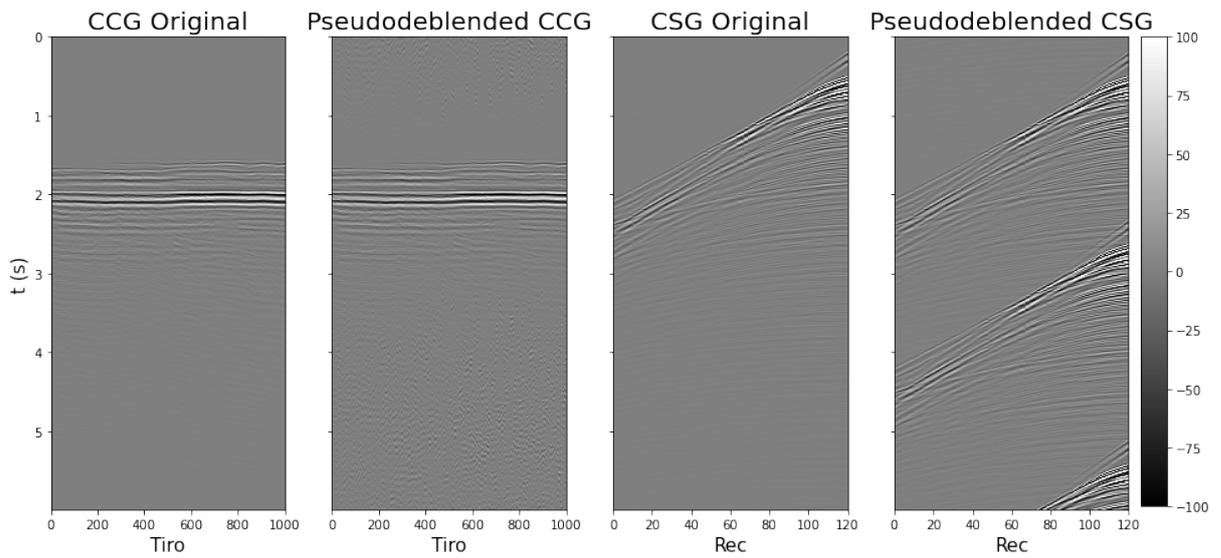
<sup>12</sup>Formato padrão para armazenamento de dados sísmicos desenvolvido pela SEG (Society of Exploration Geophysicists).

Figura 32 – Sismogramas da base de dados Volve sintético nos domínios no canal comum (CCG) e tiro comum (CSG) antes e depois dos processos de *blending* e *pseudodeblending*



Fonte: O autor (2024).

Figura 33 – Sismogramas da base de dados Mobil AVO nos domínios no canal comum (CCG) e tiro comum (CSG) antes e depois dos processos de *blending* e *pseudodeblending*



Fonte: O autor (2024).

### 5.2.2 Normalização dos Dados

Para treinamento das redes, os dados *pseudodeblended* e original foram normalizados para o intervalo  $[0,0, 1,0]$ , seguindo Sun et al. (2020b), por meio das equações:

$$\text{Dado\_pseudodeblended}_{\text{norm}} = \left( \frac{\text{Dado\_pseudodeblended}}{\text{Max}} + 1 \right) / 2 \quad (31)$$

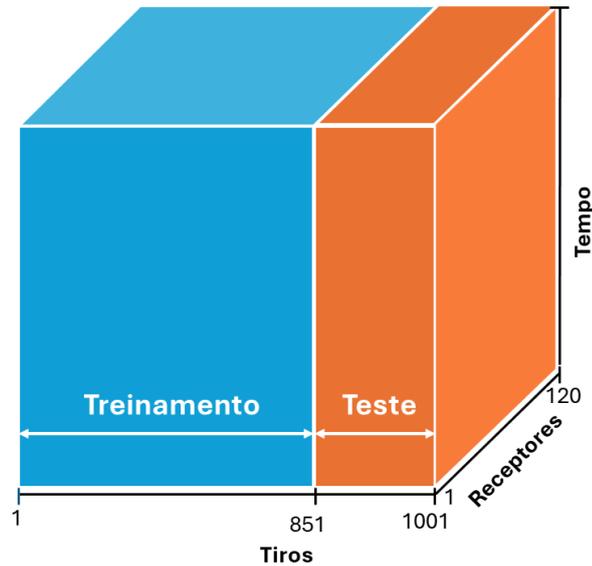
$$\text{Dado}_{\text{norm}} = \left( \frac{\text{Dado}}{\text{Max}} + 1 \right) / 2 \quad (32)$$

onde Max é o valor máximo entre os valores máximos absolutos dos dados *pseudodeblended* e original.

### 5.3 **Treinamento Supervisionado**

Para o treinamento das redes de modo supervisionado, os dados normalizados no domínio do canal comum foram separados em conjuntos de treinamento e teste, na proporção de 85% e 15%, respectivamente (Figura 34). Os dados do conjunto de treinamento da base Mobil AVO foram divididos em 10.080 *patches* de tamanho  $128 \times 128$ , sem sobreposição, dos quais 20% (2.016 *patches*) foram usados para validação durante o treinamento. Já os dados do conjunto de treinamento da base Volve Sintético foram divididos em 7.200 *patches* de tamanho  $128 \times 128$ , sem sobreposição e com a mesma proporção de 20% (1.440 *patches*) dos dados usados para validação. A Figura 35 mostra um exemplo de um par de *patches* usados no treinamento supervisionado.

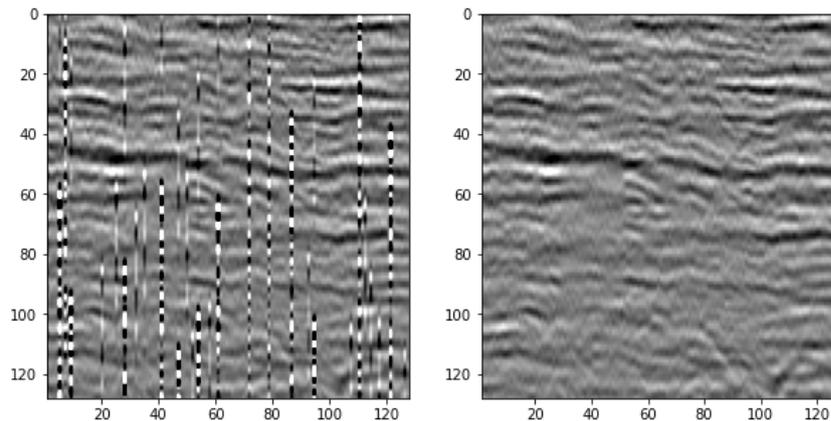
Figura 34 – Ilustração do volume de dados sísmicos Mobil AVO *Viking Graben* linha 12 separado em conjuntos de treinamento e teste



Fonte: O autor (2024).

O treinamento das redes neurais seguiu o fluxo mostrado na Figura 36. Nos experimentos envolvendo aprendizado supervisionado, os *patches* do dado *pseudodeblended* foram usados como dado de entrada e os *patches* do dado original como alvo.

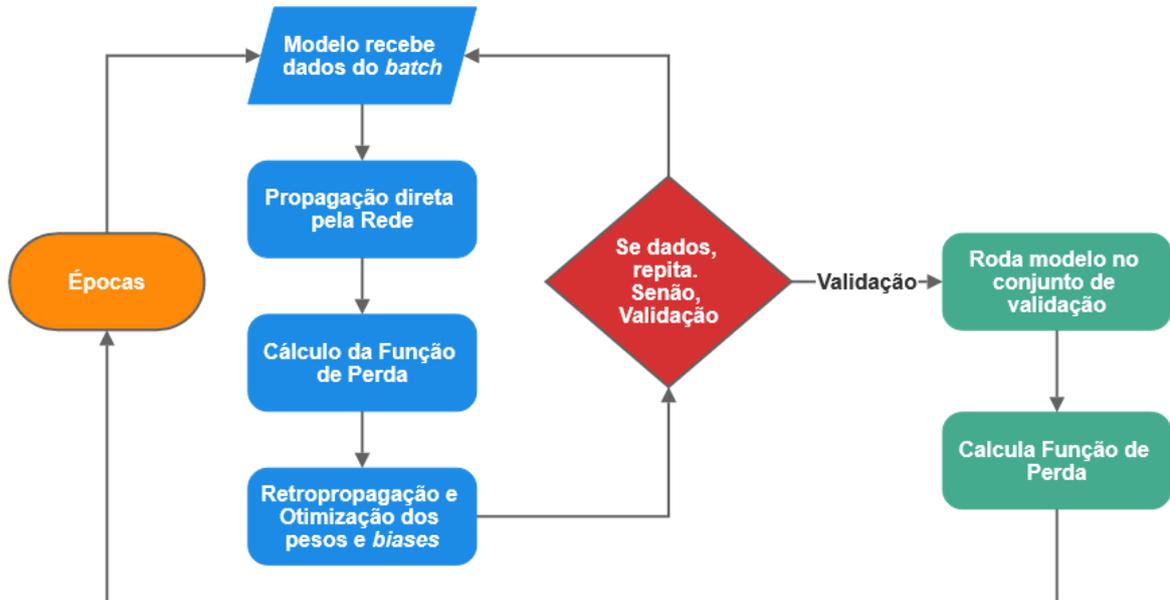
Figura 35 – Exemplo de um par de *patches* usado no treinamento supervisionado



Legenda: *Patches* usados como entrada (à esquerda) e alvo (à direita) para o treinamento supervisionado.

Fonte: O autor (2024).

Figura 36 – Fluxo de treinamento das redes neurais profundas



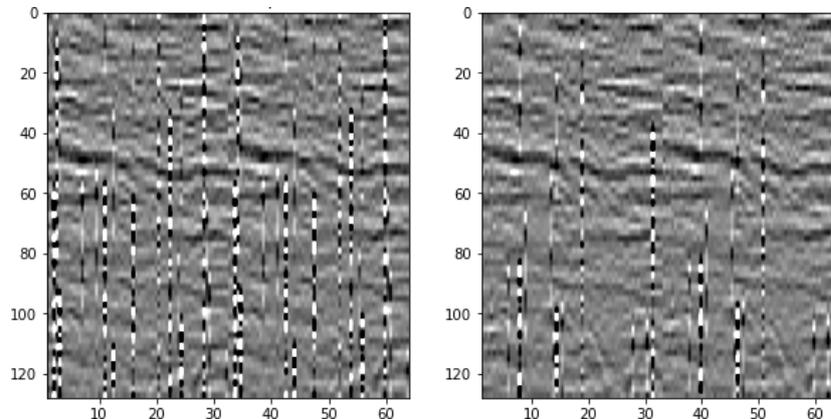
Fonte: O autor (2024).

#### 5.4 Treinamento Autossupervisionado Trace2Trace

Para o treinamento das redes de modo autossupervisionado utilizando o método Trace2Trace, apenas o dado *pseudodeblended* normalizado no domínio do receptor comum foi utilizado. Esse dado também foi separado em conjuntos de treinamento e teste, na proporção de 85% e 15%, respectivamente. Optamos por manter o mesmo procedimento de separação dos conjuntos de dados de treinamento e teste usado para o treinamento supervisionado, mesmo não sendo necessário para o treinamento autossupervisionado, com o intuito de fazer uma comparação o mais justa possível entre os métodos.

Inicialmente, os dados foram divididos em *patches* de tamanho  $128 \times 128$ , sem sobreposição, dos quais 20% foram usados para validação durante o treinamento. Em seguida, cada *patch* foi separado em traços pares e ímpares, dando origem a *patches* de tamanho  $128 \times 64$ . A Figura 37 mostra um exemplo de um par de *patches*, extraído da base de dados Mobil AVO, usado no treinamento autossupervisionado Trace2Trace.

Figura 37 – Exemplo de um par de *patches*, extraído da base de dados Mobil AVO, usado no treinamento autossupervisionado Trace2Trace



Fonte: O autor (2024).

## 5.5 Funções Objetivo

Foram utilizadas como função objetivo nos treinamentos das redes as funções Erro Quadrático Médio (*Mean Squared Error* - MSE) e Erro Médio Absoluto (*Mean Absolute Error* - MAE) dadas pelas equações (33) e (34), respectivamente:

$$\text{MSE}(\hat{\mathbf{y}}, \mathbf{y}) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (\hat{y}_{ij} - y_{ij})^2 \quad (33)$$

$$\text{MAE}(\hat{\mathbf{y}}, \mathbf{y}) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N |\hat{y}_{ij} - y_{ij}| \quad (34)$$

onde  $M$  e  $N$  são as dimensões dos *patches*,  $\hat{\mathbf{y}}$  representa o *patch deblended* predito pela rede e  $\mathbf{y}$  o *patch* usado como alvo no treinamento.

Além destas duas funções, foi utilizada também a função objetivo alternada representada pela Equação 24, dada pela soma de duas funções objetivo do mesmo tipo e que considera ambos os *patches* de treinamento como entrada e alvo simultaneamente. Neste trabalho, utilizou-se apenas a função MAE nessa composição. Por esse motivo, essa função objetivo será denominada no texto como função objetivo alternada L1 (Equação 35).

$$L_{ALT\_L1}(\hat{\mathbf{y}}_1, \mathbf{y}_1, \hat{\mathbf{y}}_2, \mathbf{y}_2) = \text{MAE}(\hat{\mathbf{y}}_1, \mathbf{y}_2) + \text{MAE}(\hat{\mathbf{y}}_2, \mathbf{y}_1) \quad (35)$$

## 5.6 Parametrização do Treinamento

Em todos os treinamentos realizados, utilizou-se o otimizador ADAM, com *learning rate* de 0,001, *batch size* de 64 *patches*, 100 épocas de treinamento e 50 épocas para *early stopping*. *Early stopping* é a técnica de regularização mais utilizada em aprendizado profundo para prevenir *overfitting* e melhorar o desempenho de generalização de um modelo (GOODFELLOW; BENGIO; COURVILLE, 2016). Ela consiste em monitorar o desempenho do modelo em um conjunto de validação durante o treinamento e interromper o processo quando não houver melhora durante um determinado número de épocas seguidas. Isso significa que após 50 épocas sem detectar redução no valor da função objetivo do modelo, o treinamento é interrompido e o modelo com o menor valor da função objetivo é selecionado como o modelo treinado. Após o treinamento, as redes treinadas são armazenadas em formato binário hdf5.

## 5.7 Etapa de Teste

Na etapa de teste, independente do modo de treinamento, as redes treinadas foram testadas usando o conjunto de dados de teste, composto por 120 sismogramas *pseudodeblended* no domínio do canal comum com tamanho  $1.500 \times 150$ , que não foram apresentados às redes durante o treinamento. Para o processo de predição, os sismogramas não foram divididos em *patches*.

O dado *deblended* resultante passa, então, pelo processo inverso da normalização, por meio da Equação 36, antes de ser comparado com o dado original e para cálculo das métricas de avaliação.

$$\text{Dado\_deblended}_{\text{desnorm}} = (\text{Dado\_deblended} \times 2 - 1) \times \text{Max} \quad (36)$$

## 5.8 *Deblending* por Inversão Esparsa - Implementação

O método de *deblending* por inversão esparsa foi implementado por meio do pacote Python PyLops (RAVASI; VASCONCELOS, 2020) usando a transformada de Fourier janelada 2D (WFT2D) e o algoritmo FISTA.

Para a transformada WFT2D, foram usadas janelas de tamanho  $20 \times 100$  com sobreposição de  $10 \times 50$ , onde o primeiro valor se refere ao eixo espacial e o segundo ao temporal.

Para execução do algoritmo FISTA, foi utilizado um total de 200 iterações, bem como o parâmetro de regularização adaptativo  $\lambda_k = ((6/5)e^{-0,05k} + 6)\lambda_0$ , onde  $k$  é o número da iteração e  $\lambda_0 = 30$ , conforme sugerido por Luiken, Ravasi e Birnie (2024). Segundo os autores, o uso de um parâmetro de regularização adaptativo e decrescente tem superado os resultados de inversão obtidos com  $\lambda$  fixo.

O método de *deblending* por inversão esparsa foi executado usando apenas os dados que compõem o conjunto de dados de teste, ou seja, 120 sismogramas *pseudodeblended* no domínio do receptor comum com tamanho  $1.500 \times 150$ .

## 5.9 Métricas

### 5.9.1 Razão Sinal-Ruído (SNR)

A Razão Sinal-Ruído (*Signal to Noise Ratio* - SNR) é uma métrica comum para quantificar a perda ou ganho de qualidade de uma imagem devido à adição ou atenuação de ruído por alguma etapa de processamento. A SNR é definida pela razão entre a energia média do sinal e a energia média do ruído e, usualmente, é representada em escala logarítmica na unidade decibel (dB). A SNR pode ser expressada como:

$$\text{SNR}(\hat{\mathbf{y}}, \mathbf{y}) = 20 \cdot \log_{10} \frac{\|\mathbf{y}\|_F}{\|\mathbf{y} - \hat{\mathbf{y}}\|_F} \quad (37)$$

onde  $\mathbf{y}$  representa o sismograma original sem efeito de interferência e  $\hat{\mathbf{y}}$  representa o dado *deblended* e  $\|\cdot\|_F$  representa a norma de Frobenius<sup>13</sup> (LIESEN; MEHRMANN, 2015).

### 5.9.2 Raiz do Erro Quadrático Médio Normalizado (NRMSE)

O Erro Quadrático Médio (*Mean Squared Error* - MSE) é o estimador mais comum da medida de qualidade de uma imagem. É uma métrica de referência completa e os valores mais próximos de zero são melhores (SARA; AKTER; UDDIN, 2019).

