

# Ekstrapolasi Frekuensi Rendah pada *Full Waveform Inversion (FWI)* dengan menggunakan *Deep Learning*. Part 1 : Validasi data Sintetik

Asido Saputra Sigalingging<sup>1,\*</sup>, Ignatius Sonny Winardhie<sup>1</sup>, dan Ekkal Dinanto<sup>1</sup>

<sup>1</sup>Teknik Geofisika, Institut Teknologi Bandung

\*Email: asido.saputra@gmail.com

Submit: 2021-12-20; Revised: 2021-12-23 ; Accepted: 2021-12-28

**Abstrak:** Kandungan seismik frekuensi rendah sangat berperan penting terhadap hasil inversi pada pemodelan *Full Waveform Inversion (FWI)*. Kehilangan frekuensi rendah dari data seismik akan membuat model akhir FWI sulit untuk konvergen. Penelitian ini melakukan ekstrapolasi frekuensi rendah dengan menggunakan deep learning. Dataset diperoleh dengan melakukan pemodelan ke depan seismik akustik menggunakan *finite difference* dari beberapa model P-Wave sintetik. Data seismik hasil pemodelan kemudian dipisah menggunakan *filter Butterworth*, sehingga diperoleh data seismik dengan frekuensi rendah ( $\leq 5$  Hz), dan frekuensi tinggi ( $\geq 5$  Hz). Data frekuensi tinggi dan frekuensi rendah masing-masing berurutan sebagai input dan output data yang akan digunakan sebagai data latih model *deep learning*. Model *deep learning Multi-Output Regression* yang digunakan dalam penelitian ini yakni *Multi-Layer Perceptron (MLP)* dan *Convolutional Neural Networks (CNN)*. Evaluasi dan ujicoba yang dilakukan terhadap model *deep learning* memberikan hasil akurasi yang baik. Berdasarkan hasil validasi akurasi model *deep learning* yang dilakukan, kedua model deep learning potensial untuk diterapkan pada ekstrapolasi frekuensi rendah data real sebelum dilakukan pemodelan FWI.

**Kata kunci:** Frekuensi Rendah, Deep Learning, Muti Layer Perceptron (MLP) , Convolutional Neural Network(CNN)

**Abstract:** Low-frequency seismic content plays an important role in the inversion results in Full Waveform Inversion (FWI) modeling. Low-frequency loss from seismic data will make the final FWI model difficult to converge. This study performs low-frequency extrapolation using deep learning. The dataset was obtained by performing acoustic seismic forward modeling using the finite-difference of several synthetic P-Wave models. After the simulated seismic is obtained, the data is separated using a Butterworth filter, so that seismic data with low frequency ( $\leq 5$  Hz), and high frequency ( $\geq 5$  Hz) are generated. High-frequency and low-frequency data respectively as input and output data will be used as training data for deep learning models. The deep learning Multi-Output Regression model used in this research is Multi-Layer Perceptron (MLP) and Convolutional Neural Networks (CNN). The evaluation and testing carried out on the deep learning model gave good accurate results. Based on the results of the validation of the accuracy of the deep learning model, the two deep learning models have the potential to be applied to low-frequency

*extrapolation of real data before Full Waveform Inversion (FWI) modeling is carried out.*

**Keywords:** Low Frequency Extrapolation, Deep Learning, Multi-Layer Perceptron (MLP), Convolutional Neural Network

## 1 PENDAHULUAN

*Full Waveform Inversion (FWI)* menjadi salah satu teknik pemodelan bawah permukaan yang memberikan nilai sifat fisika batuan dengan resolusi yang tinggi, melalui proses tomografi data seismik (Tarantola, 1984; Pratt dan Worthington, 1990). Pemodelan parameter bawah permukaan dengan FWI, dilakukan dengan memperbarui model awal secara berulang-ulang, optimasi model dilakukan dengan menggunakan metode gradien dari suatu fungsi *misfit*. Namun, proses optimasi model seringkali tidak konvergen menuju minimum global, melainkan terjebak dalam minimum lokal, hal ini terutama karena model awal yang dipilih terlalu jauh dari model bawah permukaan yang sebenarnya. Terdapat banyak faktor yang mempengaruhi optimasi model pada pemodelan FWI, diantaranya data seismik yang dimodelkan memiliki *noise* yang tinggi, misalnya *multiple* yang kuat, geometri akuisisi yang dilakukan tidak lengkap, dan kehilangan frekuensi rendah data seismik.

