

Hasil Awal Penentuan Waktu Tiba Gelombang-P Gempa Menggunakan Machine Learning

Yosua H. Lumban Gaol^{1,*}, Sandy K. Suhardja¹

¹Faculty of Exploration and Production Technology, University of Pertamina

*Email: s4ndy104@gmail.com

Submit: 2022-04-10 ; Revised: 2022-08-27 ; Accepted: 2022-10-08

Abstrak: Akurasi pemilihan waktu tiba gelombang (first break picking) pada gempa sangat penting dalam proses pengolahan data seismik. Pada umumnya pemilihan waktu tiba gelombang dilakukan secara manual atau menggunakan algoritma STA/LTA, suatu persamaan yang bekerja seperti rerata bergerak. Akan tetapi kedua cara ini memiliki beberapa kekurangan seperti memerlukan waktu yang lama, tingkat akurasi yang rendah dan tingkat subjektivitas yang masih tinggi. Penelitian ini memberikan inovasi baru pada pemilihan waktu tiba gelombang P gempa menggunakan salah satu algoritma machine learning yaitu Artificial Neural Network (ANN). Machine learning merupakan salah satu topik yang berkembang pesat dalam beberapa tahun terakhir, namun pemanfaatannya pada bidang keilmuan seismologi terutama di Indonesia masih kurang. Tujuan penelitian ini adalah untuk membuat suatu program pemilihan waktu tiba gelombang P berbasis bahasa pemrograman Python. Uji coba program yang telah dibuat dilakukan terhadap data gelombang sintesis dan data gempa yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Hasil percobaan menunjukkan bahwa program sudah cukup akurat dalam melakukan prediksi first break baik pada data sintesis maupun data asli. Salah satu faktor yang memengaruhi hasil prediksi program machine learning ini adalah tahap filter data, karena hasil percobaan menunjukkan bahwa prediksi memiliki persentase error lebih rendah pada data yang telah dilakukan filter.

Kata kunci: first break picking, gempa, python, machine learning, Artificial Neural Network


Abstract: The accuracy of the first break picking in earthquakes is very important in the seismic data processing. In general, the selection of wave arrival times is done manually or using the STA/LTA algorithm, an equation that works like a moving average. However, both of these methods have several drawbacks, such as requiring a long time, a low level of accuracy, and a high level of subjectivity. This research provides a new innovation in selecting the arrival time of the earthquake P wave using one of the machine learning algorithms, namely Artificial Neural Network (ANN). Machine learning is one of the topics that has developed rapidly in recent years, but its use in the field of seismology, especially in Indonesia, is still lacking. The purpose of this research is to create a P wave arrival timing program based on the Python programming language. The trial program that has been made is carried out on synthetic

wave data and earthquake data obtained from the Meteorology, Climatology, and Geophysics Agency (BMKG). The experimental results show that the program is quite accurate in predicting the first break on both synthetic and original data. One of the factors that affect the prediction results of this machine learning program is the data filter stage because the experimental results show that the prediction has a lower percentage of error in the data that has been filtered.

Keywords: first break picking, earthquake, python, machine learning, Artificial Neural Network