<sup>13</sup>A norma de Frobenius é definida como  $\|A\|_F = (\sum_{i=1}^n \sum_{j=1}^m |a_{ij}|^2)^{1/2}$ .

O MSE entre o sismograma *deblended* ( $\hat{\mathbf{y}}$ ) e o sismograma original sem efeito de interferência ( $\mathbf{y}$ ) é definido como:

$$\text{MSE}(\hat{\mathbf{y}}, \mathbf{y}) = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (\hat{y}_{ij} - y_{ij})^2 \quad (38)$$

onde  $M$  e  $N$  são as dimensões dos sismogramas.

A Raiz do Erro Quadrático Médio Normalizado (*Normalized Root Mean-Squared Error* - NRMSE) é calculada a partir do MSE através da equação:

$$\text{NRMSE}(\hat{\mathbf{y}}, \mathbf{y}) = \frac{\sqrt{MN} \sqrt{\text{MSE}}}{\sqrt{\sum_{i=1}^M \sum_{j=1}^N y_{ij}^2}} = \frac{\|\hat{\mathbf{y}} - \mathbf{y}\|_F}{\|\mathbf{y}\|_F} \quad (39)$$

onde  $\|\cdot\|_F$  representa a norma de Frobenius. A normalização facilita a comparação entre bases de dados e modelos com diferentes escalas. Quanto mais próximo o NRSME for de zero, mais próximo o dado *deblended*  $\hat{\mathbf{y}}$  estará do dado original  $\mathbf{y}$ , e, portanto, melhor é o resultado do processo de *deblending*.

## 5.10 Hardware

Os experimentos foram realizados em uma *workstation* HP Z8 equipada com 32 CPUs Intel Xeon Gold 6244 3,6 GHz e uma GPU Nvidia Quadro P6000. Esta GPU apresenta 3.840 núcleos CUDA e uma memória de vídeo de 24GB GDDR5X.

A GPU utilizada atendeu aos propósitos dos experimentos, uma vez que apresenta o mínimo de memória de vídeo necessária para a realização dos experimentos executados, tendo em vista as arquiteturas da rede utilizadas e, principalmente, o tamanho dos *batches*.

## 5.11 Software

Todos os experimentos computacionais foram programados em Python 3, usando a distribuição Anaconda e a interface Jupyter Notebook, rodando no sistema operacional Linux CentOS 7. Juntamente com o Python foram utilizados os seguintes pacotes e bibliotecas:

- Numpy (NUMPY, 2009) - Pacote fundamental para a computação científica com

Python. Ele contém entre outras coisas: matrizes N-dimensionais, recursos úteis de álgebra linear, transformada de Fourier, números aleatórios, entre outros;

- Scipy (SCIPY, 2020) - fornece algoritmos para otimização, integração, interpolação, problemas de autovalores, equações algébricas, equações diferenciais, estatísticas e muitas outras classes de problemas;
- Segyio (EQUINOR, 2023) - Pacote gratuito desenvolvido pela empresa Equinor para leitura e escrita de dados no formato SEG-Y;
- PyLops (RAVASI; VASCONCELOS, 2020) - é um pacote Python de código aberto focada em fornecer uma biblioteca de operadores lineares e cálculos relacionados, sem uso explícito de matrizes. É inspirado no icônico projeto MATLAB Spot – A Linear-Operator Toolbox. Operadores lineares e problemas inversos estão no centro de muitos dos algoritmos mais utilizados em processamento de sinais, processamento de imagens e sensoriamento remoto. Para problemas de pequena escala, as matrizes podem ser explicitamente computadas e manipuladas com bibliotecas científicas numéricas Python, como NumPy e SciPy. Problemas de grande escala geralmente apresentam matrizes de tamanho proibitivo, mas cujas operações podem ser descritas por funções simples. Os operadores PyLops exploram isso para representar um operador linear não como uma matriz de números, mas por funções que descrevem produtos de vetores e matrizes nos modos direto e adjunto. Além disso, muitos métodos iterativos são projetados para não depender dos elementos da matriz, apenas desses produtos de vetor e matriz. PyLops oferece esses solucionadores para muitos tipos diferentes de problemas, em particular mínimos quadrados e inversões que promovem esparsidade;
- Devito (LOUBOUTIN et al., 2019; LUPORINI et al., 2020) - é um pacote Python de código aberto para modelagem sísmica por diferenças finitas a partir de definições de problemas simbólicos de alto nível. Devito baseia-se no SymPy e emprega geração automatizada de código e compilação *just-in-time* para executar *kernels* computacionais otimizados em diversas plataformas, incluindo CPUs, GPUs e *clusters* dos

mesmos;

- Scikit Image (SCIKIT-IMAGE, 2024) - é uma coleção de algoritmos para processamento de imagens. Responsável pela geração das métricas dos resultados;
- Keras (KERAS, 2019) - API de redes neurais de alto nível, escrita em Python e capaz de rodar sobre TensorFlow, CNTK ou Theano;
- TensorFlow (TENSORFLOW, 2024) - Plataforma de código aberto de ponta a ponta para aprendizado de máquina.

## 6 RESULTADOS E DISCUSSÃO

### 6.1 Validação do Método

#### 6.1.1 Volve Sintético

A Tabela 1 apresenta a comparação entre os resultados alcançados sobre o conjunto de teste em termos das médias e desvios-padrão das métricas SNR e NRMSE para todos os métodos avaliados, além do *pseudodeblending*, para a base de dados Volve Sintético. Para esses experimentos os dados foram submetidos ao processo de *blending* numérico usando *dither times* no intervalo  $[-1,0, 1,0]$  s. Os valores médios e desvios-padrão foram calculados a partir das métricas obtidas em cinco repetições do treinamento das redes usando o mesmo conjunto de dados de treinamento. Os valores das métricas para o dado *pseudodeblended* mostram que o nível do ruído de interferência é maior que o do sinal nesse dado. Logo, espera-se que qualquer método de *deblending* proposto apresente métricas melhores que as do *pseudodeblending*, já que este não remove o ruído de *blending*, conforme discutido no Capítulo 1.

Tabela 1 – Comparação entre as métricas de avaliação dos resultados obtidas para cada método de *deblending* e o *pseudodeblending* para a base de dados Volve Sintético. As melhores métricas obtidas para cada método são destacadas em negrito. Os segundos melhores resultados são destacados em itálico.

Método	Arquitetura	Função Objetivo	SNR (dB)	NRMSE	SNR (dB) Pós-processamento	NRMSE
Deblending Autosupervisionado Trace2Trace	U-NET	MSE	15,604 (2,060)	0,170 (0,038)	18,316 (2,132)	0,125 (0,029)
		MAE	10,741 (2,594)	0,302 (0,074)	13,444 (2,763)	0,222 (0,057)
		ALTERNADA L1	10,631 (2,726)	0,307 (0,081)	13,411 (2,747)	0,223 (0,060)
	NDCNN	MSE	17,897 (1,737)	0,130 (0,028)	20,700 (1,622)	0,094 (0,019)
		MAE	22,928 (0,231)	0,071 (0,002)	25,349 (0,229)	0,054 (0,001)
		ALTERNADA L1	23,244 (0,171)	0,069 (0,001)	25,553 (0,254)	0,053 (0,002)
	RES-NDCNN	MSE	20,049 (0,467)	0,099 (0,005)	22,585 (0,686)	0,075 (0,006)
		MAE	24,312 (0,285)	0,061 (0,002)	<i>26,879 (0,249)</i>	<i>0,045 (0,001)</i>
		ALTERNADA L1	24,219 (0,256)	0,062 (0,002)	<b>27,156 (0,255)</b>	<b>0,044 (0,001)</b>
Deblending Supervisionado	U-NET	MSE	15,415 (2,783)	0,179 (0,059)	-	-
		MAE	3,353 (0,579)	0,681 (0,044)	-	-
	NDCNN	MSE	22,394 (0,370)	0,076 (0,003)	-	-
		MAE	<i>23,153 (0,274)</i>	<i>0,070 (0,002)</i>	-	-
	RES-NDCNN	MSE	21,469 (2,587)	0,089 (0,028)	-	-
		MAE	<b>25,475 (0,546)</b>	<b>0,053 (0,004)</b>	-	-
Inversão Esparsa	-	-	<b>37,224</b>	<b>0,014</b>	-	-
Pseudodeblending	-	-	-0,866	1,105	-	-

Fonte: O autor (2024).

Todos os métodos avaliados apresentaram métricas superiores às do *pseudodeblending*, atestando que, em todos os casos, o ruído de *blending* foi atenuado. No entanto, os desempenhos foram bastante diferentes, variando com a arquitetura de rede utilizada, a estratégia de treinamento, assim como a função objetivo.

O melhor resultado do método de *deblending* autossupervisionado foi obtido com a combinação da arquitetura RES-NDCNN e o uso da função objetivo alternada L1, além do procedimento de pós-processamento. Essa combinação resultou em um desempenho intermediário (27,156 dB) entre o método de *deblending* supervisionado (25,475 dB) e o *deblending* por inversão (37,224 dB).

O procedimento de pós-processamento, dado pela Equação 25, foi executado através do algoritmo LSQR implementado por meio do pacote PyLops. Cinco iterações foram suficientes para a convergência da solução, o que corroborou a informação reportada por Luiken, Ravasi e Birnie (2024).

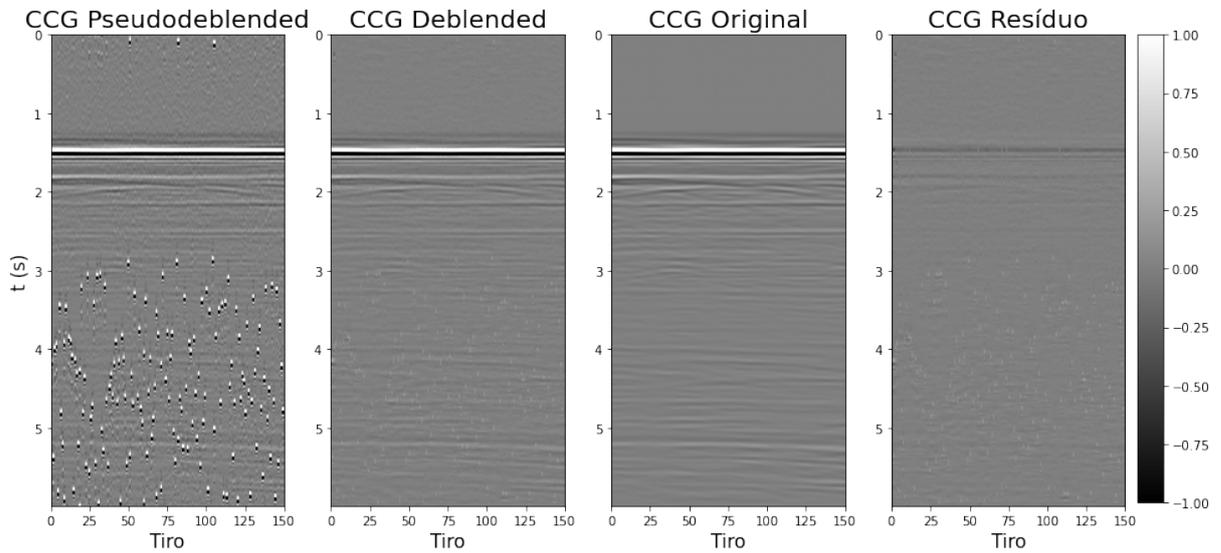
Dentre as arquiteturas experimentadas, a NDCNN e sua variação RES-NDCNN apresentaram resultados superiores à U-NET em todos os experimentos, independentemente da função objetivo e da estratégia de aprendizado.

A conexão residual global utilizada na arquitetura RES-NDCNN contribuiu para uma melhora significativa do desempenho da rede, entre 1,0 dB e 2,0 dB na razão sinal-ruído, em comparação com a versão original da NDCNN. Adicionalmente, o procedimento de pós-processamento, utilizado juntamente com o método de *deblending* autossupervisionado Trace2Trace, contribuiu para um ganho de aproximadamente 3,0 dB na SNR. Esse ganho foi fundamental para que o método autossupervisionado proposto superasse o desempenho obtido com o método supervisionado. Isso mostra que métodos de *deblending* envolvendo aprendizado autossupervisionado podem se beneficiar do uso conjunto com algoritmos de inversão, levando a uma solução híbrida que pode superar a necessidade de dados limpos para treinamento.

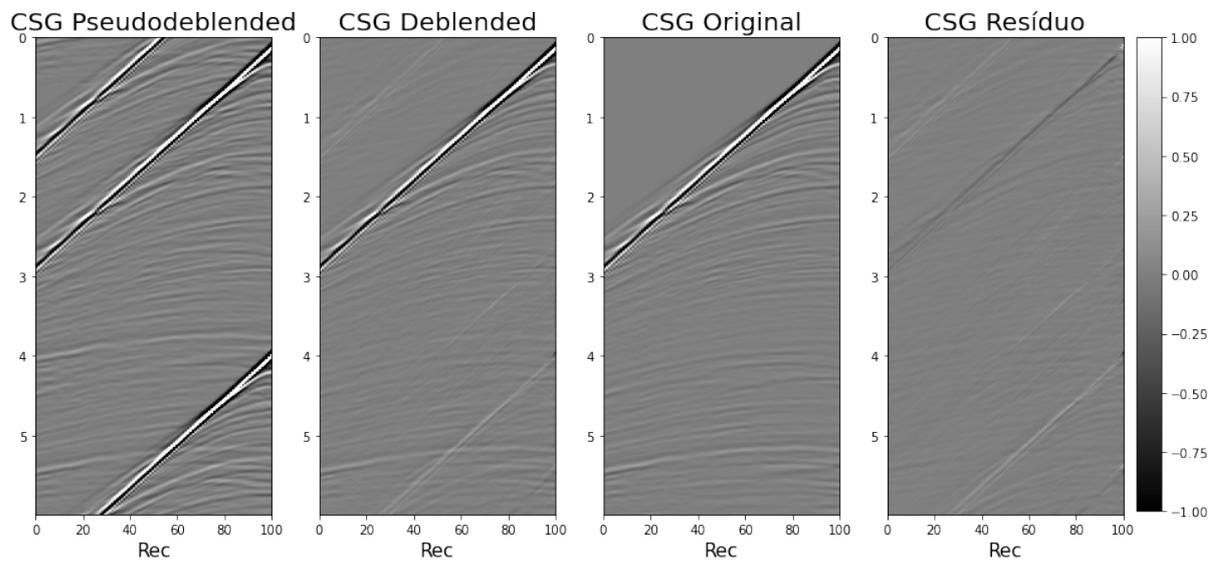
As Figuras 38, 39, e 40 mostram exemplos de sismogramas, nos domínios do canal comum (CCG) e do tiro comum (CSG), resultantes do processo de *deblending* autossupervisionado Trace2Trace, usando as arquiteturas RES-NDCNN e U-NET, além do

*deblending* por inversão. Além disso, mostram também uma comparação com o dado de entrada (*pseudodeblended*) e o dado original, sem ruído de interferência.

