

Biblioteca Universitária



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

Vinicius Guedes dos Santos

**COMPARAÇÃO DE DESEMPENHO DE DIFERENTES ARQUITETURAS DE
REDES NEURAS UTILIZADAS EM INVERSÃO SÍSMICA**

Florianópolis, Santa Catarina – Brasil
2022

Vinicius Guedes dos Santos

**COMPARAÇÃO DE DESEMPENHO DE DIFERENTES ARQUITETURAS DE
REDES NEURAS UTILIZADAS EM INVERSÃO SÍSMICA**

Trabalho de Conclusão de Curso submetido ao Programa de Graduação em Ciências da Computação da Universidade Federal de Santa Catarina para a obtenção do Grau de Bacharel em Ciências da Computação.

Orientador(a): Mauro Roisenberg, Dr.

Florianópolis, Santa Catarina – Brasil

2022

Catálogo na fonte pela Biblioteca Universitária da Universidade Federal de Santa Catarina.
Arquivo compilado às 19:42h do dia 23 de março de 2022.

Vinicius Guedes dos Santos

Comparação de Desempenho de Diferentes Arquiteturas de Redes Neurais Utilizadas em Inversão Sísmica / Vinicius Guedes dos Santos; Orientador(a), Mauro Roisenberg, Dr. - Florianópolis, Santa Catarina - Brasil, 08 de março de 2022.

70 p.

Trabalho de Conclusão de Curso - Universidade Federal de Santa Catarina, INE - Departamento de Informática e Estatística, CTC - Centro Tecnológico, Programa de Graduação em Ciências da Computação.

Inclui referências

1. Inversão Sísmica, 2. Aprendizagem de máquina, 3. Impedância Acústica, 4. Redes Neurais Artificiais, I. Mauro Roisenberg, Dr. II. Programa de Graduação em Ciências da Computação III. Comparação de Desempenho de Diferentes Arquiteturas de Redes Neurais Utilizadas em Inversão Sísmica

CDU 02:141:005.7

Vinicius Guedes dos Santos

COMPARAÇÃO DE DESEMPENHO DE DIFERENTES ARQUITETURAS DE REDES NEURAIS UTILIZADAS EM INVERSÃO SÍSMICA

Este(a) Trabalho de Conclusão de Curso foi julgado adequado(a) para obtenção do Título de Bacharel em Ciências da Computação, e foi aprovado em sua forma final pelo Programa de Graduação em Ciências da Computação do INE – Departamento de Informática e Estatística, CTC – Centro Tecnológico da Universidade Federal de Santa Catarina.

Florianópolis, Santa Catarina – Brasil, 08 de março de 2022.

Jean Everson Martina, Dr.

Coordenador(a) do Programa de
Graduação em Ciências da Computação

Banca Examinadora:

Mauro Roisenberg, Dr.

Orientador(a)
Universidade Federal de Santa
Catarina – UFSC

Prof. Daniel Santana de Freitas, Dr.

Universidade Federal de Santa Catarina –
UFSC

Prof. Elder Rizzon Santos, Dr.

Universidade Federal de Santa Catarina –
UFSC

*Este trabalho é dedicado à Mariah, minha prima,
por ser um dos motivos pelos quais eu mais desejo
o sucesso nesta vida.*

AGRADECIMENTOS

Agradeço a minha família que me apoiou durante todos esses anos na universidade e também muito antes disso em assuntos diversos que não cabem ser citados, mas que eles sabem quais são.

Agradeço ao meu amigo Thiago Cavalheiro que durante estes anos de curso me serviu como um grande exemplo de sucesso acadêmico e também me ajudou na revisão deste trabalho.

Agradeço a todos os ex-colegas do LabSEC pelos momentos de trabalho e de descontração que tivemos juntos, especialmente ao Pablo Montezano, por ter me dado a oportunidade de trabalhar lá e, assim, complementar significativamente minha formação.

Agradeço ao meu orientador Mauro Roisenberg por ter acreditado em mim para fazer este trabalho e por ter me instruído ao longo destes semestres.

RESUMO

Na geofísica, o conceito de inversão sísmica se refere ao processo de obter propriedades da subsuperfície a partir de dados sísmicos. O conhecimento sobre as propriedades da subsuperfície é muito útil no campo de extração de petróleo e gás. O uso de redes neurais artificiais para inversão sísmica pode melhorar esse processo em velocidade, qualidade das estimativas e redução da necessidade de perfuração de poços exploratórios. Esse trabalho tem como objetivo comparar, dado um mesmo conjunto de dados e mesmas métricas, o desempenho de propostas de arquiteturas de redes neurais utilizadas na realização de inversão sísmica para obtenção da propriedade de impedância acústica.

Palavras-chaves: Inversão Sísmica. Aprendizagem de máquina. Impedância Acústica. Redes Neurais Artificiais.

ABSTRACT

In geophysics, seismic inversion refers to the process of obtaining subsurface properties from seismic data. The knowledge about subsurface properties is very useful in the field of oil and gas extraction. The use of artificial neural networks may improve such process in terms of velocity, estimation quality and by reducing the need of exploratory well drilling. The present work aims to compare, when given the same dataset and same metrics, the performance of different proposed neural network architectures used in seismic inversion to extract acoustic impedance.

Keywords: Seismic Inversion. Machine Learning. Acoustic Impedance. Artificial Neural Networks.

LISTA DE FIGURAS

Figura 1	– Visão esquemática de um perceptron. Os x_i representam os componentes do vetor de entrada, os w_i representam os pesos, o b representa o <i>bias</i> $\phi(\cdot)$ é uma função de ativação e y é a saída . . .	18
Figura 2	– Gráfico da função ReLU.	20
Figura 3	– Gráfico da função sigmoid.	20
Figura 4	– Gráfico da função tangente hiperbólica.	21
Figura 5	– Visão esquemática de uma rede neural de várias camadas. . . .	22
Figura 6	– Representação das conexões entre uma região de uma imagem e um neurônio na camada oculta	23
Figura 7	– Representação da convolução como uma janela deslizante	23
Figura 8	– Exemplo de uma operação de pooling com a função max-pooling, stride 2 e tamanho 2x2	24
Figura 9	– Seção sísmica de reflexão. O eixo vertical representa o tempo duplo de trânsito, o eixo horizontal um traço de refletividade da terra. Cor próxima ao preto representa onda com amplitude máxima negativa e branco positiva	27
Figura 10	– Esquema demonstrando o método de geração do pulso e captura dos traços sísmicos na sísmica de superfície	27
Figura 11	– Arquitetura da rede proposta por (MUSTAFA; ALFARRAJ; ALRE-GIB, 2019). Entre parêntesis o tamanho da entrada e da saída do bloco, respectivamente	31
Figura 12	– Arquitetura de um <i>Temporal Block</i> de uma TCN.	32
Figura 13	– Arquitetura da rede proposta por (DAS <i>et al.</i> , 2019).	33
Figura 14	– Arquiteturas de um (a) bloco residual e do (b) gerador.	34
Figura 15	– (a) Arquitetura do codificador. (b) Arquitetura de uma camada de <i>pooling</i> de pirâmide espacial de Atrous. (c) Arquitetura do discriminador.	35
Figura 16	– Detalhamento das estruturas do conjunto de dados Marmousi2 .	37
Figura 17	– Comparação entre a inversão realizada pela CNN e a impedância acústica verdadeira	39
Figura 18	– MSE de treino e validação ao longo do treinamento da CNN . . .	40
Figura 19	– Comparação entre a impedância acústica prevista pela CNN e a impedância acústica verdadeira de alguns traços do conjunto de teste	40
Figura 20	– Comparação entre a inversão realizada pela CNN e a impedância acústica verdadeira	42
Figura 21	– MSE de treino e validação ao longo do treinamento da TCN . . .	43

Figura 22	–	Comparação entre a impedância acústica prevista pela TCN e a impedância acústica verdadeira de alguns traços do conjunto de teste. Esta comparação demonstra a superioridade desta arquitetura especialmente para o traço 7003	43
Figura 23	–	Comparação entre a inversão realizada pela GAN e a impedância acústica verdadeira. No geral, o resultado foi inferior ao da TCN, mas foi aparentemente melhor em regiões mais profundas.	44
Figura 24	–	Comparação entre a impedância acústica prevista pela GAN e a impedância acústica verdadeira de alguns traços do conjunto de teste. Esta comparação demonstra a superioridade desta arquitetura especialmente para o traço 7003.	44

LISTA DE TABELAS

Tabela 1	– Apresentação dos resultados obtidos pela TCN nos experimentos realizados pelos autores.	32
Tabela 2	– Apresentação do resultado da GAN obtido no experimento dos autores.	34
Tabela 3	– Apresentação do resultado de cada arquitetura sob cada uma das métricas avaliadas. Em negrito o melhor resultado para cada métrica.	43

LISTA DE ABREVIATURAS E SIGLAS

CNN	Rede Neural Convolucional
RNN	Rede Neural Recorrente
TCN	Rede Temporal Convolucional
GAN	Rede Geradora Adversária
MSE	Erro Quadrático Médio
MAE	Erro Absoluto Médio
MedAE	Erro Absoluto Mediano
PCC	Coeficiente de Correlação de Pearson
SSIM	Índice de Similaridade Estrutural

LISTA DE SÍMBOLOS

$*$	Convolução
$*_d$	Convolução Dilatada
r^2	Coefficiente de Determinação

SUMÁRIO

1	INTRODUÇÃO	16
1.1	OBJETIVOS	17
1.1.1	Objetivo Geral	17
1.1.2	Objetivos Específicos	17
1.2	ESTRUTURA DO TRABALHO	17
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	REDES NEURAIS ARTIFICIAIS	18
2.1.1	O Perceptron	18
2.1.2	Funções de ativação	19
2.1.3	Redes de várias camadas	21
2.1.4	Redes Neurais Convolucionais	21
2.1.5	Redes Neurais Recorrentes	24
2.1.6	Redes Geradoras Adversárias	24
2.1.7	Redes Convolucionais Temporais	25
2.2	INVERSÃO SÍSMICA	26
2.2.1	Sismologia de Reflexão	26
2.2.2	Impedância Acústica	26
2.2.3	Sísmica de superfície	27
2.2.4	Refletividade	28
2.2.5	Wavelet	28
2.2.6	Modelo Convolucional	28
2.2.7	Inversão Recursiva	29
2.2.8	Inversão Baseada em Modelos	29
2.2.9	Inversão Baseada em Redes Neurais Artificiais	29
3	TRABALHOS CORRELATOS	31
3.1	REDE CONVOLUCIONAL TEMPORAL	31
3.2	REDE NEURAL CONVOLUCIONAL	32
3.3	REDE GERADORA ADVERSÁRIA	33
4	EXPERIMENTOS E DISCUSSÃO	36
4.1	ESCOLHA DO <i>DATASET</i>	36
4.2	ESCOLHA DOS TRAÇOS	38
4.3	REDE NEURAL CONVOLUCIONAL	38
4.4	REDE CONVOLUCIONAL TEMPORAL	40
4.5	REDE GERADORA ADVERSÁRIA	41
4.6	COMPARAÇÃO DE MÉTRICAS	41

5	CONSIDERAÇÕES FINAIS	45
	REFERÊNCIAS	46
	APÊNDICE A – ARTIGO DO TCC	51

1 INTRODUÇÃO

A inversão sísmica é um processo de transformação de dados sísmicos de reflexão em dados quantitativos das propriedades das rochas (CHEN *et al.*, 2016). Dados sísmicos de reflexão são registros de ondas sonoras captados na superfície da área de estudo, na qual essa onda é artificialmente criada por algum dispositivo, como explosivo ou canhão de ar comprimido, e propaga-se pelo volume do terreno, sendo parcialmente refletida ao longo do caminho (especialmente nas trocas de meio). Essas ondas refletidas são capturadas por sensores na superfície e depois rearranjadas de forma a criar um registro sísmico (ou simplesmente "sísmica") da porção do terreno logo abaixo do sensor (SOUZA, 2018). Existem várias técnicas de inversão sísmica e elas geralmente se baseiam também em outros dados além dos registros sísmicos de reflexão, por exemplo, em registros de poços perfurados na região.

O problema da inversão sísmica não é um problema bem-posto, isto é, não é linear e não tem solução única, de forma que um mesmo registro sísmico pode ser gerado por diferentes combinações de solo e onda (CHEN *et al.*, 2016). Por esse motivo, nenhum dos métodos de inversão sísmica atualmente existentes pode ser considerado ideal, o que tem levado ao constante desenvolvimento de novos modelos, entre eles, aqueles baseados em redes neurais.

Na indústria de óleo e gás, a inversão sísmica é um dos métodos mais utilizados para a caracterização de reservatórios e é fundamental para reduzir a necessidade de perfuração de poços, o qual é tipicamente um processo muito caro e demorado (RUSSELL, 1988).

Uma rede neural artificial é um algoritmo computacional inspirado no funcionamento do cérebro. Uma rede neural é uma função matemática capaz de mapear um conjunto de entrada para um conjunto de saídas. Os algoritmos orientados à redes neurais requerem o uso de um conjunto de dados composto de pares de entradas e saídas que são utilizados no processo de refinamento dessa função matemática, similarmente a uma regressão linear (GOODFELLOW; BENGIO; COURVILLE, 2016).

No contexto da inversão sísmica, as abordagens mais tradicionais consistem em criar modelos do solo, testar sua aderência aos dados obtidos, ajustar o modelo e assim iterativamente até que se obtenha um modelo bom o suficiente, caracterizando um processo de otimização. Por outro lado, a abordagem que utiliza redes neurais artificiais requer simplesmente que se conheçam conjuntos de entradas e saídas para treinar a rede, dispensando a necessidade de criação de modelos do solo.

Dadas as vantagens citadas do uso de redes neurais, diversos modelos já foram propostos (YANG; MA, 2019; MUSTAFA; ALFARRAJ; ALREGIB, 2019; DAS *et al.*, 2019; LI *et al.*, 2020; WU; MENG; ZHAO, 2021). Todos os modelos propostos foram testados e validados por seus respectivos autores, mas utilizando dados e métricas

diferentes, alguns até mesmo utilizando dados gerados para aquele fim exclusivo, de forma que não há uma comparação de todos eles para um mesmo conjunto de entradas e para um mesmo critério de comparação. Portanto, o objetivo deste trabalho é testar diversas implementações disponíveis, considerando um mesmo conjunto de dados público cujas entradas e saídas da inversão sejam previamente conhecidas, a fim de determinar qual deles realiza a inversão com melhor correlação com a saída esperada. Além da comparação dos resultados propriamente ditos, também será feita uma descrição de cada uma das implementações, de maneira que se possa não apenas entender qual gera resultados mais próximos a impedância acústica real, mas também quais são suas características, o que pode ajudar a guiar implementações futuras.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

Comparar propostas de redes neurais utilizadas no processo de inversão sísmica sob um mesmo conjunto de dados, treinadas com o mesmo conjunto de treinamento e avaliadas utilizando as mesmas métricas

1.1.2 Objetivos Específicos

- Apresentar conceitos de inversão sísmica.
- Apresentar conceitos de redes neurais.
- Pesquisar na literatura as propostas de algoritmos de inversão sísmica baseados em redes neurais disponíveis.
- Apresentar uma descrição das propostas escolhidas.
- Encontrar um *dataset* adequado para o teste das implementações.
- Testar as propostas escolhidas e compará-las.