Faktor utama yang paling berpengaruh terhadap pemodelan FWI yakni kehilangan frekuensi rendah data seismik (Bunks dkk., 1995). Kehilangan frekuensi rendah pada data seismik diakibatkan tren model atau informasi rata-rata dari model geologi terkandung pada data seismik frekuensi rendah, sehingga kehilangan frekuensi rendah tersebut akan sangat berpengaruh terhadap konvergensi dari model FWI yang dilakukan. Pemulihan frekuensi rendah seismik telah banyak dilakukan dengan berbagai metode pengolahan data seismik, misalnya pemulihan frekuensi rendah dengan envelope sinyal (Wu dkk., 2014; Hu dkk., 2017), inversi deret reflektivitas dan konvolusi broadband wavelet sumber (Wang dan Herrmann, 2016; Zhang dkk., 2017). Namun pemulihan frekuensi rendah yang dilakukan dengan berbagai metode tersebut masih jauh dari frekuensi rendah seismik sesungguhnya, sehingga model yang dihasilkan pada FWI masih tetap jauh dari model sebenarnya. Selain itu, kelemahan utama pemulihan frekuensi rendah dengan metode

konvensional tersebut tidak praktis untuk diterapkan, karena masih memerlukan kembali berbagai teknik *preprocessing* data seismik.

Algoritma *deep learning* saat ini telah berkembang dengan baik dan banyak diterapkan dalam eksplorasi geofisika (Dramsch, 2020). Salah satu aplikasi *deep learning* dalam eksplorasi geofisika, yakni ekstrapolasi frekuensi rendah data seismik yang saat ini sedang dikembangkan oleh beberapa peneliti. Ovcharenko dkk. (2018); Sun dan Demanet (2018) melakukan ekstrapolasi frekuensi rendah data seismik akustik menggunakan algoritma *artificial neural network* (ANN) dengan arsitektur *Multi-layer Perceptron* (MLP). Algoritma MLP bekerja dengan menghubungkan input sebagai frekuensi tinggi dan output sebagai frekuensi rendah. Sun dan Demanet (2020) mengembangkan model ANN dengan menggunakan arsitektur *convolutional neural networks* (CNNs) untuk studi kasus yang sama, dengan hasil ekstrapolasi yang lebih baik dibanding dengan algoritma MLP. Sun dan Demanet (2020) dengan menggunakan algoritma CNN melakukan ekstrapolasi frekuensi rendah yang lebih kompleks untuk kasus seismik elastik multi komponen. Permasalahan ekstrapolasi frekuensi rendah dengan algoritma *deep learning* dapat diterapkan secara langsung pada data *raw seismic bandlimited* sehingga proses yang dilakukan lebih cepat dan efisien dibandingkan dengan metode konvensional.

Penelitian ini melakukan ekstrapolasi frekuensi rendah data seismik akustik dengan mengembangkan arsitektur *deep learning* MLP dan CNN. Model *deep learning* yang dihasilkan dilakukan validasi dengan data sintetik, kemudian model terbaik hasil validasi akan digunakan untuk melakukan ekstrapolasi pada data seismik riil. Data seismik riil sebelum dan setelah dilakukan pemulihan frekuensi rendahnya dengan menggunakan model MLP dan CNN, kemudian kedua data tersebut dilakukan pemodelan P-wave dengan FWI untuk menguji hasil ekstrapolasi frekuensi rendah terhadap konvergensi model FWI.

## 2 TEORI DAN METODOLOGI

Jaringan saraf tiruan ANN merupakan proses relasi  $y = f(x, w)$ , relasi yang baik tersebut terjadi ketika nilai  $w$  optimal, sehingga nilai  $y$  dan  $x$  memiliki kecocokan (*fitness*) yang baik. ANN memiliki persamaan matematika yang disederhanakan dari model jaringan saraf didalam otak manusia (Aggarwal dkk., 2018). Unit matematika dari saraf (*neuron*) dinamakan *perceptron*. Proses yang berlangsung didalam saraf akan ditiru dalam ANN, pada masing-masing *neuron* akan mengumpulkan berbagai informasi yang datang menuju *neuron* tersebut, selanjutnya akumulasi informasi yang diterima akan diteruskan melalui suatu fungsi yang bersifat non-linier, fungsi non-linier tersebut selanjutnya dinamakan sebagai fungsi aktivasi. Fungsi aktiviasi berguna untuk mengubah fungsi-fungsi linier yang datang menuju *neuron* menjadi fungsi keluaran yang bersifat non-linier, sehingga gabungan berbagai fungsi yang terdapat pada ANN akan bersifat non-linier. Gabungan dari beberapa *perceptron* (*multiperceptron*) dalam sebuah bentuk sederhana dinamakan sebagai sebuah lapisan (*layer*). Ketika masing-masing *perceptron* dari suatu *layer* terhubung ke masing-masing *perceptron* dari suatu *layer* lain, maka hubungan ini dinamakan *fully-connected* ANN (Schmidhuber, 2015).

