

PENERAPAN *DEEP LEARNING CONVOLUTIONAL NEURAL NETWORK* UNTUK SISTEM *AUTO PICKING* SINYAL GEMPA MIKRO PADA DATA SEISMOGRAM PIGRAF

(Skripsi)

Oleh

Razki Alfatah Khairu Mahli

2215051011



**KEMENTERIAN PENDIDIKAN TINGGI, SAINS, DAN TEKNOLOGI
JURUSAN TEKNIK GEOFISIKA
FAKULTAS TEKNIK
UNIVERSITAS LAMPUNG
2026**

PENERAPAN *DEEP LEARNING CONVOLUTIONAL NEURAL NETWORK* UNTUK SISTEM *AUTO PICKING* SINYAL GEMPA MIKRO PADA DATA SEISMOGRAM PIGRAF

Oleh

Razki Alfatah Khairu Mahli

Skripsi

**Sebagai Salah Satu Syarat Untuk Mencapai Gelar
SARJANA TEKNIK**

Pada

**Jurusan Teknik Geofisika
Fakultas Teknik Universitas Lampung**



**FAKULTAS TEKNIK
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG**

2026

ABSTRAK

PENERAPAN *DEEP LEARNING CONVOLUTIONAL NEURAL NETWORK* UNTUK SISTEM *AUTO PICKING* SINYAL GEMPA MIKRO PADA DATA SEISMOGRAM PIGRAF

Oleh

Razki Alfatah Khairu Mahli

Energi panas bumi merupakan sumber energi terbarukan yang memerlukan pemantauan aktivitas gempa mikro untuk mendukung pengelolaan dan monitoring pada lapangan panas bumi yang telah beroperasi. Informasi aktivitas gempa mikro dapat diperoleh melalui proses *phase picking* untuk menentukan waktu kedatangan gelombang. Namun, metode *phase picking* secara manual memiliki beberapa keterbatasan dari sisi efisiensi, konsistensi, dan objektivitas. Penelitian ini bertujuan mengembangkan sistem *auto picking* berbasis *Convolutional Neural Network* (CNN) 1D untuk mendeteksi waktu kedatangan gelombang P dan S pada data gempa mikro. Model dilatih menggunakan dataset *STanford Earthquake Dataset* (STEAD) dan divalidasi menggunakan data gempa mikro riil lapangan panas bumi. Evaluasi model dilakukan menggunakan parameter akurasi, *loss*, dan *Mean Absolute Error* (MAE). Hasil pelatihan didapatkan akurasi sebesar 94% dengan nilai *loss* sebesar 0,1219. Pada pengujian data riil menggunakan 30 *event* gempa mikro, model berhasil mendeteksi 100% *event* gelombang P dengan MAE sebesar 26,42 ms serta 90% *event* gelombang S dengan MAE sebesar 312,67 ms. Hasil menunjukkan bahwa model memiliki performa yang baik dalam mendeteksi gelombang P, namun masih terbatas dalam mendeteksi gelombang S akibat kompleksitas karakteristik sinyal. Oleh karena itu, diperlukan pengembangan arsitektur model yang lebih optimal dalam menangkap pola temporal sinyal gempa mikro untuk meningkatkan akurasi deteksi gelombang S.

Kata kunci: *Auto Picking*, *Convolutional Neural Network*, Gempa Mikro, *Phase Picking*

ABSTRACT

APPLICATION OF DEEP LEARNING CONVOLUTIONAL NEURAL NETWORK FOR AN AUTOMATIC MICROEARTHQUAKE SIGNAL PICKING SYSTEM USING PIGRAF SEISMOGRAM DATA

By

Razki Alfatah Khairu Mahli

Geothermal energy is a renewable energy source that requires monitoring of microseismic activity to support the management and monitoring of operational geothermal fields. Information on microseismic activity can be obtained through phase picking to determine wave arrival times. However, manual phase picking methods have several limitations in terms of efficiency, consistency, and objectivity. This study aims to develop a 1D Convolutional Neural Network (CNN)-based auto-picking system to detect the arrival times of P- and S-waves in microearthquake data. The model was trained using the Stanford Earthquake Dataset (STEAD) and validated using real microearthquake data from geothermal fields. Model evaluation was conducted using accuracy, loss, and Mean Absolute Error (MAE) metrics. The training results yielded an accuracy of 94% with a loss value of 0.1219. In testing on real data using 30 microearthquake events, the model successfully detected 100% of P-wave events with an MAE of 26.42 ms and 90% of S-wave events with an MAE of 312.67 ms. The results indicate that the model performs well in detecting P-waves but is still limited in detecting S-waves due to the complexity of the signal characteristics. Therefore, the development of a more optimal model architecture is needed to capture the temporal patterns of microearthquake signals to improve the accuracy of S-wave detection.

Keywords: Auto Picking, Convolutional Neural Network, Microearthquake, Phase Picking

Judul Skripsi

Penerapan *Deep Learning Convolutional Neural Network* Untuk Sistem *Auto Picking* Sinyal Gempa Mikro Pada Data Seismogram PiGraf

Nama Mahasiswa

Razki Alfatah Khairu Mahli

Nomor Pokok Mahasiswa

2215051011

Program Studi

Teknik Geofisika

Fakultas

Teknik

MENYETUJUI,

1. **Komisi Pembimbing**

Dosen Pembimbing 1

Dosen Pembimbing 2

Ir. I Gede Boy Darmawan, S.Si., M.Eng.

Aryanto, S.T, M.T.

NIP. 198805052019031019

NIP. 199006212019031011

2. **Ketua Jurusan Teknik Geofisika**

Dr. Ir. Syamsurrijal Rasimeng, S.Si., M.Si., C.EIA., IPM.

NIP. 197307162000121002

MENGESAHKAN

1. **Tim Pengujii**


Ketua

**Ir. I Gede Boy Darmawan, S.Si.,
M.Eng.**



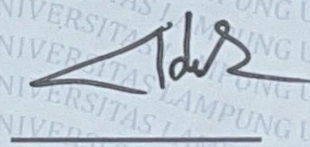
Sekretaris

Aryanto, S.T, M.T.



Anggota

**Prof. Dr. Ir. Nandi Haerudin, S.
Si., M.Si., IPM.**



2. **Dekan Fakultas Teknik**



Dr. Ahmad Herison, S.T., M.T.

Tanggal Lulus Ujian Skripsi: 13 Mei 2026

PERNYATAAN

Saya menyatakan bahwa skripsi berjudul “Penerapan *Deep Learning Convolutional Neural Network* untuk Sistem *Auto Picking* Sinyal Gempa Mikro pada Data Seismogram Pigraf” merupakan hasil karya dan pemikiran saya sendiri yang disusun sebagai salah satu syarat untuk memperoleh gelar sarjana. Seluruh sumber yang digunakan, baik yang dikutip secara langsung maupun tidak langsung, telah dicantumkan secara jelas dalam daftar pustaka sesuai dengan ketentuan penulisan ilmiah yang berlaku.

Apabila dikemudian hari pernyataan ini terbukti tidak benar, saya bersedia menerima sanksi sesuai dengan peraturan yang berlaku.

Bandar Lampung, 13 Mei 2026



Razki Alfatah Khairu Mahli

NPM. 2215051011

RIWAYAT HIDUP



Penulis dilahirkan di Kemiling, Bandar Lampung pada 07 Agustus 2004. Anak ketiga dari tiga bersaudara pasangan dari Bapak Rumli dan Ibu Armawati. Pendidikan yang pernah ditempuh oleh Penulis yaitu Taman Kanak-kanak di TK Beringin Raya dan Lulus ditahun 2010, Sekolah Dasar di SD Negeri 1 Beringin Raya dan Lulus pada tahun 2016, Sekolah Menengah Pertama di SMP Negeri 13 Bandar Lampung dan Lulus pada tahun 2019, dan menempuh Sekolah Menengah Akhir di SMA Negeri 7 Bandar Lampung dan Lulus pada tahun 2022. Penulis melanjutkan Pendidikan di Perguruan Tinggi Negeri, tepatnya di Universitas Lampung, Fakultas Teknik pada Jurusan Teknik Geofisika melalui jalur Seleksi Nasional Masuk Perguruan Tinggi Negeri (SNMPTN) tahun 2022.

Selama menempuh Pendidikan di perguruan tinggi, penulis aktif dalam berbagai kegiatan baik di bidang akademik maupun non-akademik. Penulis berkontribusi sebagai; Asisten Praktikum Sistem Informasi Geografis Prodi Teknik Geofisika tahun 2024 dan tahun 2025; Asisten Praktikum Elektronika Geofisika Prodi Teknik Geofisika tahun 2024 dan tahun 2025; Asisten Praktikum Komputasi Geofisika Prodi Teknik Geofisika tahun 2025; Asisten Praktikum Metode Geolistrik Prodi Teknik Geofisika tahun 2025. Selain itu, penulis aktif di beberapa organisasi; Anggota Bidang Multimedia Informasi Himpunan Mahasiswa Teknik Geofisika Bhuwana (HIMA TG Bhuwana) dua periode (2023-2025); Anggota Divisi Media Publikasi dalam Himpunan Ahli Geofisika Indonesia UNILA SC tahun 2024, kemudian diamanahkan menjadi Wakil Ketua Divisi pada periode kedua yaitu tahun 2025; Ketua Divisi Desain Komunikasi dan Informasi dalam Seksi Mahasiswa Ikatan Ahli Geologi Indonesia UNILA SC tahun 2024.

Penulis menjadi ketua tim dan mendapatkan insentif pada Pekan Kreativitas Mahasiswa Karsa Cipta (PKM-KC) yang diselenggarakan oleh Kementerian Riset Teknologi dan Pendidikan Tinggi tahun 2024. Penulis tergabung dalam tim Merdeka Belajar Kampus Merdeka (MBKM) riset dosen pada tahun 2024 dengan topik “Kajian *Geodiversity* dan *Geohazard* kawasan kandidat *Geopark* Kaldera Suoh untuk Pengembangan Geowisata di Provinsi Lampung”; Partisipan Presenter pada *International Conference of Geoscience and Remote Sensing Technology (IC-GEOREST)* tahun 2024. Penulis pernah menjadi Operator pada Tim *Survey* Metode Geolistrik dan Operator *Survey Drone* pada tahun 2025. Selain itu, selama menjalani masa studi penulis juga telah berkontribusi dalam publikasi ilmiah. Pada tahun 2024, penulis menerbitkan beberapa artikel ilmiah, artikel ilmiah pertama berjudul “**Studi Interdisipliner Risiko Bencana Erupsi Gunung Berbasis SIG (Sistem Informasi Geografis) Menggunakan Metode *Overlay* Pada Daerah Sekitar Kawasan Gunung Marapi**” pada Jurnal Teknologi dan Inovasi Industri (JTII) Vol. 05, No. 01 Tahun 2024. Artikel ilmiah kedua berjudul “**Identifikasi Zona Potensi Likuifaksi di Kota Bandar Lampung Berdasarkan Analisis Data Spasial**” pada Jurnal Geofisika Eksplorasi (JGE) Vol. 10, No. 03 Tahun 2024. Artikel ilmiah ketiga berjudul “*Inventory of Geodiversity, Biodiversity, Cultural Diversity and Geotourism Potential at Suoh Aspiring Geopark for Designation of Geopark Area*” pada Prosiding *IOP Conference Series: Earth and Environmental Science* tahun 2024. Pada tahun 2025, penulis menerbitkan dua artikel ilmiah, artikel ilmiah pertama berjudul “**Studi Awal Rancang Bangun *Geophone* Menggunakan Koil Magnetik Sebagai Massa Inersia dan Pegas Tipe *Static Balancing Stiffness***” pada Prosiding Seminar Nasional Ilmu Teknik dan Aplikasi Industri Fakultas Teknik Universitas Lampung tahun 2025. Artikel ilmiah kedua berjudul “*Integration of Field Observation and Spatial Analysis in Identifying Landslide Vulnerability in West Lampung Regency*” Pada *Springer Proceedings in Earth and Environmental Sciences* tahun 2025.

Penulis menjalankan kegiatan Kerja Praktik (KP) pada Bulan Agustus sampai September 2025 di Balai Besar Survei dan Pemetaan Geologi Kelautan (BBSPGL), Bandung dengan judul “Identifikasi Persebaran Porositas Batuan Pada

Formasi Paciran Lintasan “X” Menggunakan Metode Inversi *Model Based* Cekungan Jawa Timur Utara”. Selanjutnya, pada Bulan Januari 2026 sampai Mei 2026, penulis melanjutkan Tugas Akhir/Skripsi di Jurusan Teknik Geofisika dengan judul “**Penerapan *Deep Learning Convolutional Neural Network* untuk Sistem *Auto Picking* Sinyal Gempa Mikro pada Data Seismogram PiGraf**”. Penulis berhasil menyelesaikan penelitian sebagai Tugas Akhir/Skripsi untuk memperoleh gelar Sarjana Teknik dari Teknik Geofisika Pada 13 Mei 2026.

PERSEMBAHAN

Dengan penuh rasa syukur kepada Allah SWT, karya sederhana ini lahir dari perjalanan yang tidak mudah, diiringi doa, harapan, usaha, dan komitmen. Skripsi ini bukan sekadar hasil akhir, tetapi proses yang membentuk cara penulis berpikir. Penulis menyadari bahwa karya ini masih memiliki keterbatasan, namun setiap bagiannya merefleksikan usaha yang telah dilakukan. Segala pencapaian ini penulis persembahkan sebagai bentuk kecil dari rasa syukur dan bakti yang tidak akan pernah sebanding dengan apa yang telah diberikan, kepada:

Ayah dan Ibu terkasih,

Rumli S.Pd & Armawati

Dua insan yang namanya selalu penulis sebut dalam setiap doa. Terima kasih karena tidak pernah berhenti percaya dan menguatkan penulis, bahkan disaat penulis meragukan diri sendiri. Dibalik perjalanan hingga titik ini, ada doa yang diam-diam dilangitkan, ada sujud yang selalu dipanjatkan, serta ada kasih sayang dan pengorbanan yang tidak pernah meminta balasan. Penulis menyadari bahwa segala pencapaian hari ini tidak pernah lahir dari perjuangan seorang diri. Dari Ayah dan Ibu, penulis belajar bahwa kasih sayang tidak selalu hadir melalui kata-kata, tetapi melalui kesabaran, perjuangan, dan ketulusan yang terus menguatkan dalam setiap keadaan. Segala pencapaian ini penulis persembahkan sebagai bentuk kecil dari rasa syukur dan bakti yang tidak akan pernah sebanding dengan seluruh cinta dan pengorbanan yang telah diberikan. Semoga Allah SWT senantiasa menjaga Ayah dan Ibu dalam limpahan kesehatan, keberkahan, dan kebahagiaan.

MOTTO

“Sesungguhnya bersama kesulitan ada kemudahan”

(Q.S Ash-Sharh: 6)

“Maka ingatlah kepada-Ku, Aku pun akan ingat kepadamu...”

(Q.S Al-Baqarah: 152)

“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya...”

(Q.S Al-Baqarah: 286)

“...Boleh jadi kamu membenci sesuatu, padahal itu baik bagimu, dan boleh jadi kamu menyukai sesuatu, padahal itu amat buruk bagimu. Allah mengetahui, sedang kamu tidak mengetahui”

(QS. Al-Baqarah: 216)

“Tidak semua proses harus terlihat untuk menjadi berarti”

(Penulis)

KATA PENGANTAR

Segala puji dan syukur penulis panjatkan ke hadirat Allah SWT, Tuhan semesta alam, atas segala limpahan rahmat, karunia, serta ridha-Nya, sehingga penulis diberi kekuatan, kesehatan, dan kesempatan untuk menyelesaikan skripsi ini dengan baik. Tiada daya dan upaya tanpa pertolongan-Nya, berkat kehendak dan ridha-Nya, penulis dapat menyelesaikan proses penyusunan skripsi ini hingga tahap akhir dengan baik. Penulis menyadari bahwa skripsi ini masih memiliki keterbatasan. Oleh karena itu, penulis sangat mengharapkan saran, kritik, dan masukan yang membangun sebagai bahan evaluasi untuk penyempurnaan karya ini dimasa mendatang.

Skripsi yang berjudul “**Penerapan *Deep Learning Convolutional Neural Network* untuk Sistem *Auto Picking* Sinyal Gempa Mikro pada Data Seismogram Pigraf**” ini disusun sebagai salah satu syarat untuk memperoleh gelar Sarjana Teknik pada Program Studi Teknik Geofisika, Universitas Lampung yang dilaksanakan dalam rentang waktu Januari hingga Mei. Akhir kata, penulis berharap skripsi ini dapat memberikan manfaat bagi pembaca serta menjadi kontribusi awal dalam pengembangan ilmu pengetahuan terkhusus *machine learning* pada bidang kegeofisikaan. Penulis juga berharap seluruh proses, usaha, dan dukungan yang terlibat dalam penyusunan skripsi ini dapat bernilai kebaikan dan menjadi ladang amal jariyah bagi penulis dan semua pihak yang terlibat.

Bandar Lampung, 13 Mei 2026



Razki Alfatah Khairu Mahli

NPM. 2215051011

SANWACANA

Segala puji dan syukur penulis panjatkan ke hadirat Allah SWT atas rahmat, karunia, dan petunjuk-Nya, sehingga skripsi yang berjudul ***“Penerapan Deep Learning Convolutional Neural Network untuk Sistem Auto Picking Sinyal Gempa Mikro pada Data Seismogram Pigraf”*** dapat diselesaikan dengan baik. Dalam proses penyusunannya, penulis menyadari bahwa skripsi ini tidak terlepas dari dukungan, doa, bantuan, serta motivasi dari berbagai pihak. Oleh karena itu, dengan segala kerendahan hati dan rasa hormat, penulis menyampaikan terima kasih dan penghargaan yang sebesar-besarnya kepada:

1. Bapak Dr. Ahmad Herison, S.T., M.T., selaku Dekan Fakultas Teknik Universitas Lampung.
2. Bapak Dr. Ir. Syamsurijal Rasimeng, S.Si., M.Si., C.EIA., IPM., selaku Ketua Jurusan Teknik Geofisika Universitas Lampung.
3. Bapak Dr. Alimuddin Muchtar, S.Si., M.Si., C.EIA., selaku Sekretaris Jurusan Teknik Geofisika Universitas Lampung.
4. Bapak Ir. I Gede Boy Darmawan, S.Si., M.Eng., selaku dosen pembimbing pertama, yang telah membimbing penulis dengan penuh kesabaran, senantiasa meluangkan waktu di tengah kesibukan, serta memberikan saran, masukan, dan ide yang memperluas wawasan penulis hingga penelitian ini dapat diselesaikan.
5. Bapak Aryanto, S.T., M.T., selaku dosen pembimbing kedua, yang telah banyak memberikan bimbingan dan arahan kepada penulis selama proses penyusunan skripsi ini hingga dapat diselesaikan dengan baik.
6. Bapak Prof. Dr. Ir. Nandi Haerudin, S.Si., M.Si., IPM., selaku dosen penguji skripsi yang telah memberikan masukan, motivasi, semangat, serta evaluasi yang sangat membangun demi kelayakan skripsi ini. Segala masukan yang

diberikan menjadi bahan evaluasi sekaligus bekal yang sangat berharga bagi penulis dalam menyempurnakan skripsi ini

7. Bapak Dr. Ordas Dewanto, S.Si., M.Si., selaku Dosen Wali atau Pembimbing Akademik sekaligus Pembimbing Kerja Praktik yang telah memberikan bimbingan, arahan, masukan dan dukungan kepada penulis selama menjalani perkuliahan serta dalam pelaksanaan Kerja Praktik.
8. Bapak Shaska Ramadhan Zulivandama, S.T., M.T., selaku pembimbing lapangan saat penulis melaksanakan Kerja Praktik di Balai Besar Survei dan Pemetaan Geologi Kelautan yang telah memberikan bimbingan dan ilmu baru yang berharga kepada penulis selama proses pelaksanaan Kerja Praktik.
9. Seluruh dosen dan civitas akademika Prodi Teknik Geofisika, Universitas Lampung yang tidak dapat penulis sebutkan satu per satu, yang telah hadir sebagai bagian dalam perjalanan akademik penulis. Terima kasih atas ilmu, pengalaman, kepercayaan, arahan, dukungan, serta canda tawa yang menghadirkan kehangatan ditengah perjalanan perkuliahan dan akan senantiasa terpatri sebagai kenangan indah yang tak terlupakan sepanjang hayat.
10. Kedua Orang Tua tercinta, Bapak Rumli S.Pd dan Ibu Armawati, yang menjadi alasan paling kuat dalam setiap langkah yang penulis tempuh. Tidak ada kata yang benar-benar mampu mewakili besarnya doa, kasih sayang, serta pengorbanan yang telah diberikan tanpa henti. Kehadiran dan kepercayaan dari kedua orang tua selalu menjadi kekuatan yang tidak tergantikan. Apa yang berhasil dicapai hari ini bukanlah semata hasil dari usaha penulis, melainkan dari doa yang tak pernah terputus, pengorbanan yang tidak pernah dituntut balas, serta kasih sayang yang terus menguatkan. Segala pencapaian ini penulis persembahkan sebagai bentuk kecil dari rasa syukur dan bakti yang tidak akan pernah sebanding dengan apa yang telah diberikan.
11. Diri sendiri, yang telah bertahan dan terus melangkah hingga tahap ini. Pencapaian ini bukan hasil dari langkah yang selalu sempurna, tetapi dari konsistensi untuk tetap melanjutkan apa yang telah dimulai.
12. Abang dan Kakak, Vicri Oka Pratama dan Dea Dara Dwi Elis, atas setiap doa, motivasi, nasihat, serta dukungan materi maupun moril yang terus diberikan selama proses penyusunan skripsi ini.

