

ESTIMASI MAGNITUDO GEMPA BUMI DARI SINYAL SEISMIK GELOMBANG P MENGGUNAKAN METODE JST BACKPROPAGATION

ESTIMATION OF EARTHQUAKE MAGNITUDE FROM P WAVE SEISMIC SIGNAL USING BACKPROPAGATION ANN METHOD

Sholahuddin Al-Ayubi¹, Astri Novianty, S.T., M.T.² Anggumeka Luhur Prasasti, S.T., M.T.³

^{1,2,3} Prodi S1 Teknik Komputer, Fakultas Teknik Elektro, Universitas Telkom

¹ sholahuddinalayubi@student.telkomuniversity.ac.id, ² astrinov@telkomuniversity.ac.id,

³ anggunmeka@telkomuniversity.ac.id

Abstrak

Gempa bumi adalah sebuah peristiwa bergetarnya bumi karena pergerakan atau pergeseran lapisan batuan pada kulit bumi secara tiba-tiba akibat pergerakan lempeng-lempeng tektonik. Gempa bumi umumnya menghasilkan gelombang P, gelombang S dan gelombang permukaan. Gelombang P umumnya memiliki amplitudo yang lebih kecil dan kecepatan yang lebih besar daripada dua gelombang selanjutnya yang dapat menyebabkan kerusakan luas. Untuk *Earthquake Early Warning* (EEW), magnitudo harus diperkirakan cukup awal sehingga peringatan dapat dikeluarkan sebelum kedatangan gelombang yang lebih merusak (gelombang S dan gelombang permukaan). Tujuan penelitian ini adalah menghasilkan estimasi magnitudo gempa bumi dari sinyal seismik gelombang P menggunakan metode JST *Backpropagation* dan mengetahui performansinya. Sinyal seismik digunakan sebagai input data dan masuk ke dalam perhitungan ekstraksi fitur. Output dari ekstraksi fitur akan menjadi input untuk JST. Selanjutnya JST akan melakukan pelatihan untuk menghasilkan nilai bobot yang menghasilkan *error* terkecil dan nilai bobot tersebut akan digunakan dalam proses *testing* yang akan menghasilkan nilai estimasi. Performansi terbaik sistem estimasi magnitudo gempa bumi didapatkan dengan 16 nilai fitur, 11 jumlah neuron *hidden* dan nilai *learning rate* 0.4 dengan hasil performansi nilai MSE 0.369060.

Kata Kunci: Magnitudo, Gempa Bumi, Sinyal Seismik, JST Backpropagation

Abstract

Earthquake is an event that the ground is shaking due to the movement of rock layers on the earth that suddenly moves towards tectonic plates. Earthquakes generally produce P waves, S waves, and Surface waves. P waves generally have a smaller amplitude and greater speed than the next two waves which can cause extensive damage. For Earthquake Early Warning (EEW), the magnitude must be estimated early enough so that warnings can be issued before the arrival of more destructive waves (S waves and Surface Waves). The purpose of this study is to produce earthquake magnitude estimation from seismic signals using Backpropagation ANN method and find out its performance. Seismic signals are used as input data and enter into feature extraction calculations. Output from feature extraction will be input for ANN. Furthermore, ANN will conduct training to produce a weight value that produces the smallest error and the weight value will be used in the testing process which will produce an estimated value. The best performance of earthquake magnitude estimation system is obtained with 16 feature values, 11 number of hidden neurons and learning rate value 0.4 with the results of MSE value performance 0.369060.

Keywords: *Magnitude, Earthquake, Seismic Signal, Backpropagation ANN*

1. Pendahuluan

Gempa bumi (earthquake) adalah sebuah peristiwa bergetarnya bumi karena pergerakan/pergeseran lapisan batuan pada kulit bumi secara tiba-tiba akibat pergerakan lempeng-lempeng tektonik[1]. Gempa bumi menimbulkan gelombang elastis yang dipancarkan dari sumber/pusat gempa bumi ke seluruh bagian dalam bumi dan permukaan bumi yang disebut sebagai gelombang seismik[2]. Gelombang seismik secara ringkas terdiri dari 2 jenis, yaitu gelombang yang merambat di permukaan bumi (Gelombang permukaan) dan pada bagian dalam bumi (Gelombang tubuh) yang memiliki dua macam gelombang, yakni gelombang P (Primer/longitudinal) dan gelombang S (Sekunder/transversal)[1].