### 2.1 Multi Layer Perceptron(MLP)

Algoritma *Multi-Layer Perceptron*(MLP) merupakan bentuk aproksimasi suatu fungsi yang lebih kompleks, dimana terdapat sejumlah *hidden layer* diantara *layer input* dan *output* (Ramchoun dkk., 2016). Ekstrapolasi frekuensi rendah dilakukan pada masing-masing tras seismik, *input* dan *output* merupakan data seismik yang sama, masing-masing berurutan merupakan seismik frekuensi tinggi dan frekuensi rendah. Arsitektur pertama yang dilakukan untuk ekstrapolasi frekuensi seismik rendah adalah model MLP (Ovcharenko dkk., 2018). Arsitektur ini terdiri dari 3 *hidden layer* dimana masing-masing layer berurutan memiliki jumlah unit 4000, 8000, 4000. Jumlah unit pada masing-masing *input layer* dan *output layer* mengikuti jumlah sampel data tras seismik dalam domain waktu (Gambar 1).

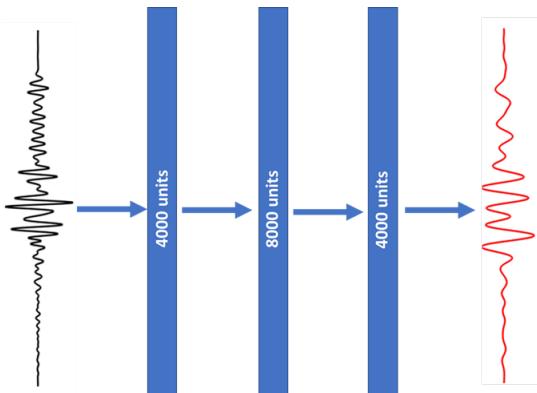
### 2.2 Convolutional Neural Networks(CNNs)

Masalah yang terjadi pada MLP adalah banyaknya parameter *training* ketika terjadi peningkatan jumlah dari parameter *input*, jumlah *hidden layer* dan *neuron* pada masing-masing *neuron* dan *output*, sehingga membutuhkan proses komputasi yang lebih kompleks dan waktu *training* yang lebih lama (Ovcharenko dkk., 2018). Pada kasus dengan data *input* yang banyak, maka arsitektur MLP tidak praktis untuk diterapkan. *Convolutional Neural Networks* (CNNs) dapat digunakan untuk mengatasi keterbatasan MLP tersebut, CNNs bekerja dengan mengimplementasikan konsep *local spatial connectivity*, artinya hanya data yang bersifat reseptif yang akan melalui *fully-connected neural network*. Proses CNNs sejatinya adalah proses untuk melakukan ekstraksi fitur (*feature extraction*), proses ekstraksi tersebut bertujuan untuk memadatkan informasi dari suatu input ke-dalam ukuran input yang lebih kecil (Aggarwal dkk., 2018). Proses ekstraksi tersebut dilakukan dengan konvolusi antara input dengan suatu *filter* yang disebut sebagai *kernel*. Pada kasus ekstrapolasi frekuensi rendah ukuran *filter* yang digunakan berbeda dengan *filter* yang digunakan pada umumnya untuk kasus klasifikasi gambar, ukuran *filter* yang digunakan untuk ekstrapolasi frekuensi rendah lebih panjang, hal ini bertujuan untuk menjaga *bandwidth* sinyal seismik tetap terpadatkan dengan baik (Sun dan Demanet, 2020).

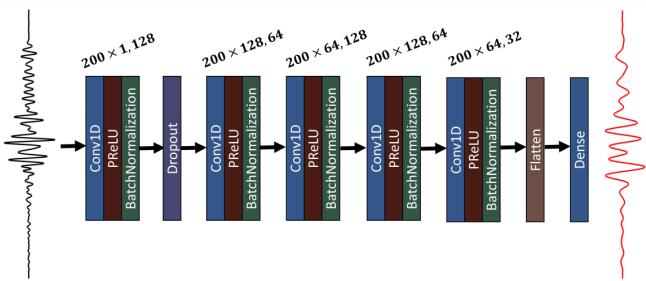
Model arsitektur kedua yang dilakukan pada penelitian ini yakni model CNNs (Sun dan Demanet, 2020), model ini terdiri dari lima blok *layer* konvolusi yang berurutan, *layer batch normalization* dan *layer PreLU*, dan paling akhir diikuti oleh *layer fully-connected*. *Input layer* merupakan amplitudo sinyal seismik frekuensi tinggi, kemudian *output layer* sama dengan *input* merupakan *output* kontinyu. Jumlah *filter* yang digunakan pada masing-masing *layer* konvolusi berurutan yakni 128, 64, 128, 64, 32. Ukuran *filter* untuk semua *layer* diatur sama dengan ukuran 80. Ukuran stride dan padding pada setiap *layer* konvolusi diatur sama masing-masing 1 dan 0 (Gambar 2).