13. Kekasih tercinta, yang telah menemani penulis dalam berkeluh kesah dan bertukar cerita, baik dalam suka maupun duka. Kehadiran dan energi semangat yang diberikan menjadi penyemangat bagi penulis dalam menjalani kehidupan.
14. Sobat “KP KP KP”, yaitu Ilham Fahmi (Aba) dan Paris Fernanda, yang telah menjadi rekan seperjuangan penulis selama pelaksanaan Kerja Praktik di Bandung.
15. Penghuni “Sastra Mesin”, yaitu Aprial, Athallah, Fajar, Made Indra, Zulfikar, Jena dan Safira. Kehangatan kalian melalui canda dan tawa di sela-sela penyusunan skripsi menjadi penyemangat tersendiri yang membantu penulis tetap bertahan dan menyelesaikan setiap tahap dengan lebih ringan.
16. Orang-orangan “*Reality Check*”, yaitu Simut (Siti Mahmudah), Mba Ca (Hafizah), dan Wakom (Hafiz Ibnu). Kehadiran kalian menjadi pengingat sekaligus penguat bagi penulis untuk tetap bertahan, bersyukur, dan terus melangkah dalam setiap proses yang dijalani. *I hope things keep getting easier for you guys and that everything you're working on moves in your favor.*
17. Rekan “TA PiGraf”, yaitu Aviv Irfan (Timi), Irgi Akbari, Asda Arwa, Firda Amalia, dan Tyas Puspaningsih, yang telah menjadi tempat bertukar ide dalam proses penyelesaian Tugas Akhir.
18. Rumah Mulyawan, yaitu Muhammad Zaid, Eka Pramuditia, Cunul (Husnul Mubarrak), Komti (Rangga Andriano), Korlap (Aflaha Afif), Bang Yus (Yusroni Tri Ananta), Aloysius Arya, Alif, Aji, Omar Liandro, serta bujang-bujang lainnya yang tidak dapat penulis sebutkan satu per satu, yang telah memberikan warna tersendiri dalam perjalanan penulis. Canda, tawa, dan kebersamaan yang tercipta menjadi ruang pelepas penat ditengah lika-liku perkuliahan.
19. Keluarga besar Teknik Geofisika 2022 ‘GRANIT’, terima kasih atas penerimaan dan kebersamaan yang telah diberikan sejak awal perkuliahan hingga akhir masa studi ini. Terima kasih telah menjadi partner dalam setiap fase, baik dalam akademik, organisasi, maupun perjalanan yang meninggalkan banyak cerita dan pelajaran.
20. Abang, kakak, dan adik-adik Teknik Geofisika yang dengan penuh semangat dan ketulusan telah turut membantu serta memberikan dukungan selama proses

penyelesaian tugas akhir ini. Terimakasih atas setiap perhatian, bantuan, dan kebersamaan yang diberikan kepada penulis.

Kepada seluruh pihak yang tidak dapat penulis sebutkan satu per satu, penulis menyampaikan terima kasih atas setiap doa, dukungan, dan kebaikan yang telah menyertai proses ini. Semoga Allah SWT membalas segala kebaikan tersebut dengan keberkahan dan balasan yang berlipat ganda.

Bandar Lampung, 13 Mei 2026

Penulis,



Razki Alfatah Khairu Mahli

NPM. 2215051011

DAFTAR ISI

	Halaman
ABSTRAK	iii
<i>ABSTRACT</i>	iv
MENYETUJUI,.....	v
MENGESAHKAN.....	vi
PERNYATAAN.....	vii
RIWAYAT HIDUP	viii
PERSEMBAHAN.....	xi
MOTTO	xii
KATA PENGANTAR.....	xiii
SANWACANA.....	xiv
DAFTAR ISI.....	xviii
DAFTAR GAMBAR.....	xxi
DAFTAR TABEL	xxiii
I. PENDAHULUAN.....	1
1.1. Latar Belakang	1
1.2. Tujuan Penelitian.....	3
1.3. Batasan Penelitian	3
1.4. Manfaat Penelitian	3
II. TINJAUAN PUSTAKA	4

2.1. Penelitian Terdahulu.....	4
2.2. Lapangan Panas Bumi Ulubelu.....	8
2.2.1. Geologi Regional Ulubelu	9
2.2.2. Stratigrafi Batuan Ulubelu	11
III. TEORI DASAR.....	13
3.1. Gelombang Seismik	13
3.1.1. Gelombang Badan.....	13
3.1.2. Gelombang Permukaan	15
3.2. Metode <i>Microearthquake</i> (MEQ)	17
3.3. Diagram Wadati.....	19
3.4. <i>Machine Learning</i>	20
3.4.1. <i>Supervised Learning</i>	21
3.4.2. <i>Unsupervised Learning</i>	22
3.5. <i>Deep Learning</i>	23
3.6. <i>Truncated Gaussian</i>	24
3.7. <i>Convolutional Neural Network</i>	25
3.7.1. <i>Convolution Layer</i>	26
3.7.2. <i>Batch Normalization</i>	27
3.7.3. <i>Dropout Layer</i>	28
3.8. Fungsi Aktivasi.....	28
3.8.1. ReLU.....	28
3.8.2. <i>Sigmoid</i>	29
3.9. <i>Mean Absolute Error (MAE)</i>	30
3.10. <i>Confusion Matrix</i>	30
IV. METODE PENELITIAN	32
4.1. Waktu dan Tempat Penelitian.....	32

4.2. Alat dan Bahan	34
4.3. Prosedur Penelitian.....	35
4.3.1. Uji Kalibrasi Alat	35
4.3.2. Studi Literatur dan Desain Akuisisi	35
4.3.3. Akuisisi Data	36
4.3.4. Pengolahan Data	38
4.3.5. Perancangan dan Pelatihan Model	39
4.3.6. Analisis dan interpretasi	46
4.4. Diagram Alir Penelitian.....	46
V. HASIL DAN PEMBAHASAN	50
5.1. Persiapan Sistem <i>Auto Picking</i> CNN	50
5.1.1. Persiapan Dataset	50
5.1.2. Pra-pemrosesan Data <i>Waveform</i>	53
5.1.3. Pembagian dan Pelabelan Dataset.....	54
5.1.4. Teknik Augmentasi.....	58
5.1.5. Rancangan Arsitektur Model CNN	59
5.2. Evaluasi dan Performa Model	61
5.2.1. Akurasi <i>Training</i> dan <i>Validation</i>	62
5.2.2. Evaluasi Performa Model pada Data Testing.....	63
5.3. Evaluasi Model Pada Data Lapangan Panas Bumi	69
VI. SIMPULAN DAN SARAN	81
6.1. Simpulan	81
6.2. Saran.....	82
DAFTAR PUSTAKA.....	83
LAMPIRAN.....	89

DAFTAR GAMBAR

Gambar	Halaman
1. Sistem Panas bumi (Wijayanti, 2023)	8
2. Peta geologi penelitian	10
3. Stratigrafi Batuan Pada Wilayah Ulubelu (Amin dkk., 2010).	11
4. Perambatan gelombang primer (P) (Braile, 2010).	14
5. Perambatan gelombang sekunder (S) (Braile, 2010)	15
6. Perambatan gelombang <i>love</i> (Braile, 2010).....	16
7. Perambatan gelombang <i>rayleigh</i> (Braile, 2010)	17
8. Tiga komponen gelombang gempa mikro (Hurukawa, 2008)	18
9. Diagram Wadati (Hurukawa, 2008)	19
10. Skema metode <i>supervised learning</i>	22
11. Skema metode <i>unsupervised learning</i>	23
12. Perbedaan antara <i>neural network</i> dengan <i>deep learning</i> (Ryu dkk., 2021)	24
13. Arsitektur MLP Sederhana (Oswald dkk., 2022)	25
14. Ilustrasi operasi konvolusi pada CNN 1D (Shenfield & Howarth, 2020).....	27
15. Bentuk kurva fungsi aktivasi ReLU (Sarno dkk., 2023).....	29
16. Bentuk kurva fungsi aktivasi sigmoid (Sarno dkk., 2023).....	30
17. Casing alat PiGraf	37
18. Stasiun PiGraf dengan panel surya	37
19. Tampilan <i>web server</i> pigraf.....	38
20. Tampilan beranda <i>software</i> PiGrafSoft_v1.2.exe.....	39
21. Visualisasi pelabelan data latih pendekatan <i>Truncated Gaussian</i>	42
22. Susunan lengkap arsitektur model CNN	45
23. Diagram alir penelitian.....	49

24. A). Persebaran data <i>event</i> gempa pada dataset STEAD. B). Persebaran stasiun seismograf dataset STEAD.	51
25. Contoh <i>waveform</i> yang telah terseleksi SNR dan magnitudo.	52
26. Perbedaan kondisi data gelombang sebelum dan sesudah proses <i>detrending</i>	53
27. <i>Confusion matrix</i> dengan pelabelan klasifikasi.	55
28. Ilustrasi uji generalisasi model dengan pendekatan <i>multi output regression</i> ..	56
29. Statistik prediksi pendekatan <i>multi output regression</i> ..	56
30. Ilustrasi pelabelan pendekatan <i>probabilistic onset</i> berbasis <i>Gaussian mask</i> ..	57
31. Rincian layer model CNN 1D ..	60
32. Arsitektur model CNN 1D ..	60
33. Histogram distribusi <i>error</i> prediksi waktu tiba gelombang P dan S pada keseluruhan dataset testing ..	64
34. Visualisasi hasil prediksi <i>onset</i> gelombang P dan S pada data testing (<i>sample</i> 4930).	66
35. Visualisasi hasil prediksi <i>onset</i> gelombang P dan S pada data testing (<i>sample</i> 831).	67
36. Visualisasi hasil prediksi <i>onset</i> gelombang P dan S pada data testing (<i>sample</i> 2364).	68
37. Dokumentasi pengambilan data seismograf PiGraf di lapangan panas bumi Ulubelu.	69
38. Contoh data rekaman gempa mikro menggunakan seismograf PiGraf stasiun 2 hingga 4 pada tanggal 10 April 2026 ..	70
39. Contoh <i>plot</i> prediksi <i>onset</i> gelombang P dan S pada data lapangan riil wilayah Ulubelu stasiun 2 PiGraf tanggal 4 April 2026 pukul 13:00 UTC ..	71
40. Contoh <i>plot</i> prediksi <i>onset</i> gelombang P dan S pada data lapangan riil wilayah Ulubelu stasiun 3 PiGraf tanggal 1 April 2026 pukul 10:23 UTC ..	73
41. Contoh <i>plot</i> prediksi <i>onset</i> gelombang P dan S pada data lapangan riil wilayah Ulubelu stasiun 2 PiGraf tanggal 1 April 2026 pukul 10:23 UTC ..	75
42. Contoh <i>plot</i> prediksi <i>onset</i> gelombang P dan S pada data lapangan riil wilayah Ulubelu stasiun 3 PiGraf tanggal 1 April 2026 pukul 06:01 UTC ..	77
43. Histogram distribusi <i>error</i> prediksi waktu tiba gelombang P dan S pada data riil lapangan.	79

DAFTAR TABEL

Tabel	Halaman
Tabel 1. Klasifikasi gempa berdasarkan magnitudo (Hurukawa, 2008).	18
Tabel 2. Jadwal kegiatan penelitian	33
Tabel 3. Data yang digunakan dalam penelitian	34
Tabel 4. Peralatan yang digunakan dalam penelitian	34
Tabel 5. Susunan data seismogram yang telah dikonversi	40
Tabel 6. Proporsi pembagian dataset pelatihan	54
Tabel 7. Tabel evaluasi kinerja model berdasarkan <i>epoch</i> dalam proses pelatihan	62
Tabel 8. Statistik <i>error</i> evaluasi kinerja model dalam prediksi waktu kedatangan gelombang P dan S	63
Tabel 9. Evaluasi kinerja model menggunakan metrik F1 <i>Score</i> pada data <i>testing</i>	65
Tabel 10. Tabel evaluasi prediksi stasiun 2 PiGraf data rekaman 4 April 2026 Pukul 13.00 UTC.....	72
Tabel 11. Tabel evaluasi prediksi stasiun 3 PiGraf data rekaman 1 April 2026 Pukul 10:23 UTC.....	74
Tabel 12. Tabel evaluasi prediksi stasiun 2 PiGraf data rekaman 1 April 2026 Pukul 10:23 UTC.....	76
Tabel 13. Tabel evaluasi prediksi stasiun 3 PiGraf data rekaman 1 April 2026 Pukul 06:01 UTC.....	78
Tabel 14. Statistik evaluasi pengujian kinerja model prediksi waktu kedatangan gelombang P dan S data riil lapangan	78

I. PENDAHULUAN

1.1. Latar Belakang

Energi panas bumi sebagai sumber energi terbarukan dan berkelanjutan semakin mendapat perhatian dalam beberapa tahun terakhir karena potensinya dalam mengurangi emisi gas rumah kaca serta ketergantungan terhadap bahan bakar fosil. Salah satu tantangan utama dalam pengembangan dan pengelolaan lapangan panas bumi adalah pemantauan serta pengendalian aktivitas mikroseismik yang terjadi sebagai respon terhadap dinamika sistem panas bumi, termasuk proses injeksi dan produksi fluida di dalam reservoir (Wibowo dkk., 2022). Aktivitas mikroseismik tersebut umumnya dikenal sebagai gempa mikro.

Pemantauan gempa mikro berperan untuk menilai kualitas reservoir, mengidentifikasi zona rekahan aktif, serta memahami mekanisme deformasi batuan yang terjadi akibat aktivitas eksploitasi (Folesky dkk., 2016; Huang dkk., 2017; Okamoto dkk., 2018; Rossi dkk., 2020). Saat ini, metode pemantauan gempa mikro telah banyak diterapkan pada berbagai bidang seperti geologi, seperti zona sesar aktif, aktivitas vulkanik, daerah rawan longsor, pertambangan, penggalian terowongan, serta reservoir panas bumi dan hidrokarbon. Informasi yang diperoleh dari kejadian gempa mikro dapat memungkinkan mendelineasi jaringan rekahan serta analisis karakteristik sumber hiposenter gempa mikro tersebut.

Kejadian gempa mikro umumnya direkam menggunakan seismometer atau akselerometer yang ditempatkan secara strategis di sekitar area reservoir. Namun, ketelitian dalam penentuan waktu kedatangan fase gelombang (*phase picking*), merupakan faktor penentu dalam keberhasilan analisis lanjutan, seperti penentuan lokasi hiposenter, estimasi magnitudo, serta interpretasi mekanisme sumber (Wang dkk., 2018). Metode konvensional untuk *phase picking*, seperti *short-term average/long-term average* (STA/LTA) dan pendekatan berbasis statistik

(Allen, 1978; Baer & Kradofer, 1987), memiliki keterbatasan dalam menghadapi data gempa mikro yang kompleks dan bising, serta kurang andal dalam mengidentifikasi fase gelombang S yang tidak muncul sebagai kedatangan awal (Lois dkk., 2013; Namjesnik dkk., 2021; Yu dkk., 2020). Seiring dengan meningkatnya volume data mikroseismik dan kebutuhan pemantauan secara *real-time*, metode manual dan semi-otomatis menjadi kurang efisien yang rentan terhadap subjektivitas analisis, serta sulit diterapkan secara berkelanjutan.

Dalam beberapa tahun terakhir, pendekatan *deep learning*, khususnya *Convolutional Neural Network* (CNN) membawakan pendekatan yang lebih *robust* untuk sistem *auto picking* waktu kedatangan (*phase picking*) gelombang. Chen dkk. (2019) membuktikan bahwa CNN berbasis konvolusi 1D mampu menghasilkan akurasi *arrival picking* yang lebih tinggi dibandingkan metode *neural network* konvensional, khususnya pada data dengan *signal to noise ratio* (SNR) rendah. Liu dkk. (2022) menunjukkan bahwa model U-Net berbasis CNN memiliki stabilitas dan akurasi yang lebih baik dibandingkan metode AIC dan berbasis energi pada data mikroseismik dengan *noise* yang tinggi. Penelitian lain juga mengindikasikan bahwa CNN mampu mempertahankan performa tinggi pada berbagai kondisi *noise* dan kompleksitas sinyal (Li dkk., 2025).

Oleh karena itu, penelitian ini difokuskan pada penerapan *Convolutional Neural Network* untuk sistem *auto picking* waktu kedatangan gelombang P dan S pada data kejadian gempa mikro yang menyesuaikan pada lapangan panas bumi. Pendekatan ini diharapkan mampu menghasilkan proses *picking* yang lebih cepat dan konsisten, sehingga dapat mendukung kebutuhan monitoring mikroseismik secara *real-time* pada lapangan panas bumi yang telah beroperasi.

1.2. Tujuan Penelitian

Tujuan dari penelitian ini adalah sebagai berikut.

1. Mengembangkan dan menjelaskan tahapan proses algoritma sistem *auto picking* berbasis *Convolutional Neural Network* (CNN) untuk mendeteksi waktu kedatangan gelombang P dan S pada data gempa mikro
2. Mengevaluasi tingkat akurasi dan kinerja sistem *auto picking* berbasis *Convolutional Neural Network* (CNN) dalam menentukan waktu kedatangan gelombang P dan S pada data gempa mikro
3. Menerapkan sistem *auto picking* berbasis *Convolutional Neural Network* (CNN) dalam bentuk prototipe pada data gempa mikro yang direkam di Lapangan Panas Bumi menggunakan seismograf PiGraf.

1.3. Batasan Penelitian

Batasan pada penelitian ini adalah sebagai berikut.

1. Data yang digunakan dalam penelitian ini terbatas pada data seismogram *open-source* dan data seismogram gempa mikro yang direkam menggunakan seismograf PiGraf pada lapangan panas bumi.
2. Penelitian ini difokuskan pada proses *auto picking* waktu kedatangan gelombang P dan S (*arrival time picking*) dan tidak mencakup analisis lanjutan
3. Metode *auto picking* berbasis *deep learning* yang digunakan dalam penelitian ini dibatasi pada satu arsitektur model yang dirancang dan dioptimasi.
4. Penelitian ini terbatas pada pengembangan dan pengujian prototipe seismogram PiGraf.

1.4. Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat ilmiah dalam pengembangan sistem monitoring gempa mikro pada lapangan panas bumi dan dapat menjadi referensi dalam penerapan *Convolutional Neural Network* (CNN) untuk sistem *auto picking* waktu kedatangan gelombang P dan S pada data seismogram. Hasil penelitian ini diharapkan mampu menghasilkan prototipe sistem *auto picking* berbasis CNN yang dapat meningkatkan kecepatan, akurasi, dan konsistensi proses *picking* dalam kebutuhan monitoring secara *real time*.

II. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Terdapat beberapa penelitian terdahulu yang berkaitan dengan penggunaan *Convolutional Neural Network* (CNN) dalam sistem *auto picking* gelombang datang. Chen dkk. (2019) yang bertujuan mengembangkan metode otomatis untuk klasifikasi *waveform* dan *arrival picking* yang lebih *robust* terhadap *noise*, serta mengurangi ketergantungan pada proses *picking manual* yang menjadi kelemahan utama metode konvensional seperti STA/LTA pada data mikroseismik.