1.2 ESTRUTURA DO TRABALHO

O Capítulo 1 apresenta a proposta do trabalho. O Capítulo 2 expõe alguns conceitos básicos tanto sobre inversão sísmica quanto sobre redes neurais artificiais. O Capítulo 3 introduz as implementações que serão testadas. O Capítulo 4 descreve os experimentos realizados e os resultados obtidos. O Capítulo 5 contém as conclusões.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 REDES NEURAIS ARTIFICIAIS

A inspiração para o desenvolvimento das redes neurais artificiais surgiu do estudo das redes neurais biológicas. No passado, tinha-se a ideia de que o cérebro armazenava todo seu conhecimento de forma codificada, isto é, havia um mapeamento um para um de um estímulo sensorial (uma vista, um som, etc.) para uma estrutura armazenada em algum lugar do cérebro (CULBERSTON, 1950). Entretanto, com o avanço da neurologia, novas teorias surgiram, entre elas a de Donald Hebb (SHAW, 1986) que propôs que o conhecimento, na verdade, não é armazenado na forma de um conjunto de estímulos conhecidos, mas sim que o cérebro age como uma complexa rede de nodos interruptores e que o aprendizado se dá pela criação de novas conexões e caminhos entre esses nodos. Uma rede neural artificial aprende de forma muito similar a esta, como será mostrado nas próximas seções.

2.1.1 O Perceptron

O perceptron, também chamado de neurônio, é a estrutura fundamental de uma rede neural. Ele é um classificador linear binário que pode ser modelado para operar sobre um espaço linear de qualquer ordem (ROSENBLATT, 1958).




Figura 1 – Visão esquemática de um perceptron. Os x_i representam os componentes do vetor de entrada, os w_i representam os pesos, o b representa o *bias* $\phi(\cdot)$ é uma função de ativação e y é a saída

Fonte: (HEMMATINEZHAD *et al.*, 2021)

O perceptron pode ser definido da seguinte forma:

$$f(x) = \begin{cases} 1, & \text{se } w \cdot x + b \geq 0 \\ 0, & \text{se } w \cdot x + b < 0 \end{cases},$$

onde w é o vetor de pesos, x é o vetor de entrada (análogo a um estímulo) e b é o viés (do inglês, *bias*) que é uma constante real. O conhecimento em um neurônio é representado pelos pesos e pelo viés, pois os mesmos determinam a saída para uma dada entrada. O valor dos pesos e do viés que melhor aproximam uma função desejada é determinado por um processo de treinamento que envolve utilizar um conjunto de pares de vetores de entrada e a saídas, ambos conhecidos, e calcular que parâmetros (pesos e viés) geram uma função que tem o menor erro para o conjunto dado. O treinamento é realizado da seguinte forma:

Seja $V = \{v_1, \dots, v_k\}$ um conjunto de entradas, $Y = \{y_1, \dots, y_k\}$ um conjunto de saídas tal que y_i é a saída esperada para a entrada v_i , w o vetor de pesos e b o viés, o erro médio quadrático cometido para um dado conjunto de pesos é dado por:

$$e(w_1, \dots, w_k, b) = \sum_{i=1}^k (w \cdot v_i + b - y_i)^2$$

Dessa forma, obter o conjunto de pesos que melhor aproxima a saída Y , dado o conjunto V , se resume a minimizar a função $e(w_1, \dots, w_k, b)$. A minimização da função $e(w_1, \dots, w_k, b)$ pode ser realizada de forma analítica, calculado a derivada parcial para cada peso w_i e para o viés b e em seguida resolvendo um sistema linear de ordem $k + 1$, mas também pode ser calculado através de métodos numéricos que facilitam esse processo para redes neurais mais complexas (RUDER, 2016).

2.1.2 Funções de ativação

Depois de aplicados os pesos e o viés do neurônio à entrada, o valor obtido é passado como parâmetro para uma função, essa função é chamada de função de ativação. No exemplo do perceptron visto, a função tinha uma saída binária, mas existem outras funções que permitem melhores previsões em diferentes contextos (NWANKPA *et al.*, 2018). Seja $z = w \cdot x + b$ resultado da aplicação dos pesos e do viés à entrada, o valor de saída do neurônio é dado pela aplicação de z a uma função de ativação. Alguns exemplos de função de ativação são:

Rectified Linear Unit - ReLU:

A função ReLU foi desenvolvida por Nair e Hinton em 2010 e desde então se tornou a função de ativação mais comum em redes neurais com resultados de estado da arte (NWANKPA *et al.*, 2018). Essa função tem limite inferior em 0 e não tem limite superior. É uma função quase linear, não sendo derivável apenas no ponto $z = 0$,

conforme mostrado na Figura 2. A função de ativação ReLU é dada por:

$$f(z) = \max(0, z) = \begin{cases} 1, & \text{se } z \geq 0 \\ 0, & \text{se } z < 0 \end{cases}$$

Função Sigmoid ou Logística:

Essa é uma função não linear cuja imagem tem um limite tanto inferior quanto superior, como visto na Figura 3, o que permite que ela seja utilizada em problemas de classificação ou probabilidade, isto é, dada uma entrada indicar a probabilidade de ela pertencer ou não a uma categoria. A função logística é dada por:

$$f(z) = \frac{1}{1 + e^{-z}}$$

Função tangente hiperbólica (*tanh*):

Muito similar a função *sigmoid*, também é utilizada em problemas de probabilidade, tem a característica de ter 0 como raiz, o que é uma vantagem para o treinamento (NWANKPA *et al.*, 2018). O gráfico da função *tanh* pode ser visto na Figura 4. A função *tanh* é dada por:

$$f(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$




Figura 2 – Gráfico da função ReLU.

Fonte: (BROWNLEE, 2021)




Figura 3 – Gráfico da função sigmoid.

Fonte: (BROWNLEE, 2021)




Figura 4 – Gráfico da função tangente hiperbólica.

Fonte: (BROWNLEE, 2021)

2.1.3 Redes de várias camadas

Embora sejam ferramentas muito poderosas, os perceptrons tem diversas limitações, como mostrado por (MINSKY; PAPERT, 1969). Neste livro, Minsky e Papert desmonstram matematicamente, entre outras coisas, a limitação aos problemas lineares dos perceptrons, isto é, eles não são capazes de classificar problemas não linearmente separáveis, como por exemplo uma função lógica ou-exclusivo, o que os torna pouco úteis na solução de problemas do mundo real. A solução para o problema encontrado foi a combinação de perceptrons na forma de camadas, caracterizando uma rede. Uma rede neural tem pelo menos três camadas: uma de entrada, que tem número de neurônios igual a dimensão da entrada do problema, uma ou mais camadas escondidas que tem número variável de neurônios dependendo da estratégia escolhida e uma camada de neurônios de saída, cuja dimensão está relacionada ao tipo de saída do problema. A primeira camada de uma rede é alimentada pelo vetor de entrada, enquanto que as camadas escondidas e a de saída são alimentadas pelas saídas de outras camadas. Diferentemente dos perceptrons, as redes neurais são capazes de aproximar qualquer problema que possa ser modelado como uma função, como foi demonstrado por (HORNIK; STINCHCOMBE; WHITE, 1989) no teorema da aproximação universal. Dessa forma, são capazes de modelar muitos problemas do mundo real.

2.1.4 Redes Neurais Convolucionais

Redes neurais convolucionais tem sido amplamente utilizadas para o reconhecimento de padrões nos últimos anos (ALBAWI; MOHAMMED; AL-ZAWI, 2017). Os principais benefícios na utilização desse tipo de rede são a redução do número de pesos e a capacidade de reconhecer padrões em espaços multidimensionais, como em imagens, videos e áudios. Supondo que se deseje criar uma rede neural capaz de detectar padrões em imagens de tamanho 32x32x3 pixels (largura x altura x profundidade). Em uma rede típica, conectar a camada de entrada a um único neurônio requereria 32x32x3 conexões e conectar a apenas dois neurônios requereria mais de 6000 conexões, contudo, pode-se supor que dois neurônios não são suficientes para




Figura 5 – Visão esquemática de uma rede neural de várias camadas.

Fonte: (AHMADIAN; KHANTEYMOORI, 2015)

realizar praticamente nenhum reconhecimento de padrões. Supondo uma rede mais realista, capaz de reconhecer bordas entre objetos em uma imagem, por exemplo, seria necessária uma camada oculta com a mesma dimensão que a entrada, que se fosse totalmente conectada com a camada de entrada, teria 3.145.728 de conexões, isso para uma imagem de baixíssima resolução (32x32).

Na procura de uma abordagem melhor, foram criadas as redes neurais convolucionais, neste tipo de rede, um neurônio dessa primeira camada oculta recebe apenas conexões de uma pequena porção da imagem, e não de todos os pixels, conforme mostrado na Figura 6, de forma que é capaz de encontrar o padrão desejado apenas naquela porção da imagem. Supondo que cada neurônio da camada oculta esteja conectado a uma região de tamanho 5x5 de entrada, o número total de conexões será 76.800, o que já representa uma queda significativa, mas ainda é possível reduzir mais ainda este valor. Sabendo que o objetivo desse tipo de rede é encontrar padrões independentemente de onde eles estejam posicionados no espaço, pode-se considerar que todos esses conjuntos de conexões de tamanho 5x5 tenham os mesmos valores para os pesos, afinal, não é necessário aprender um padrão diferente para cada região da imagem, de forma que aplicar o mesmo conjunto de pesos a toda a imagem, pedaço por pedaço, já é suficiente para encontrar as informações desejadas. Dessa forma, consegue-se reduzir o número de conexões para apenas 75 (5x5x3). O fato de que os pesos são aplicados na forma de uma janela deslizante à entrada deu o nome "convolucional" a este tipo de rede, pois esta operação é inspirada na convolução de matrizes da matemática (ALBAWI; MOHAMMED; AL-ZAWI, 2017).

No exemplo dado, considerou-se que a janela da convolução sempre desliza de um em um, mas isso nem sempre é verdade, pois pode-se deslizar em intervalos maiores. O tamanho do passo desse deslizamento é chamado de *stride*.




Figura 6 – Representação das conexões entre uma região de uma imagem e um neurônio na camada oculta

. Fonte: (ALBAWI; MOHAMMED; AL-ZAWI, 2017)




Figura 7 – Representação da convolução como uma janela deslizante

. Fonte: (ALBAWI; MOHAMMED; AL-ZAWI, 2017)

Outro ponto a ser notado é que a convolução mapeia uma região da entrada para um único neurônio, o que faz com que informação das bordas seja perdida. Para evitar que parte da entrada seja perdida (o que é indispensável no caso de haverem várias camadas de convolução), pode-se adicionar um preenchimento (em inglês chamado de *padding*) às bordas, que geralmente é o valor 0. Além da camada de convolução, redes neurais convolucionais também costumam utilizar uma camada de ativação não-linear para saturar ou limitar os valores da saída da camada de convolução e também uma camada de *pooling*, a qual tem a finalidade de reduzir a complexidade para as camadas que o sucedem. A operação de *pooling* é similar a convolução, no sentido de também ser aplicada em pequenas porções do espaço, conforme mostrado na Figura 8, porém sem pesos e com objetivo de reduzir o tamanho da entrada. A função de *pooling* também age como uma janela deslizante que seleciona apenas um valor que será mantido para a próxima camada. O tamanho das regiões de cada iteração do processo de *pooling* costuma ser pequeno (2x2 ou 3x3) e a função mais comum é a *max-pooling*, em que o valor máximo naquela janela é selecionado. Em imagens, a operação de *pooling* é equivalente a redução de resolução.




Figura 8 – Exemplo de uma operação de pooling com a função max-pooling, stride 2 e tamanho 2x2

. Fonte: (ALBAWI; MOHAMMED; AL-ZAWI, 2017)

2.1.5 Redes Neurais Recorrentes

Redes neurais recorrentes (conhecidas pela sigla em inglês RNN) são aplicadas a problemas que envolvem dados temporais ou sequenciais como, por exemplo, reconhecimento de fala. Redes desse tipo também são treinadas por conjuntos de entradas e saídas, mas diferentemente dos outros tipos de redes, estas tem entrada de tamanho variável que é processada em passos. Outra característica exclusiva das redes neurais recorrentes é a existência de ciclos nas conexões, isto é, alguns neurônios se conectam a si mesmos. Essa conexão cíclica serve para criar uma memória que permite à rede levar em consideração a informação recebida em cada passo da leitura de uma sequência de entrada. Tomando como exemplo uma rede que reconhece padrões em textos, pode-se interpretar o texto como uma sequência de entrada e cada palavra como a entrada de um passo. Assim, é fácil ver que o significado de cada palavra lida depende das palavras lidas anteriormente e também é impossível criar uma rede convencional que lê um texto de qualquer tamanho pois estas requerem que a dimensão da entrada seja igual ao número de neurônios na camada de entrada, logo, esse tipo de entrada de tamanho variável só pode ser lida em passos.

2.1.6 Redes Geradoras Adversárias

(GOODFELLOW; POUGET-ABADIE *et al.*, 2020) propuseram um novo tipo de rede neural chamadas de Redes Geradoras adversárias (ou GANs, na sigla em inglês) que são tipos de redes neurais que não realizam regressão ou classificação, mas sim aprendem o padrão de um conjunto de dados a fim de gerar novos elementos que sejam indistinguíveis de um elemento original do conjunto. Uma GAN é formada por duas redes multicamadas treinadas simultaneamente, uma delas é chamada de

geradora (G) e a outra de discriminadora (D). No caso de ambas as redes serem formadas por multicamadas de perceptrons, tem-se que a rede geradora pode ser descrita como $G(z, \theta_z)$ onde θ_z é o conjunto de pesos da rede e z é um escalar de entrada. Já a rede discriminadora pode ser descrita como $D(x, \theta_d)$ onde x é um elemento que será classificado como pertencente ou não ao conjunto de dados e θ_d é o conjunto de neurônios da rede. Tem-se ainda que a saída da rede G tem a dimensão dos elementos do conjunto de dados, a entrada da rede D é um candidato a elemento do conjunto de dados, isto é, tem a mesma dimensão que os elementos do conjunto. Já a saída $D(x)$ é a probabilidade do elemento x pertencer ao conjunto de dados original, ou seja, não ter sido gerado por G .

Pode-se dizer que o processo treinamento de uma GAN é análogo a um processo de produção de cédulas falsas em que existe um criminoso que produz as cédulas e um policial que detecta a autenticidade de nota. Cada vez que uma nota falsa é identificada como tal, o criminoso refina seu processo de falsificação e o policial seu processo de detecção até que a taxa de acertos do policial seja 50%, ou seja, as cédulas falsas passam a ser indistinguíveis das originais. O treinamento de ambas as redes é feito de maneira alternada, para cada época de treinamento de G , uma ou mais épocas de treinamento de D são realizadas. O objetivo do treinamento da rede D é maximizar a probabilidade dela identificar se um dado veio do conjunto original ou não, já o treinamento da rede G tem como objetivo minimizar a função $\log(1 - D(G(k)))$ que diminui com o aumento do erro da rede D .

2.1.7 Redes Convolucionais Temporais

(LEA *et al.*, 2016) propuseram uma classe de arquiteturas de redes neurais convolucionais chamada de Redes Convolucionais Temporais (ou TCNs). Esse tipo de rede tem o objetivo de ser capaz de encontrar padrões em entradas muito longas onde valores muito espaçados podem estar conectados. Uma das aplicações em que esse tipo de rede foi utilizada até o momento é na aprendizagem de padrões em vídeos, sendo útil nesse tipo de dado, pois tem a capacidade de utilizar frames de vários instantes de tempo ao mesmo tempo ao calcular a saída. Enquanto uma CNN normal leva em consideração uma porção da entrada correspondente ao tamanho do seu núcleo, as TCNs usam uma técnica chamada de convolução dilatada para permitir um aumento na porção da entrada utilizada em cada passo. A convolução dilatada é definida como um tipo de convolução em que os componentes do vetor de entrada não são componentes contínuos da entrada, mas estão separados por um número d de componentes, o que pode ser descrito da seguinte forma:

$$F(s) = (x *_d f)(s) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-d \cdot i},$$

no qual x é um elemento da entrada, $f : \{0, \dots, k - 1\} \rightarrow \mathbb{R}$ a função que aplica o núcleo da convolução e F a função que aplica a convolução, e $*_d$ representa a operação de convolução dilatada.