### 2.3 Dataset

Dataset yang digunakan merupakan data sintetik yang diperoleh dengan melakukan pemodelan seismik akustik *finite difference* (FD). Model kecepatan Marmousi pada Gambar



**Gambar 1.** Arsitektur model MLP. Terdiri dari tiga *hidden layer*, dimana masing-masing *hidden layer* terdiri dari 4000, 8000, 6000 unit



**Gambar 2.** Arsitektur model CNNs, dimana digunakan *filter* dengan ukuran yang besar pada setiap layer ([Sun dan Demanet, 2020](#)). Terdapat satu layer dropout yang bertujuan untuk mencegah terjadinya *over-fitting* model

3, dibagi menjadi 12 *sub-model*, dimana masing-masing *sub-model* tersebut dipilih secara acak baik pada lokasi maupun pada luas area *sub-model*. Pemilihan secara acak tersebut, bertujuan agar algoritma *deep learning* mampu melakukan ekstrapolasi dengan baik pada keseluruhan model Marmousi ([Sun dan Demanet, 2020](#)). Masing-masing *sub-model* dilakukan *grid* interpolasi, sehingga ketebalan dan lebar seluruh *sub-model* 500 x 171 *grid* sama, dimana lebar *grid* diatur homogen sebesar 20 m.

Data *training* berupa seismik akustik diperoleh dari simulasi 2D FD domain waktu dari 12 *sub-model* Marmousi (Gambar 4), menggunakan pustaka *python Devito* ([Luporini dkk., 2020](#)). Simulasi dilakukan dengan menggunakan sumber gelombang Ricker dengan frekuensi dominan 10 Hz, interval waktu 2 ms, waktu rekaman selama 4 s. Masing-masing *sub-model* terdiri dari 30 sumber dan 300 penerima, sehingga diperoleh 108.000 tras seismik sintetik sebagai dataset. Untuk data validasi pada setiap proses *training* diperoleh dari 20% total dataset. Data *testing* diperoleh dengan melakukan simulasi pada model kecepatan Marmousi lengkap (Gambar 3). Data *input* dan *output* pada proses *training* masing-masing merupakan seismik frekuensi tinggi dan rendah dalam domain waktu. Kedua data tersebut diperoleh dengan melakukan *filter Butterworth*, dimana seismik frekuensi rendah memiliki frekuensi 5 Hz dan data frekuensi tinggi memiliki frekuensi 5 Hz. Untuk meningkatkan performa model *deep learning* dilakukan normalisasi amplitudo maksimum 1 dengan membagi tiap amplitudo dengan nilai

maksimumnya. Parameter normalisasi disimpan untuk penyetaraan nilai amplitudo pada proses FWI nantinya. Hasil *filter* diperlihatkan pada Gambar 5.