Model yang digunakan dalam penelitian ini adalah CNN satu dimensi (1D CNN) yang dikombinasikan dengan metode *k-means clustering*, sementara *Multilayer Perceptron* (MLP) digunakan sebagai model pembanding. Data yang digunakan terdiri atas data mikroseismik sintetis dan data mikroseismik lapangan, dengan 25% data digunakan sebagai data latih dan sisanya sebagai data uji. Hasil penelitian menunjukkan bahwa CNN memberikan performa yang lebih baik dibandingkan MLP, terutama pada kondisi data yang ber-*noise*. Pada data bersih, CNN mencapai akurasi sebesar 0,998, sedangkan MLP sebesar 0,992. Sementara pada data *noisy* dengan SNR $-7,27$ dB, CNN-KC mampu mempertahankan akurasi sebesar 0,925 yang jauh lebih tinggi dibandingkan MLP yang hanya mencapai 0,850.

Penelitian selanjutnya dilakukan oleh Zhang dkk. (2020) dengan tujuan mengembangkan metode klasifikasi *waveform* dan *arrival picking* gelombang mikroseismik yang lebih *robust* terhadap *noise*, mengingat rendahnya rasio *signal-to-noise* pada data mikroseismik menyebabkan keterbatasan pada metode

konvensional maupun model MLP. Dalam penelitian ini, *waveform* satu dimensi terlebih dahulu ditransformasikan ke domain waktu–frekuensi menggunakan *Continuous Wavelet Transform* (CWT) sehingga menghasilkan peta spektrum 2D yang digunakan sebagai masukan CNN 2D, dengan DNN berbasis vektor 1D sebagai model pembanding. Data yang digunakan meliputi data mikroseismik sintetik sebanyak 101 *trace* dan data lapangan sekitar 70–81 *trace*, dengan hanya sebagian kecil *trace* digunakan sebagai data latih.

Hasil evaluasi menunjukkan bahwa CWT-CNN mengungguli DNN. Pada data sintetik dengan *noise* tinggi ($\sigma = 0,8$), CWT-CNN mencapai akurasi 0,94–0,96, sedangkan DNN hanya 0,86–0,88, dengan RMS *error arrival picking* masing-masing sekitar 20–30 ms dan 40–50 ms. Pada data lapangan *blind test* dengan rasio *signal-to-noise* rendah, CWT-CNN menghasilkan RMS *error* 16,4 ms, jauh lebih kecil dibandingkan DNN sebesar 44,6 ms, serta tetap menunjukkan performa lebih baik pada data lapangan lain yang lebih kompleks dengan RMS *error* 113,7 ms, dibandingkan 140,4 ms pada DNN.

Penelitian selanjutnya dilakukan oleh Liu dkk. (2022) dengan tujuan mengembangkan metode otomatis untuk mendeteksi waktu kedatangan (*arrival time*) gelombang mikroseismik secara akurat dan stabil, terutama pada kondisi data dengan rasio *signal-to-noise* rendah yang menjadi kendala utama metode konvensional seperti AIC dan *time window energy*. Penelitian ini mengusulkan penggunaan arsitektur U-Net berbasis *Convolutional Neural Network* (CNN) yang dimodifikasi untuk data satu dimensi. *Waveform* mikroseismik tidak diubah menjadi citra 2D, tetapi direpresentasikan sebagai tensor berukuran $1024 \times 1 \times 1$ agar sesuai dengan struktur U-Net. Dataset yang digunakan terdiri atas 1555 segmen data mikroseismik nyata sebagai data validasi dan 7764 segmen data sintetik sebagai data pelatihan dan pengujian, dengan total sekitar 7700 segmen *waveform*.

Hasil evaluasi menunjukkan bahwa U-Net memiliki kinerja yang kompetitif dibandingkan metode konvensional. Pada data tanpa *noise*, U-Net menghasilkan rata-rata *error arrival picking* sebesar 6,38 μs dengan *error detection rate* 3,34%, sedikit lebih rendah akurasiya dibandingkan metode AIC yang memiliki *error* 2,79 μs , namun jauh lebih baik dibandingkan metode *time window* dengan *error* 12,63

μ s. Setelah penambahan *noise* sehingga rasio *signal-to-noise* menurun, performa U-Net justru lebih stabil, dengan rata-rata *error* 11,64 μ s dan *error picking rate* 4,80%, lebih baik dibandingkan AIC yang mengalami peningkatan *error* hingga 12,16 μ s dengan *error rate* 9,51%, serta metode *time window* yang mencapai *error* 31,07 μ s dengan *error rate* 28,55%.

Penelitian selanjutnya dilakukan oleh Wei Li dkk. (2022) dengan tujuan mengembangkan sistem *real-time earthquake monitoring* melalui peningkatan akurasi klasifikasi fase seismik dan penentuan waktu kedatangan gelombang P dan S, khususnya pada data dengan rasio *signal-to-noise* rendah yang menjadi kendala utama metode konvensional dan CNN statis. Penelitian ini mengusulkan arsitektur *DynaPicker*, yaitu CNN satu dimensi berbasis *Dynamic Convolution Decomposition* (1D-DCD) yang mampu menyesuaikan kernel konvolusi secara dinamis terhadap karakteristik sinyal masukan. Model dilatih menggunakan dataset SCEDC yang terdiri dari sekitar 4,5 juta *window* sinyal tiga komponen berdurasi 4 detik, mencakup 1,5 juta *window* P-wave, 1,5 juta S-wave, dan 1,5 juta *noise*, dengan pembagian data sebesar 90% untuk pelatihan dan 10% untuk pengujian. Metode penelitian dilakukan dengan mengklasifikasikan *window* sinyal menjadi tiga kelas (P, S, dan *noise*), kemudian menerapkan *sliding window* pada data seismik untuk menentukan waktu kedatangan fase berdasarkan probabilitas maksimum.

Hasil evaluasi menunjukkan bahwa *DynaPicker* memberikan performa yang unggul dibandingkan metode pembanding, seperti GPD, CapsPhase, dan 1D-ResNet. Pada pengujian klasifikasi fase menggunakan dataset SCEDC, *DynaPicker* mencapai akurasi 98,82%, lebih tinggi dibandingkan CapsPhase dan 1D-ResNet yang masing-masing sebesar 98,66%, serta menghasilkan F1-score 98,84% untuk fase P dan 98,96% untuk fase S. Uji ketahanan terhadap *noise* pada dataset STEAD menunjukkan bahwa pada tingkat *noise* tertinggi ($\sigma = 0,15$), *DynaPicker* tetap mempertahankan akurasi 91,26%, lebih baik dibandingkan CapsPhase (88,90%) dan 1D-ResNet (89,16%). Dalam evaluasi *arrival picking* pada data seismik kontinu, *DynaPicker* mampu mendeteksi seluruh kejadian gempa tanpa *missed detection* dan menghasilkan simpangan baku *error* waktu kedatangan P-wave sekitar 0,09–0,15 s dan S-wave sekitar 0,16–0,20 s, yang secara konsisten lebih kecil dibandingkan metode pembanding.

Li dkk. (2025) melakukan penelitian dengan tujuan meningkatkan akurasi dan efisiensi estimasi gabungan *direction of arrival* (DOA) dan parameter polarisasi pada *polarisation-sensitive array*, khususnya pada kondisi SNR rendah dan jumlah *snapshot* terbatas. Penelitian ini mengusulkan arsitektur CNN yang menggunakan bagian segitiga atas matriks kovarians sinyal sebagai masukan, dengan komponen *real* dan imajiner dipisahkan menjadi dua *channel*. Dataset sintetik sebanyak 10,000 sampel digunakan, dengan pembagian 80% data latih dan 20% data uji. Model CNN terdiri dari tiga lapisan konvolusi, dua *pooling*, dan dua *fully connected*, dilatih menggunakan MSE loss, optimizer Adam, batch size 32, dan hingga 500 *epoch*, serta dilengkapi *learning rate scheduler* dan *early stopping*.

Hasil evaluasi menunjukkan bahwa metode CNN menghasilkan RMSE estimasi DOA dan parameter polarisasi yang lebih rendah dibandingkan *polarised MUSIC*, *polarised ESPRIT*, dan RD-MUSIC, terutama pada $SNR < 5$ dB, dengan performa yang lebih mendekati *Cramér–Rao Lower Bound* (CRLB). Dari sisi komputasi, metode ini juga lebih efisien dengan waktu eksekusi sekitar 0,32 s, jauh lebih cepat dibandingkan *polarised MUSIC* ($\approx 31,9$ s) dan lebih efisien dibandingkan RD-MUSIC ($\approx 0,57$ s). Berdasarkan hasil tersebut dapat disimpulkan bahwa pendekatan CNN dapat meningkatkan akurasi estimasi sekaligus menurunkan proses komputasi, sehingga *robust* untuk kondisi sinyal berkualitas rendah dan data terbatas.

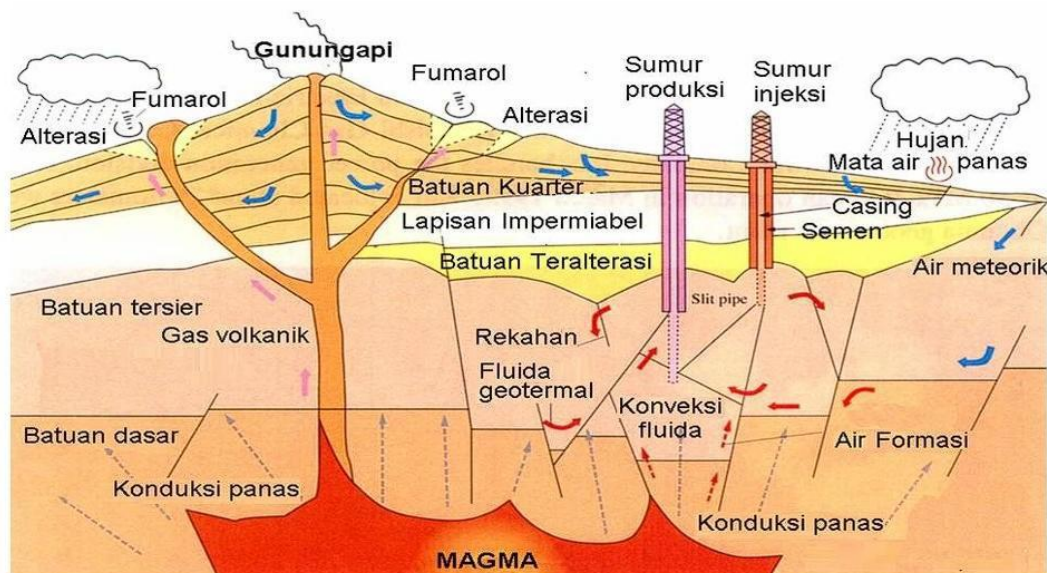
Penelitian terbaru oleh M. F. Al Hakim dkk. (2025) bertujuan mengevaluasi efektivitas PhaseNet sebagai metode *automatic phase picking* untuk identifikasi kejadian gempa mikro pada lapangan panas bumi yang umumnya memiliki lingkungan sinyal sangat *noisy*. Model yang digunakan adalah PhaseNet, yaitu jaringan saraf dalam berbasis *Convolutional Neural Network* (CNN) untuk deteksi fase P dan S secara probabilistik. Pada penelitian ini dilakukan *retrain* menggunakan data seismik lokal. Dataset diperoleh dari delapan stasiun seismometer tiga komponen dengan laju sampling 200 Hz yang merekam data kontinu selama dua bulan. Data bulan pertama (sekitar 720 jam rekaman) digunakan untuk pelatihan dengan *ground truth* berupa katalog *picking* manual, sedangkan data bulan kedua digunakan sebagai data uji. Tahapan penelitian meliputi *pre-processing* (normalisasi amplitudo dan *bandpass filter*), *phase picking*

menggunakan PhaseNet. Hasil evaluasi menunjukkan bahwa PhaseNet mampu mengidentifikasi 20.313 fase (10.323 fase P dan 9.990 fase S) dengan perbedaan waktu *picking* rata-rata terhadap katalog manual sekitar 0,1 detik dan seluruh selisih berada di bawah 1 detik.

2.2. Lapangan Panas Bumi Ulubelu

Lapangan Panas Bumi Ulubelu merupakan salah satu sistem panas bumi yang telah dikembangkan sebagai Pembangkit Listrik Tenaga Panas Bumi (PLTP) di Provinsi Lampung. Lapangan ini dicirikan oleh keberadaan berbagai manifestasi panas bumi, antara lain mata air panas, fumarol, batuan teralterasi, serta tanah beruap yang tersebar di beberapa lokasi. Keberadaan manifestasi tersebut menunjukkan aktivitas sistem hidrotermal yang masih aktif dan berkaitan erat dengan dinamika fluida di dalam reservoir panas bumi.

Zona alterasi hidrotermal pada Lapangan Panas Bumi Ulubelu menunjukkan zonasi mineral yang relatif jelas, mulai dari zona smektit di dekat permukaan hingga kedalaman sekitar 650 m di atas permukaan laut, zona lempung campuran pada kedalaman 500–650 m dpl, zona klorit pada kedalaman 100-500 m dpl, serta zona klorit-epidot pada kedalaman lebih dari 100 m dpl (Suharno & Browne, 2000). Pola zonasi alterasi tersebut mencerminkan distribusi temperatur dan sirkulasi fluida panas bumi di bawah permukaan. ilustrasi sistem panas bumi ditunjukkan pada Gambar 1.



Gambar 1. Sistem Panas bumi (Wijayanti, 2023)

Struktur geologi berperan dalam sistem panas bumi Ulubelu. Interpretasi data geofisika yang didukung oleh data geologi, geokimia, dan pengeboran menunjukkan bahwa lapangan panas bumi ini berasosiasi dengan struktur graben yang teridentifikasi pada peta anomali gravitasi residual. Sistem tersebut dicirikan oleh dua zona *upflow* terpisah dengan fase fluida reservoir yang berbeda, mencakup area sekitar 25 km², serta zona *outflow* yang berkembang di bagian selatan. Puncak reservoir utama diperkirakan berada pada kedalaman sekitar 650 m di bawah permukaan dengan suhu reservoir sekitar 260°C (Daud dkk., 2023).

Berdasarkan hasil eksplorasi pengeboran, analisis kandungan anion dan kation utama menunjukkan bahwa mata air panas dari Kelompok Way Panas merupakan air bertipe klorida yang berasal langsung dari reservoir, sedangkan mata air panas dari kelompok Danau Hijau dan Pagar Alam tergolong sebagai fluida kondensat asam-sulfat. Estimasi suhu reservoir panas bumi Ulubelu berdasarkan geotermometer Na/K dan silika mencapai $229 \pm 4^\circ\text{C}$, sehingga sistem panas bumi Ulubelu diklasifikasikan sebagai reservoir bersuhu tinggi yang didominasi oleh fluida air dengan suhu sekitar 265°C (Iqbal dkk., 2023).

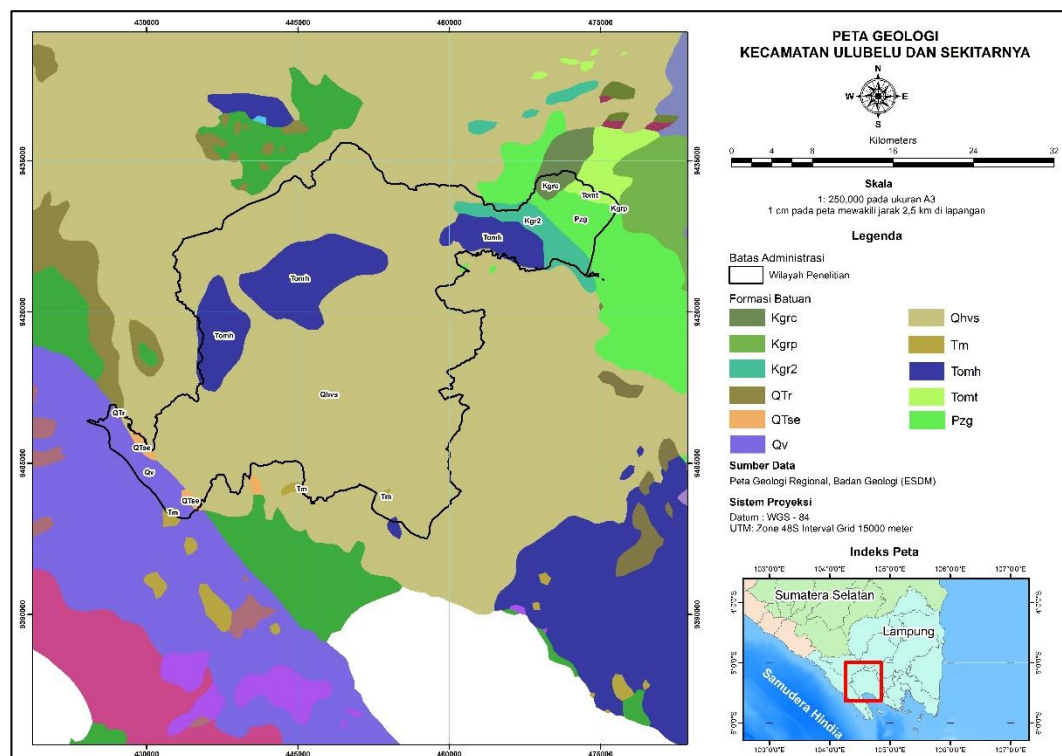
Kondisi sistem panas bumi yang dicirikan oleh temperatur tinggi, keberadaan struktur geologi aktif, serta pergerakan fluida di dalam reservoir berpotensi memicu terjadinya aktivitas mikroseismik. Selain itu, aktivitas pengembangan lapangan berupa proses injeksi dan produksi fluida dapat menyebabkan perubahan tekanan pori dan kondisi tegasan batuan, yang selanjutnya memicu terjadinya gempa mikro.

2.2.1. Geologi Regional Ulubelu

Menurut McCourt dkk., (1996), daerah Ulubelu termasuk ke dalam busur plutonik yang berumur Kapur Tengah-Akhir dan berada pada mikro-lempeng Woyla. Busur ini terfokus sepanjang zona patahan berarah barat laut-tenggara dan didominasi oleh granitoid pembawa hornblend dioritik hingga granodioritic dengan granit biotit megacrystic K-feldspar.

Berdasarkan peta geologi lembar Kota Agung oleh Amin dkk., (2010), batuan yang terdapat pada daerah Ulubelu didominasi oleh batuan gunungapi berumur Kuartar dan batuan sedimen serta gunungapi berumur Tersier. Secara regional, daerah ini merupakan bagian dari jalur vulkanik Sumatera yang aktif dan

terbentuk akibat subduksi lempeng Indo-Australia di bawah lempeng Eurasia. Sistem panas bumi Ulubelu terletak di ujung selatan Sistem Sesar Sumatera (*Sumatran Fault System*) dan dikelilingi oleh beberapa gunungapi seperti Gunung Sula di barat, Gunung Korupan di timur, Gunung Rendingan di utara, Gunung Duduk di tengah, dan Gunung Kukusan di selatan (Mulyanto dkk., 2015). Peta geologi daerah penelitian ditunjukkan pada Gambar 2



Gambar 2. Peta geologi penelitian

Berdasarkan satuan geologi daerah penelitian yang ditunjukkan pada Gambar 2, dijumpai berbagai formasi dengan rentang umur dari Paleozoikum hingga Holosen. Satuan termuda berupa aluvium (Qa) berumur Holosen yang tersusun atas material lepas seperti kerakal, kerikil, pasir, lempung, dan gambut. Selain itu, terdapat endapan gunungapi muda sekunder (Qhvs) berumur Holosen yang terdiri atas endapan lahar, aliran piroklastik sekunder, serta material vulkanik. Satuan batuan gunungapi muda (Qhv) juga berkembang pada umur Holosen dengan litologi berupa lava, breksi gunungapi, dan tuf.