2.2 INVERSÃO SÍSMICA

A inversão sísmica é o processo pelo qual se obtém propriedades do subsolo a partir de dados sísmicos.

2.2.1 Sismologia de Reflexão

A sismologia de reflexão é o método pelo qual se explora as propriedades da terra a partir de ondas de reflexão geradas por um pulso na superfície e refletidas pelas interfaces entre diferentes tipos de material no subsolo. Existem duas formas diferentes de se captar esses dados: a sismologia da superfície, onde os sensores e a fonte do pulso de energia ficam na superfície e a VSP (Vertical Seismic Profile), onde a fonte de energia assim como os sensores ficam dentro do poço. O foco deste trabalho é a sísmica de superfície, que é baseada na ideia de que quando um pulso de energia é produzido na superfície, ele percorre o solo até encontrar uma interface entre duas camadas de diferentes litologias, tal que nessa interface, parte da energia da onda é refletida e parte dela segue em direção ao subsolo. As porções de energia refletida são capturadas pelos sensores e, posteriormente, utilizadas como entrada para os métodos de inversão sísmica. Um parâmetro importante que determina o tamanho do dado capturado é o *Record Length*. Esse valor determina o tempo pelo qual os sensores ficarão ativos após emitido o pulso de energia. Embora um *Record Length* maior permita captar informações de reflexões em maiores profundidades, também é fato que a onda perde energia cada vez que é refletida, de forma que as ondas vindas de camadas mais profundas se tornam praticamente imperceptíveis e não são úteis para o processo de inversão. (SOUZA, 2018)

2.2.2 Impedância Acústica

A impedância acústica (Z) é uma grandeza relacionada a dificuldade com que uma onda sonora encontra ao viajar por um material, sendo dependente da velocidade pela qual a onda viaja (V) e da densidade do material (ρ). Embora seja uma característica acústica, a impedância está fortemente relacionada a propriedades petroelásticas do material e, por esse motivo, é de grande interesse dos geofísicos para a determinação das características do solo (MAVKO; MUKERJI; DVORKIN, 2009).




Figura 9 – Seção sísmica de reflexão. O eixo vertical representa o tempo duplo de trânsito, o eixo horizontal um traço de refletividade da terra. Cor próxima ao preto representa onda com amplitude máxima negativa e branco positiva

. Fonte: (SOUZA, 2018)

2.2.3 Sísmica de superfície

Existem duas maneiras pelas quais é possível registrar as ondas refletidas pelas interfaces entre as camadas de rocha: posicionando os sensores no interior dos poços perfurados ou posicionando-os na superfície, esta última, que o foco deste trabalho, é ilustrada pela Figura 10.




Figura 10 – Esquema demonstrando o método de geração do pulso e captura dos traços sísmicos na sísmica de superfície

. Fonte: (SOUZA, 2018)

2.2.4 Refletividade

O coeficiente de reflexão ou refletividade da terra é um conceito que indica quanto da energia de uma onda é refletida por uma interface entre duas camadas de rocha com diferentes valores de impedância acústica. Seja Z_k a impedância de uma camada de rocha e Z_{k+1} a impedância da camada de rocha logo abaixo, a refletividade (r_k) da interface entre essas duas camadas, considerando uma interface totalmente plana e uma onda perpendicular à interface, é dada por:

$$r_k = \frac{Z_{k+1} - Z_k}{Z_{k+1} + Z_k}$$

2.2.5 Wavelet

A *Wavelet* é a onda que resulta do pulso na superfície (*air-gun*, explosivo, etc). Ela depende da composição do solo e se altera enquanto o percorre. Estimar a wavelet é um processo importante para os métodos tradicionais de inversão sísmica e existem diversas maneiras de executá-lo (BROWN; MCELHATTAN; SANTIAGO, 1988; HERRERA; BAAN, 2012; SHEN *et al.*, 2020). Isolar a *wavelet* permite aos métodos tradicionais determinar a refletividade das interfaces e, conseqüentemente, a impedância acústica, mas as abordagens baseadas em redes neurais artificiais eliminam essa necessidade do processo (SOUZA, 2018).

2.2.6 Modelo Convolutacional

A forma mais simples de determinar um traço sísmico unidimensional é através do modelo convolutacional. Esse modelo toma como parâmetros a função que representa a *wavelet*, a função de refletividade e uma função de ruído. Haja visto que a refletividade só é diferente de zero em um conjunto finito de pontos, representar a refletividade do solo como uma função requer o uso da função Delta de Dirac. Dessa forma, seja N o número de camadas, k o índice correspondente a posição da camada, r_k o tempo de reflexão entre duas camadas e τ_k o tempo entre a emissão da onda e o retorno da reflexão para o receptor (chamado de tempo de trânsito duplo), a função refletividade é definida como (RUSSELL, 1988):

$$r(t) = \sum_{k=1}^n r_k \delta(t - \tau_k).$$

Uma vez que a refletividade está definida como uma função, pode-se definir o modelo convolutacional, que fornece o traço sísmico da seguinte maneira:

$$s(t) = w(t) * r(t) + n(t),$$

onde $s(t)$ é o traço sísmico, $w(t)$ é a função da wavelet, $r(t)$ é a função de refletividade, $n(t)$ uma função de ruído e $*$ a operação de convolução. O processo de obtenção

da sísmica a partir da wavelet e da refletividade é chamado de Modelagem Sísmica Direta e é o processo inverso a inversão sísmica, onde se conhece o traço sísmico e deseja-se obter a wavelet e a refletividade.

2.2.7 Inversão Recursiva

A técnica de inversão sísmica mais simples é a inversão recursiva, que se baseia em três premissas: o modelo convolucional é válido, a impedância da primeira camada é conhecida e a subsuperfície é composta por camadas paralelas, com interfaces planas entre si e de impedância constante (SOUZA, 2018). Como apresentado anteriormente, a refletividade entre duas camadas é dada por

$$r_k = \frac{Z_{k+1} - Z_k}{Z_{k+1} + Z_k}$$

e, usando de algebrismo, é possível reescrever a expressão acima como

$$Z_{k+1} = Z_k \left(\frac{1 + r_k}{1 - r_k} \right)$$

o que permite encontrar a impedância da próxima camada dada a refletividade e a impedância da camada anterior. Se todas as refletividades foram conhecidas, pode obter todas impedâncias aplicando a equação acima sucessivamente, o que pode ser visto como

$$Z_{k+1} = Z_1 \prod_{j=1}^k \left(\frac{1 + r_j}{1 - r_j} \right).$$

2.2.8 Inversão Baseada em Modelos

A inversão sísmica baseada em modelos é um algoritmo iterativo de otimização que estima os parâmetros da subsuperfícies e os aplica ao modelo convolucional a fim de comparar o traço sísmico gerado por eles a um traço sísmico real. Se o traço sísmico gerado for suficientemente similar ao traço observado, o processo se dá por encerrado, se não for, os parâmetros são ajustados e o processo repetido. Esse algoritmo utiliza os dados dos poços para obter melhores valores iniciais e, antes de inverter para valores absolutos, cria um modelo de baixa frequência, que é formado de valores de impedância acústica relativa.

2.2.9 Inversão Baseada em Redes Neurais Artificiais

O uso de redes neurais artificiais nos algoritmos de inversão sísmica tem o objetivo de extrair da sísmica padrões não facilmente identificáveis por outros métodos. Uma rede neural desse tipo recebe como entrada o traço sísmico e tem como saída a impedância acústica (se esse for o dado para o qual se deseja realizar a inversão).

O treinamento da rede, em um cenário, ocorre com os traços próximos aos poços, pois nestes é possível conhecer o valor absoluto da impedância e conseqüentemente usá-los como referência para o cálculo dos pesos da rede. Os hiperparâmetros desta rede (isto é, número de camadas, tipos das camadas, funções de ativação, etc) ainda são objetos de estudo e as diferentes propostas existentes serão comparadas nesse trabalho.

3 TRABALHOS CORRELATOS

3.1 REDE CONVOLUCIONAL TEMPORAL

(MUSTAFA; ALFARRAJ; ALREGIB, 2019) propôs o uso de uma TCN (Temporal Convolutional Network) na inversão para impedância acústica. A proposta dessa arquitetura é superar a arquitetura baseada em CNN na identificação de padrões globais, uma vez que CNNs são especializadas em encontrar padrões pequenos quando comparados ao tamanho da entrada, por exemplo, encontrar um objeto específico em uma imagem, e só conseguem identificar padrões maiores quando acrescentadas de mais e maiores camadas, o que torna o treino inviável quando o conjunto de treinamento é pequeno, que é o caso da grande maioria dos processos de inversão sísmica. O treinamento da rede proposta foi realizado utilizando conjunto de dados Marmousi. Foram selecionados 19 traços sísmicos e as correspondentes impedâncias acústicas para treinamento, a função de perda escolhida foi o erro médio quadrático, a taxa de aprendizado escolhida foi 0.001 e o método de otimização foi o método de Adam. A rede foi treinada por 2941 épocas, o que levou aproximadamente 5min em uma GPU NVIDIA GTX 1050. A Figura 11 mostra a arquitetura proposta por Mustafa.

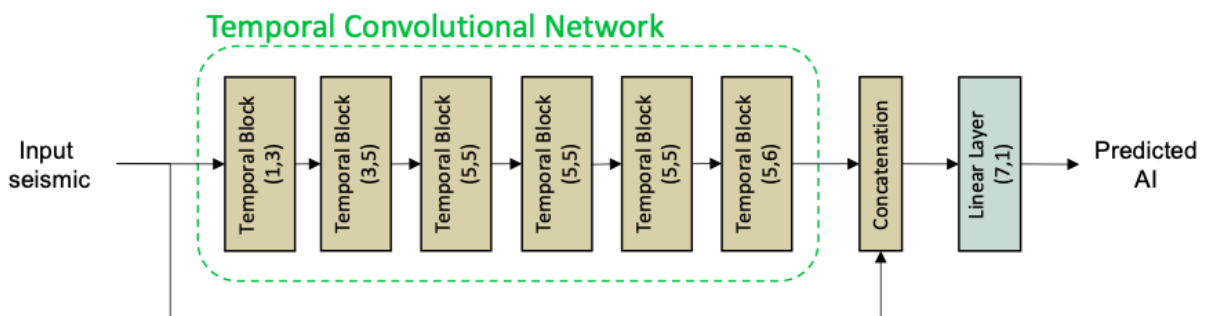


Figura 11 – Arquitetura da rede proposta por (MUSTAFA; ALFARRAJ; ALREGIB, 2019). Entre parêntesis o tamanho da entrada e da saída do bloco, respectivamente

. Fonte: (MUSTAFA; ALFARRAJ; ALREGIB, 2019)

onde cada bloco temporal é definido pela arquitetura apresentada na Figura 12. Dessa forma, é possível notar que a arquitetura da TCN tem diversas camadas convolucionas em sequência.

A comparação quantitativa apresentada na Tabela 1 demonstra a eficiência da rede segundo as métricas r^2 e PCC (coeficiente de correlação de Pearson), essas métricas indicaram similaridade de 96% e 91% respectivamente, tanto no conjunto de validação quanto no de treinamento.

```

(0): TemporalBlock(
  (conv1): Conv1d(1, 3, kernel_size=(9,), stride=(1,), padding=(4,))
  (chomp1): Chomp1d()
  (relu1): ReLU()
  (dropout1): Dropout(p=0.2, inplace=False)
  (conv2): Conv1d(3, 3, kernel_size=(9,), stride=(1,), padding=(4,))
  (chomp2): Chomp1d()
  (relu2): ReLU()
  (dropout2): Dropout(p=0.2, inplace=False)
  (net): Sequential(
    (0): Conv1d(1, 3, kernel_size=(9,), stride=(1,), padding=(4,))
    (1): ReLU()
    (2): Dropout(p=0.2, inplace=False)
    (3): Conv1d(3, 3, kernel_size=(9,), stride=(1,), padding=(4,))
    (4): ReLU()
    (5): Dropout(p=0.2, inplace=False)
  )
  (downsample): Conv1d(1, 3, kernel_size=(1,), stride=(1,))
  (relu): ReLU()
)

```

Figura 12 – Arquitetura de um *Temporal Block* de uma TCN.

Métrica	Treinamento	Validação
CCP	0,96	0,96
r^2	0,91	0,91

Tabela 1 – Apresentação dos resultados obtidos pela TCN nos experimentos realizados pelos autores.

3.2 REDE NEURAL CONVOLUCIONAL

O trabalho de (DAS *et al.*, 2019) inclui uma implementação em Python que utiliza a biblioteca PyTorch como base e está disponível no GitHub.

Nesse trabalho é realizada uma inversão 1D, isto é, inverte cada traço sísmico separadamente e não seções ou volumes simultaneamente. Das propôs uma rede com duas camadas convolucionais com funções de ativação ReLU, um núcleo de convolução de 300 amostras que é proporcional ao tamanho da *Wavelet* e inicialização de parâmetros pelo método de He. A função de perda é dada pelo erro quadrático médio, a taxa de aprendizado escolhida foi 0,001 e o número de épocas 500. A Figura 13 mostra mais detalhes da arquitetura.

A implementação utiliza GPU para acelerar o processo de treinamento, que leva aproximadamente 45min. Todos os hiperparâmetros da rede foram obtidos por tentativa e erro.

No processo de treinamento, foi utilizado um conjunto de dados com 2000 traços com 330 amostras por traço. 70% do conjunto de dados disponível foi utilizado para treinamento e os 30% restantes foram divididos igualmente entre treinamento e valida-

```

Padding size 148
CNN(
  (layer1): Sequential(
    (0): Conv1d(1, 60, kernel_size=(300,), stride=(1,), padding=(149,))
    (1): ReLU()
  )
  (layer2): Sequential(
    (0): Conv1d(60, 1, kernel_size=(300,), stride=(1,), padding=(150,))
    (1): ReLU()
  )
)

```

Figura 13 – Arquitetura da rede proposta por (DAS *et al.*, 2019).

ção. Ao comparar o resultado da inversão realizada pelo rede neural proposta com a impedância acústica verdadeira, a correlação obtida foi de 95% (segundo uma métrica não especificada), contra 89% de uma inversão baseada em modelos realizada nos mesmos dados. Os dados utilizados nesse experimento foram criados aumentando sismogramas de poços utilizando o método de refletividade de Kennet.

3.3 REDE GERADORA ADVERSÁRIA

(WU; MENG; ZHAO, 2021) propuseram um algoritmo de aprendizado semi-supervisionado utilizando uma GAN formada por três redes neurais. O gerador G proposto recebe um traço x como entrada e produz a impedância acústica y correspondente ao traço. O discriminador D dessa GAN recebe o valor da impedância acústica e retorna um escalar que representa a probabilidade de o mesmo pertencer ao conjunto de dados rotulados. Essa arquitetura conta ainda com uma terceira rede F que é uma função inversa da rede G , isto é, retorna uma traço sísmico dada a impedância acústica. A rede F permitiu o treinamento em dados não rotulados, pois, uma vez que F é uma inversa de G , para qualquer traço x tem-se que o erro cometido por G na inversão pode ser calculado pela diferença entre $F(G(x))$ e x , tal diferença tende a zero a medida que ambas as redes treinam. A Figura 14 mostra a arquitetura do gerador e da rede F , que tem arquiteturas idênticas e a Figura 15 mostra a arquitetura do discriminador.