Gempa bumi umumnya menghasilkan gelombang P, gelombang S dan gelombang permukaan. Gelombang P umumnya memiliki amplitudo yang lebih kecil dan kecepatan yang lebih besar daripada dua gelombang selanjutnya yang dapat menyebabkan kerusakan luas. Untuk Earthquake Early Warning (EEW), magnitudo harus diperkirakan cukup awal sehingga peringatan dapat dikeluarkan sebelum kedatangan gelombang yang lebih merusak (gelombang S dan gelombang permukaan). Pengukuran magnitudo yang akurat seperti dari beberapa detik pertama gelombang P akan sangat berguna untuk EEW[3].

Oleh karena itu prediksi magnitudo gempa bumi dapat membantu untuk mengambil langkah-langkah efektif untuk mengurangi kerusakan-kerusakan seperti kerusakan bangunan, kerusakan lalu lintas, dan mengurangi jumlah korban jiwa[4]. Berdasarkan permasalahan tersebut, akan dibuat penelitian untuk memberikan estimasi magnitudo gempa bumi dari sinyal seismik gelombang P yang diharapkan dapat membantu meningkatkan teknologi BMKG terkait dengan gempa bumi.

2. Dasar Teori

2.1 Ekstraksi Fitur

Sebuah metode yang dapat digunakan untuk mengenali objek berdasarkan histogram spesifik yang dimiliki oleh objek tersebut dan bertujuan untuk melakukan perbandingan berdasarkan karakteristik histogram yang dimilikinya[5]. Ekstraksi fitur yang digunakan adalah pengambilan nilai fitur yang berhubungan dengan amplitudo dari gelombang P. Nilai amplitudo digunakan karena memiliki hubungan yang tegak lurus dengan besar getaran gempa atau biasa dikenal dengan magnitudo. Semakin besar magnitudo yang di tangkap oleh seismometer maka amplitudo yang ditampilkan oleh seismograf akan menjadi semakin besar[2].

2.1.1 Short Time Average / Long Time Average (STA/LTA)

Terdapat empat buah atribut STA / LTA yang bisa digunakan sebagai ekstraksi fitur yaitu classic STA / LTA, recursive STA / LTA, delayed STA / LTA, carl STA / LTA[6, 7, 8]. Keempat atribut STA/LTA tersebut di gunakan menggunakan modul obspy.signal.trigger[11]. Formula STA/LTA secara umum dilihat pada persamaan [2.1], [2.2], [2.3]. Pada saat nilai $sta_{(nsta)} < nlta$ maka nilai $sta = 0$ [8].

$$\frac{sta}{lta} = \frac{\sum_{nsta} sta_{(nsta)}}{\sum_{nlta} lta_{(nlta)}} \quad [2.1]$$

$$nsta = \text{sampling rate} \times \text{waktu jangka pendek} \quad [2.2]$$

$$nlta = \text{sampling rate} \times \text{waktu jangka panjang} \quad [2.3]$$

2.1.2 Rata-rata Amplitudo

Rata-rata amplitudo (avg_i) dinyatakan pada rumus [2.4] dan [2.5]. Variabel $X_{[n]}$ adalah nilai amplitudo ke-n dari jumlah data, untuk waktu yang digunakan dalam persamaan rumus [2.5] adalah 30 detik. Jika data yang digunakan memiliki panjang waktu 180 detik, maka jumlah nilai rata-rata amplitudo yang dihasilkan sebanyak enam nilai.

$$avg_i = \frac{\sum_{n=1}^N X_{[n]}}{N} \quad [2.4]$$

$$N = \text{sampling rate} \times \text{waktu} \quad [2.5]$$

2.1.3 Maksimum Amplitudo

Nilai maksimum amplitudo diambil tidak menggunakan rumus. Nilai maksimum amplitudo diambil menggunakan modul atau perbandingan nilai yang lebih besar pada fungsi pengulangan. Nilai maksimum amplitudo dapat diambil dari seluruh jumlah data atau diambil dengan jarak waktu tertentu.