Figura 38 – Resultado do *deblending* autossupervisionado Trace2Trace usando a arquitetura U-NET e treinada com a função objetivo alternada L1



(a)

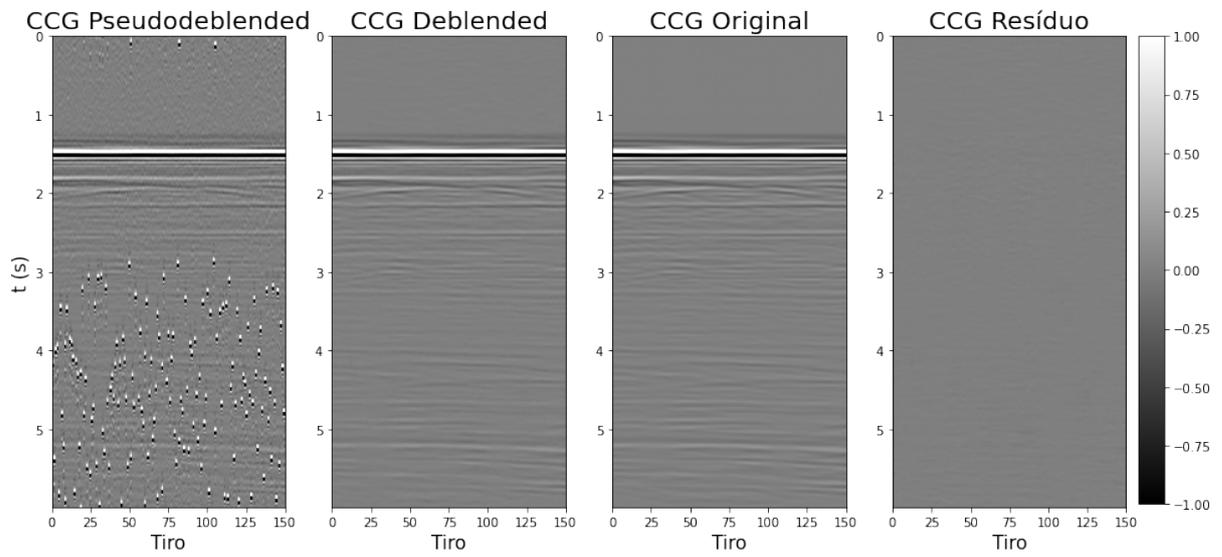


(b)

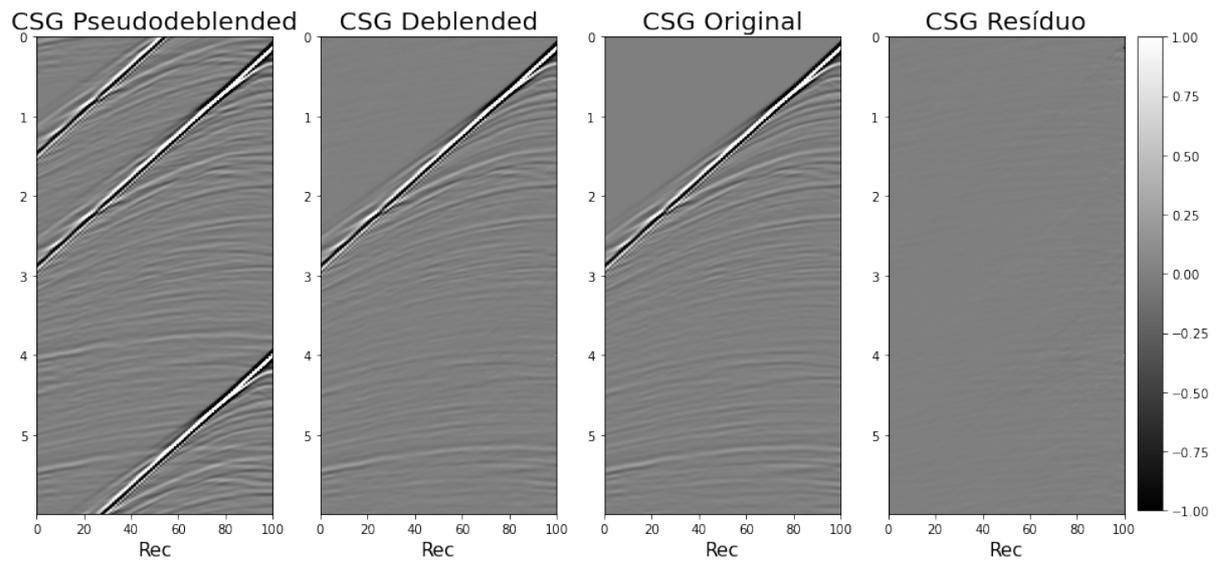
Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

Figura 39 – Resultado do *deblending* autossupervisionado Trace2Trace usando a arquitetura RES-NDCNN e treinada com a função objetivo alternada L1



(a)

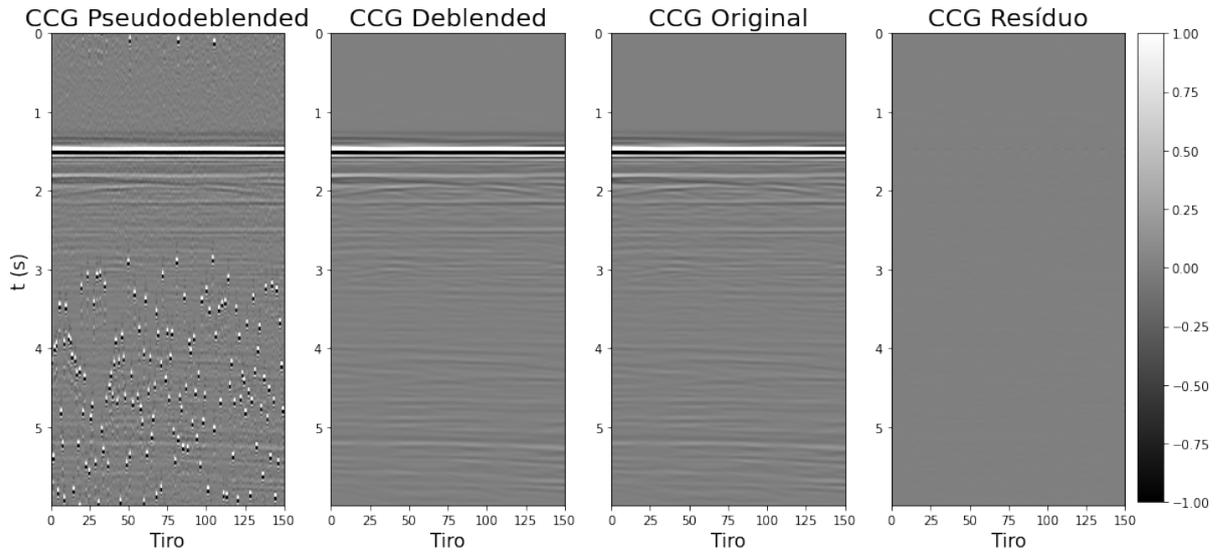


(b)

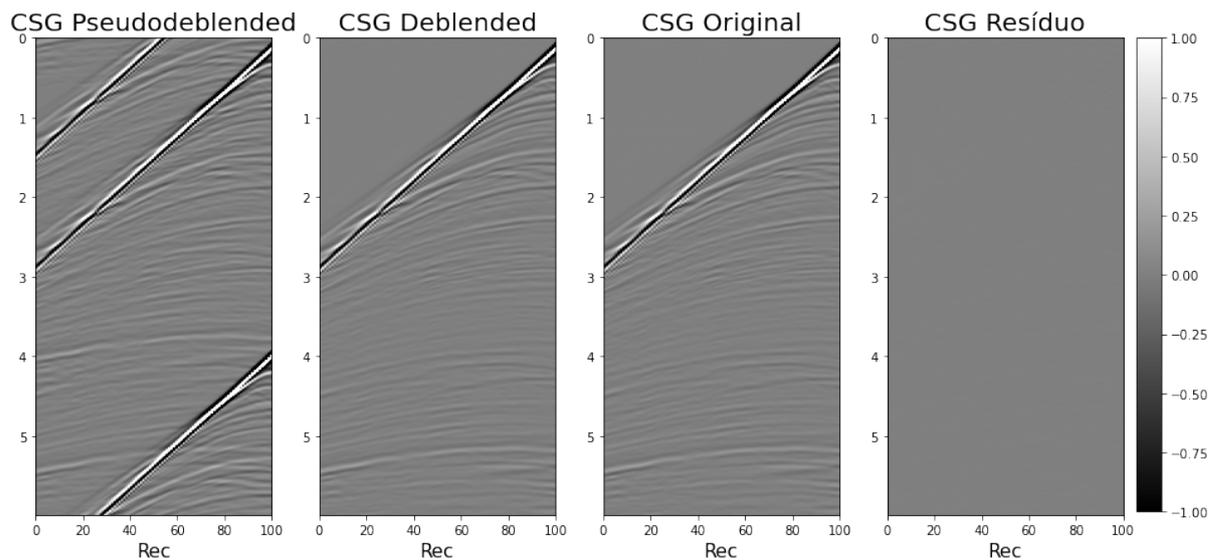
Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

Figura 40 – Resultado do *deblending* pelo método de inversão esparsa



(a)



(b)

Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

Visualmente, o resultado do *deblending* autossupervisionado Trace2Trace obtido pela rede RES-NDCNN é muito próximo do obtido pelo *deblending* por inversão, apesar da diferença de SNR médio de quase 10,0 dB. Ambos resultados mostram um baixo nível de resíduos de interferência, sobretudo na porção inferior dos sismogramas, onde o sinal mais tênue se sobrepõe ao ruído de interferência de maior amplitude. Já a rede U-NET, apesar de atenuar fortemente o ruído de *blending*, ainda apresenta marcas visíveis de interferência,

tanto na região superior quanto inferior dos sismogramas. Comparando-se os painéis que mostram a diferença entre o dado original e *deblended*, observa-se claramente um nível de resíduo mais alto nos resultados obtidos pela arquitetura U-NET, tanto na janela em que há apenas sinal, quanto nas regiões onde há a presença do ruído de *blending*. Além disso, existe um artefato que parece repetir o ruído de interferência e que atinge porções do sismograma que não eram originalmente afetadas. Estes artefatos são observados mais claramente no domínio do tiro comum (CSG), entre os tempos 3,0 s e 6,0 s.

### 6.1.2 Mobil AVO *Viking Graben*

A Tabela 2 apresenta a comparação entre os resultados obtidos sobre o conjunto de teste em termos das médias e desvios-padrão das métricas SNR e NRMSE para todos os métodos avaliados, além do *pseudodeblending*, para a base de dados reais Mobil AVO. Os valores médios e desvios-padrão foram calculados a partir das métricas obtidas em cinco repetições do treinamento das redes usando o mesmo conjunto de dados de treinamento.

Tabela 2 – Comparação entre as métricas de avaliação dos resultados obtidas para cada método de *deblending* e o *pseudodeblending* para a base de dados Mobil AVO. As melhores métricas obtidas para cada método são destacadas em negrito. Os segundos melhores resultados são destacados em itálico.

Método	Arquitetura	Função objetivo	SNR (dB)	NRMSE	SNR (dB) Pós-processamento	NRMSE
Deblending Autosupervisionado Trace2Trace	U-NET	MSE	14,818 (0,547)	0,182 (0,011)	17,770 (0,382)	0,129 (0,006)
		MAE	12,292 (1,404)	0,246 (0,035)	14,795 (1,538)	0,185 (0,029)
		ALTERNADA L1	10,111 (0,998)	0,314 (0,037)	12,628 (1,230)	0,236 (0,035)
	NDCNN	MSE	12,755 (0,215)	0,230 (0,006)	15,772 (0,182)	0,163 (0,003)
		MAE	17,429 (0,157)	0,134 (0,002)	20,204 (0,118)	0,098 (0,001)
		ALTERNADA L1	18,773 (0,238)	0,115 (0,003)	<i>21,469 (0,242)</i>	<i>0,085 (0,002)</i>
	RES-NDCNN	MSE	16,220 (0,645)	0,155 (0,012)	18,961 (0,549)	0,113 (0,007)
		MAE	17,643 (0,088)	0,131 (0,001)	20,425 (0,070)	0,095 (0,001)
		ALTERNADA L1	19,162 (0,137)	0,110 (0,002)	<b>21,905 (0,146)</b>	<b>0,080 (0,001)</b>
Deblending Supervisionado	U-NET	MSE	17,219 (1,372)	0,139 (0,023)	-	-
		MAE	9,054 (0,478)	0,353 (0,019)	-	-
	NDCNN	MSE	23,236 (0,257)	0,069 (0,002)	-	-
		MAE	<i>24,285 (0,189)</i>	<i>0,061 (0,001)</i>	-	-
	RES-NDCNN	MSE	20,981 (2,609)	0,094 (0,033)	-	-
		MAE	<b>24,577 (0,102)</b>	<b>0,059 (0,001)</b>	-	-
Inversão Esparsa	-	-	<b>23,153</b>	<b>0,070</b>	-	-
Pseudodeblending	-	-	-0,634	1,076	-	-

Fonte: O autor (2024).

Analogamente ao discutido na seção anterior, os desempenhos foram bastante dife-

rentes, variando com a arquitetura de rede utilizada, a estratégia de treinamento, assim como a função objetivo.

O melhor resultado do método de *deblending* autossupervisionado foi também obtido com a combinação da arquitetura RES-NDCNN e o uso da função objetivo alternada L1, além do procedimento de pós-processamento. O que demonstra a consistência do método de solução proposto. No entanto, para essa base de dados composta por dados reais, essa combinação apresentou resultado inferior (21,905 dB) tanto ao *deblending* por inversão (23,153 dB) quanto ao *deblending* supervisionado (24,577 dB). Vale destacar que, apesar das diferenças, para essa base de dados, os resultados dos três métodos são mais próximos entre si do que os obtidos com a base de dados sintéticos (Volve Sintético), com energia média do sinal mais de 100 vezes maior que a do ruído de interferência residual. Além disso, a natureza autossupervisionada do método proposto, utilizando apenas dados que sofreram interferência para treinamento, destaca a sua aplicabilidade em situações reais onde os dados limpos, sem efeito de interferência, não estão disponíveis.

É importante ressaltar também que os resultados obtidos com o método de inversão esparsa dependem dos parâmetros utilizados para o cálculo da transformada de Fourier janelada 2D, bem como dos parâmetros relacionados ao algoritmo FISTA. Neste trabalho, os parâmetros escolhidos seguiram as sugestões feitas por Luiken, Ravasi e Birnie (2024). No entanto, de acordo com Aujol et al. (2024), estes parâmetros são difíceis de estimar em muitos casos práticos. Portanto, a aplicação em novos dados pode necessitar de ajuste manual desses parâmetros, o que representa um desafio adicional ao uso desse método.

Novamente, a arquitetura RES-NDCNN apresentou resultados superiores à U-NET em todos os experimentos realizados.

A função objetivo alternada L1 contribuiu para uma melhora de desempenho das redes NDCNN e RES-NDCNN, treinadas de modo autossupervisionado, da ordem de 1,5 dB na razão sinal-ruído. Esse ganho foi muito mais relevante para essa base de dados do que o observado na base de dados sintéticos.

Os ganhos obtidos com a conexão residual global, utilizada na arquitetura RES-NDCNN, bem como o procedimento de pós-processamento, utilizado juntamente com

o método de *deblending* autossupervisionado proposto, se mantiveram nos experimentos realizados com essa base de dados.

Os resultados obtidos superam ou são comparáveis com os reportados na literatura usando outras técnicas e arquiteturas de rede em diferentes bases de dados, considerando o processo de *deblending* usando dados reais submetidos ao *blending* numérico. Luiken, Ravasi e Birnie (2024) utilizaram a mesma base de dados (Mobil AVO *Viking Graben* linha 12) em experimentos de *deblending* envolvendo treinamento autossupervisionado em conjunto com o algoritmo de inversão PnP (*Plug-and-Play*) e reportaram um resultado em termos de razão sinal-ruído de 23,0 dB. Neste método, a rede foi treinada de modo autossupervisionado a cada iteração do algoritmo de inversão. Esse resultado demonstra o quanto o desempenho de métodos de *deblending* autossupervisionados pode ser melhorado através do uso conjunto com algoritmos de inversão, levando a resultados similares ou melhores do que os obtidos com métodos supervisionados ou métodos de inversão convencionais.

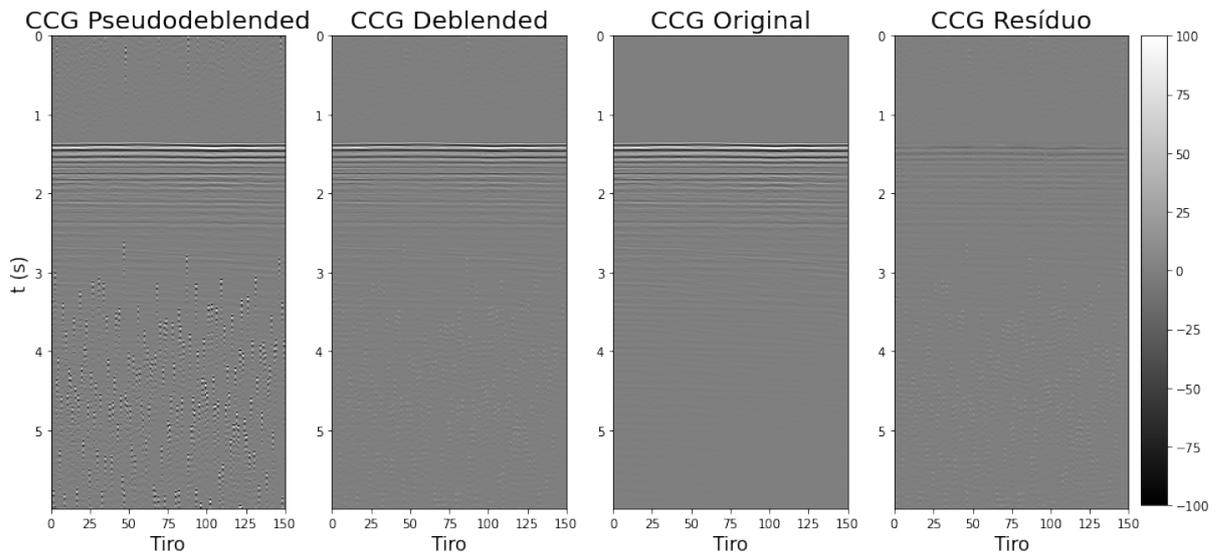
As Figuras 41, 42, e 43 mostram exemplos de sismogramas, nos domínios do canal comum (CCG) e do tiro comum (CSG), resultantes do processo de *deblending* autossupervisionado Trace2Trace, usando as arquiteturas RES-NDCNN e U-NET, além do *deblending* por inversão esparsa. Além disso, mostram também uma comparação com o dado de entrada (*pseudodeblended*) e o dado original, sem ruído de interferência.

Qualitativamente, os resultados mostram basicamente os mesmos aspectos já observados na base de dados Volve Sintético. O resultado do *deblending* autossupervisionado Trace2Trace obtido pela rede RES-NDCNN é ainda mais próximo do obtido pelo *deblending* por inversão, com uma diferença de SNR médio de cerca de 1,0 dB. Novamente, ambos resultados mostram um baixo nível de resíduos de interferência.