O teste desta arquitetura foi feito sob o conjunto de dados Marmousi2. O processo de treinamento utilizou 101 traços igualmente espaçados para treinamento, dos traços restantes foram utilizados 1350 traços aleatoriamente escolhidos para validação e 12150 para teste. As métricas utilizadas para validação da arquitetura foram o erro quadrático médio EQM , o coeficiente de determinação r^2 e o coeficiente de correlação de pearson CCP . Os resultados podem ser vistos na Tabela 2

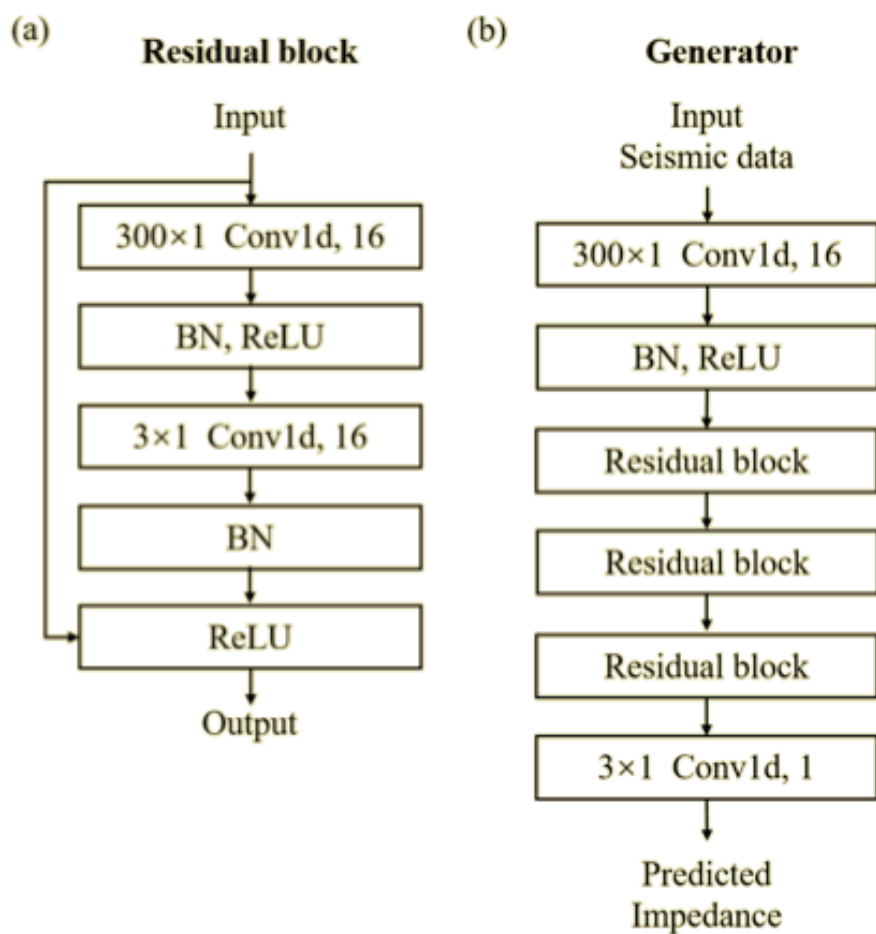


Figura 14 – Arquiteturas de um (a) bloco residual e do (b) gerador.

Fonte: (WU; MENG; ZHAO, 2021)

Métrica	Resultado
<i>MSE</i>	0,0194
<i>PCC</i>	0,9948
r^2	0,9874

Tabela 2 – Apresentação do resultado da GAN obtido no experimento dos autores.

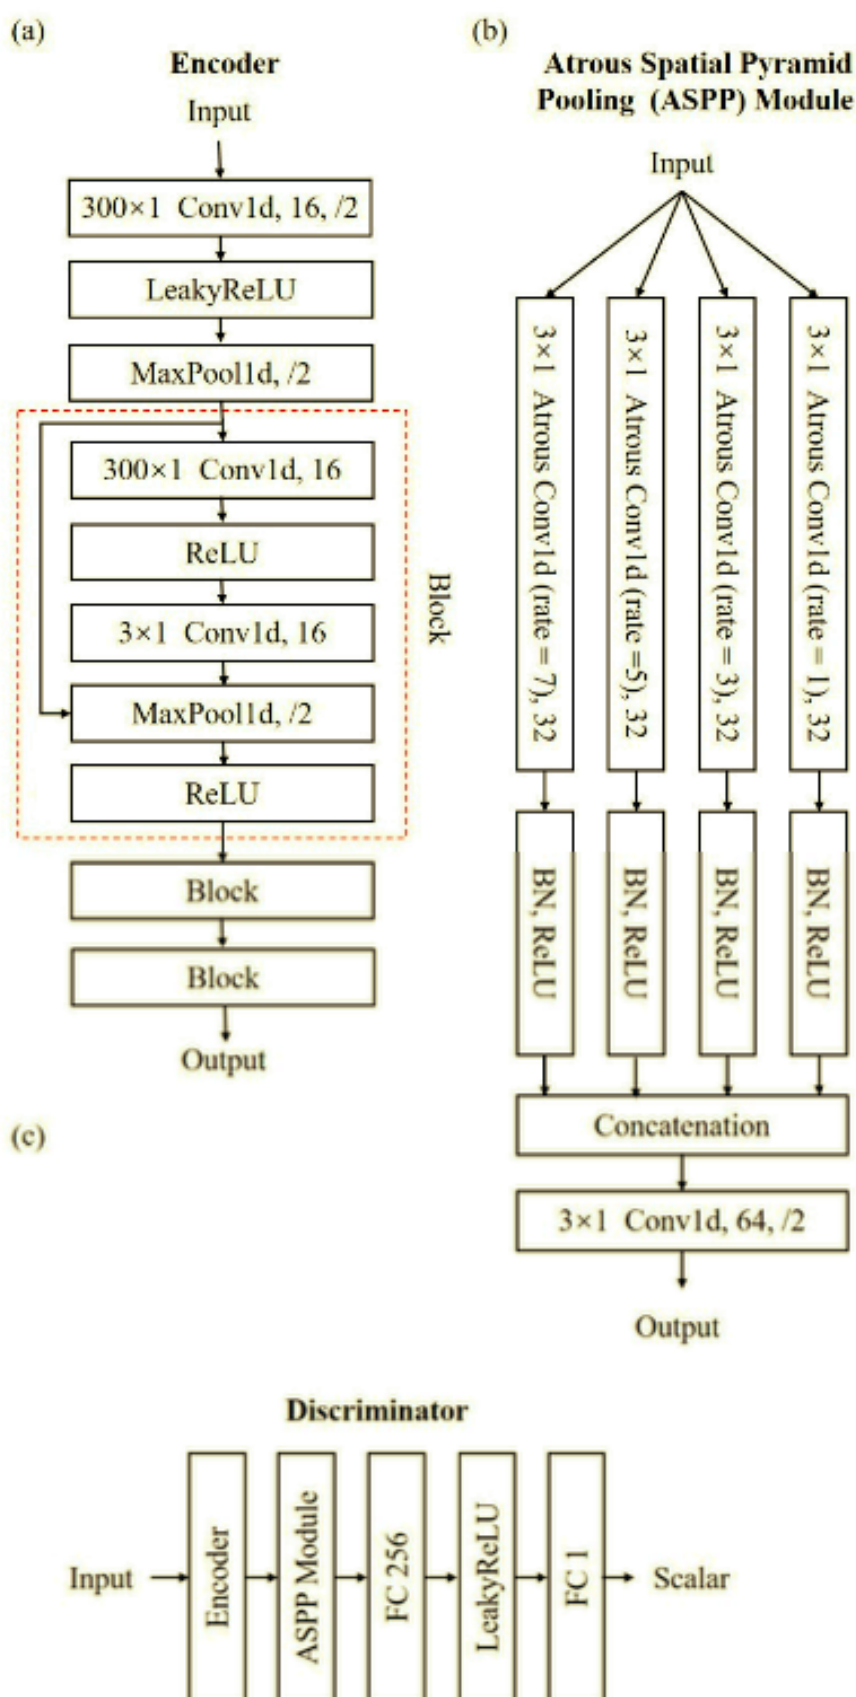


Figura 15 – (a) Arquitetura do codificador. (b) Arquitetura de uma camada de *pooling* de pirâmide espacial de Atrous. (c) Arquitetura do discriminador.

Fonte: (WU; MENG; ZHAO, 2021)

4 EXPERIMENTOS E DISCUSSÃO

4.1 ESCOLHA DO DATASET

O capítulo anterior mostrou que cada uma das propostas de arquitetura foi testada utilizando diferentes métricas e inclusive sob diferentes conjuntos de dados, o que foi suficiente para que cada autor demonstrasse a validade de sua arquitetura, mas não é suficiente para que se possa comparar as arquiteturas e eventualmente escolher qual utilizar. Os experimentos descritos neste capítulo tiveram como objetivo gerar resultados que permitam essa comparação.

O *dataset* escolhido para a realização do experimento foi o Marmousi2, que é uma extensão do *dataset* Marmousi. O Marmousi2 representa um seção de 17.000m de comprimento e 3500m de profundidade, possuindo diferentes estruturas geológicas, como canais de gás, canais de petróleo, falhas geológicas e diferentes materiais, como areia, sal e folhelho. Além disso, o Marmousi2 representa um cenário de exploração em águas profundas, que é muito comum na exploração de petróleo (MARTIN; WILEY; MARFURT, 2006). Esse *dataset* foi escolhido por ser um conjunto de dados público mais utilizados em *benchmarks* de inversão sísmica. No total o conjunto contém 13601 traços com 2800 amostras nos traços sísmicos e 2801 traços de impedância acústica. Os pontos de maior interesse no Marmousi2 são os dois reservatórios de gás apresentados no canto superior esquerdo e na região inferior central. O reservatório no canto superior esquerda é muito mais destacado por ser uma região de baixa impedância acústica, já aquele da parte inferior é pouco visível com base apenas na impedância. A identificação destas estruturas é relevante no critério de avaliação da qualidade da inversão sísmica, pois é o objetivo principal da inversão neste contexto. É importante ressaltar que a inversão sísmica não tem como objetivo identificar qual o material da rocha, ou seja, não identifica a existência de petróleo ou gás, mas sim a existência de estruturas rochosas com condições de armazenarem tais substâncias. A Figura 16 mostra, em verde, as regiões com petróleo e, em vermelho, as regiões com gás. Os reservatórios citados anteriormente se encontram nos locais apontados pelas legendas *Gas charged sand channel* e *Gas and oil cap*.




Figura 16 – Detalhamento das estruturas do conjunto de dados Marmousi2

Fonte: (MARTIN; WILEY; MARFURT, 2006)

4.2 ESCOLHA DOS TRAÇOS

Neste experimento, foram utilizados 101 traços igualmente espaçados para treinamento, do restante do conjunto foram selecionados 10% igualmente espaçados para validação, e o restante para teste. As métricas de comparação utilizadas serão o índice de similaridade estrutural (SSIM), para comparação das imagens geradas pela inversão de todo o conjunto de dados, o erro quadrático médio (EQM ou MSE), o coeficiente de determinação r^2 , o erro absoluto médio (EAM ou MAE) e o erro absoluto mediano (EAMed ou MedAE). O resultado das métricas r^2 e *SSIM* são mais relevantes, pois estas dão um índice entre 0 e 1, onde 0 é nenhuma similaridade e 1 é similaridade absoluta, isso significa que estas métricas não dependem da escala dos dados e não são afetadas pela normalização dos dados, que geralmente é aplicada durante o treinamento. Por outro lado, as métricas MSE, MAE e MedAE são proporcionais a escala dos dados e requerem conhecimento dos mesmos para interpretação da qualidade dos resultados. A métrica SSIM foi escolhida pois, em um exploração real, é mais interessante para o geofísico ter uma compreensão geral do subsolo (fornecida pela imagem) do que a informação a respeito do valor da impedância acústica em pontos específicos do volume explorado e, portanto, é importante avaliar a qualidade da imagem gerada.

Também Será realizada a geração de uma imagem resultante da inversão do conjunto todo para uma comparação visual, assim como serão mostrados o resultado da inversão traço a traço de 3 traços selecionados não utilizados em treinamento nem em validação. A métrica SSIM foi escolhida pois, em um exploração real, é mais interessante para o geofísico ter uma compreensão geral do subsolo (fornecida pela imagem) do que a informação a respeito do valor da impedância acústica em pontos específicos do volume explorado e, portanto, é importante avaliar a qualidade da imagem gerada. Esta métrica será a única calculada a partir do resultado de toda a informação (inclusive dos traços utilizados em treinamento), pois não faz sentido gerar uma imagem sem utilizar todos os traços.

4.3 REDE NEURAL CONVOLUCIONAL

O experimento com a CNN foi realizada utilizando uma GPU GTX 1080 TI e demorou cerca de 30min para treinar por 500 épocas. O teste da CNN nas condições apresentadas anteriormente chegou a resultados inferiores às demais, mas considerando que é uma rede de apenas duas camadas, ainda é um resultado interessante. A arquitetura proposta por (DAS *et al.*, 2019) teve, neste experimento, um resultado muito inferior ao obtido nos experimentos realizados no artigo em que a rede foi proposta, isso pode ser explicado pelo fato de que o presente trabalho a testou sob condições muito menos favoráveis do que aquelas criadas pelos autores. No artigo apresentado pelos autores, a CNN foi treinada em um conjunto de 1300 traços, que equivalia a mais

de 70% do conjunto de dados total, o que é uma situação muito diferente daquela encontrada no mundo real. Apesar de ter tido resultado inferior, a CNN ainda foi capaz de gerar uma imagem bastante similar à real e que, embora claramente ruidosa, permite identificar pelo menos o canal de gás no canto superior esquerdo, embora com bastante ruído ao redor, como visto na Figura 17.




Figura 17 – Comparação entre a inversão realizada pela CNN e a impedância acústica verdadeira

O processo de treinamento da CNN também foi bastante instável, como pode ser observado na figura 18, o que demonstra que a taxa de aprendizado pode ter sido grande demais para aplicação em uma sísmica de grande escala.




Figura 18 – MSE de treino e validação ao longo do treinamento da CNN

Uma comparação visual entre alguns traços escolhidos arbitrariamente mostrou que a correlação entre a impedância acústica verdadeira e a prevista não foi muito satisfatória, como pode-se ver na figura 19.




Figura 19 – Comparação entre a impedância acústica prevista pela CNN e a impedância acústica verdadeira de alguns traços do conjunto de teste

4.4 REDE CONVOLUCIONAL TEMPORAL

O treinamento da TCN também utilizou a placa GTX 1080 TI e durou pouco menos de 10min para treinar por 1800 épocas. A TCN apresentou um resultado superior àquele da CNN pura, o que era esperado, visto que ela tem diversas camadas convolucionais em cada um dos blocos temporais e, portanto, um número maior de neurônios, o que permite uma generalização melhor. Uma peculiaridade observada no experimento com a TCN foi que, durante todo o treinamento, a função de perda teve um valor menor para o conjunto de validação do que para o conjunto de treinamento,

como pode ser observado na Figura 21. Uma explicação simples para esse fenômeno seria a existência de uma interseção entre o conjunto de treinamento e o conjunto de validação, mas este não foi o caso. Uma outra explicação parcial para esse fato é que grande parte dos traços são similares, especialmente aqueles nos primeiros 8000m do conjunto, o que permite uma generalização boa mesmo que o conjunto de treinamento seja proporcionalmente pequeno. Embora o resultado geral da TCN tenha sido excelente, nota-se uma dificuldade de generalização na parte mais profunda do conjunto, onde a variação entre camadas é mais acentuada. A maior dificuldade de generalização na parte profunda pode ter sido causada pela uso de muitas camadas de convolução com núcleo dilatado, pois, visto que essas camadas calculam a saída com base em uma larga porção da entrada, isso pode ter reduzido o desempenho da rede nesta parte onde a variação entre as camadas é mais acentuada e as camadas são mais finas, que exigiriam uma previsão mais local.

A Figura 20 compara a inversão realizada pela TCN com a impedância acústica verdadeira e mostra que esta foi superior inversão realizada pela CNN e que permitiu uma visualização muito mais clara do canal de gás no canto superior esquerdo.

Uma comparação traço a traço da inversão com a impedância acústica verdadeira pode ser vista na figura 22.