2.2 Jaringan Syaraf Tiruan *Backpropagation*

JST *Backpropagation* terdiri dari tiga lapisan, yaitu lapisan input, lapisan tersembunyi, dan lapisan output. Kemudian, setiap lapisan memiliki jumlah neuron tertentu tergantung pada kompleksitas masalahnya[9]. Dalam algoritma jaringan syaraf tiruan terdapat bobot input (V_{ij}), bias input (V_{oj}), bias output (W_{ok}) dan bobot output (W_{jk}) yang nilai tersebut diinisialisasi secara acak dengan nilai inisialisasi seperti [2.6]. Memiliki salah satu fungsi aktivasi sigmoid seperti [2.7] dan fungsi turunan aktivasinya seperti [2.8]. Keseluruhan nilai tersebut akan digunakan dalam fase *feedforward* dan *backpropagation*[10].

$$-0.5 \leq V_{ij} \leq 0.5, \quad -0.5 \leq W_{jk} \leq 0.5 \quad [2.6]$$

$$f(x) = \frac{1}{1 + e^{-x}} \quad [2.7]$$

$$f'(x) = f(x)(1 - f(x)) \quad [2.8]$$

Dalam fase *feedforward* terdapat nilai neuron input (X_i) dengan i sebagai jumlah neuron input, nilai neuron *hidden* (Z_j) dengan j sebagai jumlah neuron *hidden* dan nilai neuron output (Y_k) dengan k sebagai jumlah neuron output. Perhitungan dalam fase *feedforward* terjadi pada perhitungan nilai neuron *hidden* dan neuron output[10]. Nilai neuron *hidden* adalah nilai aktivasi dari nilai penjumlahan neuron dan bobot input (zin_j) yang dijelaskan pada persamaan [2.9] dan [2.10]. Nilai neuron output adalah nilai aktivasi dari nilai penjumlahan neuron dan bobot *hidden* (yin_k) dijelaskan pada persamaan [2.11] dan [2.12].

$$Z_j = f(zin_j) \quad [2.9]$$

$$zin_j = V_{oj} + \sum X_i V_{ij} \quad [2.10]$$

$$Y_k = f(yin_k) \quad [2.11]$$

$$y_{in_k} = W_{ok} + \sum Z_j W_{jk} \quad [2.12]$$

Dalam fase *backpropagation* terdapat nilai target (T_k) dan *learning rate* (α) untuk mengoreksi eror pada nilai output, nilai hidden, nilai bobot input dan nilai bobot output. Untuk menghitung eror nilai output (δ_k) menggunakan persamaan [2.13] dan untuk menghitung koreksi error output (e_k) menggunakan persamaan [2.14]. Nilai bobot output baru (ΔW_{jk}) dapat dihitung dengan persamaan [2.15] dan bias output baru (ΔW_{ok}) dengan persamaan[2.16].

$$\delta_k = (T_k - Y_k)f'(Y_k) \quad [2.13]$$

$$e_k = \alpha \delta_k \quad [2.14]$$

$$\Delta W_{jk} = e_k Z_j + W_{jk} \quad [2.15]$$

$$\Delta W_{ok} = e_k + W_{ok} \quad [2.16]$$

Setelah menghitung nilai bobot output, selanjutnya menghitung eror nilai hidden (D_j) menggunakan persamaan [2.17]. Selanjutnya menghitung koreksi error hidden (h_j) menggunakan persamaan [2.18]. Untuk menghitung nilai bobot baru (ΔV_{ij}) input menggunakan persamaan [2.19] dan bias input baru (ΔV_{oj}) menggunakan persamaan [2.20].