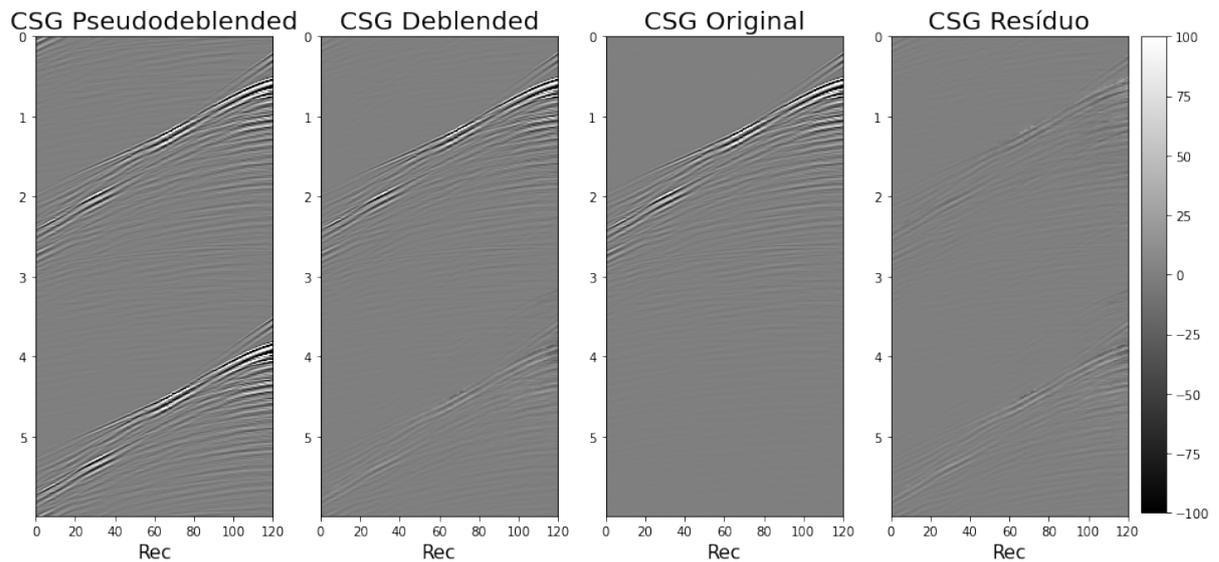
Por outro lado, os resultados obtidos com a rede U-NET, mais uma vez apresentaram marcas visíveis de interferência em todas as porções dos sismogramas, apesar de o resultado geral ser visualmente melhor do que o obtido com a base de dados Volve Sintético. Além disso, novamente, observa-se a presença de artefatos que parecem repetir o ruído de interferência e que atingem porções do sismograma que não eram originalmente afetadas.

Estes artefatos são observados mais claramente no domínio do tiro comum (CSG), entre os tempos 3,0 s e 5,0 s, e são mais sutis do que os observados nos resultados da base de dados Volve Sintético.

Figura 41 – Resultado do *deblending* autossupervisionado Trace2Trace usando a arquitetura U-NET e treinada com a função objetivo alternada L1



(a)

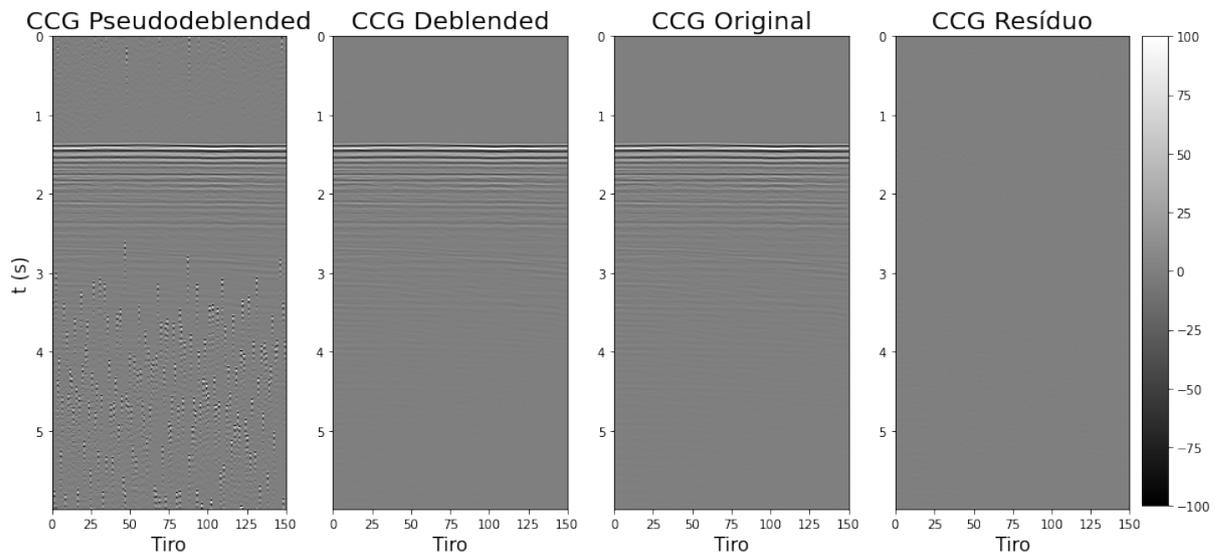


(b)

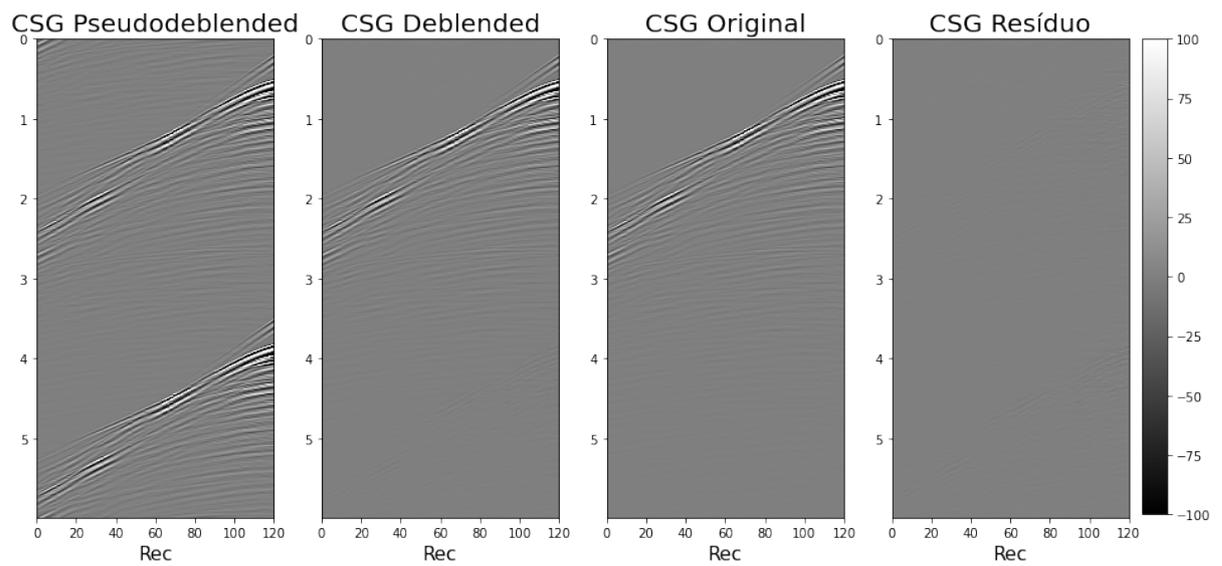
Fonte: O autor (2024).

Legenda: (a) - CCG e (b) - CSG.

Figura 42 – Resultado do *deblending* autossupervisionado Trace2Trace usando a arquitetura RES-NDCNN e treinada com a função objetivo alternada L1



(a)

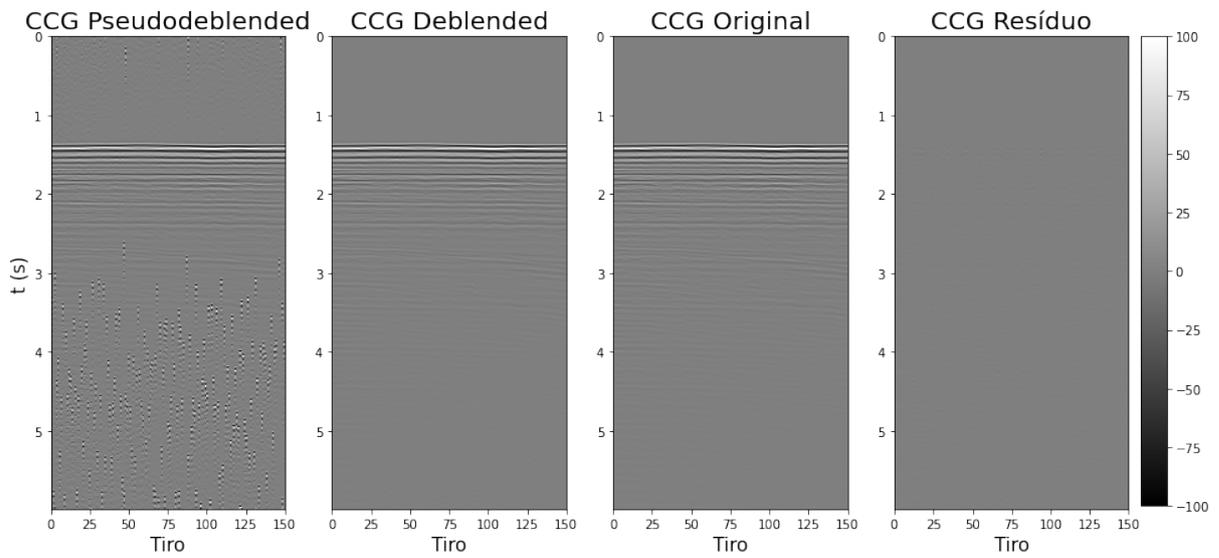


(b)

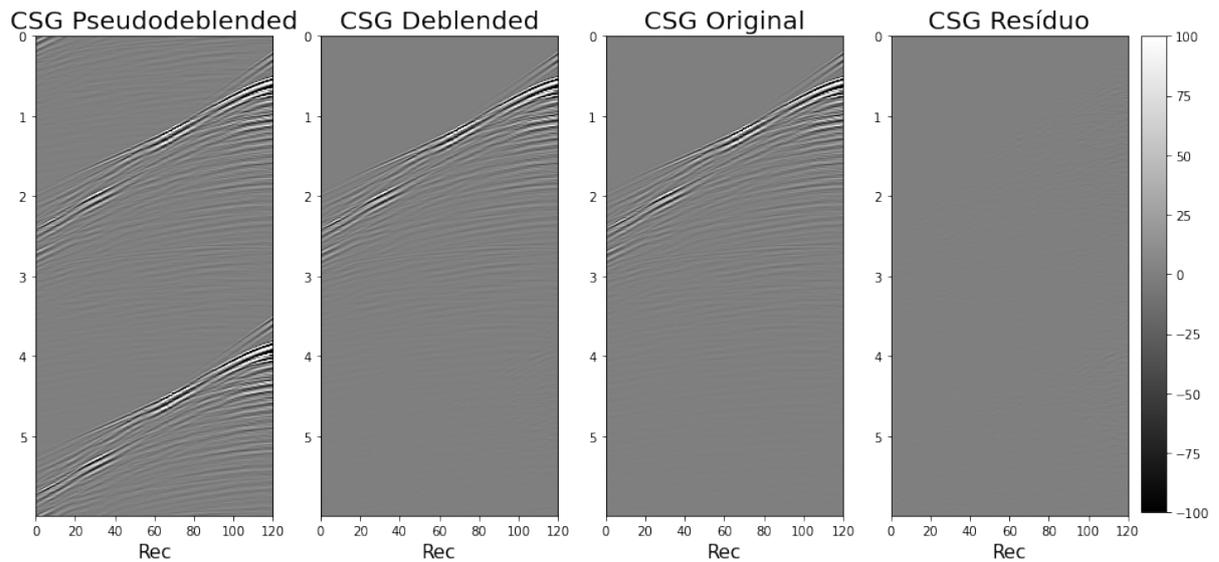
Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

Figura 43 – Resultado do *deblending* pelo método de inversão esparsa



(a)



(b)

Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

Daqui em diante, o termo *Deblending* T2T será utilizado para se referir ao método de *deblending* autossupervisionado Trace2Trace usando a arquitetura de rede que apresentou os melhores resultados nas duas bases de dados, RES-NDCNN, treinada com a função objetivo alternada L1 e com aplicação posterior da etapa de pós-processamento.

## 6.2 Análise do Efeito do *Dither Time*

A fim de analisar o efeito do intervalo de *dither time* sobre o desempenho do método de *deblending* proposto, foram executados experimentos utilizando dados da base Mobil AVO submetidos ao processo de *blending* numérico com diferentes intervalos de *dither time*. A Tabela 3 mostra os resultados obtidos em termos das médias e desvios-padrão das métricas SNR e NRMSE em cinco execuções do treinamento, além dos resultados obtidos com o método de *deblending* por inversão esparsa.

Os resultados mostram que ambos os métodos são sensíveis ao intervalo de *dither time*. Observa-se uma tendência de melhora do desempenho do *deblending* obtido com o método *Deblending T2T* com a redução do intervalo de *dither time*. Além disso, para *dither times* no intervalo  $[-0,5, 0,5]$  s, o método de *Deblending T2T* alcançou um resultado de 22,130 dB de SNR médio e superou o resultado obtido pelo *deblending* por inversão esparsa (21,354 dB). Por outro lado, o método de *deblending* por inversão parece perder desempenho com a redução do intervalo de *dither time*.

Tabela 3 – Comparação entre as métricas de avaliação dos resultados obtidas para diferentes intervalos de *dither time* para os métodos *Deblending Trace2Trace* e Inversão Esparsa.

<i>Dither Times</i>	<i>Deblending T2T</i>		<i>Deblending por Inversão</i>	
	SNR (dB)	NRMSE	SNR (dB)	NRMSE
$[-2,0, 2,0]$ s	20,341 (0,108)	0,096 (0,001)	22,128	0,078
$[-1,0, 1,0]$ s	21,905 (0,146)	0,080 (0,001)	<b>23,153</b>	<b>0,070</b>
$[-0,5, 0,5]$ s	<b>22,130 (0,178)</b>	<b>0,078 (0,002)</b>	21,354	0,086

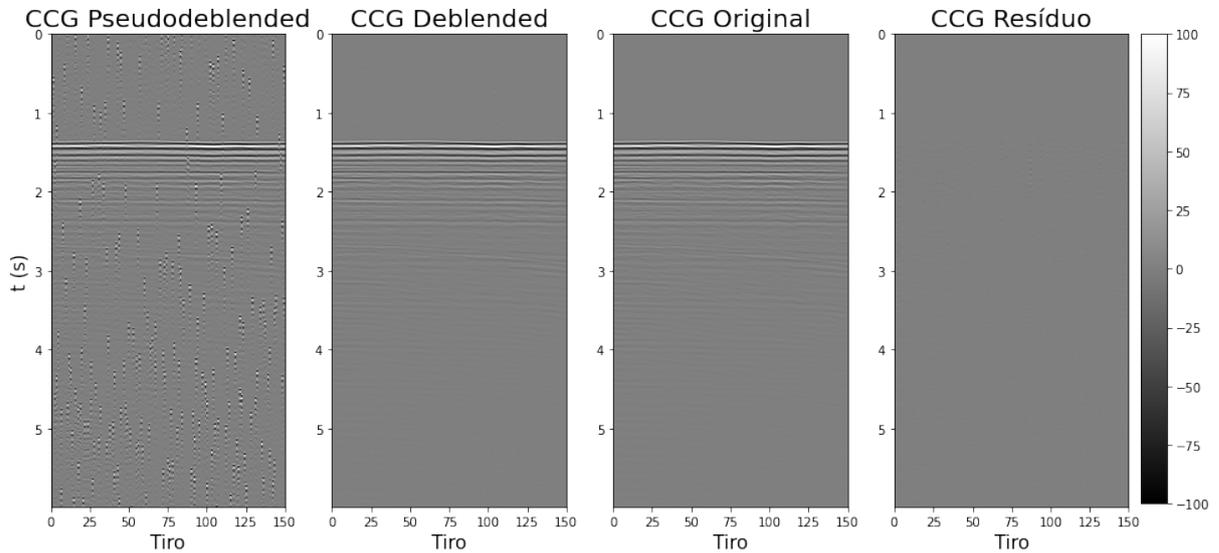
Fonte: O autor (2024).

Como o intervalo de *dither time* se trata de um parâmetro de aquisição, é possível especificar na etapa de planejamento do levantamento valores que favoreçam o processo de *deblending* considerando o método escolhido.

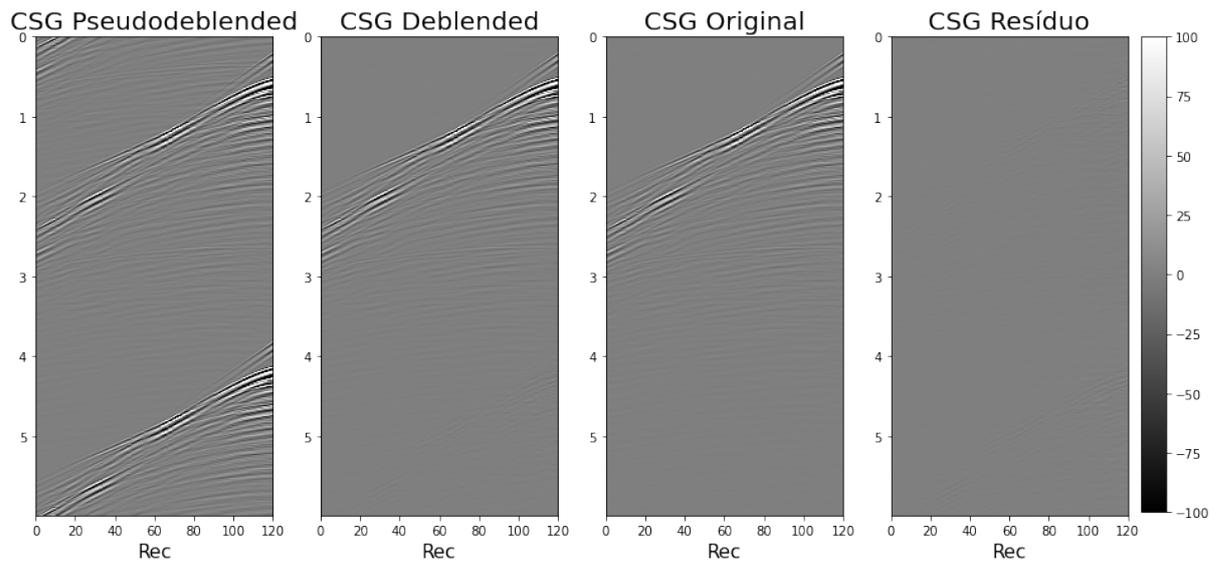
As Figuras 44, 45, 46, 47, 48 e 49 mostram exemplos de sismogramas, nos domínios do canal comum (CCG) e do tiro comum (CSG), resultantes da aplicação dos métodos *Deblending T2T* e *deblending* por inversão esparsa, para *dither times* nos intervalos  $[-2,0, 2,0]$  s,  $[-1,0, 1,0]$  s e  $[-0,5, 0,5]$  s, respectivamente. Qualitativamente, os resultados são

muito próximos e com nível baixíssimo de resíduos de interferência.