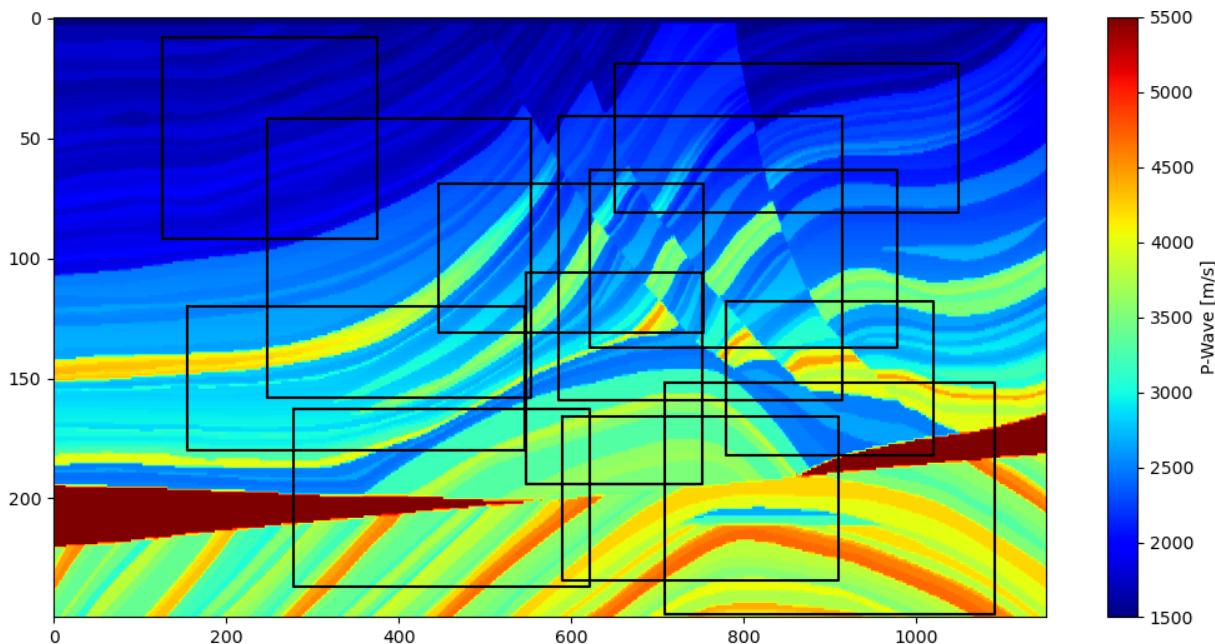
### 3 PROSES TRAINING

Training model *deep learning* dilakukan dengan menggunakan pustaka *python Keras* yang ada pada *framework TensorFlow*. Proses *training* kedua algoritma MLP dan CNNs, menggunakan optimasi Adam(*adaptive moment estimation*) dengan *minibatch* 1024 sampel pada masing-masing iterasi. Parameter *learning rate*, *regularization* masing-masing sebesar 0.001, 0.0005 nilai kedua parameter tersebut sama untuk kedua algoritma. Proses *training* dilakukan sebanyak 100 *epoch*, dimana *loss function* yang digunakan yakni *mean absolute error*(MAE). Grafik nilai kesalahan(error) model pada tiap iterasi diberikan pada Gambar 6, diperlihatkan bahwa seiring bertambahnya jumlah epoch diikuti oleh peningkatan performa kedua algoritma, dimana terjadi penurunan nilai MAE yang cukup ekstrim.