$$D_j = \sum \delta_k W_{jk} f'(Z_j) \quad [2.17]$$

$$h_j = \alpha D_j \quad [2.18]$$

$$\Delta V_{ij} = h_j X_i + V_{ij} \quad [2.19]$$

$$\Delta V_{oj} = h_j + V_{ok} \quad [2.20]$$

2.3 Normalisasi

Normalisasi (z_i) adalah teknik penskalaan untuk menemukan skala baru dari skala yang ada dengan tujuan membantu proses prediksi dan estimasi[11]. Untuk mencari nilai normalisasi menggunakan persamaan [2.21]. Dalam persamaan normalisasi $\max(x)$ adalah maksimum data, $\min(x)$ adalah nilai minimum data dan x_i adalah data yang akan di normalisasi. Untuk membalikkan nilai yang telah di normalisasi digunakan persamaan [2.22].

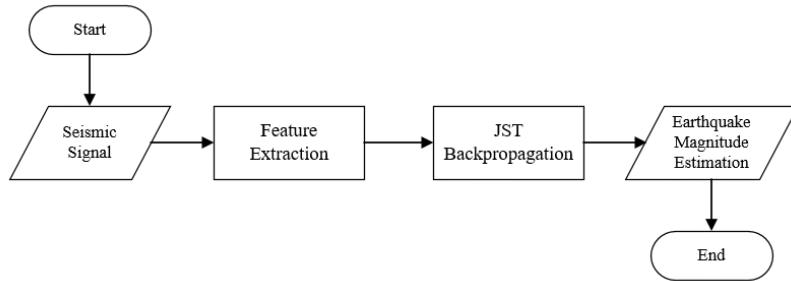
$$z_i = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad [2.21]$$

$$x_i = z_i(\max(x) - \min(x)) + \min(x) \quad [2.22]$$

3. Pembahasan

3.1 Diagram Alir Umum

Diagram alir ini menggambarkan secara umum perancangan sistem estimasi magnitudo gempa bumi. Sinyal seismik sebagai data input masuk ke proses ekstraksi fitur. Output dari proses ekstraksi fitur menjadi input untuk JST Backpropagation yang hasilnya adalah estimasi magnitudo gempa bumi.

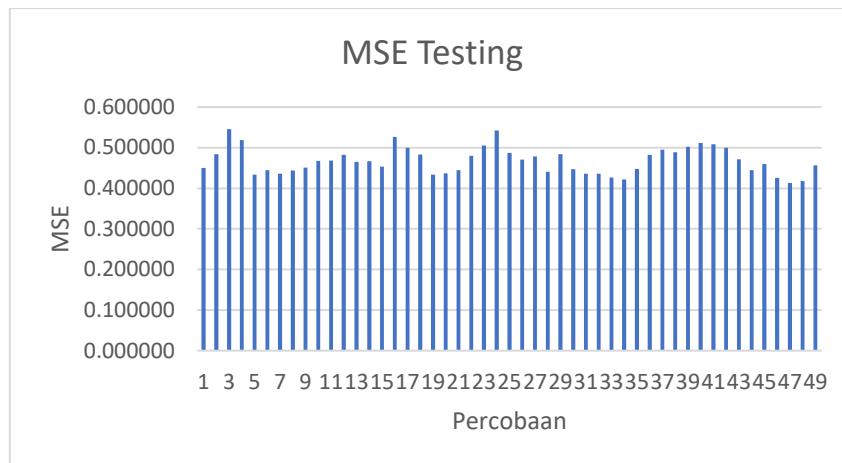
*Gambar 3. 1 Diagram alir umum estimasi magnitudo gempa bumi*