Figura 44 – Resultado da aplicação do método *Deblending* T2T usando *dither times* no intervalo  $[-2,0, 2,0]$  s



(a)

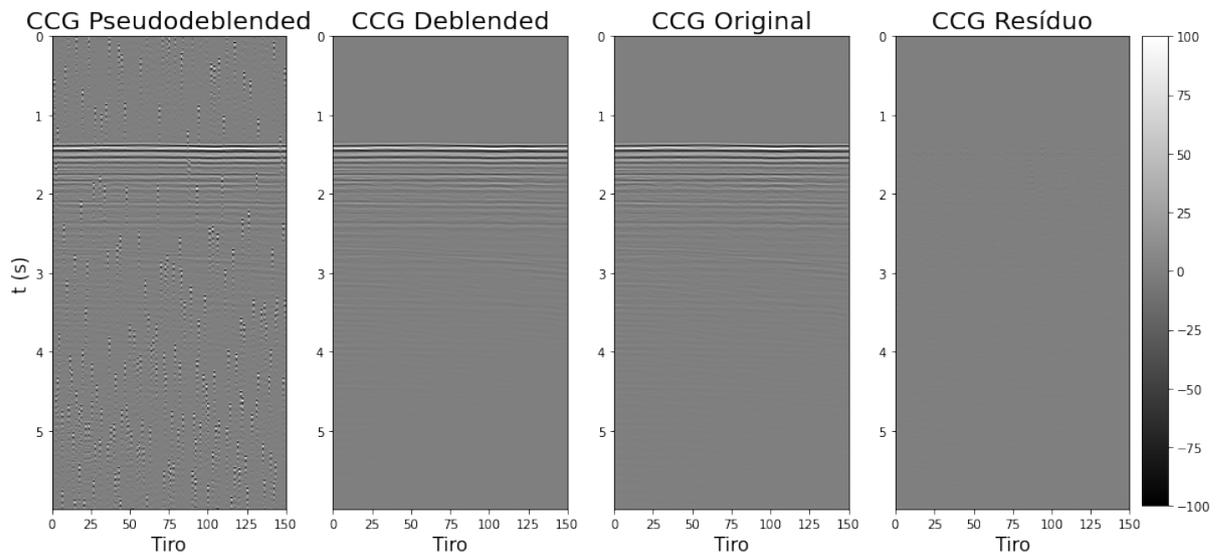


(b)

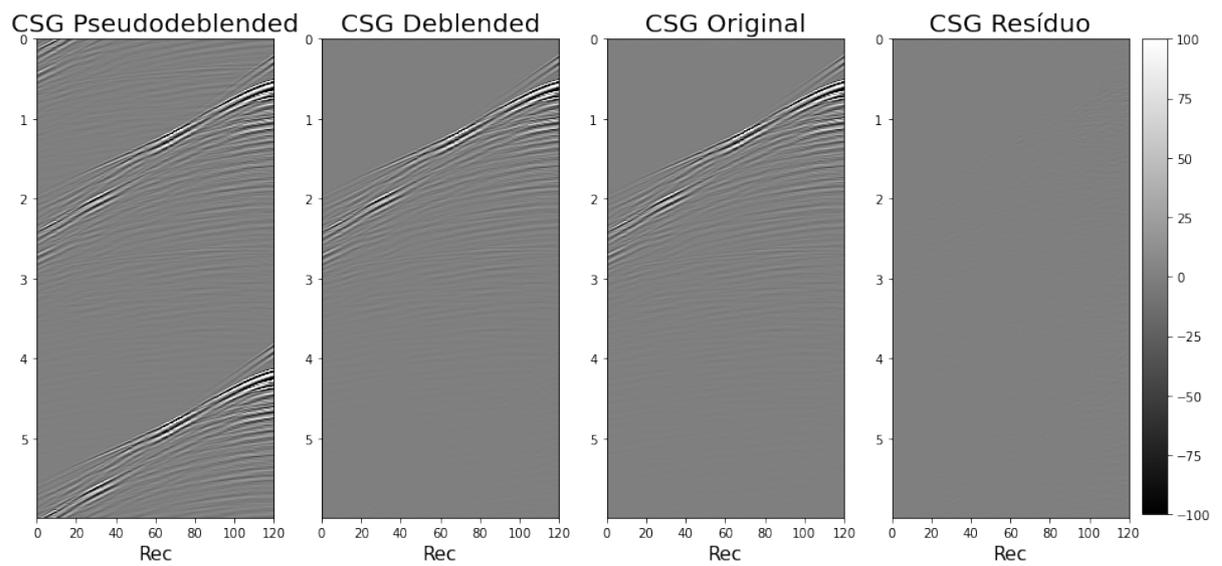
Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

Figura 45 – Resultado do *deblending* pelo método de inversão esparsa usando *dither times* no intervalo  $[-2,0, 2,0]$  s



(a)

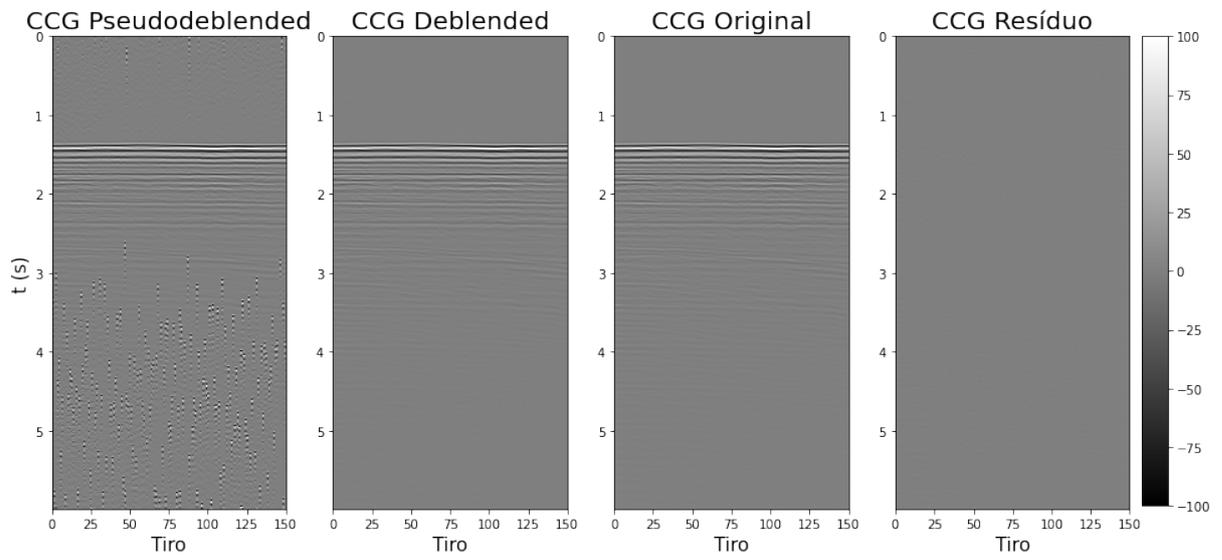


(b)

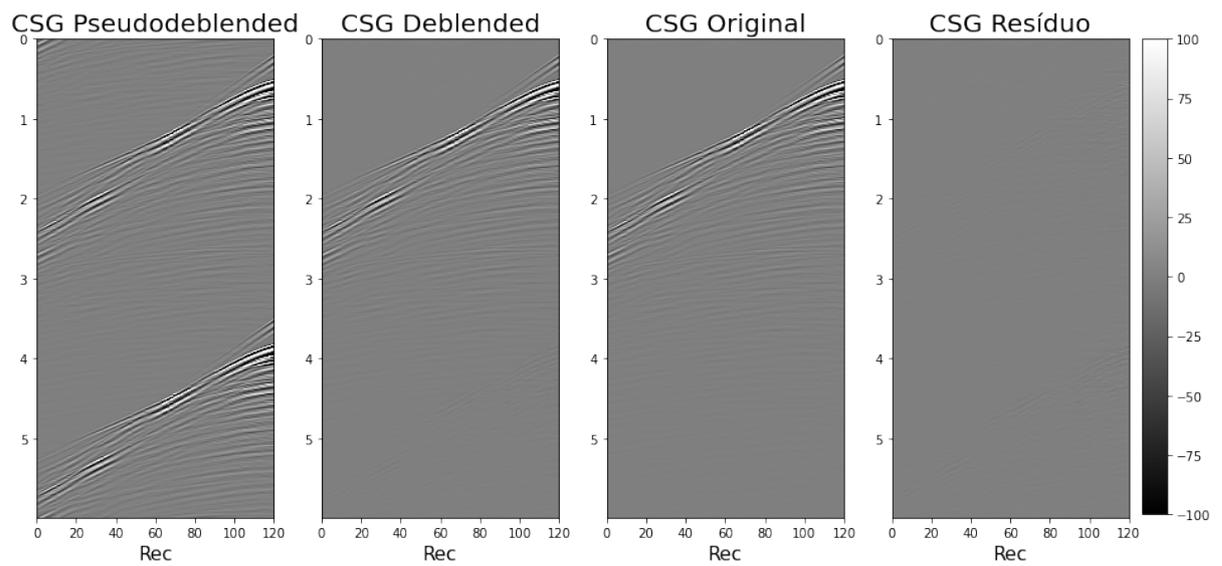
Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

Figura 46 – Resultado da aplicação do método *Deblending* T2T usando *dither times* no intervalo  $[-1,0, 1,0]$  s



(a)

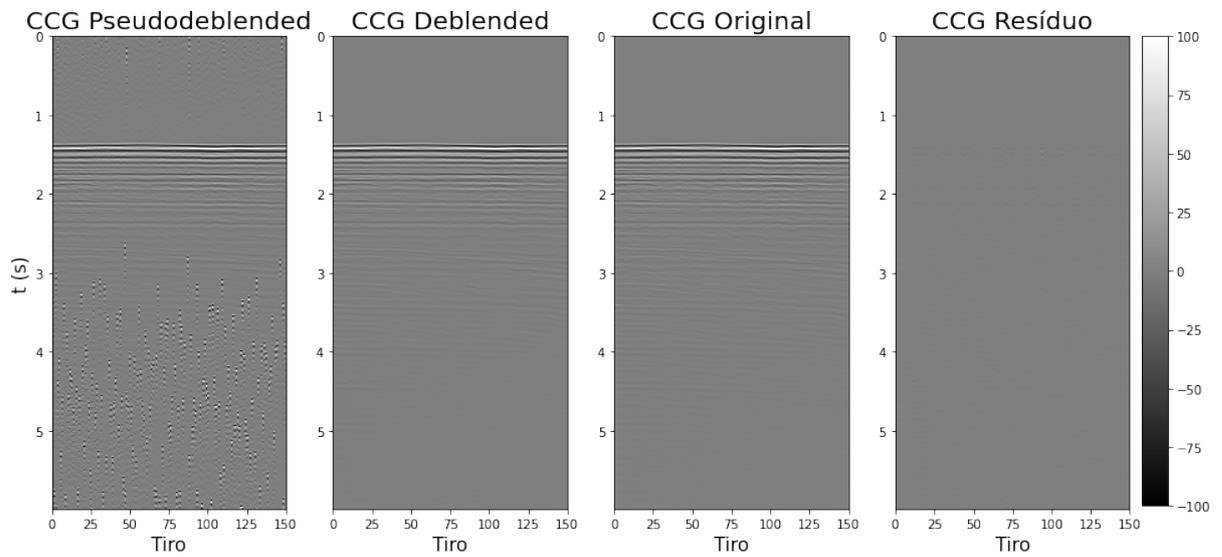


(b)

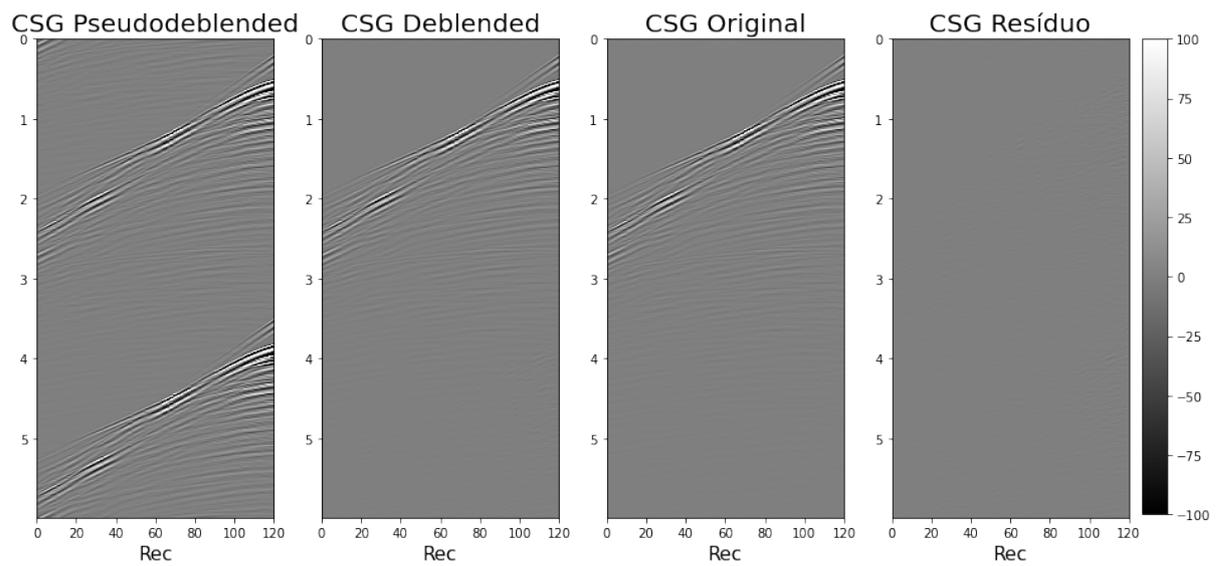
Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

Figura 47 – Resultado do *deblending* pelo método de inversão esparsa usando *dither times* no intervalo  $[-1,0, 1,0]$  s



(a)

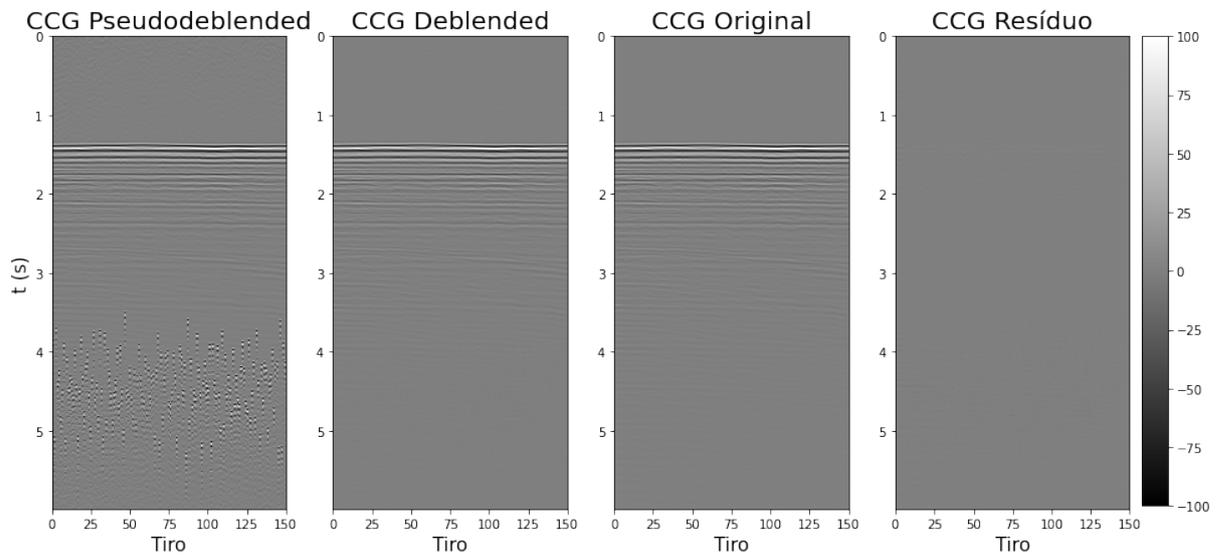


(b)