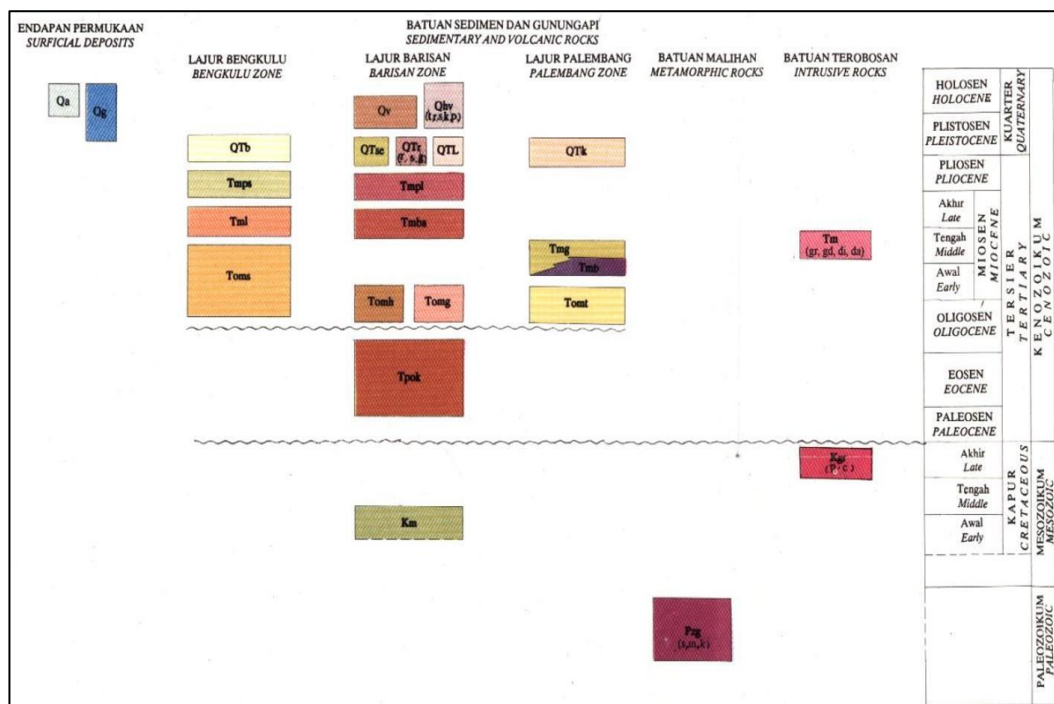
Satuan gunungapi kuartar (Qv) yang berumur Plistosen hingga Holosen tersusun atas lava andesit–basalt, breksi gunungapi, tuf, dan aglomerat. Endapan

teras (Qtr) berumur Plistosen dijumpai dalam bentuk endapan kerakal, kerikil, pasir, dan lempung, sedangkan endapan sedimen kuartar (Qtse) yang juga berumur Plistosen terdiri atas konglomerat, batupasir, dan batulempung.

Pada satuan yang lebih tua, terdapat Formasi Hulusimpang (Tomh) berumur Oligosen–Miosen yang tersusun atas lava andesit–basalt, breksi gunungapi, tuf, serta sisipan batupasir tufan. Satuan batuan sedimen tersier (Tm) berumur Miosen terdiri atas batupasir, batulempung, konglomerat, serpih, dan batugamping. Selain itu, dijumpai intrusi granit tersier (Tmgr) berumur Miosen yang tersusun atas granit, granodiorit, dan diorit kuarsa, serta granit kapur (Kgr2) berumur Kapur Atas dengan litologi berupa granit, granodiorit, dan tonalit. Satuan tertua di daerah penelitian adalah Kompleks Metamorf (Pzg) berumur Paleozoikum yang tersusun atas sekis, filit, gneiss, kuarsit, serta berbagai jenis batuan metamorf lainnya.

2.2.2. Stratigrafi Batuan Ulubelu

Stratigrafi daerah penelitian berdasarkan Amin dkk. (2010) ditunjukkan pada Gambar 3. Umur batuan di daerah Ulubelu bervariasi mulai dari Paleozoikum hingga Holosen.



Gambar 3. Stratigrafi Batuan Pada Wilayah Ulubelu (Amin dkk., 2010).

1. Batuan Tertua (Paleozoikum - Mesozoikum)

Batuan tertua di daerah Ulubelu adalah kompleks metamorf (Pzg) berumur Paleozoikum yang terdiri dari sekis, filit, genes, kuarsit, dan batuan metamorf lainnya. Batuan ini merupakan batuan dasar (*basement*) yang tersingkap terbatas di bagian barat daya daerah penelitian. Pada periode Kapur Atas, terjadi intrusi batuan granit (Kgr2) berupa granit, granodiorit, dan tonalite yang menerobos kompleks metamorf Paleozoikum. Batuan intrusi ini merupakan bagian dari jalur plutonik Sumatera yang terbentuk akibat subduksi (McCourt dkk., 1996).

2. Batuan Tersier

Pada periode Tersier, terendapkan batuan sedimen (Tm) berumur Miosen yang terdiri dari batupasir, batulempung, konglomerat, serpih, dan batugamping. Formasi ini mencerminkan lingkungan pengendapan laut dangkal hingga transisi. Aktivitas vulkanisme dimulai pada Oligosen-Miosen dengan terbentuknya Formasi Hulusimpang (Tomh) yang terdiri dari lava andesit-basal, breksi gunungapi, tuf, dan sisipan batupasir tufan. Formasi ini berumur sekitar 19-20 juta tahun dan tersebar luas serta menjadi batuan dasar lokal (*local basement*) (Mulyanto dkk., 2015). Pada Miosen, terjadi intrusi batuan granit Tersier (Tmgr) berupa granit, granodiorit, dan diorit kuarsa yang menerobos formasi-formasi lebih tua.

3. Batuan Kwartir

Batuan Kwartir dimulai dengan endapan sedimen (Qtse) berumur Plistosen berupa konglomerat, batupasir, dan batulempung yang terendapkan di cekungan-cekungan. Terdapat pula endapan teras (Qtr) berupa kerakal, kerikil, pasir, dan lempung pada teras sungai yang mencerminkan aktivitas fluvial masa lampau. Aktivitas vulkanisme Kwartir menghasilkan batuan gunungapi (Qv) berumur Plistosen-Holosen berupa lava andesit-basal, breksi gunungapi, tuf, dan aglomerat. Batuan gunungapi muda (Qhv) berumur Holosen merupakan produk erupsi terkini dari gunungapi aktif seperti Gunung Ulubelu, terdiri dari lava, breksi, dan tuf. Endapan gunungapi muda sekunder (Qhvs) berumur Holosen terbentuk dari material vulkanik yang terendapkan kembali melalui proses lahar dan aliran piroklastik sekunder. Endapan termuda adalah aluvium (Qa) yang tersebar di dataran rendah, lembah sungai, dan daerah pantai.

III. TEORI DASAR

3.1. Gelombang Seismik

Gelombang seismik merupakan gelombang elastis berfrekuensi rendah yang dihasilkan oleh kejadian gempa bumi dan merambat melalui bagian dalam maupun permukaan bumi. Gelombang ini dapat dipicu oleh peristiwa patahan batuan yang terjadi secara tiba-tiba ataupun oleh aktivitas lain seperti ledakan (Sunarjo dkk., 2010). Bumi sebagai medium perambatan gelombang tersusun atas berbagai lapisan batuan yang memiliki sifat fisis yang berbeda satu sama lain. Perbedaan sifat fisis antar lapisan tersebut menyebabkan sebagian energi gelombang seismik dipantulkan, sementara sebagian lainnya diteruskan ke lapisan yang lebih dalam. Berdasarkan mekanisme perambatannya, gelombang utama yang dihasilkan oleh gempa bumi dapat diklasifikasikan menjadi dua jenis, yaitu gelombang badan (*body wave*) dan gelombang permukaan (*surface wave*).

3.1.1. Gelombang Badan

Gelombang badan merupakan gelombang seismik yang menjalar ke segala arah di dalam bumi. Berdasarkan gerak partikel pada media dan arah penjarannya, gelombang badan dibagi menjadi 2 macam yaitu.

1. Gelombang Primer (P)


Gelombang primer (P) merupakan gelombang longitudinal yang dicirikan oleh gerakan partikel medium yang sejajar dengan arah perambatan gelombang seperti ditunjukkan pada Gambar 4. gelombang P memiliki kecepatan rambat paling tinggi sehingga menjadi gelombang pertama yang terekam oleh seismograf (Sunarjo dkk., 2010). Kecepatan perambatan gelombang P bervariasi bergantung pada medium yang dilaluinya, yaitu berkisar antara 4-7

km/s pada lapisan kerak bumi, lebih dari 8 km/s pada mantel dan inti bumi, sekitar 1,5 km/s pada medium air, serta sekitar 0,3 km/s pada udara. Secara matematis, kecepatan penjalaran gelombang P dapat dinyatakan dengan Persamaan (1) (Kayal, 2008).

$$v_p = \sqrt{\frac{k + \frac{3}{4}\mu}{\rho}} \quad (1)$$

Keterangan:

- v_p : Kecepatan gelombang P (m/s)
- k : Modulus bulk (N/m²)
- μ : Modulus geser (N/m²)
- ρ : Kerapatan material yang dilalui gelombang (kg/m³)



Gambar 4. Perambatan gelombang primer (P) (Braile, 2010).

2. Gelombang Sekunder (S)


Gelombang sekunder (S) merupakan gelombang transversal yang ditandai oleh arah gerak partikel medium yang tegak lurus terhadap arah perambatan gelombang seperti ditunjukkan pada Gambar 5. Gelombang ini hanya dapat merambat melalui medium padat, karena medium cair dan gas tidak memiliki sifat elastis yang cukup untuk mempertahankan dan mengembalikan bentuk setelah mengalami deformasi. Berdasarkan arah gerak partikelnya, gelombang S dapat dibedakan menjadi dua komponen, yaitu gelombang SH dengan gerak partikel horizontal dan gelombang SV dengan gerak partikel vertikal. Gelombang S memiliki kecepatan rambat yang

lebih rendah sehingga terekam oleh seismograf setelah kedatangan gelombang P. Kecepatan perambatan gelombang S berkisar antara 3-4 km/s pada lapisan kerak bumi, lebih dari 4,5 km/s pada mantel bumi, serta sekitar 2,5-3 km/s pada bagian inti bumi (Sunarjo dkk., 2010). Secara matematis, kecepatan penjalaraan gelombang S dapat dinyatakan dengan Persamaan (2) (Kayal, 2008).

$$v_s = \sqrt{\frac{\mu}{\rho}} \quad (2)$$

Keterangan:

- v_s : Kecepatan gelombang S (m/s)
 μ : Modulus geser (N/m²)
 ρ : Kerapatan material yang dilalui gelombang (kg/m³)



Gambar 5. Perambatan gelombang sekunder (S) (Braile, 2010)


3.1.2. Gelombang Permukaan

Gelombang permukaan merupakan gelombang elastis yang merambat di sepanjang permukaan bumi dan sering disebut sebagai *tide waves*. Perambatan gelombang ini dibatasi oleh keberadaan permukaan bebas, sehingga gelombang permukaan hanya dapat menjalar mengikuti lapisan atau bidang permukaan tertentu. Berdasarkan karakteristik perambatannya, gelombang permukaan terdiri atas gelombang *Love* dan gelombang *Rayleigh* yang bergerak sepanjang permukaan bebas bumi (Sunarjo dkk., 2010). Gelombang permukaan umumnya memiliki frekuensi yang relatif rendah, namun amplitudonya cenderung besar akibat

pengaruh permukaan bebas, yaitu batas antara medium padat bumi dan udara yang diasumsikan sebagai ruang hampa. Kecepatan perambatan gelombang permukaan lebih rendah dibandingkan gelombang P namun efek getarannya lebih menyebabkan kerusakan. gelombang permukaan dibagi menjadi 2 macam yaitu

1. Gelombang *Love*


Gelombang *Love* terbentuk sebagai hasil interferensi dari gelombang-gelombang pantul gelombang SH yang terjadi pada lapisan batuan di dekat permukaan bumi. Gerakan partikel medium yang dilewati oleh gelombang *Love* menyerupai karakteristik gerak gelombang SH, namun amplitudo gelombangnya cenderung mengalami penurunan seiring dengan bertambahnya kedalaman. Pola perambatan gelombang *Love* ditunjukkan pada Gambar 6.



Gambar 6. Perambatan gelombang *love* (Braile, 2010)

2. Gelombang *Rayleigh*

Gelombang *Rayleigh* terbentuk akibat adanya interferensi antara gelombang pantul P dan SV yang datang dengan sudut melebihi sudut kritis. Partikel medium yang dilalui oleh gelombang *Rayleigh* bergerak membentuk lintasan elips sebagai hasil kombinasi gerak partikel gelombang P dan SV, dengan amplitudo yang semakin berkurang seiring bertambahnya kedalaman. Pola perambatan gelombang *Rayleigh* ditunjukkan pada Gambar 7.




Gambar 7. Perambatan gelombang *rayleigh* (Braile, 2010)

3.2. Metode *Microearthquake* (MEQ)

Metode *microearthquake* (MEQ) merupakan salah satu metode geofisika yang efektif karena memanfaatkan sumber gelombang seismik alami dengan karakteristik frekuensi rendah. (Haerudin dkk., 2019) menyatakan bahwa gelombang *microearthquake* memiliki kemiripan dengan gelombang seismik pada umumnya, karena mekanisme terjadinya berasal dari proses fisik yang sama. Perbedaan utama antara keduanya terletak pada besarnya frekuensi dan amplitudo. Gelombang *microearthquake* memiliki nilai yang jauh lebih kecil sehingga dampak yang ditimbulkan relatif tidak signifikan.

Metode *microearthquake* merekam sinyal getaran yang kemudian diinterpretasikan sebagai kejadian seismik berupa gempa mikro pada suatu wilayah tertentu. Metode ini mendeteksi gelombang getaran yang dihasilkan oleh sumber gempa dengan magnitudo kurang dari 3 M. Prinsip dasar pengukuran *microearthquake* adalah menangkap dan merekam sinyal getaran tersebut untuk selanjutnya dianalisis sebagai peristiwa seismik (Halim dkk., 2020). Data gelombang gempa mikro yang diperoleh dari sensor pada pengukuran metode *microearthquake* umumnya direkam dalam tiga komponen utama, yaitu dua komponen horizontal dengan orientasi utara-selatan dan timur-barat, serta satu komponen vertikal yang menggambarkan arah kedalaman seperti diperlihatkan pada Gambar 8.



Gambar 8. Tiga komponen gelombang gempa mikro (Hurukawa, 2008)

Metode *microearthquake* (MEQ) dapat diaplikasikan dalam studi panas bumi baik pada tahap eksplorasi maupun tahap produksi. Pada fase eksplorasi, metode *microearthquake* dimanfaatkan untuk mengidentifikasi keberadaan retakan atau sesar aktif yang berpotensi memiliki porositas dan permeabilitas tinggi. Selain itu, metode ini juga digunakan untuk memperkirakan zona prospek panas bumi serta membantu dalam penentuan lokasi pengeboran.


Pada tahap produksi, pemantauan pola kejadian gempa mikro yang berkaitan dengan aktivitas reinjeksi fluida memungkinkan evaluasi karakteristik pengisian kembali (*recharge*) pada sistem rekahan di dalam reservoir. Informasi mengenai perilaku reinjeksi ini penting dalam kegiatan pemeliharaan dan monitoring reservoir guna mencegah terjadinya ketidakseimbangan distribusi fluida yang dapat berdampak pada penurunan kinerja produksi panas bumi (Hilyah, 2010). Tabel 1 menunjukkan klasifikasi gempa bumi berdasarkan besar kecil magnitudonya.

Tabel 1. Klasifikasi gempa berdasarkan magnitudo (Hurukawa, 2008).

Besar Magnitudo	Klasifikasi Gempa
$M \geq 7$	Gempa Besar
$M < 7$	Gempa Menengah
$M < 5$	Gempa Kecil
$M < 3$	Gempa Mikro
$M < 1$	Gempa Ultra Mikro

3.3. Diagram Wadati

Metode Diagram Wadati merupakan pendekatan yang digunakan untuk mengevaluasi hubungan antara waktu tiba gelombang P dan gelombang S. Diagram ini terbentuk dengan memplot selisih waktu tiba gelombang S dan P ($T_s - T_p$) terhadap waktu tiba gelombang P (T_p) pada beberapa stasiun pengamatan. Metode ini mengasumsikan bahwa medium penjalaran gelombang bersifat homogen atau memiliki rasio V_p/V_s yang relatif konstan, sehingga hubungan antara parameter waktu tiba tersebut membentuk pola linier. Selain digunakan untuk menentukan waktu asal gempa (*origin time*) (T_0), Diagram Wadati juga dapat dimanfaatkan untuk mengevaluasi kualitas hasil *picking* manual gelombang P dan S melalui estimasi rasio kecepatan gelombang V_p/V_s .



Gambar 9. Diagram Wadati (Hurukawa, 2008)

Gambar 9 merupakan gambar dari Diagram Wadati, sumbu horizontal menunjukkan waktu tiba gelombang P (T_p), sedangkan sumbu vertikal menunjukkan selisih waktu tiba gelombang S dan P ($T_s - T_p$). Titik-titik data hasil pengamatan kemudian didekati menggunakan garis regresi linier. Kemiringan garis regresi tersebut dinyatakan sebagai:

$$\tan \theta = \frac{V_p}{V_s} - 1 \quad (3)$$

S

dengan θ merupakan sudut kemiringan garis regresi. Nilai titik potong garis terhadap sumbu T_p menunjukkan nilai *origin time* (T_o), yaitu waktu awal terjadinya gempa pada hiposenter. Hubungan pada Diagram Wadati dinyatakan dalam Persamaan (4).

$$\frac{V_p}{V_s} - 1 = \frac{T_s - T_p}{T_p - T_o} \quad (4)$$

sehingga *origin time* dapat diperoleh melalui persamaan (5).

$$T_o = T_p - \frac{T_s - T_p}{\left(\frac{V_p}{V_s} - 1\right)} \quad (5)$$

Keterangan:

T_p : Waktu tiba gelombang P (detik)

T_s : Waktu tiba gelombang S (detik)

T_o : *Origin time* atau waktu awal terjadinya gempa pada hiposenter (detik)

V_p : Kecepatan rambat gelombang P (km/s)

V_s : Kecepatan rambat gelombang S (km/s)

$\tan \theta$: Gradien atau kemiringan garis regresi pada Diagram Wadati

3.4. Machine Learning

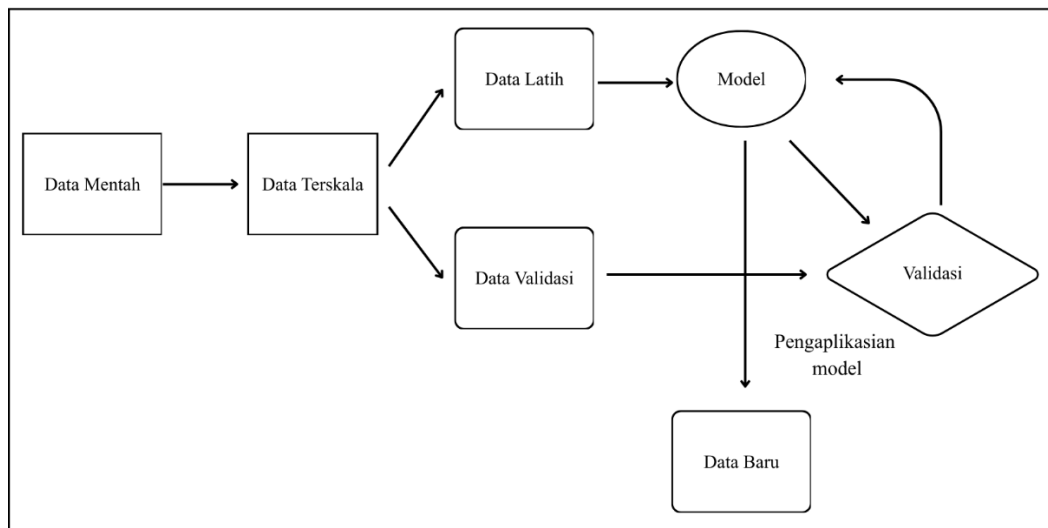
Machine learning merupakan salah satu cabang dari kecerdasan buatan yang secara khusus berkembang dalam bidang ilmu komputer. Bidang ini mempelajari sistem dan algoritma yang dirancang untuk mampu mempelajari pola dari data serta memperbarui pengetahuannya seiring dengan tersedianya informasi baru. Secara

konseptual, proses pembelajaran pada *machine learning* memungkinkan suatu sistem untuk meningkatkan kinerjanya berdasarkan pengalaman yang diperoleh dari data sebelumnya, sehingga dapat menghasilkan keluaran yang semakin mendekati hasil yang diharapkan.