4.5 REDE GERADORA ADVERSÁRIA

A implementação da GAN não foi desenvolvida para tirar proveito da GPU, de forma que seu processo de treinamento por 2000 épocas foi significativamente mais lento que o das demais, tendo durado cerca de 10h. Diferentemente das demais arquiteturas, a GAN proposta por Wu não teve uma implementação disponibilizada pelos autores, então foi utilizada uma implementação feita por (MARQUES, 2021), o que teve um resultado também superior a CNN, mas que foi inferior a TCN, o que é surpreendente, visto que a capacidade usar dados não rotulados no treinamento não foi um diferencial muito significativo. O resultado da inversão foi, ainda assim, satisfatório, como pode ser visto na Figura 23. A inversão realizada pela GAN conseguiu identificar também o canal de gás, embora com algum ruído ao redor.

A figura 24 da ideia da correlação da impedância acústica calculada com a real a nível de traço.

4.6 COMPARAÇÃO DE MÉTRICAS

A Tabela 3 demonstra que a TCN foi superior de acordo com todas as métricas, em seguida a GAN, e por fim a CNN. A melhor arquitetura, a TCN, chegou a uma correlação de 96,21%, isto é, quase perfeita, demonstrando que a única possibilidade de melhoria seria a capacidade de treinamento em conjuntos de dados menores, como

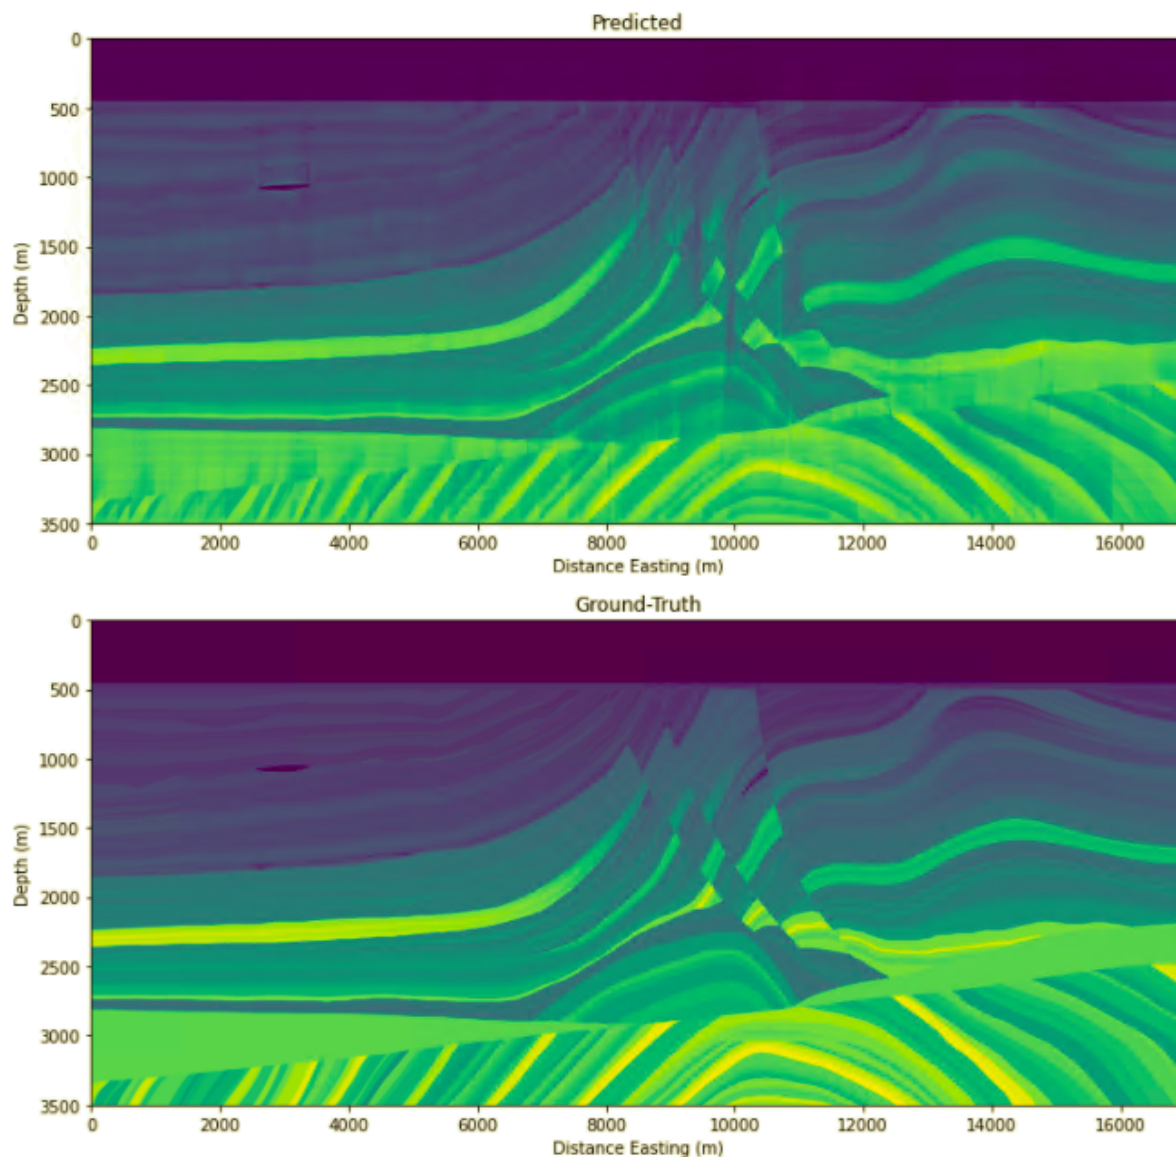


Figura 20 – Comparação entre a inversão realizada pela CNN e a impedância acústica verdadeira

ocorreria em uma cenário real.




Figura 21 – MSE de treino e validação ao longo do treinamento da TCN




Figura 22 – Comparação entre a impedância acústica prevista pela TCN e a impedância acústica verdadeira de alguns traços do conjunto de teste. Esta comparação demonstra a superioridade desta arquitetura especialmente para o traço 7003

	CNN	TCN	GAN
r^2	0,8004	0,9621	0,8906
MSE	1,5737	0,3024	0,8665
MAE	0,9102	0,4197	0,6341
$MedAE$	0,6682	0,3439	0,4244
$SSIM$	0,6857	0,8019	0,7148

Tabela 3 – Apresentação do resultado de cada arquitetura sob cada uma das métricas avaliadas. Em negrito o melhor resultado para cada métrica.

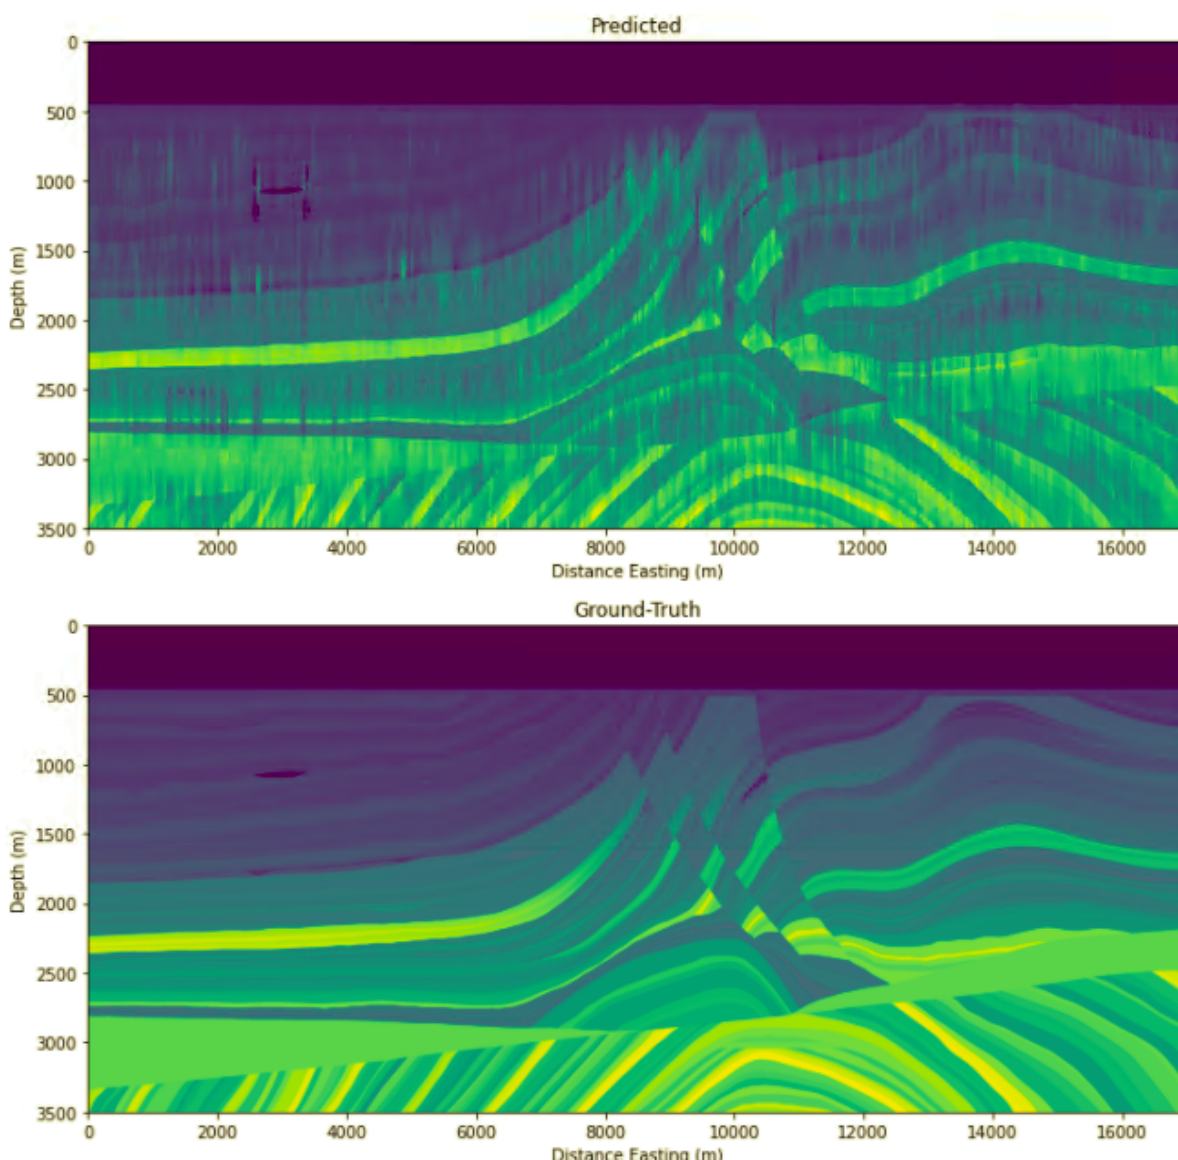


Figura 23 – Comparação entre a inversão realizada pela GAN e a impedância acústica verdadeira. No geral, o resultado foi inferior ao da TCN, mas foi aparentemente melhor em regiões mais profundas.




Figura 24 – Comparação entre a impedância acústica prevista pela GAN e a impedância acústica verdadeira de alguns traços do conjunto de teste. Esta comparação demonstra a superioridade desta arquitetura especialmente para o traço 7003.

5 CONSIDERAÇÕES FINAIS

A superioridade da TCN foi evidenciada, entanto é notável que o desempenho dela foi inferior na parte mais profunda, que é caracterizada por uma variação maior na litologia das rochas. Isso pode ter sido causado pelo uso de muitas convoluções dilatadas, que capturam padrões mais amplos, mas podem ter prejudicado a captura dos padrões menores. Também é interessante pontuar que a parte mais profunda do Marmousi2 não existia no Marmousi, que é onde está arquitetura foi testada pelos autores, e isto pode ter levado os levado a uma escolha de arquitetura que não desempenhasse bem neste tipo de formação rochosa.

Neste trabalho foram apresentados diversos conceitos sobre redes neurais e inversão sísmica necessários para a compreensão do estado da arte da inversão sísmica baseada em redes neurais. Demonstrou-se que as redes neurais já são capazes de realizar inversões melhores que os modelos tradicionais, mas ainda precisam evoluir no sentido de serem capazes de serem treinadas em conjuntos menores de dados. Os parâmetros utilizados neste experimento, por exemplo, consideraram o uso de 101 poços, o que é muito acima da quantidade praticável em explorações reais, nesse sentido, o uso de aprendizado semi-supervisionado parece promissor, pois consegue tirar proveito também de dados não rotulados. O objetivo de comparar diferentes propostas sob mesmas condições foi alcançado e produziu métricas que permitem uma comparação simples entre os modelos. Trabalhos futuros podem realizar experimentos similares, mas em condições mais realistas, isto é, com um número de poços muito baixo. Essa análise indicaria que arquiteturas são mais viáveis para problemas reais.

REFERÊNCIAS

AHMADIAN, Sajad; KHANTEYMOORI, Alireza. Training back propagation neural networks using asexual reproduction optimization. *In*: DOI: 10.1109/IKT.2015.7288738. Citado na p. 22.

ALBAWI, Saad; MOHAMMED, Tareq Abed; AL-ZAWI, Saad. Understanding of a convolutional neural network. *In*: 2017 International Conference on Engineering and Technology (ICET). [S.l.]: IEEE, ago. 2017. DOI: 10.1109/icengtechnol.2017.8308186. Disponível em: <<https://doi.org/10.1109/icengtechnol.2017.8308186>>. Citado nas pp. 21–24.

BROWN, Raymon L.; MCELHATTAN, Wendy; SANTIAGO, Donald J. Wavelet estimation: An interpretive approach. **The Leading Edge**, Society of Exploration Geophysicists, v. 7, n. 12, p. 16–19, dez. 1988. DOI: 10.1190/1.1439470. Disponível em: <<https://doi.org/10.1190/1.1439470>>. Citado na p. 28.

BROWNLEE, Jason. **How to Choose an Activation Function for Deep Learning**. [S.l.: s.n.], jan. 2021. Disponível em: <<https://machinelearningmastery.com/choose-an-activation-function-for-deep-learning>>. Citado nas pp. 20, 21.

CHEN, Yangkang *et al.* Geological structure guided well log interpolation for high-fidelity full waveform inversion. **Geophysical Journal International**, Oxford University Press (OUP), v. 207, n. 2, p. 1313–1331, set. 2016. DOI: 10.1093/gji/ggw343. Disponível em: <<https://doi.org/10.1093/gji/ggw343>>. Citado na p. 16.

CULBERSTON, James Thomas. **Consciousness and Behavior**. [S.l.]: Wm. C. Brown, 1950. ISBN 9781258130091. Citado na p. 18.

DAS, Vishal *et al.* Convolutional neural network for seismic impedance inversion. **GEOPHYSICS**, Society of Exploration Geophysicists, v. 84, n. 6, r869–r880, nov. 2019. DOI: 10.1190/geo2018-0838.1. Disponível em: <<https://doi.org/10.1190/geo2018-0838.1>>. Citado nas pp. 16, 32, 33, 38.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. [S.l.]: MIT Press, 2016. <http://www.deeplearningbook.org>. Citado na p. 16.

GOODFELLOW, Ian; POUGET-ABADIE, Jean *et al.* Generative adversarial networks. **Communications of the ACM**, Association for Computing Machinery (ACM), v. 63,

n. 11, p. 139–144, out. 2020. DOI: 10.1145/3422622. Disponível em: <<https://doi.org/10.1145/3422622>>. Citado na p. 24.

HEMMATINEZHAD, Mehrali *et al.* PREDICTING THE SUCCESS OF NATIONS IN ASIAN GAMES USING NEURAL NETWORK, jul. 2021. Citado na p. 18.

HERRERA, Roberto Henry; BAAN, Mirko van der. Short-time homomorphic wavelet estimation. **Journal of Geophysics and Engineering**, Oxford University Press (OUP), v. 9, n. 6, p. 674–680, out. 2012. DOI: 10.1088/1742-2132/9/6/674. Disponível em: <<https://doi.org/10.1088/1742-2132/9/6/674>>. Citado na p. 28.