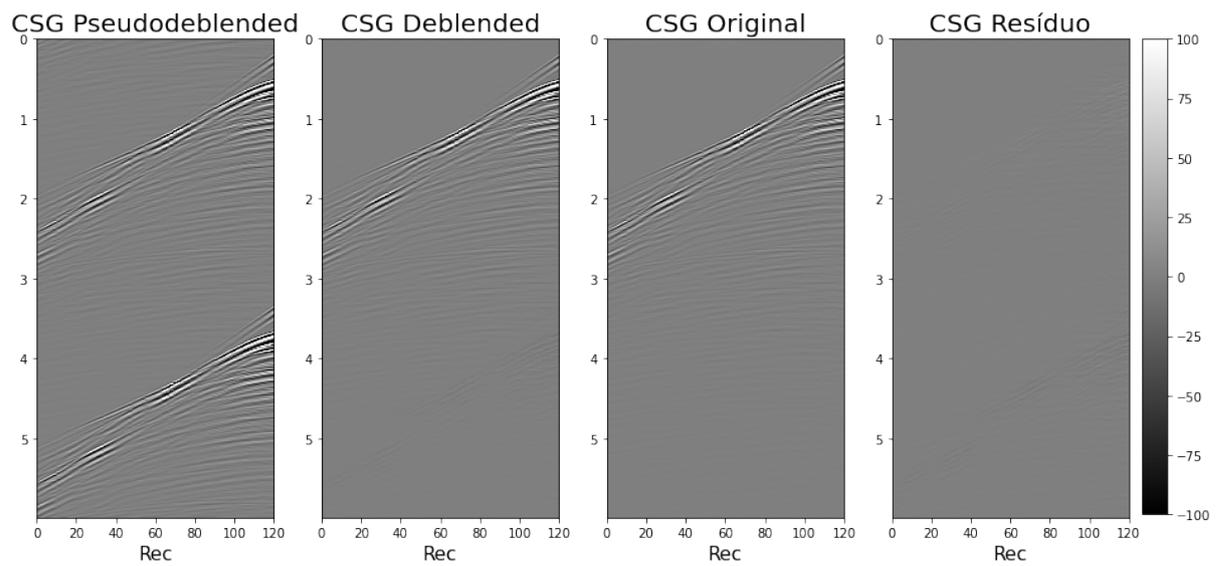
Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

Figura 48 – Resultado da aplicação do método *Deblending* T2T usando *dither times* no intervalo  $[-0,5, 0,5]$  s



(a)

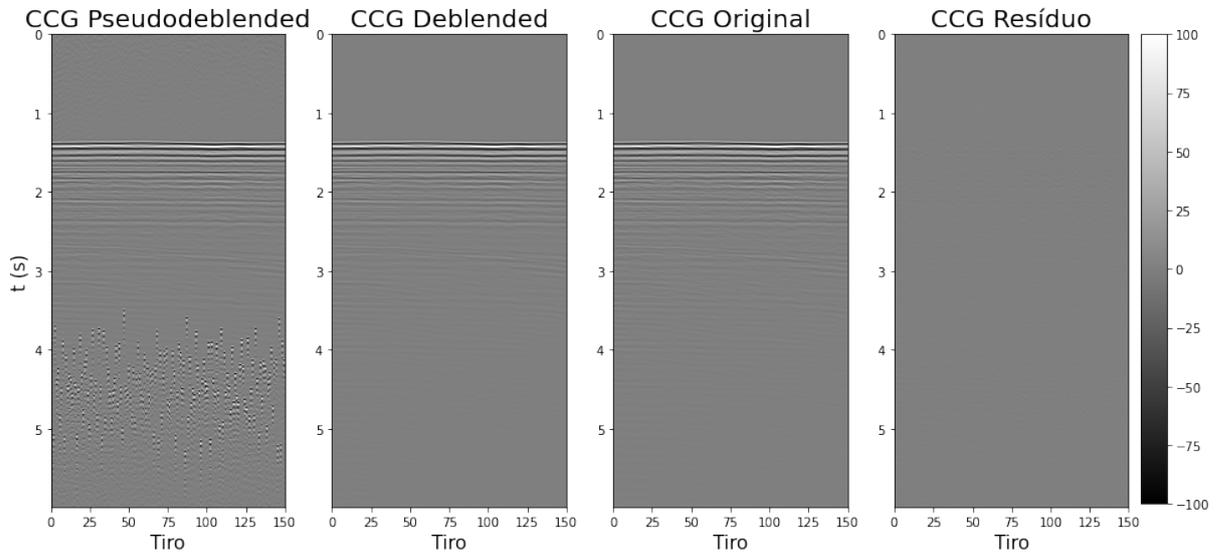


(b)

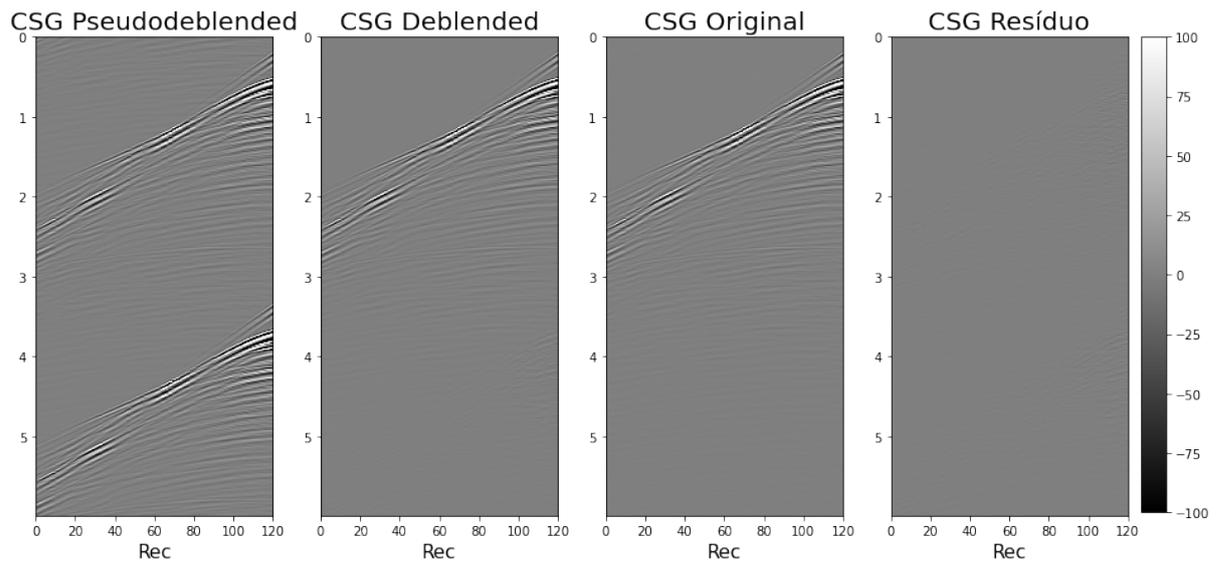
Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

Figura 49 – Resultado do *deblending* pelo método de inversão esparsa usando *dither times* no intervalo  $[-0,5, 0,5]$  s



(a)



(b)

Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

### 6.3 Avaliação da Capacidade de Generalização

Com o intuito de avaliar a capacidade de generalização do método de *Deblending* T2T, foram realizados experimentos envolvendo a aplicação do método em uma base de dados diferente da usada para o treinamento da rede.

O primeiro experimento buscou avaliar os resultados de *deblending* em uma base de dados diferente da usada para o treinamento, mas mantendo-se a mesma distribuição dos *dither times* no intervalo  $[-1,0, 1,0]$  s. A Tabela 4 mostra os resultados em termos da métrica razão sinal-ruído (SNR) para os diferentes cruzamentos entre treinamento e teste. Para tanto, foram utilizadas as versões treinadas da rede RES-NDCNN que apresentaram melhor métrica na predição usando a mesma base de dados, entre cinco execuções do treinamento.

Tabela 4 – Valores da métrica razão sinal-ruído (SNR) obtidos nos experimentos de treinamento e teste cruzado entre diferentes bases de dados para o método *Deblending* T2T usando a arquitetura RES-NDCNN.

		<b>Treinamento</b>	
		<b>Base de Dados</b>	<b>Volve Sintético</b>
<b>Teste</b>	<b>Volve Sintético</b>		27,537
	<b>Mobil AVO</b>		25,600
		<b>Mobil AVO</b>	<b>22,057</b>

Fonte: O autor (2024).

Os resultados mostram uma queda de desempenho do processo de *deblending*, em termos da razão sinal-ruído, quando a rede é treinada em uma base de dados e aplicada em outra. Entretanto, observa-se uma perda de desempenho maior no caso em que a rede foi treinada usando a base de dados sintéticos (Volve) e aplicada à base de dados reais (Mobil AVO). Nesse caso, a diferença foi de 8,0 dB em comparação com o resultado obtido considerando o treinamento e teste com essa mesma base (Mobil AVO). Por outro lado, quando a rede foi treinada usando a base de dados reais Mobil AVO e aplicada à base de dados sintéticos, a perda de desempenho foi de apenas 2,0 dB. Apesar desse tipo de aplicação não ser útil na prática, o resultado aponta que uma rede treinada usando dados reais, que possuem maior nível de complexidade do que os dados sintéticos, apresenta maior capacidade de generalização do que redes treinadas com dados sintéticos.

As Figuras 50 e 51 mostram exemplos de sismogramas, nos domínios do canal comum (CCG) e do tiro comum (CSG), resultantes da aplicação do método *Deblending* T2T em uma base de dados diferente da usada para treinamento. Em ambos os casos, o ruído de interferência foi bastante atenuado. No entanto, conforme indicado pelo resultado da

métrica, observa-se um nível mais alto de ruído de interferência ainda presente no dado *deblended*, mais facilmente observado no painel no domínio do tiro comum, no caso em que a rede foi treinada com a base de dados sintéticos e aplicada aos dados reais.

Para efeito de comparação, a Tabela 5 mostra os resultados em termos da métrica razão sinal-ruído para os diferentes cruzamentos entre treinamento e teste para o método de *deblending* supervisionado usando a arquitetura RES-NDCNN.

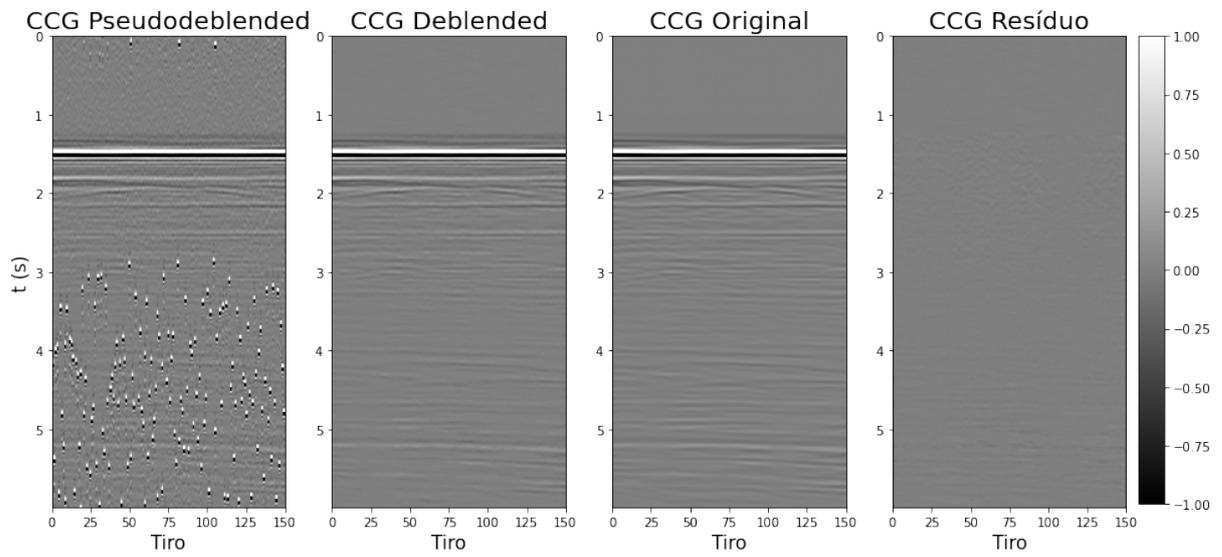
Tabela 5 – Valores da métrica razão sinal-ruído (SNR) obtidos nos experimentos de treinamento e teste cruzado entre diferentes bases de dados para o método de *deblending* supervisionado usando a rede RES-NDCNN.

		<b>Treinamento</b>	
		<b>Base de Dados</b>	<b>Volve Sintético Mobil AVO</b>
<b>Teste</b>	<b>Volve Sintético</b>	25,919	20,992
	<b>Mobil AVO</b>	11,152	24,680

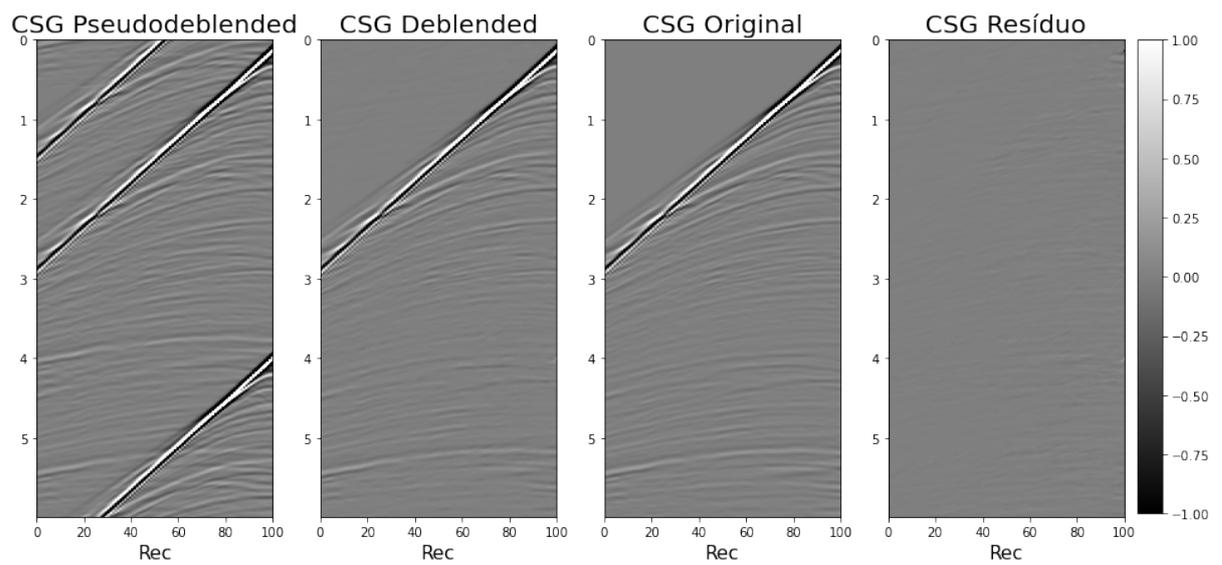
Fonte: O autor (2024).

Observa-se uma queda de desempenho, em termos da razão sinal-ruído, mais acentuada do que no caso autossupervisionado, quando a rede é treinada em uma base de dados e aplicada em outra. Esse experimento demonstra que a rede treinada de modo supervisionado apresenta uma capacidade de generalização mais baixa do que quando treinada usando o método autossupervisionado proposto para a tarefa de *deblending*. Em uma situação real de uma aquisição sísmica *blended*, apenas dados que sofreram interferência entre disparos consecutivos estariam disponíveis. Logo, a aplicação do método supervisionado dependeria do treinamento prévio em dados sintéticos ou reais adquiridos de forma convencional e submetidos ao processo de *blending* numérico, antes da aplicação no dado *blended* real. Isto conseqüentemente reduziria o desempenho do método, conforme observado nos experimentos de generalização. Por outro lado, o método de *Deblending* T2T proposto, por ser autossupervisionado, poderia ser utilizado diretamente no dado em que se deseja fazer o *deblending*.