1 PENDAHULUAN

Gempa merupakan getaran yang dirasakan di permukaan bumi efek dari adanya sumber getar yang berasal dari dalam bumi. Adapun pusat sumber gempa tersebut ditentukan menjadi dua titik, hiposenter atau titik kedalaman gempa dan episenter atau lokasi tegak lurus dari sepisenter di permukaan bumi. Informasi tersebut penting untuk diketahui karena dapat menjadi dasar untuk menentukan mitigasi bencana yang perlu dilakukan saat gempa terjadi. Lokasi dan kekuatan gempa dapat diperhitungkan dari penentuan waktu tiba gempa, karena berdasarkan pemrosesan sinyalnya data tersebut memiliki hubungan dengan kondisi properti (Seidl dan Stammer, 1984). Tahap awal penentuan lokasi gempa adalah melakukan first pick, yang mana umumnya dilakukan dengan cara manual dengan aturan tertentu (Diehl dkk., 2012; Bormann dkk., 2002), namun meskipun telah memiliki pedoman hasilnya tetap dapat bervariasi dari tiap operator. Seiring perkembangan ilmu pengetahuan, metode manual tersebut telah mulai dikembangkan menjadi auto-picking dan/atau mengotomatisasi sebagian proses pengolahannya (Diehl dkk., 2009). Salah satu metode yang dapat digunakan adalah Short Term Averaging/ Long Term Averaging (STA/LTA), namun metode ini hanya efektif pada data dengan signal to noise ratio (SNR) tinggi. SNR merupakan perbandingan antara noise (gangguan) dan sinyal informasi yang terdapat dalam sebuah media transmisi (Simangunsong dkk., 2013). Pada penelitian ini penulis akan membahas tentang penerapan metode STA/LTA dan machine learning Artificial Neural Network (ANN) untuk mengotomatisasi proses picking waktu tiba gempa, dan nantinya pengujian akan dilakukan pada data sintetik dan real event



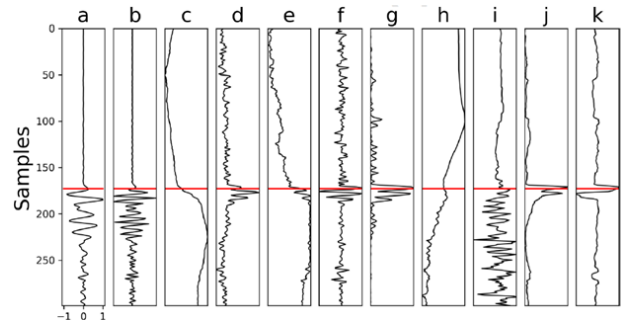
Gambar 1. Arsitektur Artificial Neural Network

dari Badan Meteorologi, Klimatologi, dan Geofisika BMKG. STA/LTA sederhananya berarti algoritma yang bekerja seperti rerata bergerak (moving average), lebar jendela dari STA lebih kecil dari LTA, dan rasio perbedaan itulah yang biasa dipakai mengestimasi waktu tiba gelombang P pertama kali terekam (Chen, 2020). Penelitian difokuskan pada analisa gelombang-P gempa karena P berarti primer atau gelombang yang pertama kali terekam dan dapat menjalar di semua medium, sehingga diperhitungkan untuk mengetahui lokasi dan kedalaman gempa (Kearey dkk., 2002). Secara umum machine learning dibagi menjadi dua bagian yaitu *supervised learning* dan *unsupervised learning*, di mana *supervised* mencakup proses input-train-klasifikasi dan *unsupervised* cukup dengan menyediakan data *parameter input* dan *clustering* (proses pengelompokkan) berdasarkan kemiripan data (Fernandes de Mello dan Antonelli Ponti, 2018). Sebagai salah satu metode machine learning, ANN merupakan algoritma yang menyimulasikan bagaimana cara otak bekerja, seperti susunan saraf neuron yang memiliki beberapa bagian tersusun dari dendrit-akson-sinapsis informasi ANN juga tersusun dari beberapa *layer*.

Seperti informasi otak manusia yang diproses dari data yang dikumpulkan dendrit lalu impulsnya dikirim ke akson, kemudian data diproses akson lalu impulsnya diteruskan lagi ke sinapsis untuk dapat digunakan oleh sel lain, pada ANN data juga di proses serupa. Seperti pada Gambar 1 Input Layer menjadi tempat dikumpulkannya data, kemudian diteruskan pada *Hidden Layer* atau tempat di mana data dilatih sesuai parameter dan algoritma tertentu, dan terakhir *Output Layer* berfungsi sebagai penerus dari data yang telah diproses di bagian sebelumnya menjadi bentuk keluaran tertentu (Pineda-Jaramillo dkk., 2018).