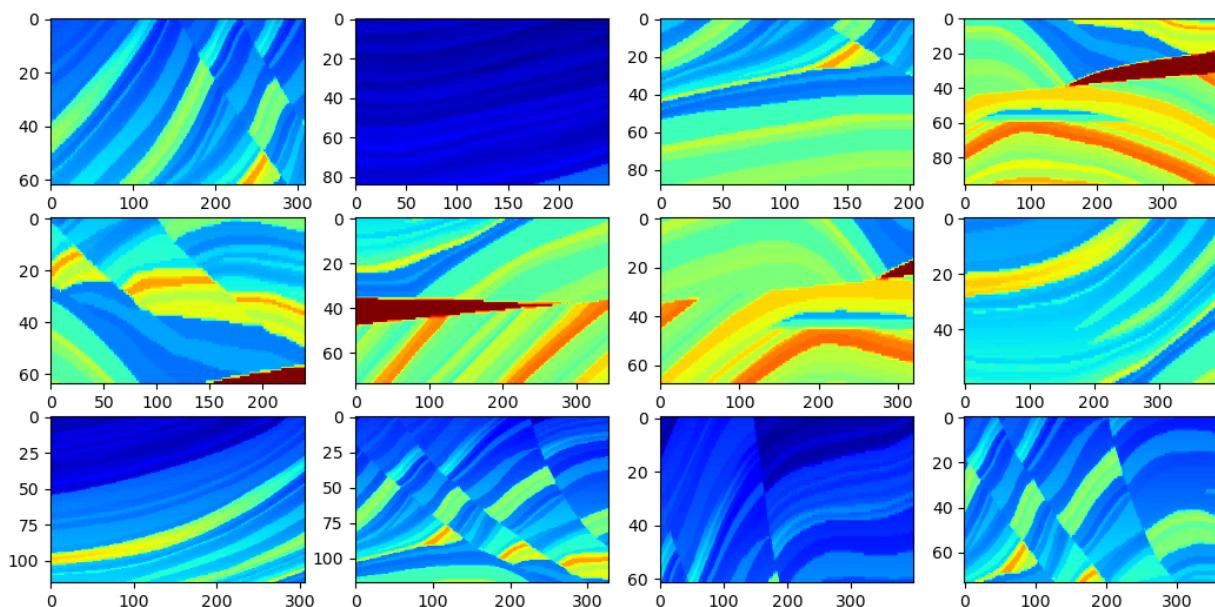
### 4 HASIL DAN PEMBAHASAN

Setelah proses *training* selesai dilakukan, kemudian model dievaluasi dengan melakukan ekstrapolasi frekuensi rendah pada data validasi. Data validasi berasal dari simulasi seismik model Marmousi dengan ukuran yang lengkap dan telah dilakukan *filter* frekuensi rendah sebelum dilakukan ekstrapolasi. Pada Gambar 5 diberikan perbedaan shot gather frekuensi rendah antara seismik sebenarnya dan hasil ekstrapolasi deep learning, dimana lokasi sumber berada 5km pada jarak horizontal. Kedua algoritma *deep learning* MLP dan CNNs akurat dalam melakukan ekstrapolasi frekuensi rendah, penampang seismik frekuensi rendah antara data sebenarnya dengan hasil ekstrapolasi kedua algoritma memiliki kecocokan yang tinggi, dimana selisih nilai amplitudo sangat kecil baik untuk MLP dan CNNs. Walaupun nilai MAE dari kedua metode sama-sama kecil, tetapi hasil prediksi CNNs memberikan akurasi yang lebih baik dibandingkan dengan hasil prediksi MLP (Gambar 7). Akurasi CNNs lebih baik dibandingkan dengan MLP, hal ini karena proses konvolusi dalam CNNs mampu mengekstrak informasi dari input data dengan baik sebelum diteruskan ke *layer fully connected*.

Pada Gambar 8 diperlihatkan perbedaan tras seismik frekuensi rendah sebenarnya dan hasil ekstrapolasi dengan menggunakan kedua algoritma *deep learning* MLP dan CNNs. Kedua algoritma tersebut melakukan ekstrapolasi dengan baik, dimana perbedaan seismik trasnya sangat kecil. Namun masih terdapat limitasi akurasi model *deep learning*, dimana kemungkinan model mengalami *over fitting*. Kasus *over fitting* terjadi karena jumlah dataset yang digunakan jauh lebih kecil(108.000) dibandingkan dengan parameter model *deep learning* yang harus dilakukan optimasi(>70 juta). Limitasi lain yakni ketidakseimbangan dari dataset, dimana dominan energi gelombang langsung(*direct wave*) lebih dibandingkan dengan gelombang refleksi(*reflection wave*), hal ini mengakibatkan model akan lebih dipengaruhi oleh amplitudo dari gelombang langsung dan kurang sensitif terhadap perubahan gelombang refleksi.



**Gambar 3.** Model kecepatan(P-Wave) Marmousi akan digunakan sebagai model validasi (*testing*)



**Gambar 4.** Sub-model yang diekstrak dari model Marmousi, digunakan sebagai model kecepatan untuk *data training*

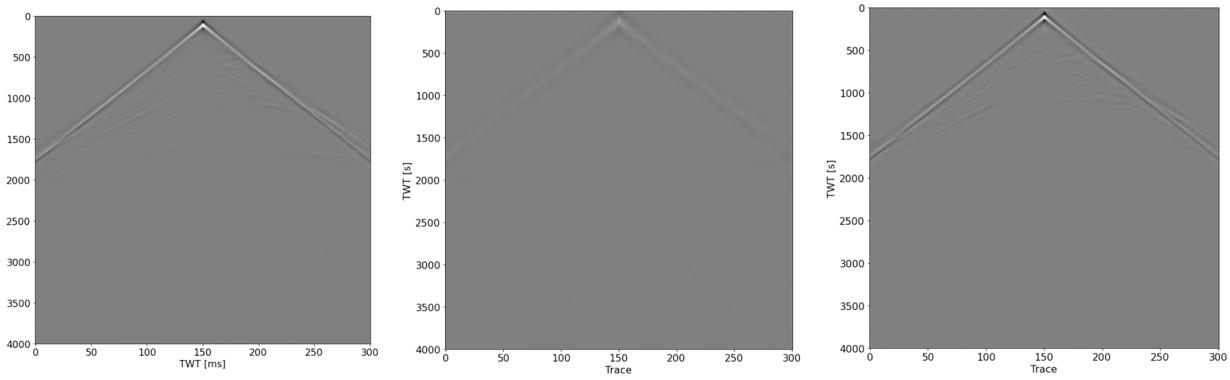
## 5 KESIMPULAN

Dua pendekatan model *deep learning* yang digunakan dalam studi ini untuk ekstrapolasi frekuensi rendah, memberikan hasil yang akurat terhadap data validasi. Namun model CNNs memiliki akurasi yang lebih baik dibandingkan model MPL dalam prediksi data seismik frekuensi rendah. Berdasarkan hasil validasi data tersebut, maka model *deep learning* yang diperoleh selanjutnya dapat diterapkan untuk ekstrapolasi frekuensi rendah data real, sebelum dilakukan pemodelan dengan FWI. Ekstrapolasi frekuensi dapat dilakukan langsung pada data *shot gather* tanpa perlu melakukan preprocessing.