Figura 50 – Resultado da aplicação do método *Deblending* T2T, treinado com dados da base Mobil AVO e aplicado aos dados da base Volve Sintético



(a)

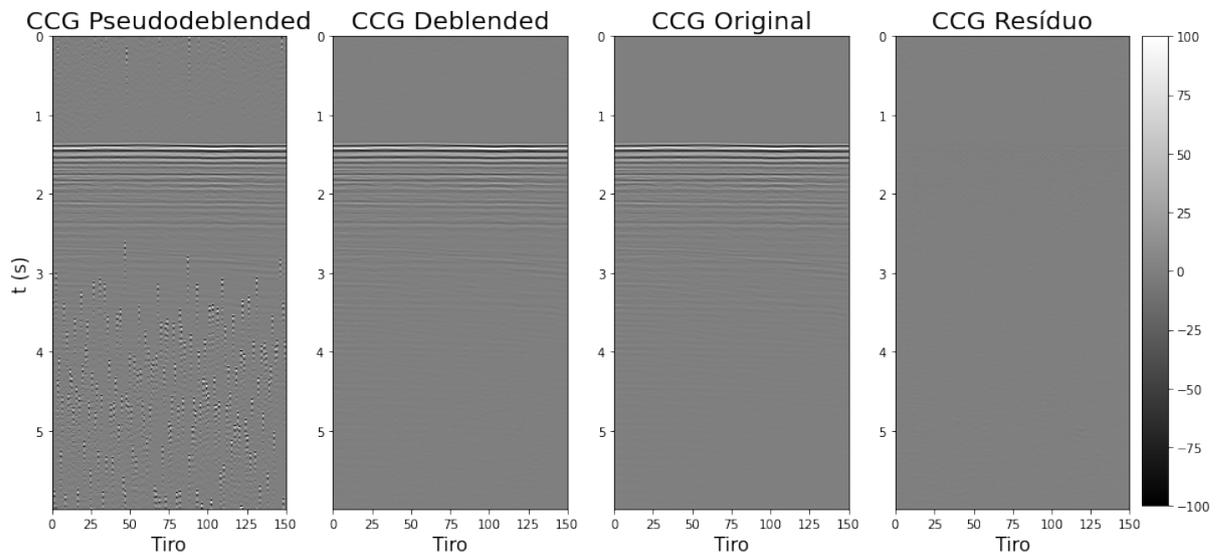


(b)

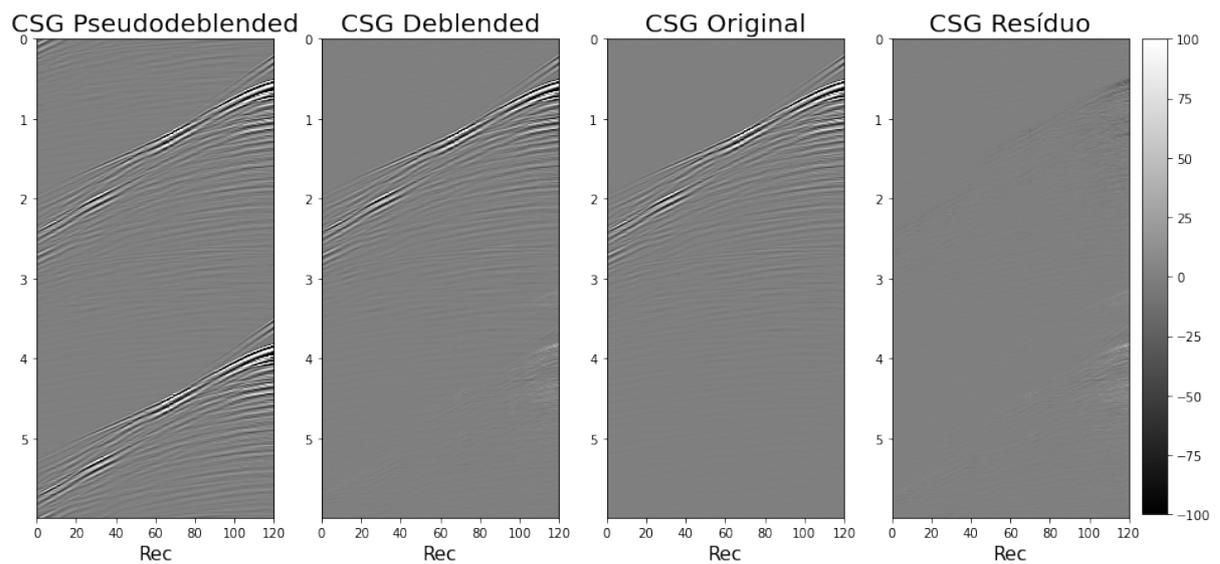
Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

Figura 51 – Resultado da aplicação do método *Deblending* T2T, treinado com dados da base Volve Sintético e aplicado aos dados da base Mobil AVO



(a)



(b)

Legenda: (a) - CCG e (b) - CSG.

Fonte: O autor (2024).

O segundo experimento teve como objetivo avaliar a capacidade de generalização considerando a mesma base de dados, Mobil AVO, porém, submetida ao processo de *blending* numérico usando diferentes intervalos de *dither time*. A Tabela 6 mostra os resultados em termos da métrica SNR para os diversos cruzamentos entre treinamento e teste. Novamente, foram utilizadas as versões da rede RES-NDCNN que apresentaram a melhor

métrica de predição entre cinco execuções do treinamento.

Tabela 6 – Valores da métrica razão sinal-ruído (SNR) obtidos nos experimentos de treinamento e teste usando dados da base Mobil AVO submetidos a diferentes intervalos de *dither time*.

		Treinamento			
		<i>Dither Times</i>	[-0,5, 0,5] s	[-1,0, 1,0] s	[-2,0, 2,0] s
Teste	[-0,5, 0,5] s		22,375	22,330	21,098
	[-1,0, 1,0] s		21,845	22,057	21,582
	[-2,0, 2,0] s		17,743	19,056	20,479
Média			20,654	21,148	21,053
Desvio Padrão			2,535	1,817	0,553

Fonte: O autor (2024).

Os resultados mostram que, independente do intervalo de *dither time* usado no conjunto de dados de treinamento, o desempenho do processo de *deblending* piorou com o aumento do intervalo de *dither time* do dado de teste. Entretanto, quanto maior o intervalo de *dither time* dos dados do conjunto de treinamento, menor foi a variabilidade dos resultados em dados com intervalos diferentes de *dither time*, e, portanto, melhor é a capacidade de generalização.

Interessante notar que quando a rede é treinada em um dado com intervalo de *dither time* e testada no mesmo dado com um intervalo inferior, que é um subconjunto do primeiro, o resultado é inclusive melhor do que quando o teste é feito em um dado com mesmo intervalo de *dither time* do dado de treinamento. Esse efeito acontece nos experimentos com *dither times* nos intervalos [-1,0, 1,0] s e [-2,0, 2,0] s quando aplicados a dados com intervalos inferiores.

Cabe reforçar que, apesar dos experimentos para avaliação da capacidade de generalização realizados, o método autossupervisionado proposto pode ser aplicado diretamente ao dado em que se deseja fazer o *deblending*, sem a necessidade de treinamento prévio em dados diferentes, sintéticos ou reais, ou com intervalo de *dither time* diferente.

## CONCLUSÃO

Este trabalho apresentou a proposta de um método de aprendizado profundo autossupervisionado para *deblending* de dados sísmicos marítimos, em alternativa aos métodos baseados em aprendizado supervisionado e inversão esparsa. Essa proposta se justifica tendo em vista que em uma aquisição sísmica *blended* apenas estarão disponíveis dados que sofreram interferência de tiros consecutivos, o que limita o uso de métodos supervisionados para a tarefa de *deblending*.

A validação do método proposto (*Deblending* T2T) foi realizada por meio da comparação dos resultados obtidos em duas bases de dados, uma sintética e outra real, com os métodos de *deblending* supervisionado e *deblending* por inversão esparsa. Além disso, foram avaliados os efeitos da arquitetura utilizada, da função objetivo e do pós-processamento.

Os melhores resultados do método proposto foram obtidos com a combinação da arquitetura RES-NDCNN e o uso da função objetivo alternada L1, além do pós-processamento. Vale destacar que essa combinação envolve as principais contribuições deste trabalho. Primeiro, propõe a utilização do método Trace2Trace, originalmente proposto para atenuação de ruído aleatório em imagens sísmicas, para a tarefa de *deblending*. Segundo, propõe o uso da função objetivo alternada L1 que introduz um vínculo de consistência no processo de *deblending* usando o método Trace2Trace. Terceiro, propõe a arquitetura RES-NDCNN, uma variação da rede NDCNN, utilizando a estratégia da conexão residual global, em substituição à arquitetura U-NET utilizada no trabalho seminal do método Trace2Trace. E por fim, propõe o uso de um procedimento de pós-processamento baseado no algoritmo iterativo LSQR. Tal combinação resultou em um desempenho intermediário, de 27,156 dB de razão sinal-ruído média, entre o método de *deblending* supervisionado (25,475 dB) e o *deblending* por inversão esparsa (37,224 dB), usando a base de dados sintéticos. Para a base de dados reais, essa combinação apresentou resultado inferior (21,905 dB) tanto ao *deblending* por inversão (23,153 dB) quanto ao *deblending* supervisionado (24,577 dB). Entretanto, a natureza autossupervisionada do método proposto, utilizando apenas dados que sofreram interferência para treinamento, destaca a sua aplicabilidade em situações reais onde os dados limpos, sem efeito de interferência, não estão disponíveis.

A conexão residual global utilizada na arquitetura RES-NDCNN contribuiu para uma melhora significativa do desempenho da rede, entre 1,0 dB e 2,0 dB na SNR, em comparação com a versão original da NDCNN. Já a função objetivo alternada L1 contribuiu para uma melhora de desempenho das redes NDCNN e RES-NDCNN, treinadas de modo autossupervisionado, da ordem de 1,5 dB na SNR. Adicionalmente, o procedimento de pós-processamento contribuiu para um ganho de aproximadamente 3,0 dB na SNR.

Após a definição da arquitetura, analisou-se o efeito do intervalo de *dither time* sobre os resultados, bem como a capacidade de generalização da rede quando aplicada a uma base de dados diferente da utilizada para o treinamento. Os resultados mostraram que tanto o método *Deblending* T2T quanto o de inversão são sensíveis ao intervalo de *dither time*. Observa-se uma tendência de melhora do desempenho do método proposto com a redução do intervalo de *dither time*. Além disso, para *dither times* no intervalo  $[-0,5, 0,5]$  s, o método proposto alcançou um resultado de 22,130 dB de SNR e superou o resultado obtido pelo *deblending* por inversão esparsa (21,354 dB). Em experimentos realizados envolvendo treinamento e teste cruzado em dados com intervalos diferentes de *dither time*, observou-se que quanto maior o intervalo de *dither time* dos dados do conjunto de treinamento, menor é a variabilidade dos resultados, e, portanto, melhor é a capacidade de generalização da rede.

Os resultados da aplicação das redes em bases de dados diferentes das usadas no treinamento foram inferiores aos alcançados quando se utilizam as mesmas bases de dados, independentemente do método de treinamento. No entanto, observou-se uma perda de desempenho maior no caso em que a rede foi treinada de modo supervisionado. O que demonstra que o método autossupervisionado proposto apresentou melhor capacidade de generalização do que o método supervisionado.

Em resumo, o método *Deblending* T2T proposto se mostrou uma alternativa viável aos métodos de *deblending* supervisionado e *deblending* por inversão esparsa, com capacidade de superar o desempenho dos mesmos em certas condições e com resultados que superam ou são comparáveis aos reportados na literatura usando outras técnicas e arquiteturas de rede em experimentos semelhantes.

## TRABALHOS FUTUROS

Tendo em vista que todos os experimentos realizados utilizaram dados adquiridos ou modelados considerando apenas a tecnologia de aquisição *streamer* e geometrias 2D, uma continuação natural deste trabalho envolveria a avaliação do método proposto em dados sísmicos adquiridos com outras tecnologias, tais como OBN e PRM, além de geometrias de aquisição 3D.

Para aplicação do método em volumes de dados sísmicos completos, oriundos de levantamentos de produção, deve-se investir em implementações paralelizadas em GPUs usando ambientes de computação de alto desempenho.

Outro aspecto relevante a respeito dos dados de entrada é o fato de que este trabalho se utilizou do processo de *blending* numérico devido à falta de acesso a dados adquiridos com técnicas de fontes simultâneas. Logo, é de fundamental importância a avaliação do método proposto usando dados sísmicos reais já adquiridos de forma *blended*.

Como o método autossupervisionado proposto independe da arquitetura de rede, pode-se ainda investigar a utilização de outras arquiteturas, assim como de outros tipos de função objetivo.

O presente trabalho se restringiu à análise dos sismogramas nos domínios do canal e tiro comum após o processo de *deblending*. Portanto, um passo adiante seria seguir com o fluxo de processamento sísmico com o intuito de avaliar os efeitos dos resíduos de interferência, ainda presentes nos sismogramas que passaram pelo processo de *deblending*, nas imagens sísmicas finais.

Conforme também discutido, métodos de *deblending* autossupervisionados podem se beneficiar de estratégias conjuntas com algoritmos de inversão. Um caminho promissor pode ser a utilização do método autossupervisionado aqui proposto aliado a estratégias tais como *Plug and Play* (LUIKEN; RAVASI; BIRNIE, 2024) e *Regularization by Denoising* (BAHIA; LIN; SACCHI, 2021), com o intuito de melhorar o desempenho do método de *deblending* e/ou acelerar a convergência dos algoritmos de inversão.

## REFERÊNCIAS

- ABMA, R.; FOSTER, M. S. Simultaneous source seismic acquisition. In: \_\_\_\_\_. Society of Exploration Geophysicists, 2021. Disponível em: <<https://library.seg.org/doi/abs/10.1190/1.9781560803799.fm>>.
- ABMA, R. et al. Independent simultaneous source acquisition and processing. *GEOPHYSICS*, v. 80, n. 6, p. WD37–WD44, 2015. Disponível em: <<https://doi.org/10.1190/geo2015-0078.1>>.
- ABMA, R.; KABIR, N. 3d interpolation of irregular data with a pocs algorithm. *GEOPHYSICS*, Society of Exploration Geophysicists, v. 71, n. 6, p. E91–E97, nov. 2006. ISSN 1942-2156. Disponível em: <<http://dx.doi.org/10.1190/1.2356088>>.
- ANJOM, F. K.; VACCARINO, F.; SOCCO, L. V. Machine learning for seismic exploration: Where are we and how far are we from the holy grail? *GEOPHYSICS*, v. 89, n. 1, p. WA157–WA178, 2024. Disponível em: <<https://doi.org/10.1190/geo2023-0129.1>>.
- AUJOL, J.-F. et al. Parameter-free fista by adaptive restart and backtracking. *SIAM Journal on Optimization*, v. 34, n. 4, p. 3259–3285, 2024. Disponível em: <<https://doi.org/10.1137/23M158961X>>.
- Classification and Suppression of Blending Noise Using Convolutional Neural Networks*, Day 2 Tue, March 19, 2019 de *SPE Middle East Oil and Gas Show and Conference*, (SPE Middle East Oil and Gas Show and Conference, Day 2 Tue, March 19, 2019). D021S005R001 p. Disponível em: <<https://doi.org/10.2118/194731-MS>>.
- BAGAINI, C. Overview of simultaneous vibroseis acquisition methods. In: \_\_\_\_\_. *SEG Technical Program Expanded Abstracts 2006*. [s.n.], 2006. p. 70–74. Disponível em: <<https://library.seg.org/doi/abs/10.1190/1.2370358>>.
- BAHIA, B.; LIN, R.; SACCHI, M. Regularization by denoising for simultaneous source separation. *GEOPHYSICS*, v. 86, n. 6, p. P69–P83, 2021. Disponível em: <<https://doi.org/10.1190/geo2021-0068.1>>.
- BEASLEY, C. J.; CHAMBERS, R. E.; JIANG, Z. A new look at simultaneous sources. In: *SEG Technical Program Expanded Abstracts 1998*. Society of Exploration Geophysicists, 1998. Disponível em: <<https://doi.org/10.1190%2F1.1820149>>.
- BECK, A.; TEBoulLE, M. A fast iterative shrinkage-thresholding algorithm for linear inverse problems. *SIAM Journal on Imaging Sciences*, v. 2, n. 1, p. 183–202, 2009. Disponível em: <<https://doi.org/10.1137/080716542>>.
- BERG, E. van den; FRIEDLANDER, M. P. Probing the pareto frontier for basis pursuit solutions. *SIAM Journal on Scientific Computing*, v. 31, n. 2, p. 890–912, 2009. Disponível em: <<https://doi.org/10.1137/080714488>>.
- BERKHOUT, A. J. “. Changing the mindset in seismic data acquisition. *The Leading Edge*, Society of Exploration Geophysicists, v. 27, n. 7, p. 924–938, jul 2008. Disponível em: <<https://doi.org/10.1190%2F1.2954035>>.

- BJORLYKKE, K. *Petroleum Geoscience*. Springer Berlin Heidelberg, 2010. Disponível em: <<https://doi.org/10.1007%2F978-3-642-02332-3>>.
- BORDING, R. P.; LINES, L. R. *Seismic Modeling and Imaging with the Complete Wave Equation*. Society of Exploration Geophysicists, 1997. ISBN 9781560801870. Disponível em: <<http://dx.doi.org/10.1190/1.9781560801870>>.
- BOYD, S. et al. *Distributed Optimization and Statistical Learning via the Alternating Direction Method of Multipliers*. [S.l.: s.n.], 2011.
- BUSSON, A. J. G. *A SELF-SUPERVISED METHOD FOR BLIND DENOISING OF SEISMIC SHOT GATHERS*. Tese (Doutorado) — Faculdades Catolicas, 2022. Disponível em: <<http://dx.doi.org/10.17771/PUCRio.acad.59152>>.
- CALVARONS, A. F. Improved noise2noise denoising with limited data. In: *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*. [S.l.: s.n.], 2021. p. 796–805.
- CHAMBERS, S.; LOMASK, J. Boulder prediction for offshore windfarm site evaluation using an interactive 2d cnn and a unique weighting scheme on unmigrated seismic. In: \_\_\_\_\_. *Third International Meeting for Applied Geoscience & Energy Expanded Abstracts*. [s.n.], 2023. p. 990–993. Disponível em: <<https://library.seg.org/doi/abs/10.1190/image2023-3909163.1>>.
- CHEN, Y.; FOMEL, S.; HU, J. Iterative deblending of simultaneous-source seismic data using seislet-domain shaping regularization. *GEOPHYSICS*, v. 79, n. 5, p. V179–V189, 2014. Disponível em: <<https://doi.org/10.1190/geo2013-0449.1>>.
- CHENG, J. et al. Deblending of simultaneous-source seismic data based on deep convolutional neural network. *IEEE Transactions on Geoscience and Remote Sensing*, Institute of Electrical and Electronics Engineers (IEEE), v. 60, p. 1–13, 2022. Disponível em: <<https://doi.org/10.1109%2Ftgrs.2022.3153642>>.
- DONDURUR, D. *Acquisition and Processing of Marine Seismic Data*. Elsevier Science, 2018. ISBN 9780128114919. Disponível em: <<https://books.google.com.br/books?id=pyk0DwAAQBAJ>>.
- ELAD, M. *Sparse and Redundant Representations: From Theory to Applications in Signal and Image Processing*. Springer New York, 2010. ISBN 9781441970114. Disponível em: <<http://dx.doi.org/10.1007/978-1-4419-7011-4>>.
- EQUINOR. *Volve field data set — equinor.com*. 2018. <<https://www.equinor.com/energy/volve-data-sharing>>. [Accessed 08-11-2023].
- EQUINOR. *GitHub - equinor/segyio: Fast Python library for SEG Y files*. 2023. Disponível em: <<https://github.com/equinor/segyio>>.
- FICHTNER, A. *Full Seismic Waveform Modelling and Inversion*. Springer Berlin Heidelberg, 2011. ISSN 1866-8356. ISBN 9783642158070. Disponível em: <<http://dx.doi.org/10.1007/978-3-642-15807-0>>.
- GEOSPACE. *Reservoir Intelligence - Geospace Technologies*. 2024. Disponível em: <<https://www.geospace.com/products/reservoir-intelligence>>.