2 DATA DAN METODOLOGI

Data pada penelitian ini didapatkan dari BMKG, data direkam dari 06 November 2019 sampai 15 November 2019 oleh stasiun perekaman gempa dengan kode nama stasiun GLMI, dan total jumlah data yang didapatkan 106 events. Sedangkan, data sintetis yang akan diuji didapatkan dari situs web International Seismological Centre (ISC) yaitu pada laman <http://www.isc.ac.uk/>. Lokasi perekaman berada di bagian utara Maluku dan berfokus pada event dengan magnitudo lebih dari 3. Bentuk data yang akan diolah adalah waveform dan alasan data dibatasi pada magnitudo 3 ke atas adalah karena sinyalnya memiliki kualitas cukup baik




Gambar 2. Pemilihan first break secara otomatis menggunakan machine learning. (a) Sinyal gelombang gempa, (b) gradien amplitudo absolut, (c) *trace entropy*, (d) *gradien trace entropy*, (e) metode *fractal dimension*, (f) *gradien metode fractal dimension*, (g) STA/LTA, (h) *amplitude spectrum summation*, (i) gradien dari h, (j) kurtosis, dan (k) *skewness* (Mezyk dan Malinowski, 2019)

dan mudah untuk dipelajari oleh komputer. Metode otomatisasi *first break picking* data gempa menggunakan metode STA/LTA dan machine learning ANN sebelumnya telah dilakukan oleh (Mezyk dan Malinowski, 2019). Pada penelitian tersebut, mereka menggunakan 11 parameter yang nantinya akan dipelajari oleh komputer agar mampu melakukan pemilihan *first break* secara otomatis.

Pada Gambar 2 dapat diperhatikan bagian garis merah, di mana pada data awal (a) atau sinyal gelombang gempa peak dari waktu tiba tidak memiliki kontras besar dibanding dengan bagian yang lain, namun setelah dilakukan beberapa proses maka hasil kontras *peak* dapat tampil dengan baik pada data-data seperti kurtosis dan *skewness*. Oleh karena itu, dengan pengoptimalan visual data, maka nantinya akan dapat memudahkan mesin dalam melakukan otomatisasi *first break picking* dan hasilnya tetap dapat dipercaya. Pengolahan data yang akan dilakukan pada penelitian ini adalah pertama-tama menguji perhitungan pada data sintetis lalu diaplikasikan pada data sesungguhnya. Data awal disiapkan dengan memfilternya menjadi hanya magnitudo 3 ke atas, lalu perhitungan STA/LTA, kurtosis, dan *skewness* dapat dilakukan. Kemudian, setelah hasilnya dianalisis, arsitektur ANN dapat ditentukan, dan fokus penulis adalah untuk melakukan *blind testing* untuk *training data*. *Blind test* merupakan proses pengambilan *P-phase* pada set seismogram baru. Pembahasan lebih lanjut mengenai pengolahan data pada penelitian ini akan dibahas dalam dua topik yaitu tahapan persiapan data dan tahapan pengolahan data.

2.1 Tahapan Persiapan Data

Tahap pertama pada pra-pengolahan data adalah membaca data waveform gempa yang telah dimiliki. Lalu, dipilih beberapa event untuk mewakili cakupan data yang diteliti, dan pada penelitian ini akan dibatasi pada pemilihan 3 *event* utama yang terdapat pada bagian wilayah Papua dan Sulawesi. Kemudian, untuk memudahkan pengolahan lanjutan data maka data tersebut difilter dengan mengambil 30 detik dari waktu sebelum dan setelah kejadian gempa. Perlu diperhatikan bahwa data BMKG memiliki *sampling rate* sebesar 20 sampel per detik, maka dari data yang dipotong



Gambar 3. Ilustrasi arsitektur ANN yang digunakan pada penelitian

sebelumnya yang sebanyak 60 detik, memiliki 1200 sampel data, dan dari jumlah sampel dan beda waktu tersebut nantinya hasil dapat divalidasi kebenarannya.