4. Implementasi dan pengujian sistem

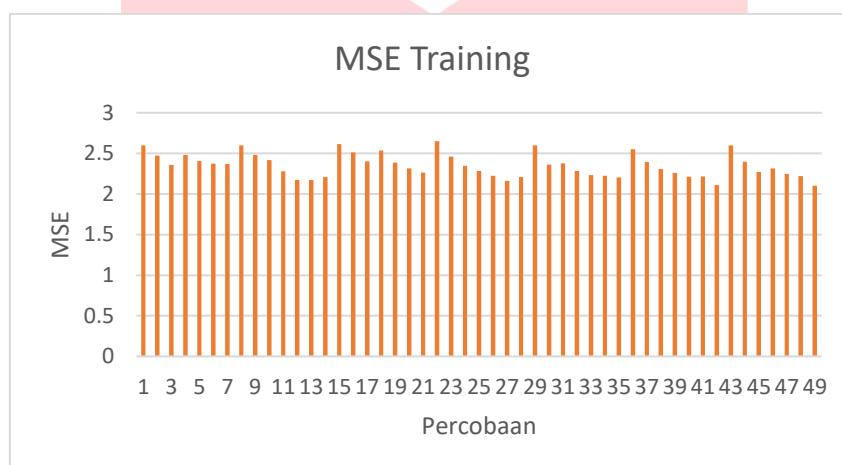
4.1 Pengujian skema ekstraksi fitur ke-1

Tabel 4. 1 Beberapa hasil pengujian skema ekstraksi fitur ke-1

Pengujian	Neuron Hidden	Learning rate	MSE Testing	MSE Training	Waktu (s)
1	6	0.1	0.449950	2.598701	376.252
2	6	0.2	0.484140	2.473571	371.342
3	6	0.3	0.545460	2.360052	372.190
4	6	0.4	0.518640	2.480762	371.415
5	6	0.5	0.433370	2.404090	392.394
6	6	0.6	0.444250	2.373801	368.158
7	6	0.7	0.435800	2.368672	381.677
8	7	0.1	0.443870	2.600071	475.025
9	7	0.2	0.451230	2.479716	425.288
10	7	0.3	0.467500	2.416484	404.149
11	7	0.4	0.468300	2.279221	421.717
12	7	0.5	0.482670	2.171425	450.283
13	7	0.6	0.464910	2.171794	424.365
14	7	0.7	0.4666860	2.207612	420.880
15	8	0.1	0.453650	2.616277	441.028
16	8	0.2	0.526460	2.513997	469.510
17	8	0.3	0.499980	2.403259	490.991
18	8	0.4	0.483580	2.537237	470.339
19	8	0.5	0.433370	2.386776	496.378
20	8	0.6	0.436350	2.315019	480.780



Gambar 4. 1 Grafik MSE testing hasil pengujian skema ekstraksi fitur ke-1



Gambar 4. 2 Grafik MSE training hasil pengujian skema ekstraksi fitur ke-1

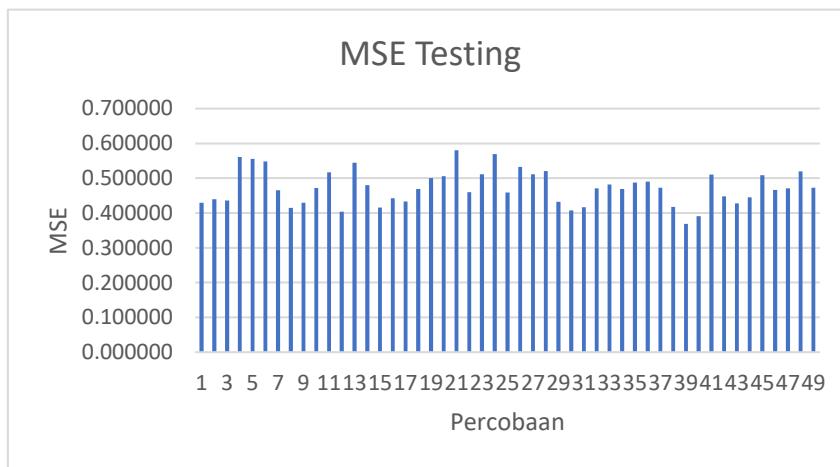
Berdasarkan grafik pada Gambar 4.1, dapat dilihat bahwa nilai MSE testing terbaik terjadi pada percobaan 47. Berdasarkan grafik pada Gambar 4.2, nilai MSE training terbaik terjadi pada percobaan 49. Dapat disimpulkan pada pengujian ini bahwa MSE training terbaik tidak menghasilkan MSE testing terbaik.