HORNIK, Kurt; STINCHCOMBE, Maxwell; WHITE, Halbert. Multilayer feedforward networks are universal approximators. **Neural Networks**, Elsevier BV, v. 2, n. 5, p. 359–366, jan. 1989. DOI: 10.1016/0893-6080(89)90020-8. Disponível em: <[https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8)>. Citado na p. 21.

LEA, Colin *et al.* Temporal Convolutional Networks: A Unified Approach to Action Segmentation. *In*: LECTURE Notes in Computer Science. [S.l.]: Springer International Publishing, 2016. P. 47–54. DOI: 10.1007/978-3-319-49409-8_7. Disponível em: <https://doi.org/10.1007/978-3-319-49409-8_7>. Citado na p. 25.

LI, Shucai *et al.* Deep-Learning Inversion of Seismic Data. **IEEE Transactions on Geoscience and Remote Sensing**, Institute of Electrical e Electronics Engineers (IEEE), v. 58, n. 3, p. 2135–2149, mar. 2020. DOI: 10.1109/tgrs.2019.2953473. Disponível em: <<https://doi.org/10.1109/tgrs.2019.2953473>>. Citado na p. 16.

MARQUES, Caique Rodrigues. Um estudo comparativo entre diferentes modelos de Redes Neurais de Aprendizado Profundo aplicados ao problema da Inversão Sísmica. **Qualificação de mestrado: Universidade Federal de Santa Catarina**, 2021. Citado na p. 41.

MARTIN, Gary S.; WILEY, Robert; MARFURT, Kurt J. Marmousi2: An elastic upgrade for Marmousi. **The Leading Edge**, Society of Exploration Geophysicists, v. 25, n. 2, p. 156–166, fev. 2006. DOI: 10.1190/1.2172306. Disponível em: <<https://doi.org/10.1190/1.2172306>>. Citado nas pp. 36, 37.

MAVKO, Gary; MUKERJI, Tapan; DVORKIN, Jack. **The Rock Physics Handbook**. [S.l.]: Cambridge University Press, 2009. DOI: 10.1017/cbo9780511626753. Disponível em: <<https://doi.org/10.1017/cbo9780511626753>>. Citado na p. 26.

MINSKY, Marvin; PAPERT, Seymour. **Perceptrons**: An introduction to computational geometry. [S.l.]: The MIT press, jul. 1969. ISBN 9780262130431. Citado na p. 21.

MUSTAFA, Ahmad; ALFARRAJ, Motaz; ALREGIB, Ghassan. Estimation of acoustic impedance from seismic data using temporal convolutional network. *In*: SEG Technical Program Expanded Abstracts 2019. [S.l.]: Society of Exploration Geophysicists, ago. 2019. DOI: 10.1190/segam2019-3216840.1. Disponível em: <<https://doi.org/10.1190/segam2019-3216840.1>>. Citado nas pp. 16, 31.

NWANKPA, Chigozie *et al.* **Activation Functions: Comparison of trends in Practice and Research for Deep Learning**. [S.l.: s.n.], 2018. eprint: arXiv:1811.03378. Citado nas pp. 19, 20.

ROSENBLATT, F. The perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, American Psychological Association (APA), v. 65, n. 6, p. 386–408, 1958. DOI: 10.1037/h0042519. Disponível em: <<https://doi.org/10.1037/h0042519>>. Citado na p. 18.

RUDER, Sebastian. **An overview of gradient descent optimization algorithms**. [S.l.: s.n.], 2016. eprint: arXiv:1609.04747. Citado na p. 19.

RUSSELL, Brian H. **Introduction to Seismic Inversion Methods**. [S.l.]: Society of Exploration Geophysicists, jan. 1988. DOI: 10.1190/1.9781560802303. Disponível em: <<https://doi.org/10.1190/1.9781560802303>>. Citado nas pp. 16, 28.

SHAW, G. L. Donald Hebb: The Organization of Behavior. *In*: BRAIN Theory. [S.l.]: Springer Berlin Heidelberg, 1986. P. 231–233. DOI: 10.1007/978-3-642-70911-1_15. Disponível em: <https://doi.org/10.1007/978-3-642-70911-1_15>. Citado na p. 18.

SHEN, Yi *et al.* A novel wavelet extraction method from seismic data without well information. *In*: SEG Technical Program Expanded Abstracts 2020. [S.l.]: Society of Exploration Geophysicists, set. 2020. DOI: 10.1190/segam2020-3427201.1. Disponível em: <<https://doi.org/10.1190/segam2020-3427201.1>>. Citado na p. 28.

SOUZA, Marcelo Gomes de. **Inversão Sísmica acústica determinística utilizando redes neurais artificiais**. 2018. Tese (Doutorado). DOI: 10.17771/pucrio.acad.34647. Disponível em: <<https://doi.org/10.17771/pucrio.acad.34647>>. Citado nas pp. 16, 26–29.

WU, Bangyu; MENG, Delin; ZHAO, Haixia. Semi-Supervised Learning for Seismic Impedance Inversion Using Generative Adversarial Networks. **Remote Sensing**, MDPI AG, v. 13, n. 5, p. 909, fev. 2021. DOI: 10.3390/rs13050909. Disponível em: <<https://doi.org/10.3390/rs13050909>>. Citado nas pp. 16, 33–35.

YANG, Fangshu; MA, Jianwei. Deep-learning inversion: A next-generation seismic velocity model building method. **Geophysics**, Society of Exploration Geophysicists, v. 84, n. 4, r583–r599, 2019. DOI: 10.1190/geo2018-0249.1. Citado na p. 16.

Apêndices

APÊNDICE A – ARTIGO DO TCC

Comparação de Desempenho de Diferentes Arquiteturas de Redes Neurais Utilizadas Em Inversão Sísmica

Vinicius G. Santos¹, Mauro Roisenberg¹

¹Depto. de Informática e Estatística – Universidade Federal de Santa Catarina (UFSC)
Caixa Postal 476 – 88040-900 – Florianópolis – SC – Brasil

vinicius_gs_lp@hotmail.com, mauro.roisenberg@ufsc.br

Abstract. *In geophysics, seismic inversion refers to the process of obtaining subsurface properties from seismic data. The knowledge about subsurface properties is very useful in the field of oil and gas extraction. The use of artificial neural networks may improve such process in terms of velocity, estimation quality and by reducing the need of exploratory well drilling. The present paper aims to compare, when given the same dataset and same metrics, the performance of different proposed neural network architectures used in seismic inversion to extract acoustic impedance.*

Resumo. *Na geofísica, o conceito de inversão sísmica se refere ao processo de obter propriedades da subsuperfície a partir de dados sísmicos. O conhecimento sobre as propriedades da subsuperfície é muito útil no campo de extração de petróleo e gás. O uso de redes neurais artificiais para inversão sísmica pode melhorar esse processo em velocidade, qualidade das estimativas e redução da necessidade de perfuração de poços exploratórios. Esse trabalho tem como objetivo comparar, dado um mesmo conjunto de dados e mesmas métricas, o desempenho de propostas de arquiteturas de redes neurais utilizadas na realização de inversão sísmica para obtenção da propriedade de impedância acústica.*

1. Introdução

A inversão sísmica é um processo de transformação de dados sísmicos de reflexão em dados quantitativos das propriedades das rochas [Chen et al. 2016]. Dados sísmicos de reflexão são registros de ondas sonoras captados na superfície da área de estudo, na qual essa onda é artificialmente criada por algum dispositivo, como explosivo ou canhão de ar comprimido, e propaga-se pelo volume do terreno, sendo parcialmente refletida ao longo do caminho (especialmente nas trocas de meio). Essas ondas refletidas são capturadas por sensores na superfície e depois rearranjadas de forma a criar um registro sísmico (ou simplesmente "sísmica") da porção do terreno logo abaixo do sensor [de Souza 2018]. Existem várias técnicas de inversão sísmica e elas geralmente se baseiam também em outros dados além dos registros sísmicos de reflexão, por exemplo, em registros de poços perfurados na região.

O problema da inversão sísmica não é um problema bem-posto, isto é, não é linear e não tem solução única, de forma que um mesmo registro sísmico pode ser gerado por diferentes combinações de solo e onda [Chen et al. 2016]. Por esse motivo, nenhum dos métodos de inversão sísmica atualmente existentes pode ser considerado ideal, o que tem

levado ao constante desenvolvimento de novos modelos, entre eles, aqueles baseados em redes neurais.

Na indústria de óleo e gás, a inversão sísmica é um dos métodos mais utilizados para a caracterização de reservatórios e é fundamental para reduzir a necessidade de perfuração de poços, o qual é tipicamente um processo muito caro e demorado [Russell 1988].

Uma rede neural artificial é um algoritmo computacional inspirado no funcionamento do cérebro. Uma rede neural é uma função matemática capaz de mapear um conjunto de entrada para um conjunto de saídas. Os algoritmos orientados à redes neurais requerem o uso de um conjunto de dados composto de pares de entradas e saídas que são utilizados no processo de refinamento dessa função matemática, similarmente a uma regressão linear [Goodfellow et al. 2016].

No contexto da inversão sísmica, as abordagens mais tradicionais consistem em criar modelos do solo, testar sua aderência aos dados obtidos, ajustar o modelo e assim iterativamente até que se obtenha um modelo bom o suficiente, caracterizando um processo de otimização. Por outro lado, a abordagem que utiliza redes neurais artificiais requer simplesmente que se conheçam conjuntos de entradas e saídas para treinar a rede, dispensando a necessidade de criação de modelos do solo.

Dadas as vantagens citadas do uso de redes neurais, diversos modelos já foram propostos [Yang and Ma 2019, Mustafa et al. 2019, Das et al. 2019, Li et al. 2020, Wu et al. 2021]. Todos os modelos propostos foram testados e validados por seus respectivos autores, mas utilizando dados e métricas diferentes, alguns até mesmo utilizando dados gerados para aquele fim exclusivo, de forma que não há uma comparação de todos eles para um mesmo conjunto de entradas e para um mesmo critério de comparação. Portanto, o objetivo deste trabalho é testar diversas implementações disponíveis, considerando um mesmo conjunto de dados público cujas entradas e saídas da inversão sejam previamente conhecidas, a fim de determinar qual deles realiza a inversão com melhor correlação com a saída esperada. Além da comparação dos resultados propriamente ditos, também será feita uma descrição de cada uma das implementações, de maneira que se possa não apenas entender qual gera resultados mais próximos a impedância acústica real, mas também quais são suas características, o que pode ajudar a guiar implementações futuras.

2. Redes Neurais Artificiais

2.1. Redes Neurais Convolucionais

Redes neurais convolucionais tem sido amplamente utilizadas para o reconhecimento de padrões nos últimos anos [Albawi et al. 2017]. Os principais benefícios na utilização desse tipo de rede são a redução do número de pesos e a capacidade de reconhecer padrões em espaços multidimensionais, como em imagens, vídeos e áudios. Esse tipo de rede é baseada na operação matemática de convolução entre matrizes, de forma que os neurônios da camada convolucional de uma rede neural representam o núcleo de uma convolução e tem seus pesos ajustados para gerarem a saída desejada. A operação de convolução entre matrizes é definida da seguinte maneira:

$$F(s) = (x * f)(s) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-i},$$

no qual x é um elemento da entrada, $f : \{0, \dots, k - 1\} \rightarrow \mathbb{R}$ a função que aplica o núcleo da convolução e $*$ a operação de convolução. A Figura 1 ilustra esquematicamente a uma camada convolucional de uma rede neural.

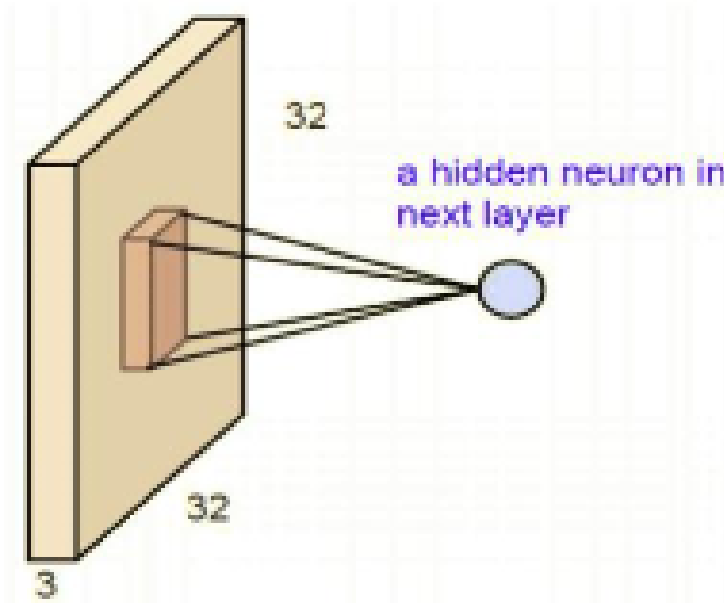


Figura 1. Representação visual de uma operação de convolução. Extraído de [Albawi et al. 2017]

2.2. Redes Geradoras Adversárias

[Goodfellow et al. 2020] propuseram um novo tipo de rede neural chamadas de Redes Geradoras adversárias (ou GANs, na sigla em inglês) que são tipos de redes neurais que não realizam regressão ou classificação, mas sim aprendem o padrão de um conjunto de dados a fim de gerar novos elementos que sejam indistinguíveis de um elemento original do conjunto. Uma GAN é formada por duas redes multicamadas treinadas simultaneamente, uma delas é chamada de geradora (G) e a outra de discriminadora (D). No caso de ambas as redes serem formadas por multicamadas de perceptrons, tem-se que a rede geradora pode ser descrita como $G(z, \theta_z)$ onde θ_z é o conjunto de pesos da rede e z é um escalar de entrada. Já a rede discriminadora pode ser descrita como $D(x, \theta_d)$ onde x é um elemento que será classificado como pertencente ou não ao conjunto de dados e θ_d é o conjunto de neurônios da rede. Tem-se ainda que a saída da rede G tem a dimensão dos elementos do conjunto de dados, a entrada da rede D é um candidato a elemento do conjunto de dados, isto é, tem a mesma dimensão que os elementos do conjunto. Já a saída $D(x)$ é a probabilidade do elemento x pertencer ao conjunto de dados original, ou seja, não ter sido gerado por G . A Figura 2 representa esquematicamente o funcionamento de uma GAN.

O treinamento de ambas as redes é feito de maneira alternada, para cada época de treinamento de G , uma ou mais épocas de treinamento de D são realizadas. O objetivo do treinamento da rede D é maximizar a probabilidade dela identificar se um dado veio do conjunto original ou não, já o treinamento da rede G tem como objetivo minimizar a função $\log(1 - D(G(k)))$ que diminui com o aumento do erro da rede D , assim, tem-se que a rede atingiu o treinamento máximo quando a taxa de erro da rede D estiver próxima de 50%.