2.2 Tahapan Pengolahan Data


Pada pengolahan data metode ANN terdapat tiga tahap penting, yaitu training data, validation data, dan prediction. Pada tahap training data yang perlu dilakukan adalah menormalisasi data agar tiap data gempa yang akan di-training memiliki rentang parameter yang sama. Selanjutnya penentuan arsitektur ANN seperti berapa jumlah *hidden layer* yang akan dipakai (Gambar 3). Jumlah hidden layer yang dipakai pada penelitian ini adalah sebanyak tiga hidden layer. Lalu pada tahapan training, kurva akurasi serta loss pada data yang telah dilakukan training menjadi perhatian utama.

Apabila hasil akurasi dan loss yang telah diperoleh sesuai harapan, maka selanjutnya adalah tahapan validasi. Blind testing dilakukan pada tahapan yang sama dengan validasi, di mana akan dilakukan pemilihan waktu tiba gelombang-P secara manual lalu dibandingkan dengan hasil prediksi dengan *machine learning*. Validasi bagus atau tidaknya metode yang digunakan divalidasi dari pengolahan pada data sintetik yang telah memiliki hasil berupa waktu tiba gelombang-P, apabila telah mendapatkan nilai kemiripan/hubungan yang bagus maka metode akan diaplikasikan pada data sesungguhnya. Namun, jika hasilnya belum cukup baik maka arsitektur ANN sebelumnya perlu dibangun ulang dan mengulangi tahap validasi. Setiap input nantinya akan diberikan pembobotan dan bias sebelum ke *hidden layer* dan sebelum ke *output layer*. Hal ini dilakukan berulang kali secara terus menerus hingga mencapai akurasi paling optimum (Gambar 4).

Persamaan umum dari ANN adalah sebagai berikut (Aggarwal dkk., 2018):

$$y = f \left(\sum_{i=0}^n (x_i + W_i) + B \right) \quad (1)$$

Adapun y diartikan sebagai *output*, x adalah input, W adalah bobot, dan B adalah bias. Lebih lanjut, kurtosis dan *skewness* sudah cukup banyak digunakan dalam penentuan waktu tiba gelombang-P gempa. Kurtosis adalah ukuran ketajaman distribusi suatu data. Distribusi normal data amplitudo gempabumi memiliki keruncingan kurva yang tinggi dan sifat ini yang dapat dipakai dalam penentuan waktu tiba gelombang-P gempa. Sampel dengan kurva keruncing-



Gambar 4. Ilustrasi Artificial neural network beserta pembobotannya (Aggarwal dkk., 2018)

an tertinggi dapat dikatakan sebagai waktu tiba gelombang dari gelombang-P. *Skewness* dapat digunakan untuk menggambarkan distribusi normal suatu data. Jika distribusi data lebih besar daripada rata-ratanya maka ketajaman kurva miring ke kiri, sedangkan jika distribusi data lebih kecil dari rata-ratanya maka ketajaman kurva miring ke kanan. Pada identifikasi waktu kedatangan gelombang-P gempa, *skewness* dapat dipakai untuk melihat apakah gelombang-P ketika direkam pertama kali bernilai positif (*peak*) atau negatif (*trough*). Nilai maksimum (positif) atau minimum (negatif) dari *skewness* suatu sampel data gempa menunjukkan *peak* atau *trough* suatu gelombang ketika pertama kali terekam di seismogram (Gunawan dkk., 2012).

Persamaan kurtosis dan *skewness* adalah sebagai berikut (Ross dan Ben-Zion, 2014):