Kemampuan sistem berbasis *machine learning* dalam meningkatkan performa pada suatu tugas tertentu sangat bergantung pada kemampuannya dalam mengenali pola yang terdapat pada data. Proses ini dikenal sebagai *pattern recognition* yang menjadi pondasi utama dalam pengembangan berbagai teknik *machine learning* dan merupakan aspek terpenting dalam kecerdasan buatan (Sarno dkk., 2023). Berdasarkan mekanisme pembelajarannya, *machine learning* secara umum dapat diklasifikasikan ke dalam beberapa tipe, yaitu.

3.4.1. Supervised Learning

Supervised learning merupakan salah satu pendekatan *machine learning* yang paling umum digunakan. Pada metode ini, sistem dilatih menggunakan sekumpulan data contoh yang disebut sebagai data pelatihan. Setiap data masukan telah dilengkapi dengan label keluaran yang sesuai. *Supervised learning* dapat diterapkan pada permasalahan regresi dan prediksi kontinu (Sarno dkk., 2023), termasuk dalam pemodelan probabilistik untuk penentuan waktu kedatangan gelombang seismik. Dalam konteks ini, data pelatihan biasanya direpresentasikan sebagai pasangan terurut $(X_1, Y_1), \dots, (X_n, Y_n)$, X_i menyatakan vektor masukan atau fitur, sedangkan Y_i merepresentasikan target keluaran yang diharapkan yang dapat berupa nilai diskrit maupun fungsi kontinu, tergantung pada permasalahan yang dimodelkan. Alur skema metode *supervised learning* dapat ditunjukkan pada Gambar 10.



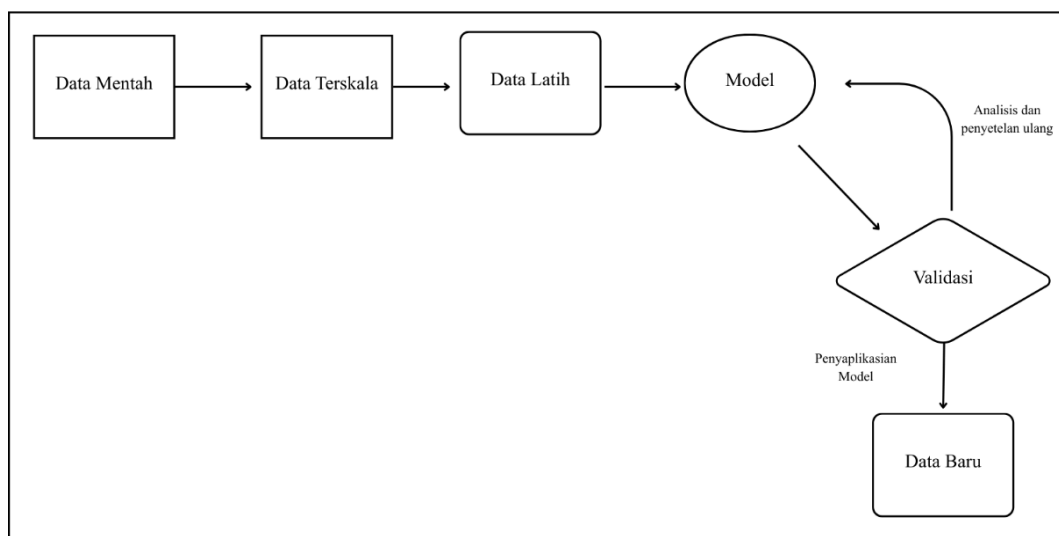
Gambar 10. Skema metode *supervised learning*

Sebagian besar algoritma *supervised learning* dilatih dengan cara meminimalkan suatu fungsi kerugian (*loss function*) yang merepresentasikan tingkat kesalahan antara keluaran sistem dan nilai keluaran yang diinginkan. Fungsi kerugian yang umum digunakan antara lain fungsi yang menghitung deviasi atau selisih antara hasil prediksi dan nilai target (Akhtar dkk., 2025). Setelah proses pelatihan selesai, kinerja model dievaluasi menggunakan sekumpulan data terpisah yang tidak digunakan selama pelatihan yang dikenal sebagai data validasi. Tahap ini bertujuan untuk menguji kemampuan generalisasi model, yaitu sejauh mana model mampu menghasilkan prediksi yang benar terhadap data baru yang belum pernah dilihat sebelumnya (Khalili dkk., 2023).

3.4.2. *Unsupervised Learning*

Pada pendekatan *unsupervised learning*, data pelatihan yang digunakan tidak disertai dengan label kelas. Dalam kondisi ini, sistem secara mandiri mempelajari struktur data dengan cara mengorganisasi dan merepresentasikan informasi berdasarkan pola yang terbentuk dari data itu sendiri. Algoritma *unsupervised learning* umumnya diterapkan pada permasalahan pengelompokan (*clustering*) yang pada sekumpulan data masukan tersedia tanpa adanya informasi awal mengenai kelas, jumlah kelas, maupun karakteristik kelas yang mungkin terbentuk. Pada situasi seperti ini, pendekatan *supervised learning* tidak dapat diterapkan

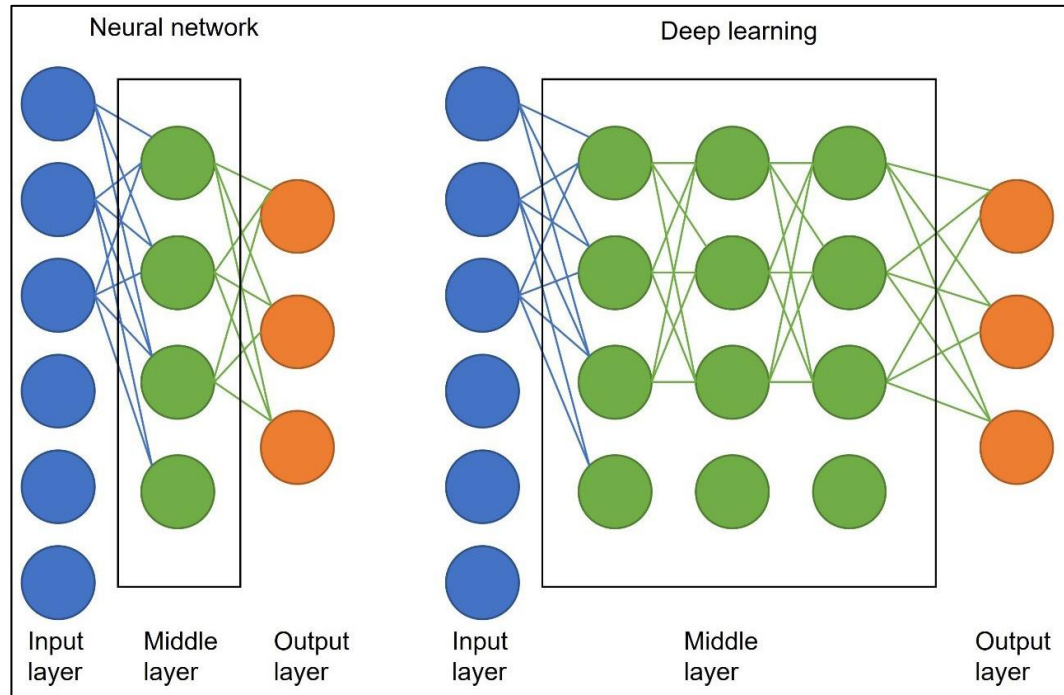
karena informasi mengenai label atau jumlah kelas tidak diketahui sebelumnya (Sarno dkk., 2023). Alur skema metode *supervised learning* dapat ditunjukkan pada Gambar 11.



Gambar 11. Skema metode *unsupervised learning*

3.5. Deep Learning

Deep learning (DL) merupakan salah satu cabang dari *machine learning* yang berfokus pada pembelajaran representasi data secara bertingkat melalui pembentukan hierarki fitur. Pada pendekatan ini, fitur tingkat tinggi dibangun dari kombinasi fitur tingkat yang lebih rendah. Satu fitur pada level rendah dapat berkontribusi dalam pembentukan berbagai fitur pada level yang lebih tinggi. Arsitektur *deep learning* merupakan pengembangan dari jaringan saraf tradisional (*neural network*) dengan menambahkan sejumlah lapisan tersembunyi diantara lapisan *input* dan *output* sehingga mampu memodelkan hubungan data yang kompleks dan bersifat non linier (Mohsen dkk., 2018). Gambar 12 menunjukkan perbedaan antara *neural network* sederhana dengan *deep learning*



Gambar 12. Perbedaan antara *neural network* dengan *deep learning* (Ryu dkk., 2021)

3.6. *Truncated Gaussian*

Truncated Gaussian merupakan fungsi *Gaussian* yang digunakan dalam proses pelabelan data latih untuk merepresentasikan waktu kedatangan fase gelombang yang dibatasi pada interval waktu tertentu, sehingga nilai fungsi di luar batas tersebut dianggap nol. Pendekatan ini digunakan untuk merepresentasikan ketidakpastian temporal dari hasil *manual picking* serta untuk memformulasikan proses *phase picking* sebagai permasalahan segmentasi waktu (*temporal segmentation*) (Park dkk., 2025). Secara matematis, *Truncated Gaussian* dapat dinyatakan sebagai Persamaan (6).


$$G(t) = \begin{cases} \exp\left(-\frac{(t - \mu)^2}{2\sigma^2}\right), & |t - \mu| \leq \Delta \\ 0, & |t - \mu| > \Delta \end{cases} \quad (6)$$

Keterangan:

- $G(t)$: Nilai kernel *Gaussian* pada waktu ke- t
 μ : Waktu kedatangan fase gelombang
 σ : Simpangan baku lebar kernel
 Δ : Batas *truncation gaussian*
 t : Waktu

3.7. Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan salah satu arsitektur *deep learning* yang dirancang untuk mengekstraksi fitur lokal dari data yang memiliki struktur spasial atau spasio-temporal. Data seismogram dapat direpresentasikan dalam bentuk matriks dua dimensi yang mencerminkan hubungan antara dimensi waktu dan *channel* atau fitur sinyal. Representasi ini dapat memungkinkan CNN untuk memanfaatkan operasi konvolusi dua dimensi guna menangkap pola lokal dan korelasi antar-sampel waktu serta antar-*channel* sinyal. Dengan demikian, CNN mampu mengekstraksi karakteristik dari gelombang seismik, seperti perubahan amplitudo, pola *onset*, dan struktur *waveform* yang menjadi aspek penting untuk proses *arrival time picking*. Penggunaan CNN dalam pemrosesan data gelombang dapat menangani sinyal yang bersifat kompleks dan data dengan *noise* yang tinggi, karena lapisan konvolusi berperan sebagai *feature extractor* otomatis yang tidak bergantung pada perancangan fitur secara manual (Zhu & Beroza, 2018).



Gambar 13. Arsitektur MLP Sederhana (Oswald dkk., 2022)

Gambar 13 memperlihatkan arsitektur *Multilayer Perceptron* (MLP) yang terdiri atas sejumlah lapisan pada setiap lapisan tersusun atas beberapa *neuron*. MLP menerima data masukan dalam bentuk satu dimensi yang kemudian dipropagasikan melalui jaringan hingga menghasilkan keluaran. Setiap *neuron* pada suatu lapisan terhubung dengan *neuron* pada lapisan berikutnya melalui parameter bobot yang berperan dalam menentukan kinerja model. Proses pemrosesan data pada MLP diawali dengan operasi linear menggunakan bobot tersebut, kemudian hasilnya ditransformasikan melalui fungsi non linier yang dikenal sebagai fungsi aktivasi (Oswald dkk., 2022).

Berbeda dengan MLP, pada Arsitektur *Convolutional Neural Network* (CNN) tersusun atas beberapa komponen utama yang saling terintegrasi dalam proses ekstraksi, pengolahan, dan representasi fitur dari data masukan. Setiap komponen memiliki fungsi dan peran yang berbeda dalam menentukan kemampuan model untuk mempelajari pola data. Komponen-komponen utama yang digunakan dalam arsitektur CNN meliputi.


3.7.1. Convolution Layer

Konvolusi merupakan salah satu bentuk operasi linear khusus yang digunakan dalam *Convolutional Neural Network* (CNN) untuk mengekstraksi fitur dari data masukan. Pada proses ini, sebuah kernel berupa matriks berisi nilai numerik diaplikasikan secara lokal pada *tensor input* yang direpresentasikan sebagai matriks seismogram dengan dimensi waktu dan *channel* sinyal. Nilai keluaran pada setiap posisi diperoleh dari hasil perkalian elemen kernel dengan elemen input yang bersesuaian, kemudian dijumlahkan untuk membentuk *feature map*. Proses ini dilakukan secara berulang dengan menggeser kernel sepanjang dimensi temporal data, sehingga diperoleh *feature map* yang merepresentasikan karakteristik lokal sinyal seismik, seperti perubahan amplitudo dan pola *onset* gelombang. Ilustrasi dari operasi konvolusi seperti pada Gambar 14. Penggunaan ukuran kernel yang berbeda memungkinkan model mengekstraksi fitur pada skala temporal yang berbeda sehingga berpengaruh terhadap jenis fitur yang dihasilkan (Sarno dkk., 2023). Proses propagasi konvolusi secara matematis ditunjukkan pada Persamaan (7).

$$a_{ij}^{(k)} = \sum_{s=0}^{m-1} \sum_{t=0}^{n-1} W_{st}^k x_{(i+s)(j+t)} + b^k \quad (7)$$

Keterangan:

- x : Nilai *input*
 a^k : Konvolusi setelah
 k : Indeks kernel
 W : Kernel (filter bobot)
 b : Bias



Gambar 14. Ilustrasi operasi konvolusi pada CNN 1D (Shenfield & Howarth, 2020).

3.7.2. Batch Normalization

Batch Normalization merupakan salah satu teknik yang digunakan dalam pelatihan jaringan saraf berlapis untuk menormalkan data masukan pada setiap lapisan berdasarkan *mini-batch*. Penerapan *layer* ini mampu meningkatkan

stabilitas proses pembelajaran serta mempercepat konvergensi model, sehingga pelatihan jaringan dapat dicapai dengan jumlah *epoch* yang lebih sedikit dibandingkan tanpa normalisasi (Singh dkk., 2021).

3.7.3. Dropout Layer

Dropout layer merupakan teknik regularisasi pada jaringan saraf tiruan yang bekerja dengan menonaktifkan *neuron* secara acak selama proses pelatihan. Setiap *neuron* hanya diaktifkan dengan nilai probabilitas tertentu, sehingga jaringan tidak bergantung pada kombinasi *neuron* tertentu dan secara efektif melatih banyak sub-jaringan yang berbeda. Fungsi utama *dropout* adalah mengurangi *overfitting* dengan mencegah ketergantungan *neuron* antar *neuron* sehingga model menjadi lebih mampu melakukan generalisasi, lebih *robust* terhadap pola yang lebih kompleks, dan menghasilkan performa yang baik pada data baru (Srivastava dkk., 2014).


3.8. Fungsi Aktivasi

Fungsi aktivasi merupakan suatu operasi matematis yang diterapkan pada sinyal keluaran *neuron* dalam jaringan saraf. Fungsi ini berperan dalam menentukan tingkat keaktifan suatu *neuron* berdasarkan hasil kombinasi bobot dan data masukan yang diterima. Penggunaan fungsi aktivasi memungkinkan jaringan saraf memodelkan hubungan non linier dalam data. Beberapa fungsi aktivasi yang umum digunakan pada *Convolutional Neural Network* (CNN) antara lain *tanh*, *Rectified Linear Unit* (ReLU), *sigmoid*, dan *softmax*, pada penelitian ini digunakan fungsi aktivasi berupa *Rectified Linear Unit* (ReLU) dan *Sigmoid* (Dzulqarnain dkk., 2019).

3.8.1. ReLU

Fungsi aktivasi *Rectified Linear Unit* (ReLU) merupakan fungsi aktivasi yang menghasilkan nilai keluaran nol ketika masukan bernilai negatif. Sebaliknya, apabila nilai masukan bersifat positif, keluaran *neuron* akan sama dengan nilai masukan tersebut. Secara matematis, karakteristik fungsi ReLU dapat dinyatakan melalui Persamaan (8) dan Gambar 15 menunjukkan bentuk kurva fungsi ReLU.

$$f(x) = \max(0, x) \quad (8)$$



Gambar 15. Bentuk kurva fungsi aktivasi ReLU (Sarno dkk., 2023)


3.8.2. Sigmoid

Fungsi aktivasi *sigmoid* merupakan salah satu fungsi non linier yang umum digunakan dalam jaringan saraf dengan keluaran yang dibatasi pada rentang nilai antara 0 dan 1. Karakteristik ini menyebabkan *sigmoid* sering digunakan untuk memodelkan tingkat aktivasi *neuron*, nilai keluaran yang mendekati 1 menunjukkan *neuron* berada dalam kondisi aktif, sedangkan nilai keluaran yang mendekati 0 merepresentasikan *neuron* yang tidak aktif. Secara matematis, fungsi sigmoid memiliki bentuk kurva menyerupai huruf S (*S-shaped curve*) seperti ditunjukkan pada Gambar 16. Adapun persamaan 9 merupakan persamaan dari fungsi *sigmoid*, e merupakan epsilon (Sarno dkk., 2023).

$$\psi(x) = \frac{1}{1 + e^{-x}} \quad (9)$$

Keterangan:

- $\psi(x)$: Nilai keluaran fungsi *sigmoid*
- x : Nilai masukan neuron
- e : bilangan eksponensial (bilangan *Euler*)



Gambar 16. Bentuk kurva fungsi aktivasi sigmoid (Sarno dkk., 2023)

3.9. Mean Absolute Error (MAE)

Mean Absolute Error (MAE) adalah rata-rata dari nilai absolut dari kesalahan (gap) antara nilai aktual dan nilai prediksi. Kesalahan absolut mengacu pada nilai perbedaan tanpa memperhatikan tanda positif atau negatif Secara matematis. MAE dapat dinyatakan dalam persamaan (10) (Chai & Draxler, 2014).

$$MAE = \frac{1}{n} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (10)$$

Keterangan:

- y_i = Nilai target
- \hat{y}_i = Nilai prediksi
- n = Jumlah sampel

3.10. Confusion Matrix

Confusion matrix adalah metrik perhitungan yang digunakan untuk mengevaluasi kinerja suatu model yang membandingkan hasil prediksi model dengan nilai sebenarnya dalam dataset pengujian. Pada penelitian ini *confusion matrix* yang digunakan yaitu *True Positive* (TP) dengan menunjukkan prediksi

onset gelombang tiba yang benar dan berada dalam batas toleransi, *False Positive* (FP), prediksi yang salah atau meleset dari toleransi, sedangkan *False Negative* (FN) adalah *event* yang tidak berhasil terdeteksi oleh model. Berdasarkan *confusion matrix*, berbagai metrik evaluasi seperti, *precision*, *recall*, dan metrik lainnya dapat dihitung untuk menilai kinerja model (L. Hakim dkk., 2025).

Precision yaitu proporsi dari prediksi positif yang benar terhadap total jumlah prediksi positif. Ini mengukur seberapa banyak dari hasil yang diprediksi sebagai positif yang sebenarnya benar positif. Secara matematis, *Precision* dapat dinyatakan dalam persamaan (11).

$$Presisi = \frac{TP}{TP + FP} \quad (11)$$

Recall (*Sensitivity* atau *True Positive Rate*) adalah ukuran yang menunjukkan perbandingan antara jumlah data positif yang berhasil diprediksi dengan benar dan total seluruh data yang benar-benar termasuk dalam kelas positif. Metrik ini menggambarkan kemampuan model dalam mendeteksi seluruh kasus positif. Secara matematis, *recall* dapat dinyatakan dalam persamaan (12).

$$Recall = \frac{TP}{TP + FN} \quad (12)$$

F1-Score merupakan nilai rata-rata antara *precision* dan *recall* yang digunakan untuk menyeimbangkan kedua metrik tersebut. Secara matematis, *F1-Score* dapat dinyatakan dalam persamaan (13).

$$F1 - Score = 2x \frac{Precision \times Recall}{Precision + Recall} \quad (13)$$

IV. METODE PENELITIAN

4.1. Waktu dan Tempat Penelitian

Penelitian ini dilaksanakan pada waktu dan lokasi sebagai berikut.

Waktu : Januari 2026 – Mei 2026

Tempat : Laboratorium Instrumentasi Geofisika Jurusan Teknik
Geofisika, Fakultas Teknik, Universitas Lampung

Alamat : Jalan Prof. Dr. Soemantri Brojonegoro No.1, Gedong Meneng,
Kec. Rajabasa, Kota Bandar Lampung, Lampung 35141

Adapun penjelasan lebih detail terkait waktu dan agenda penelitian, terdapat pada Tabel 2 berikut.