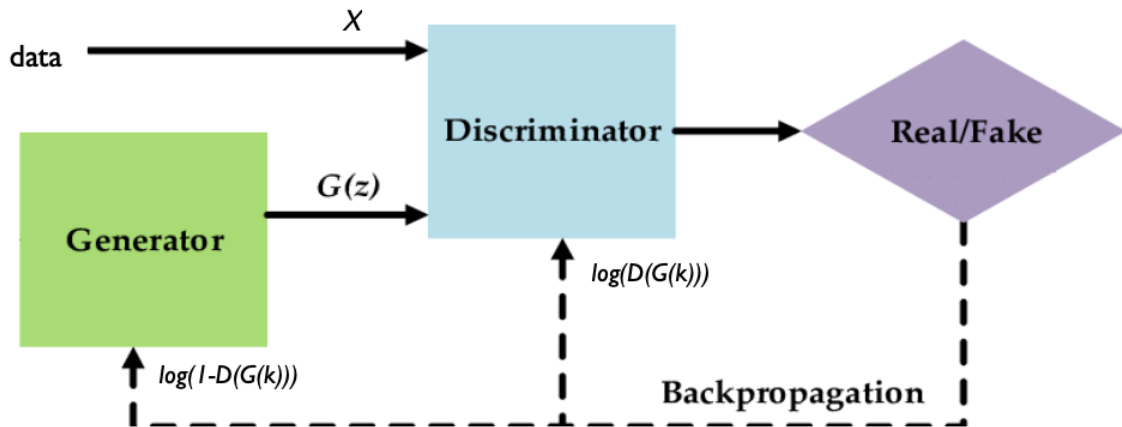


Figura 2. Visão esquemática da interação do Gerador e do Discriminador em uma GAN. Extraído de [Feng et al. 2020]

2.3. Redes Convolucionais Temporais

[Lea et al. 2016] propuseram uma classe de arquiteturas de redes neurais convolucionais chamada de Redes Convolucionais Temporais (ou TCNs). Esse tipo de rede tem o objetivo de ser capaz de encontrar padrões em entradas muito longas onde valores muito espaçados podem estar conectados. Uma das aplicações em que esse tipo de rede foi utilizada até o momento é na aprendizagem de padrões em vídeos, sendo útil nesse tipo de dado, pois tem a capacidade de utilizar frames de vários instantes de tempo ao mesmo tempo ao calcular a saída. Enquanto uma CNN normal leva em consideração uma porção da entrada correspondente ao tamanho do seu núcleo, as TCNs usam uma técnica chamada de convolução dilatada para permitir um aumento na porção da entrada utilizada em cada passo, como visto na Figura 3. A convolução dilatada é definida como um tipo de convolução em que os componentes do vetor de entrada não são componentes contínuos da entrada, mas estão separados por um número d de componentes, o que pode ser descrito da seguinte forma:

$$F(s) = (x *_d f)(s) = \sum_{i=0}^{k-1} f(i) \cdot x_{s-di},$$

no qual x é um elemento da entrada, $f : \{0, \dots, k-1\} \rightarrow \mathbb{R}$ a função que aplica o núcleo da convolução e F a função que aplica a convolução, e $*_d$ representa a operação de convolução dilatada.




Figura 3. Esquema demonstrando a forma como TCNs utilizam sucessivas convoluções dilatadas a fim de utilizar uma porção maior da entrada no cálculo da saída. Extraído de [Prasad et al. 2020]

3. Inversão Sísmica

3.1. Sismologia de Reflexão

A sismologia de reflexão é o método pelo qual se explora as propriedades da terra a partir de ondas de reflexão geradas por um pulso na superfície e refletidas pelas interfaces entre diferentes tipos de material no subsolo. O foco deste trabalho é a sísmica de superfície, que é baseada na ideia de que quando um pulso de energia é produzido na superfície, ele percorre o solo até encontrar uma interface entre duas camadas de diferentes litologias, tal que nessa interface, parte da energia da onda é refletida e parte dela segue em direção ao subsolo. As porções de energia refletida são capturadas pelos sensores e, posteriormente, utilizadas como entrada para os métodos de inversão sísmica.

3.2. Impedância Acústica

A impedância acústica (Z) é uma grandeza relacionada a dificuldade com que uma onda sonora encontra ao viajar por um material, sendo dependente da velocidade pela qual a onda viaja (V) e da densidade do material (ρ). Embora seja uma característica acústica, a impedância está fortemente relacionada a propriedades petroelásticas do material e, por esse motivo, é de grande interesse dos geofísicos para a determinação das características do solo [Mavko et al. 2009].

4. Trabalhos Correlatos

4.1. Rede Neural Convolutacional

O trabalho de [Das et al. 2019] inclui uma implementação em Python que utiliza a biblioteca PyTorch como base e está disponível no GitHub.

Nesse trabalho é realizada uma inversão 1D, isto é, inverte cada traço sísmico separadamente e não seções ou volumes simultaneamente. Das propôs uma rede com duas camadas convolucionais com funções de ativação ReLU, um núcleo de convolução de 300 amostras que é proporcional ao tamanho da *Wavelet* e inicialização de parâmetros pelo método de He. A função de perda é dada pelo erro quadrático médio, a taxa de aprendizado escolhida foi 0,001 e o número de épocas 500. A Figura 4 mostra mais detalhes da arquitetura.

```
Padding size 148
CNN(
  (layer1): Sequential(
    (0): Conv1d(1, 60, kernel_size=(300,), stride=(1,), padding=(149,))
    (1): ReLU()
  )
  (layer2): Sequential(
    (0): Conv1d(60, 1, kernel_size=(300,), stride=(1,), padding=(150,))
    (1): ReLU()
  )
)
```

Figura 4. Arquitetura da rede proposta por [Das et al. 2019].

A implementação utiliza GPU para acelerar o processo de treinamento, que leva aproximadamente 45min. Todos os hiperparâmetros da rede foram obtidos por tentativa e erro.

No processo de treinamento, foi utilizado um conjunto de dados com 2000 traços com 330 amostras por traço. 70% do conjunto de dados disponível foi utilizado para treinamento e os 30% restantes foram divididos igualmente entre treinamento e validação. Ao comparar o resultado da inversão realizada pelo rede neural proposta com a impedância acústica verdadeira, a correlação obtida foi de 95% (segundo uma métrica não especificada), contra 89% de uma inversão baseada em modelos realizada nos mesmos dados. Os dados utilizados nesse experimento foram criados aumentando sismogramas de poços utilizando o método de refletividade de Kennet.

4.2. Rede Convolutacional Temporal

[Mustafa et al. 2019] propôs o uso de uma TCN (Temporal Convolutional Network) na inversão para impedância acústica. A proposta dessa arquitetura é superar a arquitetura baseada em CNN na identificação de padrões globais, uma vez que CNNs são especializadas em encontrar padrões pequenos quando comparados ao tamanho da entrada, por exemplo, encontrar um objeto específico em uma imagem, e só conseguem identificar padrões maiores quando acrescidas de mais e maiores camadas, o que torna o treino inviável quando o conjunto de treinamento é pequeno, que é o caso da grande maioria dos processos de inversão sísmica. O treinamento da rede proposta foi realizado utilizando conjunto de dados Marmousi. Foram selecionados 19 traços sísmicos e as correspondentes impedâncias acústicas para treinamento, a função de perda escolhida foi o erro médio quadrático, a taxa de aprendizado escolhida foi 0.001 e o método de otimização foi o método de Adam. A rede foi treinada por 2941 épocas, o que levou aproximadamente 5min em uma GPU NVIDIA GTX 1050. A Figura 5 mostra a arquitetura proposta por Mustafa.

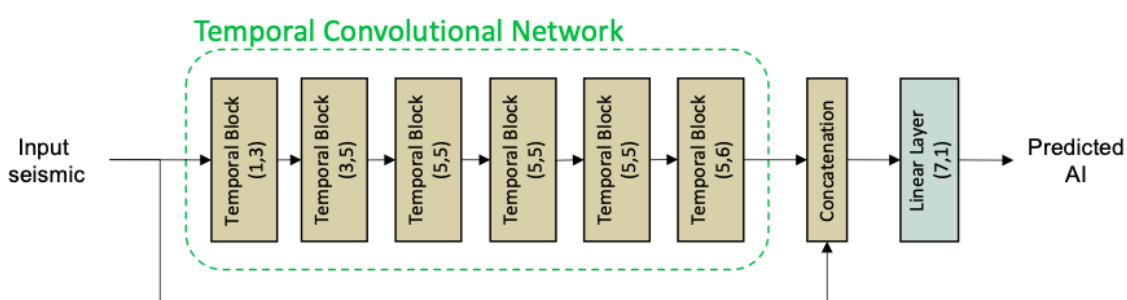


Figura 5. Arquitetura da rede proposta por [Mustafa et al. 2019]. Entre parêntesis o tamanho da entrada e da saída do bloco, respectivamente

. Fonte: [Mustafa et al. 2019]

onde cada bloco temporal é definido pela arquitetura apresentada na Figura 6. Dessa forma, é possível notar que a arquitetura da TCN tem diversas camadas convolucionais em sequência.

A comparação quantitativa apresentada na Tabela 1 demonstra a eficiência da rede segundo as métricas r^2 e PCC (coeficiente de correlação de Pearson).

```

(0): TemporalBlock(
  (conv1): Conv1d(1, 3, kernel_size=(9,), stride=(1,), padding=(4,))
  (chomp1): Chomp1d()
  (relu1): ReLU()
  (dropout1): Dropout(p=0.2, inplace=False)
  (conv2): Conv1d(3, 3, kernel_size=(9,), stride=(1,), padding=(4,))
  (chomp2): Chomp1d()
  (relu2): ReLU()
  (dropout2): Dropout(p=0.2, inplace=False)
  (net): Sequential(
    (0): Conv1d(1, 3, kernel_size=(9,), stride=(1,), padding=(4,))
    (1): ReLU()
    (2): Dropout(p=0.2, inplace=False)
    (3): Conv1d(3, 3, kernel_size=(9,), stride=(1,), padding=(4,))
    (4): ReLU()
    (5): Dropout(p=0.2, inplace=False)
  )
  (downsample): Conv1d(1, 3, kernel_size=(1,), stride=(1,))
  (relu): ReLU()
)

```

Figura 6. Arquitetura de um *Temporal Block* de uma TCN

Tabela 1. Apresentação dos resultados obtidos pela TCN nos experimentos realizados pelos autores.

Métrica	Treinamento	Validação
CCP	0,96	0,96
r^2	0,91	0,91

4.3. Rede Geradora Adversária

[Wu et al. 2021] propuseram um algoritmo de aprendizado semi-supervisionado utilizando uma GAN formada por três redes neurais. O gerador G proposto recebe um traço x como entrada e produz a impedância acústica y correspondente ao traço. O discriminador D dessa GAN recebe o valor da impedância acústica e retorna um escalar que representa a probabilidade de o mesmo pertencer ao conjunto de dados rotulados. Essa arquitetura conta ainda com uma terceira rede F que é uma função inversa da rede G , isto é, retorna um traço sísmico dada a impedância acústica. A rede F permitiu o treinamento em dados não rotulados, pois, uma vez que F é uma inversa de G , para qualquer traço x tem-se que o erro cometido por G na inversão pode ser calculado pela diferença entre $F(G(x))$ e x , tal diferença tende a zero a medida que ambas as redes treinam. A Figura 7 mostra a arquitetura do gerador (que é a rede utilizada para inversão ao fim do treinamento) e da rede F , que tem arquiteturas idênticas construídas a partir de camadas convolucionais. O discriminador tem uma arquitetura mais complexa que inclui convoluções dilatadas.

O teste desta arquitetura foi feito sob o conjunto de dados Marmousi2. O processo de treinamento utilizou 101 traços igualmente espaçados para treinamento, dos traços restantes foram utilizados 1350 traços aleatoriamente escolhidos para validação e 12150 para teste. As métricas utilizadas para validação da arquitetura foram o erro quadrático médio EQM , o coeficiente de determinação r^2 e o coeficiente de correlação de pearson

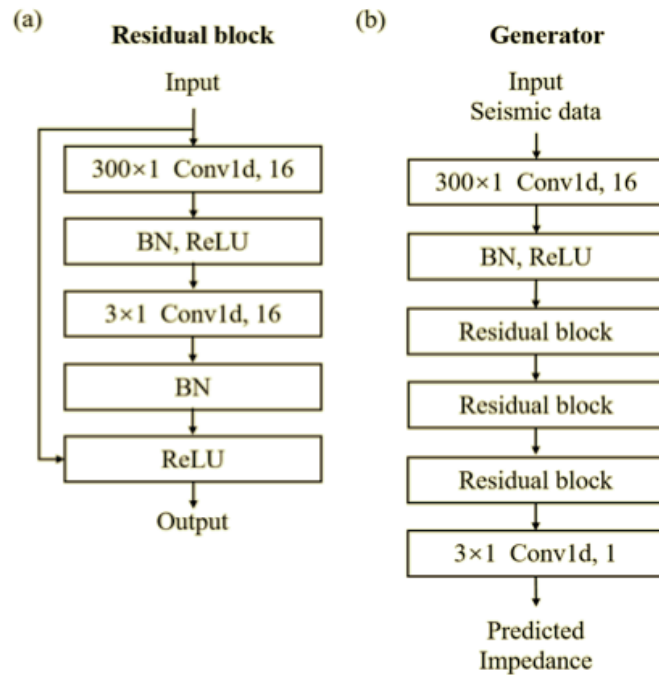


Figura 7. Arquiteturas de um (a) bloco residual e do (b) gerador.

Fonte: [Wu et al. 2021]

Tabela 2. Apresentação do resultado da GAN obtido no experimento dos autores

Métrica	Resultado
MSE	0,0194
PCC	0,9948
r^2	0,9874

CCP. Os resultados podem ser vistos na Tabela 2

5. Experimentos e Discussões

5.1. Escolha do dataset

O capítulo anterior mostrou que cada uma das propostas de arquitetura foi testada utilizando diferentes métricas e inclusive sob diferentes conjuntos de dados, o que foi suficiente para que cada autor demonstrasse a validade de sua arquitetura, mas não é suficiente para que se possa comparar as arquiteturas e eventualmente escolher qual utilizar. Os experimentos descritos neste capítulo tiveram como objetivo gerar resultados que permitam essa comparação.

O dataset escolhido para a realização do experimento foi o Marmousi2, que é uma extensão do dataset Marmousi. O Marmousi2 representa um seção de 17.000m de comprimento e 3500m de profundidade, possuindo diferentes estruturas geológicas, como canais de gás, canais de petróleo, falhas geológicas e diferentes materiais, como areia, sal e folhelho. Além disso, o Marmousi2 representa um cenário de exploração em águas profundas, que é muito comum na exploração de petróleo [Martin et al. 2006]. Esse dataset foi escolhido por ser um conjunto de dados público mais utilizados em benchmarks de inversão sísmica. No total o conjunto contém 13601 traços com 2800 amostras nos

traços sísmicos e 2801 traços de impedância acústica. Os pontos de maior interesse no Marmousi2 são os dois reservatórios de gás apresentados no canto superior esquerdo e na região inferior central. O reservatório no canto superior esquerda é muito mais destacado por ser uma região de baixa impedância acústica, já aquele da parte inferior é pouco visível com base apenas na impedância. A identificação destas estruturas é relevante no critério de avaliação da qualidade da inversão sísmica, pois é o objetivo principal da inversão neste contexto. É importante ressaltar que a inversão sísmica não tem como objetivo identificar qual o material da rocha, ou seja, não identifica a existência de petróleo ou gás, mas sim a existência de estruturas rochosas com condições de armazenarem tais substâncias. A Figura 8 mostra, em verde, as regiões com petróleo e, em vermelho, as regiões com gás. Os reservatórios citados anteriormente se encontram nos locais apontados pelas legendas *Gas charged sand channel* e *Gas and oil cap*.




Figura 8. Detalhamento das estruturas do conjunto de dados Marmousi2

Fonte: [Martin et al. 2006]

5.2. Escolha dos traços

Neste experimento, foram utilizados 101 traços igualmente espaçados para treinamento, do restante do conjunto foram selecionados 10% igualmente espaçados para validação, e o restante para teste. As métricas de comparação utilizadas serão o índice de similaridade estrutural (SSIM), para comparação das imagens geradas pela inversão de todo o conjunto de dados, o erro quadrático médio (EQM ou MSE), o coeficiente de determinação r^2 , o erro absoluto médio (EAM ou MAE) e o erro absoluto mediano (EAMed ou MedAE). O resultado das métricas r^2 e *SSIM* são mais relevantes, pois estas dão um índice entre 0 e 1, onde 0 é nenhuma similaridade e 1 é similaridade absoluta, isso significa que estas métricas não dependem da escala dos dados e não são afetadas pela normalização

dos dados, que geralmente é aplicada durante o treinamento. Por outro lado, as métricas MSE, MAE e MedAE são proporcionais a escala dos dados e requerem conhecimento dos mesmos para interpretação da qualidade dos resultados. A métrica SSIM foi escolhida pois, em um exploração real, é mais interessante para o geofísico ter uma compreensão geral do subsolo (fornecida pela imagem) do que a informação a respeito do valor da impedância acústica em pontos específicos do volume explorado e, portanto, é importante avaliar a qualidade da imagem gerada.