$$Kurtosis = \frac{\sum_{i=1}^M (x_i + \bar{x})^4}{(M-1) s_x^4} - 3 \quad (2)$$

$$Skewness = \frac{\sum_{i=1}^M (x_i + \bar{x})^3}{(M-1) s_x^3} \quad (3)$$

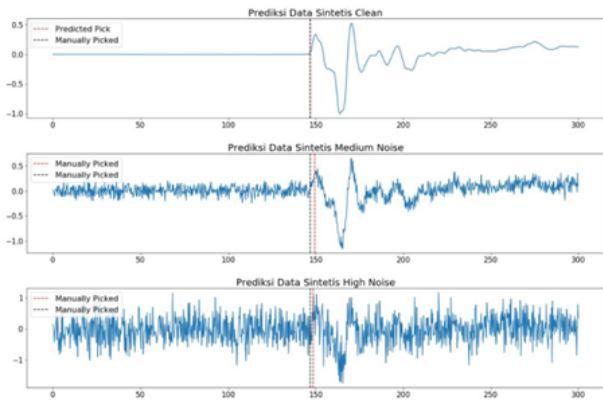
M adalah jumlah sampel amplitudo gempa, $x=x_1, x_2, \dots, x_M$ adalah amplitudo gempa, \bar{x} adalah rata-rata dari amplitudo, dan S_x adalah standar deviasi.

3 HASIL DAN DISKUSI

Tujuan utama dari penelitian ini adalah untuk mampu melihat bahwa metode otomatisasi *first break picking* data gempa menggunakan metode STA/LTA dan machine learning ANN dapat diaplikasikan pada data penulis, serta apakah hasil yang dihasilkan serta parameter yang digunakan pada *machine learning* tersebut cukup baik dalam mengidentifikasi *first break* gelombang-P. Adapun karena pengolahannya dilakukan pada 2 data, maka pembahasannya akan dilakukan berdasarkan pembagian tersebut.

3.1 Hasil Pengolahan Data Sintetik

Pada pengolahan data sintetik dilakukan pembagian kasus pada datanya yaitu data sintesis clean (*free noise*), *medium noise*, dan *high noise*. Hal ini dilakukan untuk melihat bagaimana respon parameter dan perubahannya pada tiap data sintesis.



Gambar 5. Hasil Prediksi pada tiga jenis data sintetik

Tabel 1. Analisa Prediksi First-Break pada Data Sintetik


| | Posisi Sampel Manual Picking | Posisi Sampel Otomatis Picking | Perbedaan |
|----------------------------|------------------------------|--------------------------------|-----------------------|
| Data Sintetik Tanpa Noise | 588 (detik 147) | 588 (detik 147) | 0 |
| Data Sintetik Medium Noise | 588 (detik 147) | 597 (detik 149.25) | 9 sampel (2.25 detik) |
| Data Sintetik High Noise | 588 (detik 147) | 593 (detik 148.25) | 5 sampel (1.25 detik) |

Seperti yang tampak pada gambar 5 di atas, dapat dilihat bahwa hasil prediksi yang didapatkan sudah cukup baik, di mana hal tersebut dapat diketahui dari rentang beda waktu tiba yang didapatkan dari manual pick dan predicted pick. Adapun untuk lebih detail, perbedaannya dapat diperhatikan pada tabel 1 di bawah. Perbedaan posisi first break antara manual (dianggap first break sebenarnya) dengan otomatis sudah cukup baik. Selisih terbesar hanya 9 sampel, yakni pada data sintetik dengan medium noise dan hasil ini sudah cukup untuk kita lakukan uji coba pada data asli.


3.2 Hasil Pengolahan Data Asli

Pengolahan data asli akan difokuskan pada 3 data asli yaitu event 1 gempa magnitudo 6,1 di wilayah Papua, event 2 dengan magnitudo 5.1 yang juga berlokasi di wilayah Papua, dan event 3 dengan magnitudo 5,1 di wilayah Semenanjung Minahasa, Sulawesi. Hasil prediksi dilakukan pada data yang belum dilakukan filter dan sudah dilakukan filter. Hasilnya akan dibandingkan pada data manual pick yang sebelumnya telah dilakukan pada data yang difilter, serta perlu diingat bahwa sampling rate pada pengolahan data asli ini adalah 20 sampel per detik.