Tabel 2. Jadwal kegiatan penelitian

Kegiatan	Januari				Februari				Maret				April				Mei	
	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2
Studi Literatur	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■	■
Desain Akuisisi	■	■	■	■	■													
Bimbingan Proposal	■	■																
Penyusunan Proposal	■	■	■	■														
Seminar Proposal				■														
Persiapan Alat				■	■	■												
Pemasangan Alat						■												
Pengolahan Data dan Pembuatan Model						■	■	■	■	■	■	■	■	■	■	■		
Penyusunan Hasil													■	■	■	■		
Bimbingan Hasil													■	■	■	■		
Seminar Hasil																■		
Revisi Hasil																■	■	■
Sidang Komprehensif																		■

4.2. Alat dan Bahan

Adapun alat dan bahan yang digunakan dalam penelitian ini terdapat pada Tabel 3 dan Tabel 4.

Tabel 3. Data yang digunakan dalam penelitian

No.	Jenis Data	Sumber dan Fungsi Data
1.	Data Seismogram Gempa Lokal (STEAD)	Data ini berupa kumpulan dataset gempa yang disusun oleh (Mousavi dkk., 2019) sebagai data latih penelitian ini.
2.	Data Seismogram gempa mikro PiGraf	Data ini didapatkan dari hasil pengukuran pada lapangan panas bumi.

Tabel 4. Peralatan yang digunakan dalam penelitian

No.	Hardware/Software	Fungsi
1.	Laptop	Perangkat utama untuk mengoperasikan seluruh <i>software</i> pemrosesan dan penyusunan <i>model</i>
2.	Seismograf PiGraf	Merekam sinyal mikroseismik pada lapangan panas bumi sehingga memperoleh data gempa mikro
3.	<i>Logbook</i> (Buku Catatan Lapangan)	Mencatat informasi dan kondisi lapangan selama proses akuisisi data
4.	Kamera/ <i>Handphone</i>	Mendokumentasikan kondisi lokasi pengukuran
5.	<i>Software SeisGram2K</i>	Membaca dan menganalisis gelombang datang dari data gempa mikro
6.	<i>Google Colab</i>	<i>Platform</i> berbasis <i>cloud</i> yang digunakan untuk penyusunan model dengan bahasa <i>python</i> dan pelatihan <i>model</i> (CNN), serta evaluasi kinerja sistem <i>auto picking</i> .
7.	<i>Software Qgis</i>	Membuat peta wilayah penelitian

8. *Software Ms. Office 2021* Menyusun, mengolah, dan mengatur dokumen laporan penelitian, termasuk penulisan naskah skripsi, penyusunan data pengukuran, pembuatan tabel, grafik, dan presentasi hasil penelitian
-

4.3. Prosedur Penelitian

Adapun prosedur pengolahan data yang dilakukan pada penelitian ini adalah sebagai berikut.

4.3.1. Uji Kalibrasi Alat

Uji kalibrasi alat dilakukan untuk mengevaluasi kemampuan seismograf PiGraf dalam merekam sinyal getaran. Tahapan ini menjadi langkah awal untuk memastikan kualitas data seismogram hasil perekaman alat. Proses kalibrasi dilakukan dengan menempatkan beberapa unit PiGraf pada satu lintasan pengukuran dengan jarak antar alat sejauh 3 meter. Sumber getaran yang digunakan berupa sumber aktif, yaitu pukulan palu pada plat besi. Sumber getaran ditempatkan di ujung lintasan dengan jarak sekitar satu meter dari alat pertama. Kalibrasi dianggap berhasil apabila sinyal gelombang pertama yang tiba terekam terlebih dahulu oleh sensor yang posisinya paling dekat dengan sumber getaran yang kemudian diikuti oleh sensor-sensor berikutnya sesuai urutan jarak terhadap sumber.

4.3.2. Studi Literatur dan Desain Akuisisi

Studi literatur dilakukan untuk memahami mengenai penerapan metode *Convolutional Neural Network* (CNN) pada penentuan waktu kedatangan gelombang P dan S secara otomatis (*auto picking*). Studi ini mencakup kajian terhadap konsep dasar CNN, arsitektur jaringan yang umum digunakan, teknik pelabelan data, serta metode evaluasi performa model. Studi literatur juga bertujuan untuk menelaah sejauh mana CNN telah diaplikasikan pada data seismik dan data seismogram dengan tingkat rasio *signal-to-noise* yang rendah, sehingga dapat dijadikan dasar dalam perancangan model CNN yang sesuai dengan karakteristik data PiGraf.

Beberapa studi menegaskan bahwa pendekatan berbasis *deep learning* dapat meningkatkan konsistensi hasil *picking* dan mengurangi subjektivitas interpretasi terutama pada data gempa mikro dengan amplitudo kecil dan *noise* yang relatif tinggi (Mousavi dkk., 2019; Rossi dkk., 2020; Zhu & Beroza, 2018) Selain itu, desain akuisisi disusun untuk memperoleh rekaman seismogram yang representatif terhadap aktivitas gempa mikro di area panas bumi, dengan mempertimbangkan distribusi stasiun pengukuran, jarak antar stasiun, serta cakupan area pengamatan. Desain akuisisi direncanakan dengan menempatkan beberapa stasiun PiGraf yang tersebar di sekitar area lapangan panas bumi yang telah beroperasi.

4.3.3. Akuisisi Data

Tahapan akuisisi data dilakukan di Lapangan Panas bumi Ulubelu dengan menggunakan seismograf PiGraf yang dipasang pada sebanyak 10 stasiun pengukuran. Setiap stasiun dirancang untuk merekam kejadian gempa mikro yang terjadi di area panas bumi, sehingga diperoleh data seismogram yang merepresentasikan aktivitas mikroseismik di wilayah penelitian.

Sebelum proses perekaman dimulai, terlebih dahulu dilakukan instalasi seluruh stasiun PiGraf di lokasi pengukuran yang telah ditentukan. Setelah seluruh stasiun terpasang dan berfungsi dengan baik, akuisisi data dilakukan selama kurang lebih satu bulan. Pada setiap stasiun pengukuran, perangkat PiGraf ditempatkan pada kedalaman sekitar 70 sentimeter di dalam casing pelindung seperti ditunjukkan pada Gambar 17.



Gambar 17. Casing alat PiGraf

Casing ini berfungsi untuk melindungi alat dari rembesan air dan gangguan eksternal lainnya. Bagian dasar casing dibuat dari beton untuk mempermudah proses *levelling* alat serta untuk meningkatkan akurasi antara sensor dan medium tanah sehingga perambatan gelombang seismik menuju sensor dapat direkam secara optimal. Setiap stasiun PiGraf dilengkapi dengan modem untuk mendukung pengiriman data secara jarak jauh serta panel surya sebagai sumber catu daya utama seperti ditunjukkan pada Gambar 18.



Gambar 18. Stasiun PiGraf dengan panel surya

4.3.4. Pengolahan Data

Pengolahan data pada penelitian ini diawali dengan proses identifikasi kejadian gempa mikro (MEQ), pemilihan *event* gempa mikro diikuti dengan proses penentuan waktu kedatangan gelombang P dan gelombang S secara manual. Informasi waktu kedatangan gelombang P dan S yang diperoleh dari proses *picking manual* tersebut kemudian disimpan dan digunakan sebagai label validasi dalam evaluasi hasil prediksi model CNN. Rangkaian tahapan pengolahan data yang dilakukan pada penelitian ini diuraikan lebih lanjut sebagai berikut.

1. Pengunduhan data

Tahapan awal dalam proses pengolahan data pada penelitian ini diawali dengan pengambilan data hasil perekaman. Data tersebut diperoleh melalui *web server* PiGraf yang menyimpan seluruh rekaman seismogram dari masing-masing stasiun pengukuran. Antarmuka PiGraf *web server* yang digunakan dalam proses pengunduhan data ditampilkan pada Gambar 19.

PiGraf Files
Copyright © 2023 by Way Ratul Research Team - University of Lampung

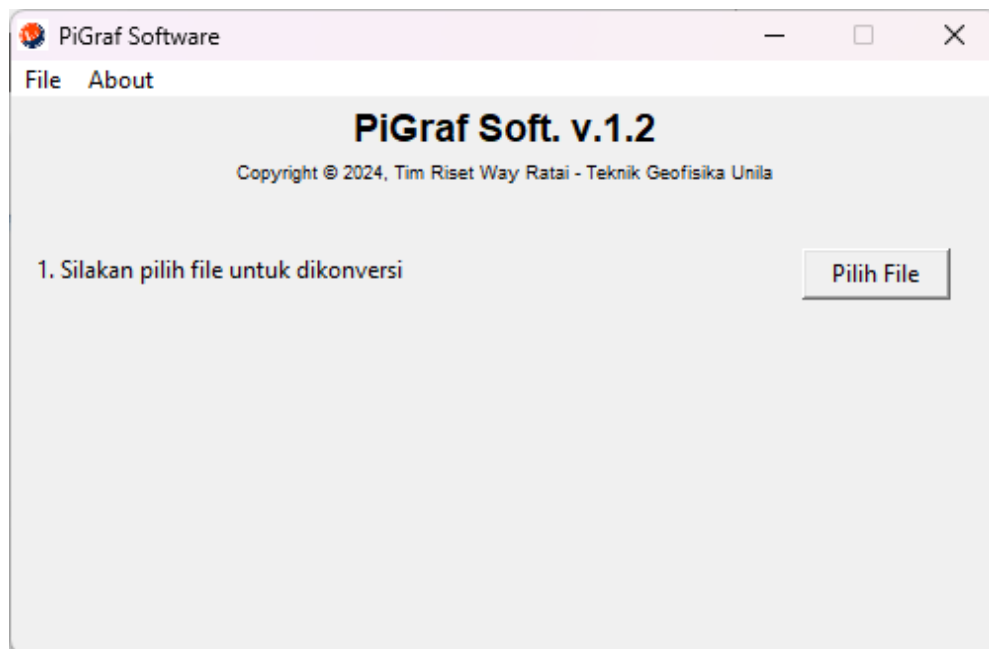
Filename	Last Modified	Filesize	Download	Delete
PG_Z2W01_20230720131232819.bin	2023-07-20 13:13:03	44.05 KB	Download	Delete
PG_Z2W01_20230716131443038.bin	2023-07-16 13:16:27	124.13 KB	Download	Delete
PG_Z2W01_20230716000009714.bin	2023-07-16 09:38:25	41.62 MB	Download	Delete
PG_Z2W01_20230715000008646.bin	2023-07-16 00:00:01	102.31 MB	Download	Delete
PG_Z2W01_20230714000011371.bin	2023-07-15 00:00:00	104.07 MB	Download	Delete
PG_Z2W01_20230713000011091.bin	2023-07-14 00:00:03	101.17 MB	Download	Delete
PG_Z2W01_20230712000010243.bin	2023-07-13 00:00:03	99.42 MB	Download	Delete
PG_Z2W01_20230711000010758.bin	2023-07-12 00:00:02	101.77 MB	Download	Delete
PG_Z2W01_20230710000010945.bin	2023-07-11 00:00:02	105.37 MB	Download	Delete
PG_Z2W01_20230709105648099.bin	2023-07-10 00:00:02	57.54 MB	Download	Delete

1 2 3 4 5 Next >>

Gambar 19. Tampilan *web server* pigraf

2. Konversi Data *Waveform* .bin ke .mseed dan .sac

Proses pengonversian data seismogram yang sebelumnya masih dalam format .bin diubah menjadi mseed dan sac dilakukan menggunakan *software* PiGrafSoft_v1.2.exe, Gambar 20 merupakan tampilan beranda dari *software* PiGrafSoft_v1.2.exe.



Gambar 20. Tampilan beranda *software* PiGrafSoft_v1.2.exe

3. Pemilihan *Event* dan *Picking* Waktu Tiba Gelombang P & S

Data hasil perekaman yang telah dikonversi formatnya menggunakan *software* PiGraf_v1.2, selanjutnya diproses melalui tahapan pemilihan *event* dan penentuan waktu kedatangan gelombang P dan S. Pemilihan *event* dilakukan secara manual dengan meninjau keseluruhan rekaman seismogram dari 10 pengukuran selama periode satu bulan akuisisi. *Event* gempa mikro yang dipilih merupakan kejadian yang terekam oleh minimal 3 stasiun. Tahapan ini menghasilkan informasi waktu kedatangan gelombang P dan S pada masing-masing stasiun, serta selisih waktu kedatangan antara kedua fase gelombang tersebut untuk setiap *event* yang teridentifikasi. Informasi waktu kedatangan gelombang P dan S disimpan dan digunakan sebagai label validasi dalam evaluasi hasil prediksi model CNN.

4.3.5. Perancangan dan Pelatihan Model

Tahapan perancangan dan pelatihan model diawali dengan pengunduhan dan penyusunan dataset, pra-pemrosesan data seismogram, pelabelan waktu kedatangan gelombang P dan S menggunakan pendekatan *truncated Gaussian*, pembagian dataset, perancangan arsitektur model CNN dan evaluasi performa model CNN. Tahapan perancangan dan pelatihan model pada penelitian ini adalah sebagai berikut.

1. Pengunduhan Data

Tahap awal dari perancangan dan pelatihan model yaitu pengunduhan data. Data yang dibutuhkan adalah data seismogram yang digunakan sebagai data latih model dan sebagai data uji generalisasi pada saat model sudah terlatih. Adapun data yang digunakan pada penelitian ini didapatkan dari data seismogram *open source STanford Earthquake Dataset (STEAD)*. Sumber data ini sudah dilengkapi dengan label dalam format waktu tiba gelombang P dan S.

2. Penyusunan dataset

Pada tahap ini, data seismogram yang telah diekstraksi, dikonversi ke dalam format *Comma Separated Values (CSV)* untuk memudahkan proses pelatihan model CNN. Susunan data pada CSV ditunjukkan pada Tabel 5 yang terdiri atas kolom “sec” sebagai representasi waktu relatif sejak awal perekaman dalam satuan detik, kolom “E”, “N”, dan “Z” yang masing-masing merepresentasikan nilai amplitudo sinyal dari tiga komponen sensor seismograf, kolom “p_arrival” dan “s_arrival” yang berisi informasi waktu kedatangan gelombang P dan gelombang S dalam satuan detik sebagai label acuan.

Tabel 5. Susunan data seismogram yang telah dikonversi

sec	E	N	Z	p_arrival	s_arrival
0	0	0	0	7	12.95
0.01	-0.0115	-0.0078	-0.0201	7	12.95
0.02	-0.0421	-0.0327	-0.0476	7	12.95
0.03	-0.089	-0.0851	-0.1105	7	12.95
0.04	-0.0968	-0.139	-0.104	7	12.95
0.05	-0.0702	-0.1827	-0.1208	7	12.95
0.06	0.02186	-0.1506	-0.0766	7	12.95
0.07	0.16348	-0.0003	-0.0588	7	12.95
0.08	0.3492	0.28068	-0.1094	7	12.95
0.09	0.60495	0.67018	-0.1697	7	12.95
0.1	0.85139	1.06074	-0.3649	7	12.95
0.11	1.08087	1.44377	-0.4018	7	12.95
0.12	1.11026	1.79272	-0.4329	7	12.95

3. Pra-pemrosesan data seismogram

Pra-pemrosesan data seismogram dilakukan untuk meningkatkan kualitas sinyal serta menyesuaikan karakteristik data agar sesuai dengan kebutuhan pelatihan model CNN. Tahapan awal pra-pemrosesan meliputi proses *detrending*, yaitu proses untuk menghilangkan komponen tren atau *offset linier* pada sinyal seismogram yang dapat muncul akibat pengaruh instrumen, maupun perubahan *baseline* selama perekaman.

Selanjutnya, diterapkan *bandpass filter* pada rentang frekuensi 1-45 Hz untuk menekan komponen *noise* frekuensi rendah dan tinggi yang tidak berkaitan dengan sinyal gempa mikro dan mencakup keberagaman karakteristik data STEAD dalam jumlah yang banyak. Rentang frekuensi tersebut dipilih melalui percobaan *trial and error* hingga mendapatkan hasil yang optimal, sehingga proses *filtering* ini diharapkan meningkatkan rasio *signal-to-noise ratio* pada data seismogram.

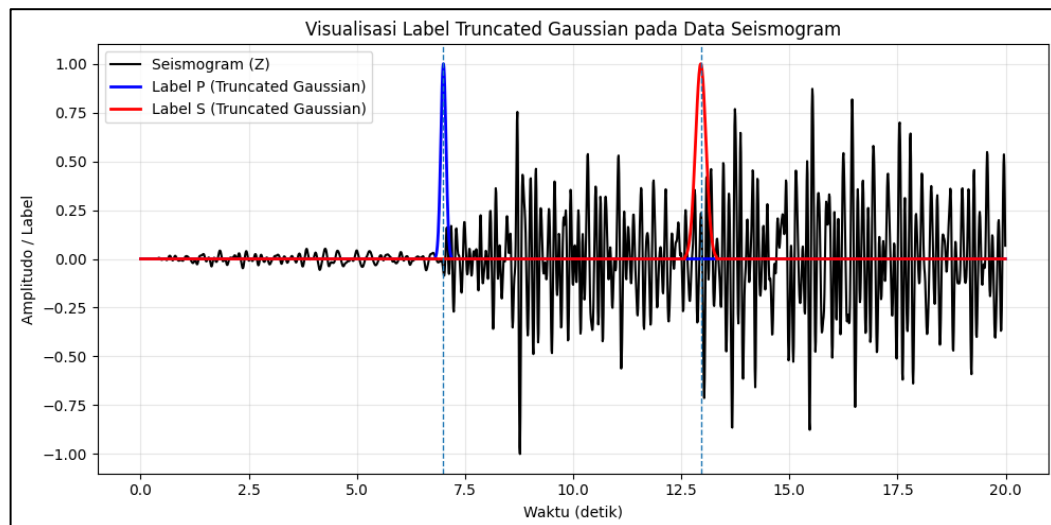
Dilakukan juga normalisasi data untuk menskalakan amplitudo sinyal ke rentang tertentu dengan nilai rata-rata mendekati nol. Proses normalisasi ini bertujuan untuk mengurangi perbedaan skala amplitudo antar rekaman seismogram. Tahapan akhir pra-pemrosesan adalah pemotongan data seismogram menjadi jendela waktu (*windowing*) berdurasi tetap. Tahapan pada *windowing* disertai dengan teknik augmentasi melalui metode *random jittering* untuk menghasilkan sampel positif. Jendela waktu digeser secara acak di sekitar waktu kedatangan gelombang P dan S, sehingga menghasilkan segmen-segmen dengan variasi posisi *onset* yang berbeda-beda. Pendekatan ini bertujuan untuk memperbanyak jumlah data latihan dan mencegah model CNN menghafal posisi absolut gelombang di dalam jendela waktu. Selain sampel positif, tahapan ini juga mengekstraksi sampel negatif (*noise*) dengan memotong segmen data *noise* sekitar rekaman yang terletak sebelum kedatangan gelombang P. Teknik ini melatih model agar lebih *robust* dalam membedakan sinyal seismik asli dari *noise*, sekaligus menekan tingkat kesalahan deteksi.

4. Labeling Data Pelatihan

Proses pelabelan data pelatihan dilakukan menggunakan pendekatan *truncated Gaussian* untuk merepresentasikan ketidakpastian waktu kedatangan gelombang.

Pada pendekatan ini, waktu kedatangan gelombang P dan gelombang S yang diperoleh dari hasil *picking manual* dijadikan sebagai pusat distribusi *Gaussian*. Nilai *label* maksimum diberikan di sekitar waktu kedatangan fase gelombang, dengan nilai probabilitas tertinggi mendekati nilai satu, kemudian menurun secara bertahap seiring bertambahnya jarak waktu dari titik kedatangan tersebut.

Distribusi *Gaussian* yang digunakan bersifat terpotong atau *truncated*, sehingga nilai fungsi diluar rentang waktu tertentu dianggap bernilai nol. Pendekatan ini bertujuan untuk membatasi kontribusi *label* hanya pada interval waktu yang relevan di sekitar fase gelombang P dan S, sekaligus menghindari pengaruh bagian sinyal yang tidak berkaitan dengan fase yang dipelajari. Ilustrasi pelabelan data latih pada seismogram ditunjukkan pada Gambar 21.