4.2 Pengujian skema ekstraksi fitur ke-2

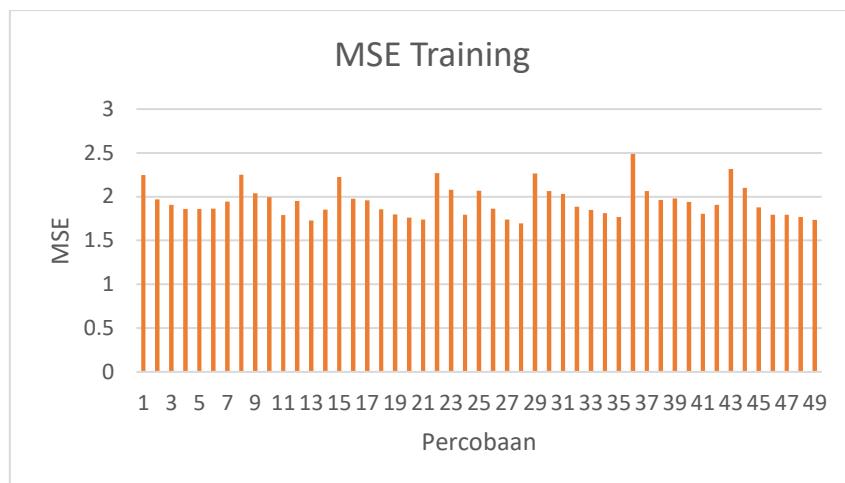
Tabel 4. 2 Beberapa hasil pengujian skema ekstraksi fitur ke-2

Pengujian	Neuron Hidden	Learning rate	MSE Testing	MSE Training	Waktu (s)
1	6	0.1	0.429520	2.245422	456.981
2	6	0.2	0.439690	1.970383	458.009
3	6	0.3	0.435500	1.905421	456.127
4	6	0.4	0.560740	1.859199	453.678
5	6	0.5	0.555580	1.858618	476.723
6	6	0.6	0.547740	1.863449	457.331
7	6	0.7	0.465510	1.943015	457.663

Pengujian	Neuron Hidden	Learning rate	MSE Testing	MSE Training	Waktu (s)
8	7	0.1	0.414580	2.249609	508.479
9	7	0.2	0.429030	2.03682	527.686
10	7	0.3	0.471790	1.995135	500.721
11	7	0.4	0.517180	1.788467	520.469
12	7	0.5	0.403450	1.951709	611.723
13	7	0.6	0.544290	1.727989	562.663
14	7	0.7	0.479820	1.850458	566.267
15	8	0.1	0.416020	2.225763	538.346
16	8	0.2	0.442220	1.976532	539.949
17	8	0.3	0.433280	1.95882	582.947
18	8	0.4	0.468880	1.854983	577.810
19	8	0.5	0.500070	1.797251	636.120
20	8	0.6	0.505820	1.761801	612.569



Gambar 4. 3 Grafik MSE testing hasil pengujian skema ekstraksi fitur ke-2



Gambar 4. 4 Grafik MSE training hasil pengujian skema ekstraksi fitur ke-2

Berdasarkan grafik pada Gambar 4.3, dapat dilihat bahwa nilai MSE testing terbaik terjadi pada percobaan 39. Berdasarkan grafik pada Gambar 4.4, nilai MSE training terbaik terjadi pada percobaan 49. Dapat disimpulkan pada pengujian ini bahwa MSE training terbaik tidak menghasilkan MSE testing terbaik.

4.2 Analisis keunggulan sistem

Keunggulan dari sistem setelah dilakukan pengujian adalah nilai error yang dihasilkan masih tergolong kecil. Kelemahan dari sistem setelah pengujian adalah luasnya parameter JST sehingga membutuhkan banyak percobaan untuk menemukan parameter terbaik. Selain luasnya parameter JST, kelemahan selanjutnya adalah waktu training yang dibutuhkan cukup lama untuk satu percobaan dengan 10000 epoch.