Pada gambar di atas terlihat bahwa untuk pada data Event 1 yang difilter, hasil prediksi sudah sama dengan hasil manual pick yang dilakukan. Sedangkan, hasil prediksi untuk data yang belum difilter masih terdapat selisih dari manual pick yang kita lakukan. Event 1 merupakan data dengan tingkat noise yang cenderung rendah. Prediksi first break pada Event 1 yang tidak dilakukan filter adalah sampel ke-641 (detik ke-32,05) dan pada Event filter adalah sam-



Gambar 6. Hasil Prediksi pada Event 1



Gambar 7. Hasil Prediksi pada Event 2



Gambar 8. Hasil Prediksi pada Event 3

pel ke-624 (detik ke- 32,05), dimana besar error dari hasil prediksi ini adalah 0,004% atau berbeda 3 sampel dari first break yang telah dipilih secara manual, dan error dengan nilai seperti itu dapat diartikan bahwa hasil pengolahannya sangat baik karena selisih yang didapatkan sangat kecil.

Selanjutnya, cukup berbeda dengan kasus pada Event 1, Event 2 merupakan data dengan tingkat noise yang cenderung lebih besar dari Event 1. Prediksi first break pada Event 2 yang tidak dilakukan filter adalah sampel ke-630 (detik ke-31,5), dimana hasil prediksi ini memiliki eror 0.021% atau berbeda 13 sampel dari first break yang telah dipilih secara manual. Posisi sampel prediksi first break pada Event 2 yang dilakukan filter adalah sampel ke-620 (detik ke-31), dimana hasil prediksi ini berbeda 8 sampel (error 0,013%) dari first break yang telah dipilih secara manual. Meskipun selisih sampelnnya cukup berbeda dengan hasil Event 1, tetapi hasil pada event tetap dapat dikatakan cukup baik, dikarenakan posisi prediksi first break secara otomatis masih berada pada daerah yang bisa dipertimbangkan sebagai first break.

Event 3 merupakan data dengan tingkat noise yang cenderung rendah. Prediksi first break pada Event 3 yang tidak

Tabel 2. Analisa Prediksi First-Break pada Data Sintetik

| Event | Perbedaan pada Data Tidak Difilter | Perbedaan pada Data Difilter |
|---------|------------------------------------|------------------------------|
| Event 1 | 9 sampel (0.45 s) | 7 sampel (0.35s) |
| Event 2 | 1 sampel (0.05 s) | 15 sampel (0.75s) |
| Event 3 | 3 sampel (0.15 s) | 1 sampel (0.05s) |

dilakukan filter adalah sampel ke-267 (detik ke-13,35), dimana hasil prediksi ini memiliki error 0.042% atau berbeda 11 sampel dari *first break* yang telah dipilih secara manual. Posisi sampel prediksi *first break* pada *Event 3* yang dilakukan filter adalah sampel ke-256 (detik ke-12,8), dimana hasil prediksi ini memiliki eror 0,007% atau berbeda 2 sampel dari *first break* yang telah dipilih secara manual. Oleh karena itu, hasil dari pengolahan *event* ini juga dapat dikatakan sangat baik, mengingat selisihnya hanya berbeda 2 sampel data. Detail perbandingan hasil pengolahan data dari 3 *event* di atas, lebih jelas dapat dilihat pada tabel di bawah ini.

Berdasarkan hasil percobaan pada tiga data asli, maka bisa diperhatikan bahwa salah satu hal yang mempengaruhi akurasi prediksi secara otomatis adalah dilakukannya filter atau tidak pada data yang akan diprediksi. Hal ini dikarenakan dari ketiga percobaan, besar selisih antara prediksi *first break* secara otomatis cenderung berkurang pada data yang dilakukan filter.

4 KESIMPULAN

Berdasarkan penelitian dan analisa yang telah dilakukan, maka kesimpulan yang diperoleh adalah sebagai berikut:

(i) Program *auto-picking* berbasis bahasa pemrograman Python telah berhasil dibuat dengan hasil deteksi pada data sintetik dan data asli cukup memuaskan dengan error atau selisih paling besar hanya sejumlah 9 *event*. Dikatakan cukup memuaskan karena hasil yang diperoleh sudah cukup akurat meskipun hanya 106 *data event* gempa yang digunakan sebagai *data training*. Sebagai perbandingan, pada salah satu penelitian lain yang serupa digunakan 1000 *data event* gempa sebagai data training.