Gambar 21. Visualisasi pelabelan data latih pendekatan *Truncated Gaussian*

5. Pembagian dataset pelatihan

Proses pembagian dataset pelatihan dilakukan pada tahapan pelatihan model dan evaluasi model CNN. Dataset yang digunakan pada penelitian ini berjumlah 44,000 data seismogram. Dataset yang telah melalui tahapan pra-pemrosesan selanjutnya dibagi menjadi tiga kelompok utama, yaitu dataset latih, dataset validasi, dan dataset uji. Dataset latih digunakan sebagai data utama dalam proses pembelajaran model untuk menyesuaikan bobot dan parameter jaringan. Dataset validasi digunakan untuk memantau kinerja model selama proses pelatihan serta

sebagai dasar dalam pengaturan *hyperparameter* dan pencegahan *overfitting*. Sementara itu, dataset uji digunakan untuk mengevaluasi kemampuan generalisasi model terhadap data baru yang tidak pernah dilihat sebelumnya selama proses pelatihan.

6. Perancangan arsitektur model CNN

Arsitektur model *Convolutional Neural Network* (CNN) pada penelitian ini dirancang untuk mempelajari karakteristik temporal sinyal seismogram dan menghasilkan prediksi probabilitas *onset* gelombang P dan S pada setiap sampel waktu. Data masukan berupa seismogram *multichannel* (Z, N, dan E) yang telah melalui tahapan pra-pemrosesan selanjutnya diperlakukan sebagai data runtun waktu (*time series*), sehingga arsitektur CNN yang digunakan adalah CNN satu dimensi (Conv1D) yang sesuai untuk mengekstraksi pola temporal sinyal seismik.

Model CNN disusun atas satu blok konvolusi awal dan 6 blok konvolusi terdilatasi (*dilated convolution*) satu dimensi (Conv1D) yang bekerja untuk mengekstraksi fitur sinyal pada berbagai skala waktu. Blok konvolusi awal dengan ukuran kernel 7 berfungsi untuk menangkap fitur-fitur lokal berfrekuensi tinggi, seperti lonjakan amplitudo tiba-tiba yang mengindikasikan kedatangan awal (*onset*) gelombang. 6 blok konvolusi berikutnya menerapkan konfigurasi dilatasi yang meningkat secara eksponensial (dari 2 hingga 64) dipadukan dengan ukuran kernel 5 sebagai ekstraksi fitur lebih spesifik. Model dapat menganalisis konteks sinyal secara global, merangkum memori fisis perambatan gelombang, dan dengan jelas membedakan pola *background noise*, coda gelombang P, dan kedatangan gelombang S. Setiap lapisan konvolusi diintegrasikan dengan *Batch Normalization* untuk menstabilkan distribusi nilai aktivasi internal serta lapisan *Dropout* (20%) untuk mencegah terjadinya *overfitting* selama proses pelatihan. Penggunaan fungsi aktivasi *sigmoid* pada lapisan ini memastikan keluaran berada pada rentang probabilitas 0 hingga 1 untuk setiap titik sampel secara kontinu. Susunan lengkap arsitektur model CNN beserta dimensi keluaran setiap lapisannya ditunjukkan pada Gambar 22.

Dikarenakan model menghasilkan distribusi probabilitas sepanjang deret waktu, diperlukan sebuah algoritma pemilih (*picker*) untuk mengonversi

probabilitas kontinu tersebut menjadi titik waktu diskrit kedatangan gelombang. Algoritma pemilih (*picker*) pada penelitian ini memadukan *threshold* probabilitas 0 untuk penentuan *onset* gelombang P dan S. *Onset* gelombang P ditetapkan berdasarkan titik puncak probabilitas global (*argmax*) yang melampaui nilai *threshold*. Untuk menghindari deteksi *onset* S yang palsu (*shadow peak*), pencarian *onset* gelombang S dibatasi dalam jendela temporal antara 10 hingga 300 sampel (3 detik pada 100 Hz) setelah kedatangan gelombang P. Pembatasan maksimum 3 detik ini untuk mengikat prediksi agar selalu mematuhi hukum fisis waktu tunda ($T_s - T_p$) gempa mikro. Puncak probabilitas tertinggi didalam batasan jendela inilah yang dideklarasikan sebagai waktu tiba gelombang S yang valid.

Layer (type)	Output Shape	Param #
seismic_input (InputLayer)	(None, 800, 3)	0
conv1d (Conv1D)	(None, 800, 32)	704
batch_normalization (BatchNormalization)	(None, 800, 32)	128
activation (Activation)	(None, 800, 32)	0
conv1d_1 (Conv1D)	(None, 800, 64)	10,304
batch_normalization_1 (BatchNormalization)	(None, 800, 64)	256
activation_1 (Activation)	(None, 800, 64)	0
dropout (Dropout)	(None, 800, 64)	0
conv1d_2 (Conv1D)	(None, 800, 64)	20,544
batch_normalization_2 (BatchNormalization)	(None, 800, 64)	256
activation_2 (Activation)	(None, 800, 64)	0
dropout_1 (Dropout)	(None, 800, 64)	0
conv1d_3 (Conv1D)	(None, 800, 64)	20,544
batch_normalization_3 (BatchNormalization)	(None, 800, 64)	256
activation_3 (Activation)	(None, 800, 64)	0
dropout_2 (Dropout)	(None, 800, 64)	0
conv1d_4 (Conv1D)	(None, 800, 64)	20,544
batch_normalization_4 (BatchNormalization)	(None, 800, 64)	256
activation_4 (Activation)	(None, 800, 64)	0
dropout_3 (Dropout)	(None, 800, 64)	0
conv1d_5 (Conv1D)	(None, 800, 64)	20,544
batch_normalization_5 (BatchNormalization)	(None, 800, 64)	256
activation_5 (Activation)	(None, 800, 64)	0
dropout_4 (Dropout)	(None, 800, 64)	0
conv1d_6 (Conv1D)	(None, 800, 64)	20,544
batch_normalization_6 (BatchNormalization)	(None, 800, 64)	256
activation_6 (Activation)	(None, 800, 64)	0
dropout_5 (Dropout)	(None, 800, 64)	0
conv1d_7 (Conv1D)	(None, 800, 32)	2,080
onset_probability (Conv1D)	(None, 800, 2)	66

Gambar 22. Susunan lengkap arsitektur model CNN

7. Evaluasi performa model CNN

Evaluasi performa model CNN dilakukan untuk menilai kualitas proses pelatihan serta kemampuan generalisasi model dalam melakukan prediksi *onset* gelombang P dan S. Pada tahap ini, evaluasi dilakukan dengan memvisualisasikan kurva nilai *loss* dan *validation loss* selama proses pelatihan. Kurva tersebut digunakan untuk mengamati perilaku konvergensi model serta mengidentifikasi indikasi terjadinya *overfitting* atau *underfitting*.

Model dikatakan mengalami *overfitting* apabila nilai *loss* pada data latih terus menurun sementara *validation loss* cenderung meningkat, sedangkan kondisi *underfitting* ditunjukkan oleh nilai *loss* dan *validation loss* yang sama-sama tinggi dan tidak menunjukkan penurunan. Pada tahap evaluasi dilakukan uji generalisasi model dengan menggunakan data uji yang telah dilakukan pembagian pada tahap pembagian dataset.

8. *Export* model CNN

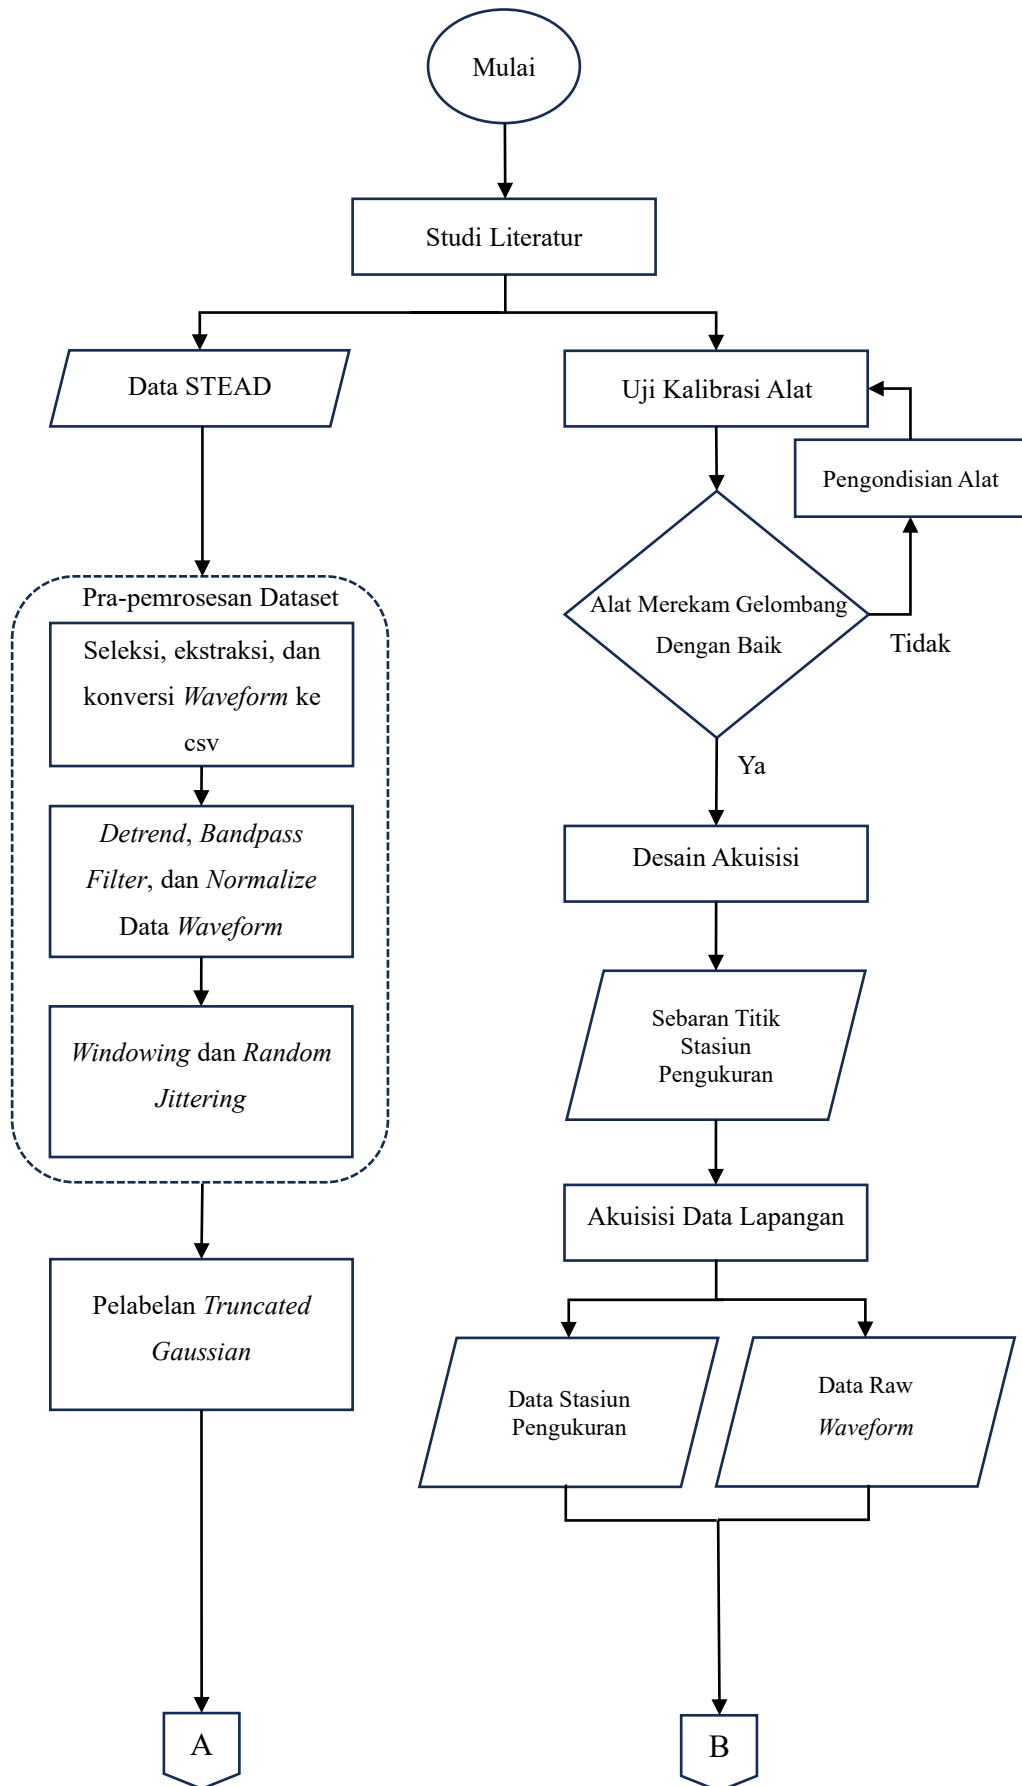
Proses *export* model CNN dilakukan setelah diperoleh model dengan kinerja optimal berdasarkan hasil evaluasi pelatihan dan validasi. Model yang telah terlatih dan memenuhi kriteria performa selanjutnya disimpan dalam format “.keras”. Model CNN yang telah di-*export* kemudian digunakan kembali dan diaplikasikan pada data seismogram hasil pengukuran pada Lapangan Panas bumi Ulubelu yang direkam menggunakan seismograf PiGraf. Pada tahap ini, model digunakan untuk melakukan prediksi probabilitas *onset* serta menentukan waktu kedatangan gelombang P dan S secara otomatis.