Também Será realizada a geração de uma imagem resultante da inversão do conjunto todo para uma comparação visual, assim como serão mostrados o resultado da inversão traço a traço de 3 traços selecionados não utilizados em treinamento nem em validação. A métrica SSIM foi escolhida pois, em um exploração real, é mais interessante para o geofísico ter uma compreensão geral do subsolo (fornecida pela imagem) do que a informação a respeito do valor da impedância acústica em pontos específicos do volume explorado e, portanto, é importante avaliar a qualidade da imagem gerada. Esta métrica será a única calculada a partir do resultado de toda a informação (inclusive dos traços utilizados em treinamento), pois não faz sentido gerar uma imagem sem utilizar todos os traços.

5.3. Rede Neural Convolutional

O teste da CNN nas condições apresentadas anteriormente chegou a resultados inferiores às demais, mas considerando que é uma rede de apenas duas camadas, ainda é um resultado interessante. A arquitetura proposta por [Das et al. 2019] teve, neste experimento, um resultado muito inferior ao obtido nos experimentos realizados no artigo em que a rede foi proposta, isso pode ser explicado pelo fato de que o presente trabalho a testou sob condições muito menos favoráveis do que aquelas criadas pelos autores. No artigo apresentado pelos autores, a CNN foi treinada em um conjunto de 1300 traços, que equivalia a mais de 70% do conjunto de dados total, o que é uma situação muito diferente daquela encontrada no mundo real. Apesar de ter tido resultado inferior, a CNN ainda foi capaz de gerar uma imagem bastante similar à real e que, embora claramente ruidosa, permite identificar pelo menos o canal de gás no canto superior esquerdo, embora com bastante ruído ao redor, como visto na Figura 9.




Figura 9. Comparação entre a inversão realizada pela CNN e a impedância acústica verdadeira

O processo de treinamento da CNN também foi bastante instável, como pode ser observado na Figura 10, o que demonstra que a taxa de aprendizado pode ter sido grande demais para aplicação em uma sísmica de grande escala.

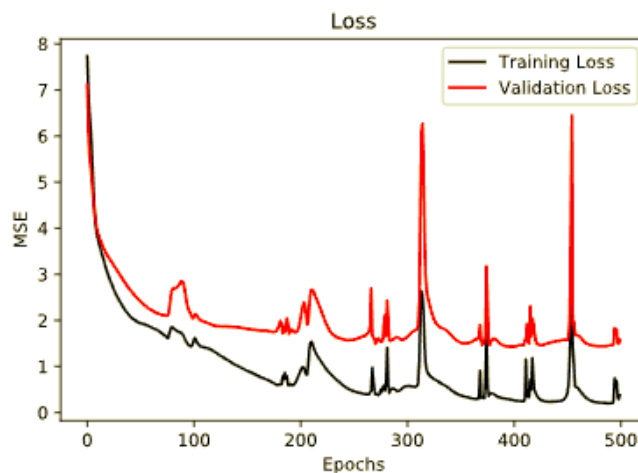


Figura 10. MSE de treino e validação ao longo do treinamento da CNN

Uma comparação visual entre alguns traços escolhidos arbitrariamente mostrou que a correlação entre a impedância acústica verdadeira e a prevista não foi muito satisfatória, como pode-se ver na Figura 11.




Figura 11. Comparação entre a impedância acústica prevista pela CNN e a impedância acústica verdadeira de alguns traços do conjunto de teste

5.4. Rede Convolutiva Temporal

A TCN apresentou um resultado superior àquele da CNN pura, o que era esperado, visto que ela tem diversas camadas convolucionais em cada um dos blocos temporais e, portanto, um número maior de neurônios, o que permite uma generalização melhor. Uma peculiaridade observada no experimento com a TCN foi que, durante todo o treinamento, a função de perda teve um valor menor para o conjunto de validação do que para o conjunto de treinamento, como pode ser observado na Figura 13. Uma explicação simples para esse fenômeno seria a existência de uma interseção entre o conjunto de treinamento e o conjunto de validação, mas este não foi o caso. Uma outra explicação parcial para esse fato é que grande parte dos traços são similares, especialmente aqueles nos primeiros 8000m do conjunto, o que permite uma generalização boa mesmo que o conjunto de treinamento seja proporcionalmente pequeno. Embora o resultado geral da TCN tenha sido excelente,

nota-se uma dificuldade de generalização na parte mais profunda do conjunto, onde a variação entre camadas é mais acentuada. A maior dificuldade de generalização na parte profunda pode ter sido causada pela uso de muitas camadas de convolução com núcleo dilatado, pois, visto que essas camadas calculam a saída com base em uma larga porção da entrada, isso pode ter reduzido o desempenho da rede nesta parte onde a variação entre as camadas é mais acentuada e as camadas são mais finas, que exigiriam uma previsão mais local.

A Figura 12 compara a inversão realizada pela TCN com a impedância acústica verdadeira e mostra que esta foi superior inversão realizada pela CNN e que permitiu uma visualização muito mais clara do canal de gás no canto superior esquerdo.




Figura 12. Comparação entre a inversão realizada pela CNN e a impedância acústica verdadeira

Uma comparação traço a traço da inversão com a impedância acústica verdadeira pode ser vista na Figura 14.




Figura 13. MSE de treino e validação ao longo do treinamento da TCN




Figura 14. Comparação entre a impedância acústica prevista pela TCN e a impedância acústica verdadeira de alguns traços do conjunto de teste. Esta comparação demonstra a superioridade desta arquitetura especialmente para o traço 7003

5.5. Rede Geradora Adversária

Diferentemente das demais arquiteturas, a GAN proposta por Wu não teve uma implementação disponibilizada pelos autores, então foi utilizada uma implementação feita por [Marques 2021], o que teve um resultado também superior a CNN, mas que foi inferior a TCN, o que é surpreendente, visto que a capacidade usar dados não rotulados no treinamento não foi um diferencial muito significativo. O resultado da inversão foi, ainda assim, satisfatório, como pode ser visto na Figura 15. A inversão realizada pela GAN conseguiu identificar também o canal de gás, embora com algum ruído ao redor.

A Figura 16 da ideia da correlação da impedância acústica calculada com a real a nível de traço.

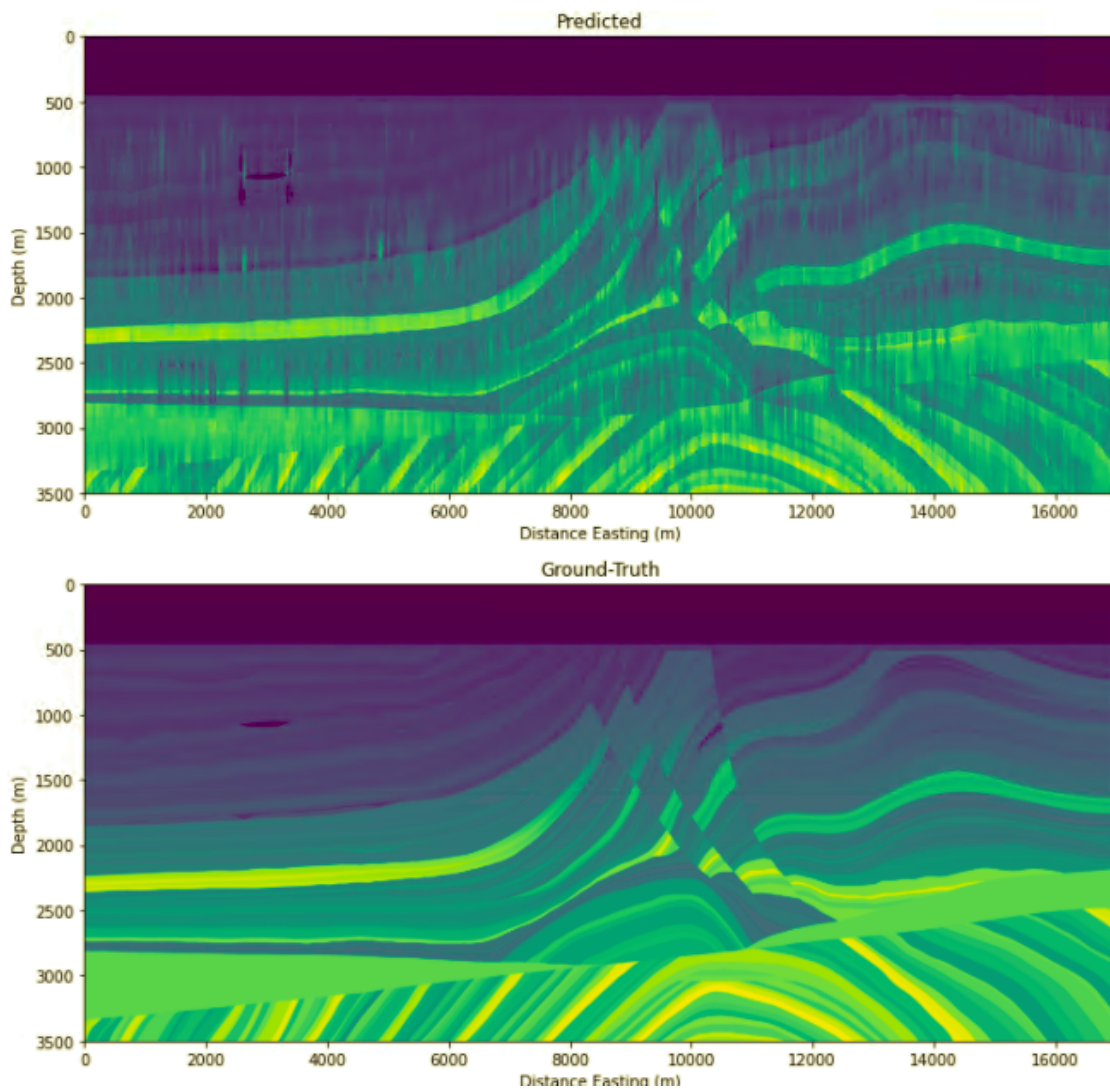


Figura 15. Comparação entre a inversão realizada pela GAN e a impedância acústica verdadeira. No geral, o resultado foi inferior ao da TCN, mas foi aparentemente melhor em regiões mais profundas.




Figura 16. Comparação entre a impedância acústica prevista pela GAN e a impedância acústica verdadeira de alguns traços do conjunto de teste. Esta comparação demonstra a superioridade desta arquitetura especialmente para o traço 7003.

Tabela 3. Apresentação do resultado de cada arquitetura sob cada uma das métricas avaliadas. Em negrito o melhor resultado para cada métrica.

	CNN	TCN	GAN
r^2	0,8004	0,9621	0,8906
<i>MSE</i>	1,5737	0,3024	0,8665
<i>MAE</i>	0,9102	0,4197	0,6341
<i>MedAE</i>	0,6682	0,3439	0,4244
<i>SSIM</i>	0,6857	0,8019	0,7148

5.6. Comparação de Métricas

A Tabela 3 demonstra que a TCN foi superior de acordo com todas as métricas, em seguida a GAN, e por fim a CNN. A melhor arquitetura, a TCN, chegou a uma correlação de 96,21%, isto é, quase perfeita, demonstrando que a única possibilidade de melhoria seria a capacidade de treinamento em conjuntos de dados menores, como ocorreria em uma cenário real.

6. Considerações Finais

A superioridade da TCN foi evidenciada, entanto é notável que o desempenho dela foi inferior na parte mais profunda, que é caracterizada por uma variação maior na litologia das rochas. Isso pode ter sido causado pelo uso de muitas convoluções dilatadas, que capturam padrões mais amplos, mas podem ter prejudicado a captura dos padrões menores. Também é interessante pontuar que a parte mais profunda do Marmousi2 não existia no Marmousi, que é onde está arquitetura foi testada pelos autores, e isto pode ter levado ao levado a uma escolha de arquitetura que não desempenhasse bem neste tipo de formação rochosa.

Neste artigo demonstrou-se que as redes neurais já são capazes de realizar inversões melhores que os modelos tradicionais, mas ainda precisam evoluir no sentido de serem capazes de serem treinadas em conjuntos menores de dados. Os parâmetros utilizados neste experimento, por exemplo, consideraram o uso de 101 poços, o que é muito acima da quantidade praticável em explorações reais, nesse sentido, o uso de aprendizado semi-supervisionado parece promissor, pois consegue tirar proveito também de dados não rotulados. O objetivo de comparar diferentes propostas sob mesmas condições foi alcançado e produziu métricas que permitem uma comparação simples entre os modelos. Trabalhos futuros podem realizar experimentos similares, mas em condições mais realistas, isto é, com um número de poços muito baixo. Essa análise indicaria que arquiteturas são mais viáveis para problemas reais.

Referências

- Albawi, S., Mohammed, T. A., and Al-Zawi, S. (2017). Understanding of a convolutional neural network. In *2017 International Conference on Engineering and Technology (ICET)*. IEEE.
- Chen, Y., Chen, H., Xiang, K., and Chen, X. (2016). Geological structure guided well log interpolation for high-fidelity full waveform inversion. *Geophysical Journal International*, 207(2):1313–1331.
- Das, V., Pollack, A., Wollner, U., and Mukerji, T. (2019). Convolutional neural network for seismic impedance inversion. *GEOPHYSICS*, 84(6):R869–R880.
- de Souza, M. G. (2018). *Inversão Sísmica acústica determinística utilizando redes neurais artificiais*. PhD thesis.
- Feng, J., Feng, X., Chen, J., Cao, X., Zhang, X., Jiao, L., and Yu, T. (2020). Generative adversarial networks based on collaborative learning and attention mechanism for hyperspectral image classification. *Remote Sensing*, 12(7):1149.
- Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., and Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11):139–144.
- Lea, C., Vidal, R., Reiter, A., and Hager, G. D. (2016). Temporal convolutional networks: A unified approach to action segmentation. In *Lecture Notes in Computer Science*, pages 47–54. Springer International Publishing.
- Li, S., Liu, B., Ren, Y., Chen, Y., Yang, S., Wang, Y., and Jiang, P. (2020). Deep-learning inversion of seismic data. *IEEE Transactions on Geoscience and Remote Sensing*, 58(3):2135–2149.
- Marques, C. R. (2021). Um estudo comparativo entre diferentes modelos de redes neurais de aprendizado profundo aplicados ao problema da inversão sísmica. *Qualificação de mestrado: Universidade Federal de Santa Catarina*.
- Martin, G. S., Wiley, R., and Marfurt, K. J. (2006). Marmousi2: An elastic upgrade for marmousi. *The Leading Edge*, 25(2):156–166.
- Mavko, G., Mukerji, T., and Dvorkin, J. (2009). *The Rock Physics Handbook*. Cambridge University Press.
- Mustafa, A., Alfarraj, M., and AlRegib, G. (2019). Estimation of acoustic impedance from seismic data using temporal convolutional network. In *SEG Technical Program Expanded Abstracts 2019*. Society of Exploration Geophysicists.
- Prasad, N., Gallego, J. M., Sander, R., Shihui Chen, Kim, K., and Hamilton, D. (2020). Ai-powered portfolio optimization using market segmentation, time series prediction, and predictive control.
- Russell, B. H. (1988). *Introduction to Seismic Inversion Methods*. Society of Exploration Geophysicists.

Wu, B., Meng, D., and Zhao, H. (2021). Semi-supervised learning for seismic impedance inversion using generative adversarial networks. *Remote Sensing*, 13(5):909.

Yang, F. and Ma, J. (2019). Deep-learning inversion: A next-generation seismic velocity model building method. *Geophysics*, 84(4):R583–R599.