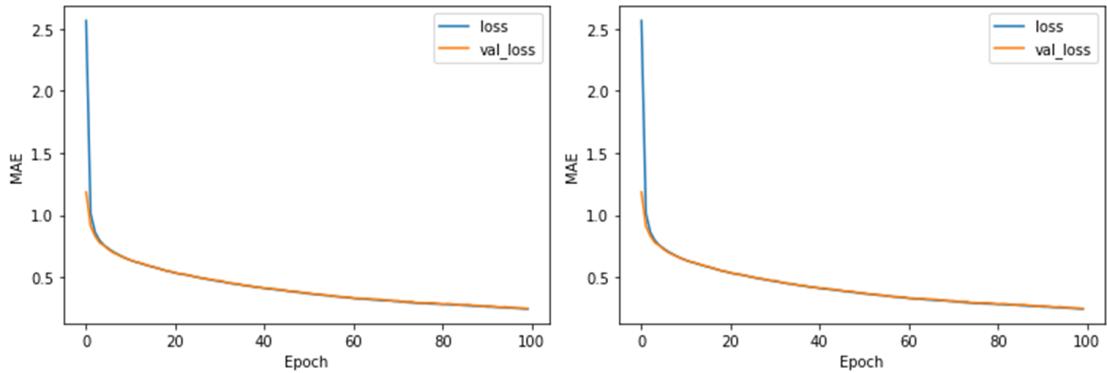
kukan langsung pada data *shot gather* tanpa perlu melakukan preprocessing.

## UCAPAN TERIMA KASIH

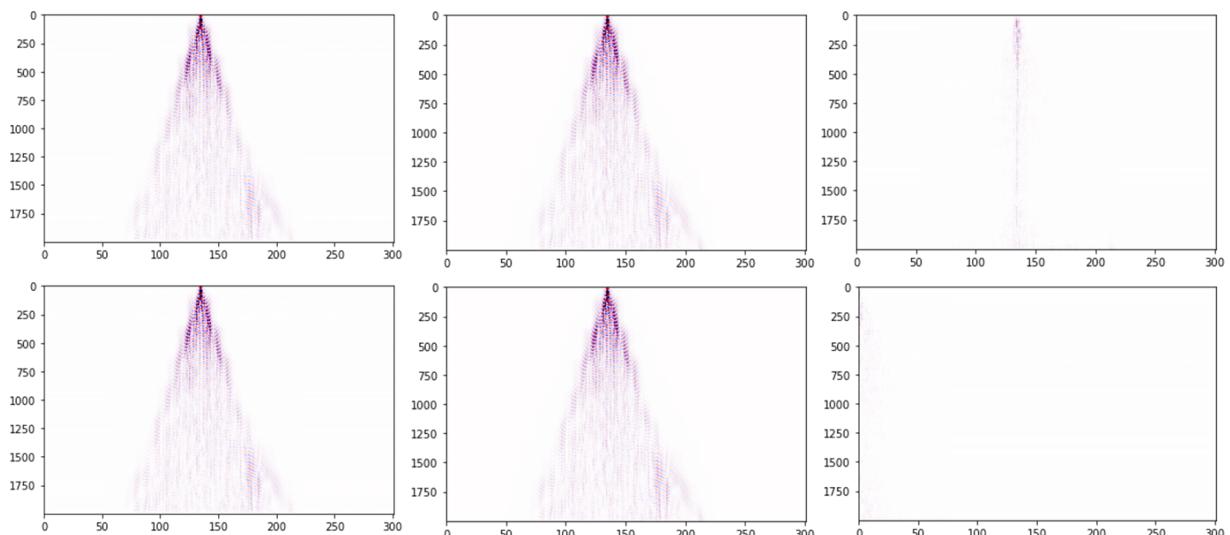
Penulis mengucapkan terimakasih kepada program magister teknik geofisika Institut Teknologi Bandung(ITB) atas dukungan penyelesaian paper ini.



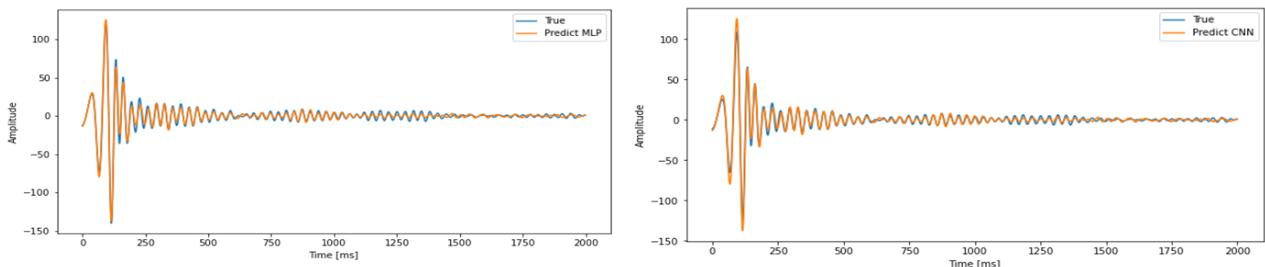
**Gambar 5.** Shot Gather seluruh rentang frekuensi(kiri), Shot Gather frekuensi rendah;5 Hz (tengah), Shot Gather frekuensi tinggi;5 Hz(kanan).