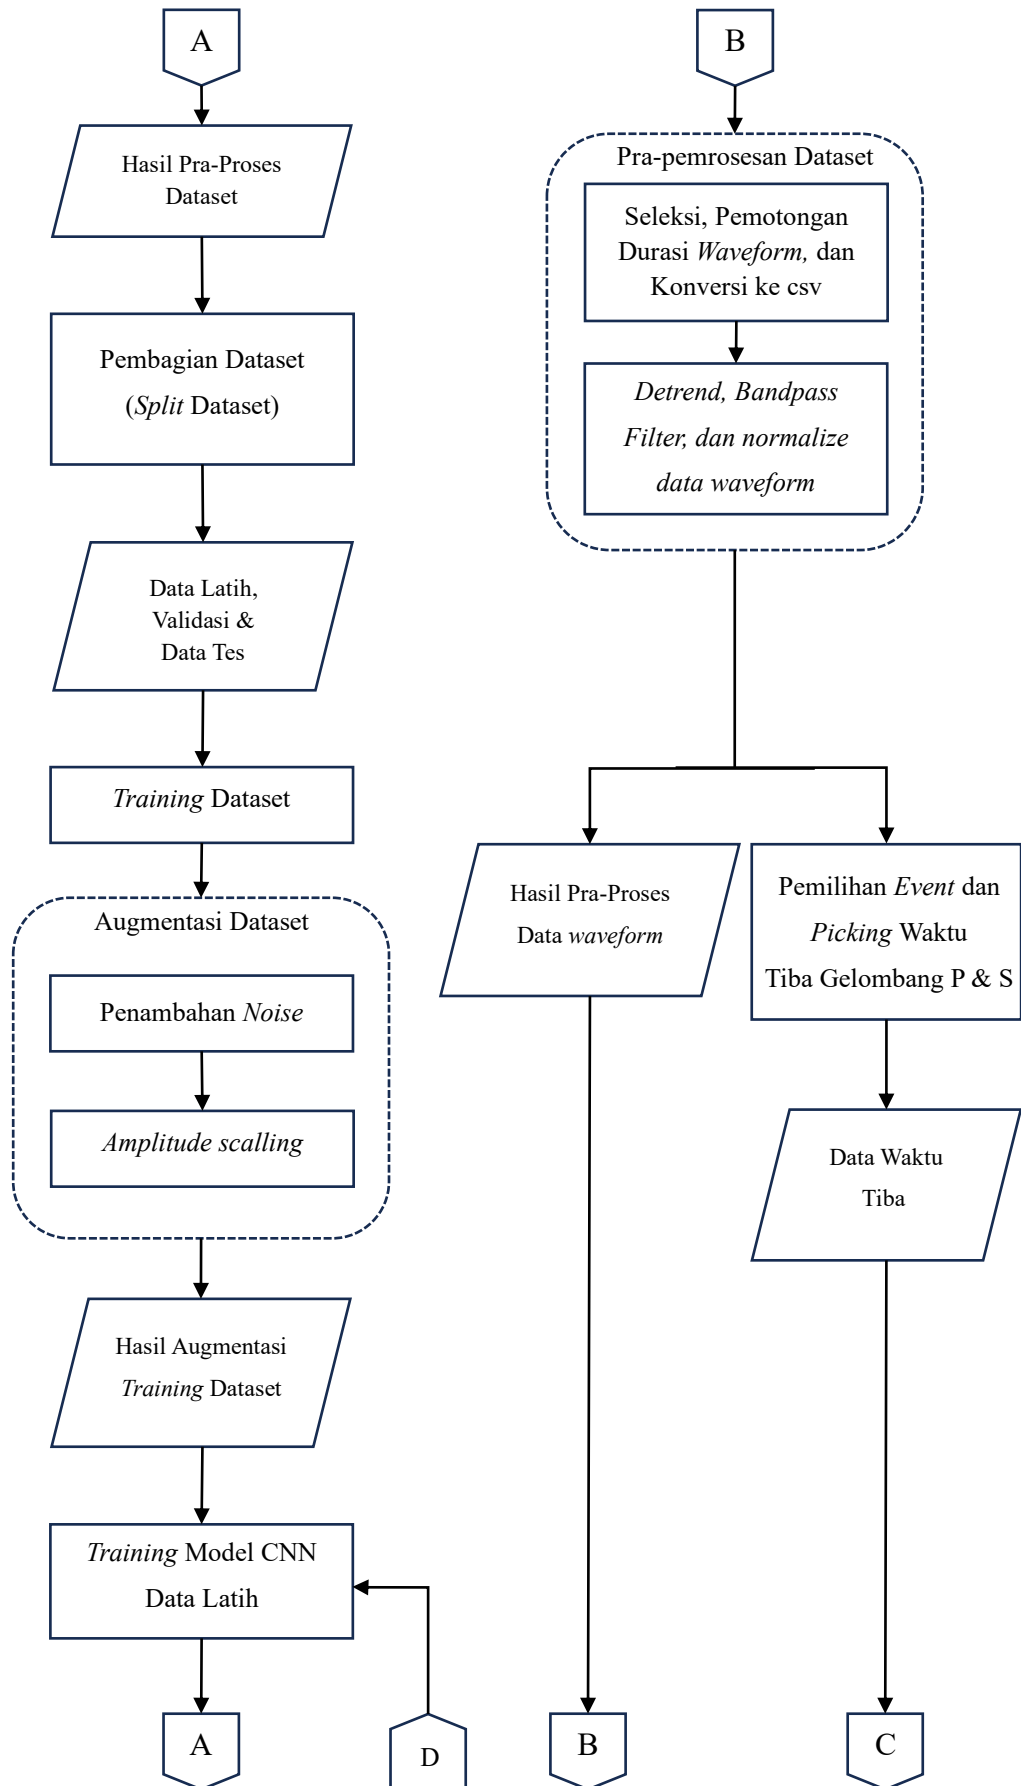
4.3.6. Analisis dan interpretasi

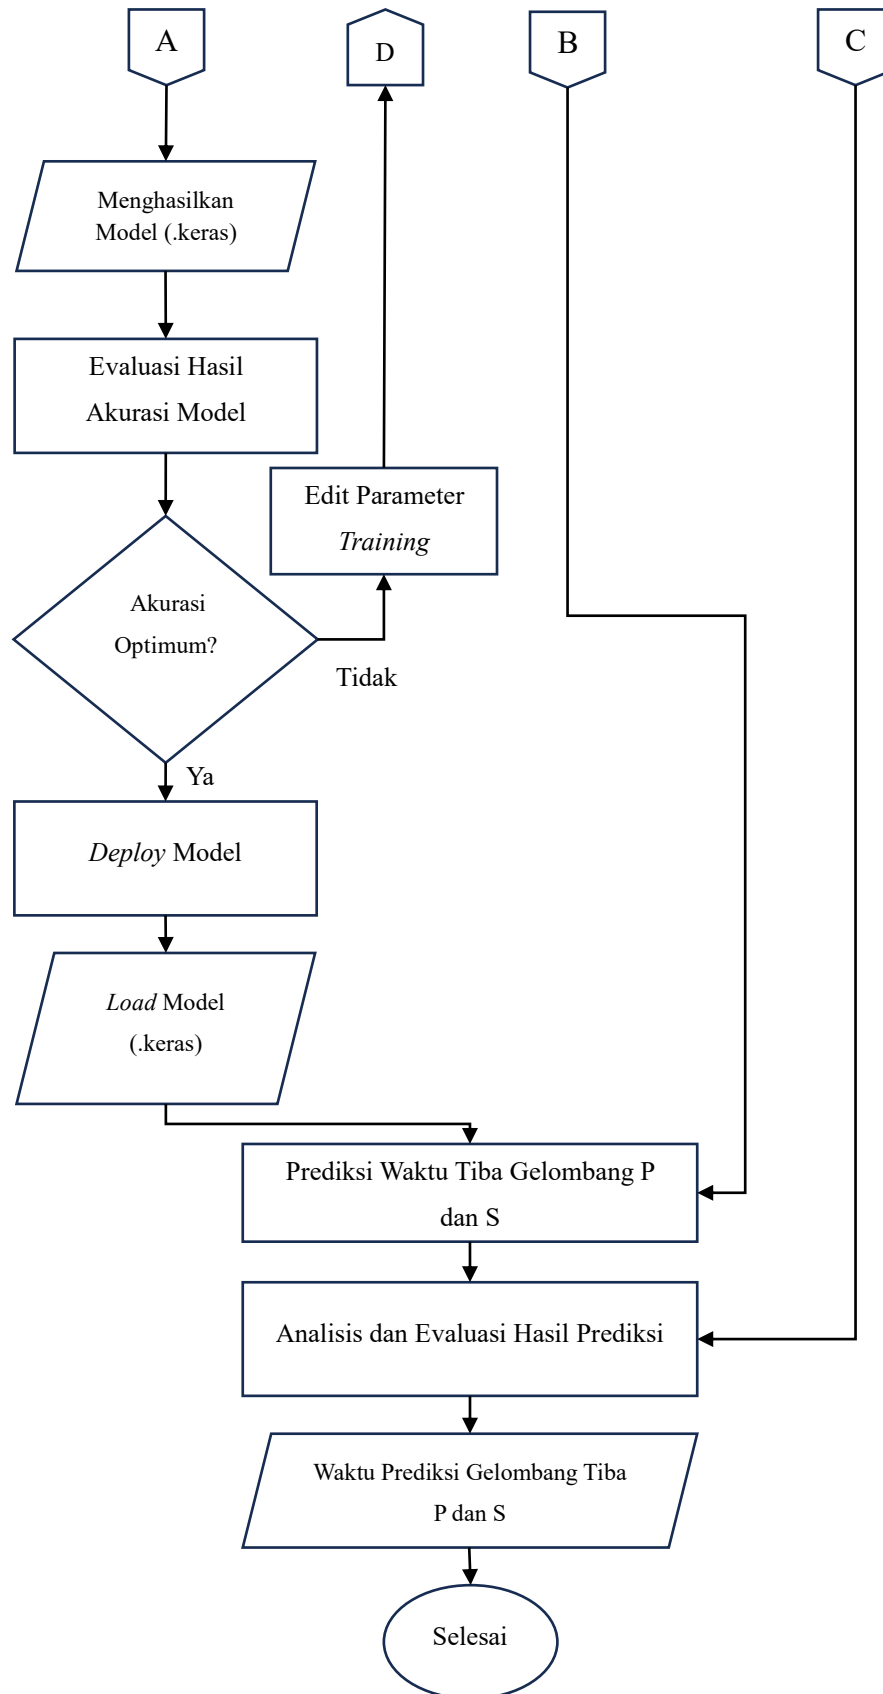
Data seismogram hasil pengukuran lapangan selanjutnya dianalisis dengan menerapkan model CNN yang telah dilatih dan disimpan pada tahap sebelumnya. Pada proses ini, data seismogram dimasukkan sebagai data masukan ke dalam model untuk menghasilkan prediksi probabilitas *onset* yang kemudian digunakan untuk menentukan waktu kedatangan gelombang P dan gelombang S secara otomatis. Hasil prediksi tersebut selanjutnya dianalisis dengan membandingkan waktu kedatangan yang dihasilkan model terhadap informasi waktu tiba hasil *picking manual*, sehingga dapat dilakukan interpretasi mengenai tingkat akurasi model dalam mengidentifikasi fase gelombang datang pada data riil lapangan.

4.4. Diagram Alir Penelitian

Adapun diagram alir penelitian ini ditunjukkan pada Gambar 23.







Gambar 23. Diagram alir penelitian

VI. SIMPULAN DAN SARAN

6.1. Simpulan

Kesimpulan pada penelitian tugas akhir ini sebagai berikut.

1. Tahapan proses algoritma sistem *autopicking* berbasis *Convolutional Neural Network* (CNN) untuk mendeteksi waktu kedatangan gelombang P dan S meliputi persiapan dataset, pra-pemrosesan (penerapan *detrending* dan *bandpass filter*), pembagian dan pelabelan dataset, penerapan augmentasi data dan evaluasi hasil *training* model untuk mengukur kemampuan model dalam mendeteksi dan mengestimasi waktu tiba gelombang P dan S
2. Berdasarkan hasil pelatihan model CNN hingga 100 *epoch*, performa terbaik diperoleh pada *epoch* ke-39 dengan akurasi pelatihan sebesar 94,40% dan akurasi validasi sebesar 94,87%. Pada tahap pengujian, model menunjukkan kinerja yang baik dalam mendeteksi gelombang P dengan *precision* 97,38%, *recall* 97,28%, dan *F1 Score* 97,33%, dengan jumlah *event* yang berhasil terdeteksi sebanyak 5463 dari 5616 *event*. Sementara itu, pada gelombang S diperoleh *precision* 89,10%, *recall* 88,89%, dan *F1 Score* 88,99%, dengan jumlah *event* terdeteksi sebanyak 4992 dari 5616 *event*
3. Model berhasil mencapai tingkat deteksi sebesar 100% (30 dari 30 *event*) dengan tingkat akurasi pada *onset* gelombang P yang tinggi ditunjukkan oleh nilai MAE sebesar 26,42 ms dan simpangan baku sebesar 45,57 ms. Pada gelombang S, model mencapai tingkat deteksi sebesar 90% (27 dari 30 *event*). Namun, performa model mengalami penurunan yang ditunjukkan oleh peningkatan nilai MAE menjadi 312,67 ms serta simpangan baku yang lebih besar, yaitu 501,13 ms. Hal ini menunjukkan bahwa prediksi waktu *onset* gelombang S memiliki deviasi yang lebih besar dan variasi yang lebih tinggi dibandingkan gelombang P.

6.2. Saran

Berdasarkan hasil penelitian yang telah dilakukan, terdapat beberapa saran yang dapat dipertimbangkan untuk pengembangan selanjutnya. Perlu dilakukan evaluasi kembali terhadap penempatan alat seismograf serta pelaksanaan *quality control* (QC) data secara berkala dengan tujuan untuk meminimalkan terjadinya data rekaman dengan kualitas rendah, sehingga data yang diperoleh lebih representatif dan optimal untuk proses analisis selanjutnya. Mengenai pengembangan model, disarankan untuk mengeksplorasi arsitektur *deep learning* yang lebih lanjut, seperti model yang mampu menangkap fitur temporal pada data *time series*. Pendekatan ini diharapkan dapat meningkatkan kemampuan deteksi, khususnya pada *onset* gelombang S yang memiliki karakteristik yang lebih kompleks dan perlu dikembangkan sebuah algoritma *picking* yang lebih adaptif dengan pendekatan *multi-event picking*, sehingga model tidak hanya mendeteksi satu kejadian (*single event pick*), tetapi mampu mengidentifikasi beberapa kemungkinan sepasang *onset* dalam satu rekaman secara akurat.

DAFTAR PUSTAKA

- Akhtar, M., Tanveer, M., & Arshad, Mohd. (2025). RoBoSS: A Robust, Bounded, Sparse, and Smooth Loss Function for Supervised Learning. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 47(1), 149–160. <https://doi.org/10.1109/TPAMI.2024.3465535>
- Allen, R. V. (1978). Automatic earthquake recognition and timing from single traces. *Bulletin of the Seismological Society of America*, 68(5), 1521–1532. <https://doi.org/10.1785/BSSA0680051521>
- Amin, T. C., Sidarto, Santosa, S., & Gunawan, W. (2010). *Peta Geologi Lembar Kotaagung, Sumatera*. Pusat Penelitian dan Pengembangan Geologi.
- Baer, M., & Kradolfer, U. (1987). An automatic phase picker for local and teleseismic events. *Bulletin of the Seismological Society of America*, 77(4), 1437–1445. <https://doi.org/10.1785/BSSA0770041437>
- Braile, L. (2010). Seismic Wave Demonstrations and Animations. *Purdue University*. <https://web.ics.purdue.edu/~braile/edumod/waves/WaveDemo.pdf>
- Chai, T., & Draxler, R. R. (2014). Root Mean Square Error (RMSE) or Mean Absolute Error (MAE) – Arguments Against Avoiding RMSE in the Literature. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Chen, Y., Zhang, G., Bai, M., Zu, S., Guan, Z., & Zhang, M. (2019). Automatic Waveform Classification and Arrival Picking Based on Convolutional Neural Network. *Earth and Space Science*, 6(7), 1244–1261. <https://doi.org/10.1029/2018EA000466>

- Daud, Y., Iskandar, C., Putri, F. F., Martha, A. A., Nuqramadha, W. A., Fahmi, F., Tifani, M. A., Tarmidi, S., Putro, D. I. M. S., Pratama, S. A., & Yunis, Y. (2023). *Reservoir Imaging Over the Patuha Geothermal System (Indonesia) Using Ambient Noise Tomography*. <https://doi.org/10.2139/ssrn.4598519>
- Dzulqarnain, M. F., Suprpto, S., & Makhrus, F. (2019). Improvement of Convolutional Neural Network Accuracy on Salak Classification Based Quality on Digital Image. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 13(2), 189. <https://doi.org/10.22146/ijccs.42036>
- Folesky, J., Kummerow, J., Shapiro, S. A., Häring, M., & Asanuma, H. (2016). Rupture directivity of fluid-induced microseismic events: Observations from an enhanced geothermal system. *Journal of Geophysical Research: Solid Earth*, 121(11), 8034–8047. <https://doi.org/10.1002/2016JB013078>
- Haerudin, N., Alami, F., & Rustadi. (2019). *Mikroseismik, Mikrotremor dan Microearthquake Dalam Ilmu Kebumihan*. Pusaka Media.
- Hakim, M. F. Al, Putra, I. P. R. A., Annisa, D. K., Muhlisin, H., Pratama, H. P., Sule, M. R., & Yudha, F. (2025). The use of PhaseNet for Event Identification of Microearthquake Monitoring in Geothermal Field. *Journal of Petroleum and Geothermal Technology*, 6(1), 56–62. <https://doi.org/10.31315/jpgt.v6i1.13437>
- Hakim, L., Sobri, A., Sunardi, L., & Nurdiansyah, D. (2025). Prediksi Penyakit Jantung Berbasis Mesin Learning Dengan Menggunakan Metode K-NN. *Jurnal Digital Teknologi Informasi*, 7(2), 14. <https://doi.org/10.32502/digital.v7i2.9429>
- Halim, G. R., Utama, W., & Mariyanto, M. (2020). Uji Lokasi Hiposenter Mikro-Earthquake (MEQ) Dengan Metode Inversi Simulated Annealing Pada Lapangan Panas Bumi “XX.” *Jurnal Geosaintek*, 6(2), 71. <https://doi.org/10.12962/j25023659.v6i2.6548>
- Hilyah, A. (2010). Studi Gempa Mikro Untuk Mendeteksi Rekahan di Area Panas Bumi Kamojang Kabupaten Garut. *Jurnal Fisika dan Aplikasinya*, 6(2).

- Huang, W., Wang, R., Li, H., & Chen, Y. (2017). Unveiling the signals from extremely noisy microseismic data for high-resolution hydraulic fracturing monitoring. *Scientific Reports*, 7(1), 11996. <https://doi.org/10.1038/s41598-017-09711-2>
- Hurukawa, N. (2008). *Practical Analyses of Local Earthquakes*. International Institute of Seismology and Earthquake Engineering.
- Iqbal, M., Al-Hassan, M. A., Herdianita, N. R., & Juliarka, B. R. (2023). Determining recharge area in ULUBELU geothermal field, LAMPUNG, Indonesia using stable isotope data. *Applied Geochemistry*, 156, 105763. <https://doi.org/10.1016/j.apgeochem.2023.105763>
- Kayal, J. R. (2008). *Microearthquake Seismology and Seismotectonics of South Asia*. Springer Netherlands. <https://doi.org/10.1007/978-1-4020-8180-4>
- Khalili, M. M., Zhang, X., & Abroshan, M. (2023, November 7). Loss Balancing for Fair Supervised Learning. *International Conference on Machine Learning*. <https://doi.org/10.48550/arXiv.2311.03714>
- Li, P., Hu, D., & Zhao, C. (2025). Convolutional Neural Network Based Joint Estimation of Direction of Arrival and Polarisation Parameters. *IET Radar, Sonar & Navigation*, 19(1). <https://doi.org/10.1049/rsn2.70102>
- Liu, W., Chang, H., Xiao, Y., Yu, S., Huang, C., & Yao, Y. (2022). Automated Detection of Microseismic Arrival Based on Convolutional Neural Networks. *Shock and Vibration*, 2022, 1–14. <https://doi.org/10.1155/2022/8000477>
- Lois, A., Sokos, E., Martakis, N., Paraskevopoulos, P., & Tselentis, G.-A. (2013). A new automatic S-onset detection technique: Application in local earthquake data. *Geophysics*, 78(1), KS1–KS11. <https://doi.org/10.1190/geo2012-0050.1>
- McCourt, W. J., Crow, M. J., Cobbing, E. J., & Amin, T. C. (1996). Mesozoic and Cenozoic plutonic evolution of SE Asia: evidence from Sumatra, Indonesia. *Geological Society, London, Special Publications*, 106(1), 321–335. <https://doi.org/10.1144/GSL.SP.1996.106.01.21>
- Mohsen, H., El-Dahshan, E.-S. A., El-Horbaty, E.-S. M., & Salem, A.-B. M. (2018). Classification Using Deep Learning Neural Networks for Brain Tumors. *Future Computing and Informatics Journal*, 3(1), 68–71. <https://doi.org/10.1016/j.fcij.2017.12.001>

- Mousavi, S. M., Sheng, Y., Zhu, W., & Beroza, G. C. (2019). STanford EArthquake Dataset (STEAD): A Global Data Set of Seismic Signals for AI. *IEEE Access*, 7, 179464–179476. <https://doi.org/10.1109/ACCESS.2019.2947848>
- Mulyanto, Puspadianti, A., Giriarsa, J. P., & Hartanto, D. B. (2015). The Initial-State Geochemistry as a Baseline for Geochemical Monitoring at Ulubelu Geothermal Field, Indonesia. *Proceedings World Geothermal Congress 2015*.
- Namjesnik, D., Kinscher, J., Gunzburger, Y., Poiata, N., Dominique, P., Bernard, P., & Contrucci, I. (2021). Automatic Detection and Location of Microseismic Events from Sparse Network and Its Application to Post-mining Monitoring. *Pure and Applied Geophysics*, 178(8), 2969–2997. <https://doi.org/10.1007/s00024-021-02773-4>
- Okamoto, K., Yi, L., Asanuma, H., Okabe, T., Abe, Y., & Tsuzuki, M. (2018). Triggering processes of microseismic events associated with water injection in Okuaizu Geothermal Field, Japan. *Earth, Planets and Space*, 70(1), 15. <https://doi.org/10.1186/s40623-018-0787-7>
- Oswald, J. N., Erbe, C., Gannon, W. L., Madhusudhana, S., & Thomas, J. A. (2022). Detection and Classification Methods for Animal Sounds. Dalam *Exploring Animal Behavior Through Sound: Volume 1* (hlm. 269–317). Springer International Publishing. https://doi.org/10.1007/978-3-030-97540-1_8
- Park, Y., Armstrong, A. D., Yeck, W. L., Shelly, D. R., & Beroza, G. C. (2025). Divide and Conquer: Separating the Two Probabilities in Seismic Phase picking. *Geophysical Journal International*, 243(2). <https://doi.org/10.1093/gji/ggaf333>
- Rossi, C., Grigoli, F., Cesca, S., Heimann, S., Gasperini, P., Hjörleifsdóttir, V., Dahm, T., Bean, C. J., Wiemer, S., Scarabello, L., Nooshiri, N., Clinton, J. F., Obermann, A., Ágústsson, K., & Ágústsdóttir, T. (2020). Full-Waveform based methods for Microseismic Monitoring Operations: an Application to Natural and Induced Seismicity in the Hengill Geothermal Area, Iceland. *Advances in Geosciences*, 54, 129–136. <https://doi.org/10.5194/adgeo-54-129-2020>
- Ryu, J. Y., Chung, H. Y., & Choi, K. Y. (2021). Potential Role of Artificial Intelligence in Craniofacial Surgery. *Archives of Craniofacial Surgery*, 22(5), 223–231. <https://doi.org/10.7181/acfs.2021.00507>

- Sarno, R., Sabilla, S. I., Malikhah, Purbawa, D. P., & Ardani, S. H. (2023). *Machine Learning dan Deep Learning: Konsep dan Pemrograman Python*. Penerbit ANDI.
- Shenfield, A., & Howarth, M. (2020). A Novel Deep Learning Model for the Detection and Identification of Rolling Element-Bearing Faults. *Sensors*, 20(18), 5112. <https://doi.org/10.3390/s20185112>
- Singh, P., Singh, N., Singh, K. K., & Singh, A. (2021). Diagnosing of Disease Using Machine Learning. Dalam *Machine Learning and the Internet of Medical Things in Healthcare* (hlm. 89–111). Elsevier. <https://doi.org/10.1016/B978-0-12-821229-5.00003-3>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 5(1), 1929–1958.
- Suharno, & Browne, P. (2000). Subsurface Hydrothermal Alteration at The Ulubelu Geothermal Field, Lampung, Southern Sumatra, Indonesia. *PROCEEDINGS, Twenty-fifth Workshop on Geothermal Reservoir Engineering*.
- Sunarjo, Gunawan, M. T., & Pribadi, S. (2010). *Gempabumi Edisi Populer*. BMKG.
- Wang, P., Chang, X., & Zhou, X. (2018). Estimation of the Relative Arrival Time of Microseismic Events Based on Phase-Only Correlation. *Energies*, 11(10), 2527. <https://doi.org/10.3390/en11102527>
- Wei Li, Chakraborty, M., Köhler, J., Cartaya, C. Q., Rumpker, G., & Srivastava, N. (2022). Real-time Earthquake Monitoring using Deep Learning: a case study on Turkey Earthquake Aftershock Sequence. *arXiv preprint arXiv:2211.09539*.
- Wibowo, D. A., Ramadhan, I., Agoes Nugroho, I., Baroek, M. C., Ganefianto, N., Azis, H., Suryantini, Sahara, D. P., & Mozef, P. W. (2022). Microseismic and Focal Mechanism Analyses for Structural Interpretation – Muara Laboh Geothermal Field. *IOP Conference Series: Earth and Environmental Science*, 1014(1), 012004. <https://doi.org/10.1088/1755-1315/1014/1/012004>
- Wijayanti, M. D. (2023). *Energi Panas Bumi*. Bumi Aksara.

- Yu, Z.-C., Yu, J., Feng, F.-F., Tan, Y.-Y., Hou, G.-T., & He, C. (2020). Arrival picking method for microseismic phases based on curve fitting. *Applied Geophysics*, *17*(3), 453–464. <https://doi.org/10.1007/s11770-020-0831-9>
- Zhang, G., Lin, C., & Chen, Y. (2020). Convolutional neural networks for microseismic waveform classification and arrival picking. *Geophysics*, *85*(4), WA227–WA240. <https://doi.org/10.1190/geo2019-0267.1>
- Zhu, W., & Beroza, G. C. (2018). PhaseNet: A Deep-Neural-Network-Based Seismic Arrival Time Picking Method. *Geophysical Journal International*, *216*(1), 261–273.