GONZALEZ, R.; WOODS, R. *Digital Image Processing Global Edition*. Pearson Deutschland, 2017. 1024 p. ISBN 9781292223049. Disponível em: <<https://elibrary.pearson.de/book/99.150005/9781292223070>>.

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

*Acquisition Using Simultaneous Sources*, All Days de *SEG International Exposition and Annual Meeting*, (SEG International Exposition and Annual Meeting, All Days). SEG-2008-2816 p.

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.

HOU, S.; MESSUD, J. Machine learning for seismic processing: The path to fulfilling promises. In: \_\_\_\_\_. *First International Meeting for Applied Geoscience & Energy Expanded Abstracts*. [s.n.], 2021. p. 3204–3208. Disponível em: <<https://library.seg.org/doi/abs/10.1190/segam2021-3590137.1>>.

IBRAHIM, A.; SACCHI, M. D. Simultaneous source separation using a robust radon transform. *GEOPHYSICS*, v. 79, n. 1, p. V1–V11, 2014. Disponível em: <<https://doi.org/10.1190/geo2013-0168.1>>.

KERAS. *Home - Keras Documentation*. 2019. Disponível em: <<https://keras.io/>>.

KEYS, R. G.; FOSTER, D. J. 1. a data set for evaluating and comparing seismic inversion methods. In: \_\_\_\_\_. *Comparison of Seismic Inversion Methods on a Single Real Data Set*. [s.n.], 2012. p. 1–12. Disponível em: <<https://library.seg.org/doi/abs/10.1190/1.9781560802082.ch1>>.

KINGMA, D.; BA, J. Adam: A method for stochastic optimization. arXiv, 2015. Disponível em: <<https://arxiv.org/abs/1412.6980>>.

KRULL, A.; BUCHHOLZ, T.-O.; JUG, F. Noise2void-learning denoising from single noisy images. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.: s.n.], 2019. p. 2129–2137.

LAINE, S. et al. *High-Quality Self-Supervised Deep Image Denoising*. arXiv, 2019. Disponível em: <<https://arxiv.org/abs/1901.10277>>.

LECUN, Y. et al. Handwritten digit recognition: Applications of neural network chips and automatic learning. *IEEE Communications Magazine*, IEEE, v. 27, n. 11, p. 41–46, 1989.

LEHTINEN, J. et al. *Noise2Noise: Learning Image Restoration without Clean Data*. 2018.

LIESEN, J.; MEHRMANN, V. *Linear Algebra*. Springer International Publishing, 2015. ISSN 2197-4144. ISBN 9783319243467. Disponível em: <<http://dx.doi.org/10.1007/978-3-319-24346-7>>.

LIU, B. et al. Unsupervised deep learning for random noise attenuation of seismic data. *IEEE Geoscience and Remote Sensing Letters*, v. 19, p. 1–5, 2022.

LOUBOUTIN, M. et al. Devito (v3.1.0): an embedded domain-specific language for finite differences and geophysical exploration. *Geoscientific Model Development*, v. 12, n. 3, p. 1165–1187, 2019. Disponível em: <<https://www.geosci-model-dev.net/12/1165/2019/>>.

LUIKEN, N.; RAVASI, M.; BIRNIE, C. Integrating self-supervised denoising in inversion-based seismic deblending. *GEOPHYSICS*, v. 89, n. 1, p. WA39–WA51, 2024. Disponível em: <<https://doi.org/10.1190/geo2023-0131.1>>.

LUPORINI, F. et al. Architecture and performance of devito, a system for automated stencil computation. *ACM Trans. Math. Softw.*, Association for Computing Machinery, New York, NY, USA, v. 46, n. 1, apr 2020. ISSN 0098-3500. Disponível em: <<https://doi.org/10.1145/3374916>>.

MAHDAD, A.; DOULGERIS, P.; BLACQUIERE, G. Separation of blended data by iterative estimation and subtraction of blending interference noise. *GEOPHYSICS*, v. 76, n. 3, p. Q9–Q17, 2011. Disponível em: <<https://doi.org/10.1190/1.3556597>>.

MAHDAD, A.; DOULGERIS, P.; BLACQUIÈRE, G. Iterative method for the separation of blended seismic data: discussion on the algorithmic aspects. *Geophysical Prospecting*, European Association of Geoscientists & Engineers, v. 60, n. 4 - Simultaneous Source Methods for Seismic Data, p. 782–801, 2012. ISSN 1365-2478. Disponível em: <<https://www.earthdoc.org/content/journals/10.1111/j.1365-2478.2012.01084.x>>.

MANSOUR, H. et al. Randomized marine acquisition with compressive sampling matrices. *Geophysical Prospecting*, v. 60, n. 4, p. 648–662, 2012. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1365-2478.2012.01075.x>>.

MATHARU, G. et al. Simultaneous source deblending using a deep residual network. In: *SEG 2019 Workshop: Mathematical Geophysics: Traditional vs Learning, Beijing, China, 5–7 November 2019*. Society of Exploration Geophysicists, 2020. Disponível em: <[https://doi.org/10.1190/%2Fiwmg2019\\_04.1](https://doi.org/10.1190/%2Fiwmg2019_04.1)>.

MONK, D. J. *Survey Design and Seismic Acquisition for Land, Marine, and In-between in Light of New Technology and Techniques*. Society of Exploration Geophysicists, 2020. Disponível em: <<https://doi.org/10.1190%2F1.9781560803713>>.

MULLER, A. P. O. et al. Deep pre-trained FWI: where supervised learning meets the physics-informed neural networks. *Geophysical Journal International*, v. 235, n. 1, p. 119–134, 05 2023. ISSN 0956-540X. Disponível em: <<https://doi.org/10.1093/gji/ggad215>>.

NUMPY. *NumPy*. 2009. Disponível em: <<https://numpy.org/>>.

OLIVEIRA, D. A. B. et al. Interpolating seismic data with conditional generative adversarial networks. *IEEE Geoscience and Remote Sensing Letters*, v. 15, n. 12, p. 1952–1956, 2018.

OLVER, P. J.; SHAKIBAN, C. *Applied Linear Algebra*. Springer International Publishing, 2018. ISSN 2197-5604. ISBN 9783319910413. Disponível em: <<http://dx.doi.org/10.1007/978-3-319-91041-3>>.

OPENPR. *Marine Seismic Equipment and Acquisition Market Analysis, Type, Size, Trends, Key Players and Forecast 2016 to 2*. openPR,

2022. Disponível em: <<https://www.openpr.com/news/2863883/marine-seismic-equipment-acquisition-market-analysis-type>>.

OURABAH, A.; CHATENAY, A. Unlocking ultra-high-density seismic for ccus applications by combining nimble nodes and agile source technologies. *The Leading Edge*, v. 41, n. 1, p. 27–33, 2022. Disponível em: <<https://doi.org/10.1190/tle41010027.1>>.

PAIGE, C. C.; SAUNDERS, M. A. Lsq: An algorithm for sparse linear equations and sparse least squares. *ACM Trans. Math. Softw.*, Association for Computing Machinery, New York, NY, USA, v. 8, n. 1, p. 43–71, mar. 1982. ISSN 0098-3500. Disponível em: <<https://doi.org/10.1145/355984.355989>>.

PEAK-SEISMIC. *Ocean Bottom Seismic*. 2024. Disponível em: <<https://www.peakseismic.com/content/ocean-bottom-seismic.asp>>.

PODAREANU, D. et al. *Best Practice Guide - Deep Learning*. [S.l.: s.n.], 2019.

PRADO, T. de A.; GUARNERI, G. A. Estudo comparativo entre algoritmos para decomposição esparsa de sinais elétricos com distorções harmônicas. In: *Proceedings XXII Congresso Brasileiro de Automática*. SBA Sociedade Brasileira de Automática, 2018. (CBA2018). ISSN 2525-8311. Disponível em: <<http://dx.doi.org/10.20906/CPS/CBA2018-0768>>.

PRINCE, S. J. *Understanding Deep Learning*. The MIT Press, 2023. Disponível em: <<http://udlbook.com>>.

RANI, V. et al. Self-supervised learning: A succinct review. *Archives of Computational Methods in Engineering*, Springer Science and Business Media LLC, v. 30, n. 4, p. 2761–2775, jan. 2023. ISSN 1886-1784. Disponível em: <<http://dx.doi.org/10.1007/s11831-023-09884-2>>.

RAVASI, M. *VolveSynthetic*. Zenodo, 2022. Disponível em: <<https://doi.org/10.5281/zenodo.6572286>>.

RAVASI, M.; VASCONCELOS, I. Pylops—a linear-operator python library for scalable algebra and optimization. *SoftwareX*, v. 11, p. 100361, 2020. ISSN 2352-7110. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352711019301086>>.

RICHARDSON, A.; FELLER, C. *Seismic data denoising and deblending using deep learning*. 2019.

RICHTER, M. *Inverse Problems: Basics, Theory and Applications in Geophysics*. Springer International Publishing, 2016. ISSN 2512-3211. ISBN 9783319483849. Disponível em: <<http://dx.doi.org/10.1007/978-3-319-48384-9>>.

ROBERTS, D. A.; YAIDA, S.; HANIN, B. *The Principles of Deep Learning Theory*. [S.l.]: Cambridge University Press, 2022. <<https://deeplearningtheory.com>>.

ROBERTSSON, J. O.; AMUNDSEN, L.; PEDERSEN, A. S. Signal apparition for simultaneous source wavefield separation. *Geophysical Journal International*, v. 206, n. 2, p. 1301–1305, 06 2016. ISSN 0956-540X. Disponível em: <<https://doi.org/10.1093/gji/ggw210>>.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-net: Convolutional networks for biomedical image segmentation. In: *Lecture Notes in Computer Science*. Springer International Publishing, 2015. p. 234–241. Disponível em: <[https://doi.org/10.1007%2F978-3-319-24574-4\\_28](https://doi.org/10.1007%2F978-3-319-24574-4_28)>.

RUDER, S. An overview of gradient descent optimization algorithms. *CoRR*, abs/1609.04747, 2016. Disponível em: <<http://arxiv.org/abs/1609.04747>>.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. *Nature*, Springer Science and Business Media LLC, v. 323, n. 6088, p. 533–536, out. 1986. ISSN 1476-4687. Disponível em: <<http://dx.doi.org/10.1038/323533a0>>.

SARA, U.; AKTER, M.; UDDIN, M. S. Image quality assessment through fsim, ssim, mse and psnr—a comparative study. *Journal of Computer and Communications*, Scientific Research Publishing, Inc., v. 07, n. 03, p. 8–18, 2019. ISSN 2327-5227. Disponível em: <<http://dx.doi.org/10.4236/jcc.2019.73002>>.

SCIKIT-IMAGE. *scikit-image: Image processing in Python — scikit-image*. 2024. Disponível em: <<https://scikit-image.org/>>.

SCIPY. *SciPy.org — SciPy.org*. 2020. Disponível em: <<https://scipy.org/>>.

SEG. *Mobil AVO viking graben line 12 - SEG Wiki - wiki.seg.org*. 2021. <[https://wiki.seg.org/wiki/Mobil\\_AVO\\_viking\\_graben\\_line\\_12](https://wiki.seg.org/wiki/Mobil_AVO_viking_graben_line_12)>. [Accessed 30-08-2023].

SHAO, D. et al. Noisy2noisy: Denoise pre-stack seismic data without paired training data with labels. *IEEE Geoscience and Remote Sensing Letters*, v. 19, p. 1–5, 2022.

SMYTHE, J. Advances in obn technology: Full azimuth, long offset illumination for complex reservoirs. In: AAPG (Ed.). *AAPG Latin America and Caribbean Region GTW, Optimization of E&P Projects: Integrating Geosciences and Engineering from Block Acquisition through Production*. [S.l.: s.n.], 2017.

SONG, C. et al. Regularized deep learning for unsupervised random noise attenuation in poststack seismic data. *Journal of Geophysics and Engineering*, v. 21, n. 1, p. 60–67, 11 2023. ISSN 1742-2132. Disponível em: <<https://doi.org/10.1093/jge/gxad094>>.

SUN, J. et al. Attenuation of marine seismic interference noise employing a customized u-net. *Geophysical Prospecting*, v. 68, n. 3, p. 845–871, 2020. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/1365-2478.12893>>.

SUN, J. et al. A convolutional neural network approach to deblending seismic data. *GEOPHYSICS*, Society of Exploration Geophysicists, v. 85, n. 4, p. WA13–WA26, jan 2020. Disponível em: <<https://doi.org/10.1190/%2Fgeo2019-0173.1>>.

TENSORFLOW. *TensorFlow*. 2024. Disponível em: <<https://www.tensorflow.org/?hl=pt-br>>.

TIBSHIRANI, R. Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society. Series B (Methodological)*, [Royal Statistical Society, Oxford University Press], v. 58, n. 1, p. 267–288, 1996. ISSN 00359246. Disponível em: <<http://www.jstor.org/stable/2346178>>.

- VELASQUES, M. M. *Seismic deblending: using iterative and compressive sensing methods to quantify blending noise impact on 4D projects*. Colorado School of Mines. Arthur Lakes Library, 2020. Disponível em: <<https://hdl.handle.net/11124/174184>>.
- VENKATAKRISHNAN, S. V.; BOUMAN, C. A.; WOHLBERG, B. Plug-and-play priors for model based reconstruction. In: *2013 IEEE Global Conference on Signal and Information Processing*. [S.l.: s.n.], 2013. p. 945–948.
- WANG, B. et al. Intelligent deblending of seismic data based on u-net and transfer learning. *IEEE Transactions on Geoscience and Remote Sensing*, Institute of Electrical and Electronics Engineers (IEEE), v. 59, n. 10, p. 8885–8894, oct 2021. Disponível em: <<https://doi.org/10.1109%2Ftgrs.2020.3048746>>.
- WANG, S. et al. Seismic deblending by self-supervised deep learning with a blind-trace network. In: *First International Meeting for Applied Geoscience and Energy Expanded Abstracts*. Society of Exploration Geophysicists, 2021. Disponível em: <<https://doi.org/10.1190\%2Fsegam2021-3583662.1>>.
- WANG, X. et al. A self-supervised method using noise2noise strategy for denoising crp gathers. *IEEE Geoscience and Remote Sensing Letters*, v. 20, p. 1–5, 2023.
- WASON, H. *Simultaneous-source seismic data acquisition and processing with compressive sensing*. Tese (Doutorado) — University of British Columbia, 2017. Disponível em: <<https://open.library.ubc.ca/collections/ubctheses/24/items/1.0355227>>.
- WU, S.; BLACQUIÈRE, G.; GROENESTIJN, G.-J. Adriaan van. Shot repetition: An alternative seismic blending code in marine acquisition. *GEOPHYSICS*, Society of Exploration Geophysicists, v. 83, n. 6, p. P29–P37, nov. 2018. ISSN 1942-2156. Disponível em: <<http://dx.doi.org/10.1190/geo2017-0649.1>>.
- XU, W. et al. Seismic intelligent deblending via plug and play method with blended CSGs trained deep CNN gaussian denoiser. *IEEE Transactions on Geoscience and Remote Sensing*, Institute of Electrical and Electronics Engineers (IEEE), v. 60, p. 1–13, 2022. Disponível em: <<https://doi.org/10.1109\%2Ftgrs.2022.3166029>>.
- ZHANG, A. et al. *Dive into Deep Learning*. [S.l.: s.n.], 2020. <<https://d2l.ai>>.
- ZHANG, K. et al. Beyond a gaussian denoiser: Residual learning of deep cnn for image denoising. *IEEE Transactions on Image Processing*, v. 26, n. 7, p. 3142–3155, 2017.
- ZHANG, X.-D. References. In: \_\_\_\_\_. *Matrix Analysis and Applications*. [S.l.]: Cambridge University Press, 2017. p. 681–707.
- ZHAO, Y. et al. Low-frequency noise suppression method based on improved dncnn in desert seismic data. *IEEE Geoscience and Remote Sensing Letters*, v. 16, n. 5, p. 811–815, 2019.
- ZHENG, Y.; YUAN, Y.; SI, X. The improved dncnn for linear noise attenuation. In: \_\_\_\_\_. *SEG 2019 Workshop: Mathematical Geophysics: Traditional vs Learning, Beijing, China, 5–7 November 2019*. [s.n.], 2020. p. 56–59. Disponível em: <[https://library.seg.org/doi/abs/10.1190/iwmg2019\\_14.1](https://library.seg.org/doi/abs/10.1190/iwmg2019_14.1)>.

ZU, S. et al. Iterative deblending for simultaneous source data using the deep neural network. *GEOPHYSICS*, v. 85, n. 2, p. V131–V141, 2020. Disponível em: <<https://doi.org/10.1190/geo2019-0319.1>>.