**Gambar 6.** Error pada proses *training dataset* Marmousi (kiri) MLP, (kanan) CNNs. Grafik *loss* (garis biru) menjelaskan nilai MAE untuk setiap dataset yang ikutsertakan pada proses *training*, sedangkan Grafik *val-loss*(jingga) menjelaskan MAE hanya pada *data testing* yang tidak ikutsertakan dalam proses *training*.



**Gambar 7.** Gambar di baris pertama adalah hasil MLP dan di baris kedua adalah hasil CNNs. Frekuensi rendah sebenarnya(simulasi Marmousi lengkap) (kolom kiri), frekuensi rendah hasil ekstrapolasi dengan *deep learning* (kolom tengah), perbedaan sebenarnya dengan hasil ekstrapolasi (kolom kanan).



**Gambar 8.** Perbedaan tras seismik frekuensi rendah sebenarnya(biru) dan hasil ekstrapolasi (jingga). Tras seismik berada pada posisi horizontal 5 km model Marmousi lengkap.

## Pustaka

- Aggarwal, C.C. dkk. (2018): Neural Networks and Deep Learning: A Textbook, vol. 10. Springer International Publishing.
- Bunks, C., Saleck, F.M., Zaleski, S. dan Chavent, G. (1995): Multiscale seismic waveform inversion. *Geophysics*, **60**(5), 1457–1473.
- Dramsch, J.S. (2020): 70 years of machine learning in geoscience in review. In: *Machine Learning in Geosciences*. Elsevier, 1–55, doi:10.1016/bs.agph.2020.08.002.
- Hu, Y., Han, L., Xu, Z., Zhang, F. dan Zeng, J. (2017): Adaptive multi-step full waveform inversion based on waveform mode decomposition. *Journal of Applied Geophysics*, **139**, 195–210.
- Luporini, F. dkk. (2020): Architecture and performance of devito, a system for automated stencil computation. *ACM Transactions on Mathematical Software (TOMS)*, **46**(1), 1–28.
- Ovcharenko, O., Kazei, V., Peter, D., Zhang, X. dan Alkhailah, T. (2018): Low-frequency data extrapolation using a feed-forward ann. *80th EAGE Conference and Exhibition 2018*, European Association of Geoscientists & Engineers, vol. 2018, 1–5.
- Pratt, R.G. dan Worthington, M.H. (1990): Inverse theory applied to multi-source cross-hole tomography. part 1: Acoustic wave-equation method 1. *Geophysical prospecting*, **38**(3), 287–310.
- Ramchoun, H., Idrissi, M.A.J., Ghanou, Y. dan Ettaouil, M. (2016): Multilayer perceptron: Architecture optimization and training. *Int. J. Interact. Multim. Artif. Intell.*, **4**, 26–30.
- Schmidhuber, J. (2015): Deep learning in neural networks: An overview. *Neural networks*, **61**, 85–117.
- Sun, H. dan Demanet, L. (2018): Low frequency extrapolation with deep learning. In: *SEG Technical Program Expanded Abstracts 2018*. Society of Exploration Geophysicists, 2011–2015.
- Sun, H. dan Demanet, L. (2020): Extrapolated full-waveform inversion with deep learning. *Geophysics*, **85**(3), R275–R288.
- Tarantola, A. (1984): Inversion of seismic reflection data in the acoustic approximation. *Geophysics*, **49**(8), 1259–1266.
- Wang, R. dan Herrmann, F. (2016): Frequency down extrapolation with tv norm minimization. In: *SEG Technical Program Expanded Abstracts 2016*. Society of Exploration Geophysicists, 1380–1384.
- Wu, R.S., Luo, J. dan Wu, B. (2014): Seismic envelope inversion and modulation signal model. *Geophysics*, **79**(3), WA13–WA24.
- Zhang, P., Han, L., Xu, Z., Zhang, F. dan Wei, Y. (2017): Sparse blind deconvolution based low-frequency seismic data reconstruction for multiscale full waveform inversion. *Journal of Applied Geophysics*, **139**, 91–108.