(ii) Parameter yang dapat digunakan sebagai pendeteksi waktu tiba gelombang-P dan dapat digunakan pada program *machine learning* adalah parameter kurtosis, dan *skewness*. Kedua parameter ini sudah cukup baik untuk membantu memprediksi waktu tiba gelombang-P

(iii) Diperlukan training dengan jumlah data yang lebih banyak dan bervariasi untuk meningkatkan akurasi prediksi menggunakan *machine learning*.

5 UCAPAN TERIMA KASIH

Kami ucapkan terima kasih mendalam kepada semua rekan yang terlibat dalam penelitian dan penulisan jurnal ini, terutama pihak Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) yang telah berkenan memberikan akses data sehingga penelitian ini dapat terwujud.

Pustaka

- Aggarwal, C.C. dkk. (2018): Neural networks and deep learning. *Springer*, **10**, 978–3, doi:10.1007./978-3-319-94463-0.
- Bormann, P., Klinge, K. dan Wendt, S. (2002): Data analysis and seismogram interpretation in bormann p. (ed.) new manual of seismological observatory practice 2 (nmsop-2). *Potsdam : Deutsches GeoForschungsZentrum GFZ*, 1–126, doi:10.2312/GFZ.NMSOP-2'ch11.
- Chen, Y. (2020): Automatic microseismic event picking via unsupervised machine learning. *Geophysical Journal International*, **222**(3), 1750–1764, doi:10.1093/gji/ggx420.
- Diehl, T., Deichmann, N., Kissling, E. dan Husen, S. (2009): Automatic s-wave picker for local earthquake tomography. *Bulletin of the Seismological Society of America*, **99**(3), 1906–1920, doi:10.1785/0120080019.
- Diehl, T., Kissling, E. dan Bormann, P. (2012): Tutorial for consistent phase picking at local to regional distances in: Bormann, p. (ed.), new manual of seismological observatory practice 2 (nmsop-2). *Deutsches GeoForschungsZentrum GFZ*, 1–21, doi:10.2312/GFZ.NMSOP-2'IS'11.4.
- Fernandes de Mello, R. dan Antonelli Ponti, M. (2018): A brief review on machine learning. *Machine Learning*, 1–74.
- Gunawan, H., Puspito, N.T., Ibrahim, G., Haryadi, P.P. dan Kadnan, K. (2012): Penentuan waktu tiba gelombang-p secara otomatis dengan metoda skewness dan kurtosis terintegrasi. *Jurnal Meteorologi dan Geofisika*, **13**(1).
- Kearey, P., Brooks, M. dan Hill, I. (2002): An Introduction to Geophysical Exploration. Wiley Blackwell, 3rd edn.
- Mezyk, M. dan Malinowski, M. (2019): Multi-pattern algorithm for first-break picking employing open-source machine learning libraries. *Journal of Applied Geophysics*, **170**, doi:10.1016/j.jappgeo.2019.103848.
- Pineda-Jaramillo, J.D., Insa, R. dan Martínez, P. (2018): Modeling the energy consumption of trains by applying neural networks. *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit*, **232**(3), 816–823, doi:10.1177/0954409717694522.
- Ross, Z.E. dan Ben-Zion, Y. (2014): Automatic picking of direct p, s seismic phases and fault zone head waves. *Geophysical Journal International*, **199**(1), 368–381, doi:10.1093/gji/ggu267.
- Seidl, D. dan Stammer, W. (1984): Restoration of broadband seismograms (part i). *Journal of geophysics*, **54**(2), 114–122.
- Simangunsong, D.S., Zahra, A.A. dan Hidayatno, A. (2013): Estimasi perbaikan nilai snr (signal to noise ratio) pada proses denoising menggunakan metode wavelet terhadap suatu sinyal berderau. *Transient: Jurnal Ilmiah Teknik Elektro*, **2**(4), 895–899.