5. Kesimpulan dan Saran

5.1 Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan pada Tugas Akhir ini, maka dapat diberi kesimpulan bahwa:

1. Performansi pengujian terbaik pada skema ekstraksi fitur ke-1 dengan menggunakan 11 nilai fitur (4 nilai STA/LTA, 6 nilai rata-rata amplitudo dan 1 nilai maksimum amplitudo) adalah dengan menggunakan 12 jumlah neuron *hidden* dan nilai *learning rate* 0.5 dengan hasil MSE 0.413050.
2. Performansi pengujian terbaik pada skema ekstraksi fitur ke-1 dengan menggunakan 16 nilai fitur (4 nilai STA/LTA, 6 nilai rata-rata amplitudo dan 6 nilai maksimum amplitudo) adalah dengan menggunakan 11 jumlah neuron *hidden* dan nilai *learning rate* 0.4 dengan hasil MSE 0.369060.
3. Performansi terbaik sistem estimasi magnitudo gempa bumi di dapatkan dengan 16 nilai fitur, 11 jumlah neuron *hidden* dan nilai *learning rate* 0.4 dengan hasil performansi nilai MSE 0.369060.

5.2 Saran

Berdasarkan hasil penelitian yang telah dilakukan pada Tugas Akhir ini, maka saran yang dapat diusulkan adalah:

1. Menggunakan dataset yang lebih baik untuk meningkatkan performansi sistem.
2. Menggunakan noise removal agar data yang di dapat dari sampel menjadi lebih baik

Daftar Pustaka

- [1] Sunarjo, M. T. Gunawan, and S. Pribadi, *Gempabumi Edisi Populer*. 2012.
- [2] M. Båth and M. Båth, “Seismographs,” *Introd. to Seismol.*, no. Page 3, pp. 29–60, 1979, doi: 10.1007/978-3-0348-5283-8_2.
- [3] A. Kundu, Y. S. Bhaduria, S. Basu, and S. Mukhopadhyay, “Artificial neural network based estimation of moment magnitude with relevance to Earthquake Early Warning,” in *Proceedings of the 2017 International Conference on Wireless Communications, Signal Processing and Networking, WiSPNET 2017*, 2018, vol. 2018-Janua, pp. 1955–1959, doi: 10.1109/WiSPNET.2017.8300102.
- [4] E. Amar, T. Khattab, and F. Zada, “Intelligent Earthquake Prediction System Based On Neural Network,” *Int. J. Civ. Environ. Eng.*, vol. 8, no. 12, pp. 874–878, 2014.
- [5] Y. A. Sya’bani, “Implementation of Automatic First Arrival Picking On P-Wave Seismic Signal Using Logistic Regression Method,” pp. 134–138, 2020.
- [6] M. wahyu putra Indi, “Automatic First Arrival Picking on P-Wave Seismic Signal Using Support Vector Machine Method,” pp. 128–133, 2020.
- [7] M. Withers *et al.*, “A comparison of select trigger algorithms for automated global seismic phase and event detection,” *Bull. Seismol. Soc. Am.*, vol. 88, no. 1, pp. 95–106, 1998.
- [8] O. D. Team, “ObsPy Tutorial,” 2020, [Online]. Available: <https://docs.obspy.org/tutorial/index.html>.
- [9] B. Nassih, A. Amine, M. Ngadi, and N. Hmina, “DCT and HOG Feature Sets Combined with BPNN for Efficient Face Classification,” *Procedia Comput. Sci.*, vol. 148, pp. 116–125, 2019, doi: 10.1016/j.procs.2019.01.015.
- [10] I. Kholis, “Analisis Variasi Parameter Backpropagation Artificial Neural Network Terhadap Pengenalan Pola Data Iris,” *J. Tek. Ilmu Komput.*, vol. 4, no. 14, pp. 1–10, 2015.
- [11] S. G. K. Patro and K. K. sahu, “Normalization: A Preprocessing Stage,” *Iarjset*, no. April, pp. 20–22, 2015, doi: 10.17148/iarjset.2015.2305.