

**UJI PERFORMA ALGORITMA JARINGAN SARAF TIRUAN
UNTUK MEMPREDIKSI MAGNITUDO GEMPA BUMI
DI WILAYAH JAWA TIMUR**

THESIS

Oleh:

**MUHAMMAD AJI PERMANA
NIM. 210605220015**



**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**UJI PERFORMA ALGORITMA JARINGAN SARAF TIRUAN
UNTUK MEMPREDIKSI MAGNITUDO GEMPA BUMI
DI WILAYAH JAWA TIMUR**

THESIS

**Diajukan Kepada :
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Untuk Memenuhi Salah Satu Persyaratan Dalam
Memperoleh Gelar Magister Informatika (M.Kom)**

**Oleh :
MUHAMMAD AJI PERMANA
210605220015**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**UJI PERFORMA ALGORITMA JARINGAN SARAF TIRUAN
UNTUK MEMPREDIKSI MAGNITUDO GEMPA BUMI
DI WILAYAH JAWA TIMUR**

THESIS

**Diajukan Kepada:
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang
untuk Memenuhi Salah Satu Persyaratan dalam
Memperoleh Gelar Magister Informatika (M.Kom)**

**Oleh:
MUHAMMAD AJI PERMANA
210605220015**

**PROGRAM STUDI MAGISTER INFORMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM
MALANG
2024**

**UJI PERFORMA ALGORITMA JARINGAN SARAF TIRUAN UNTUK
MEMPREDIKSI MAGNITUDO GEMPA BUMI DI WILAYAH JAWA TIMUR**

THESIS

**Oleh:
MUHAMMAD AJI PERMANA
210605220015**

Telah diperiksa dan disetujui untuk diuji:
Tanggal: 5 September 2024

Pembimbing I



Dr. M. Faisal, M.T.
NIP 19740510 200501 1 007


Pembimbing II



Dr. Usman Pagalay, M.Si.
NIP 19650414 200312 1 001

Mengetahui,
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Dr. Cahyo Crysdian
NIP. 19740424 200901 1 008

**UJI PERFORMA ALGORITMA JARINGAN SARAF TIRUAN UNTUK
MEMREDIKSI MAGNITUDO GEMPA BUMI DI WILAYAH JAWA TIMUR**

THESIS

**Oleh:
MUHAMMAD AJI PERMANA
NIM. 210605220015**

Telah Dipertahankan di Depan Dewan Penguji Thesis
dan Dinyatakan Diterima Sebagai Salah Satu Persyaratan
Untuk Memperoleh Gelar Magister Komputer (M. Kom.)
Tanggal: 5 September 2024

Susunan Dewan Penguji

Penguji I : Dr. M. Amin Hariyadi, M.T.
NIP. 19670118 200501 1 001

Penguji II : Dr. Zainal Abidin, M.Kom.
NIP. 19760613 200501 1 004

Pembimbing I : Dr. M. Faisal, M.T.
NIP. 19740510 200501 1 007

Pembimbing II : Dr. Usman Pagalay, M.Si.
NIP.19650414 200312 1 001

Tanda Tangan

()


()

()

()

Mengetahui dan Mengesahkan,
Ketua Program Studi Magister Informatika
Fakultas Sains dan Teknologi
Universitas Islam Negeri Maulana Malik Ibrahim Malang




Cahyo Crysdian
19740424 200901 1 008

PERNYATAAN KEASLIAN TULISAN

Yang bertanda tangan di bawah ini saya,

Nama : Muhammad Aji Permana
NIM : 210605220015
Program : Magister Informatika (S-2)
Fakultas : Sains dan Teknologi

Saya menyatakan dengan sebenar-benarnya, bahwa Thesis yang saya tulis ini benar-benar merupakan hasil usaha saya sendiri dan bukan merupakan perampasan data, tulisan atau pemikiran orang lain yang saya akui sebagai hasil tulisan atau pemikiran saya sendiri, kecuali mencantumkan sumbernya dalam daftar pustaka.

Jika terdapat bukti atau di kemudian hari dapat dibuktikan bahwa Thesis ini merupakan plagiat, saya bersedia menerima sanksi atas perbuatan tersebut.

Malang, 5 September 2024

Yang membuat pernyataan,



Muhammad Aji Permana

MOTTO

*“Berusahalah untuk menjadi muslim yang baik dengan senantiasa bersyukur,
bersabar dan ridho atas segala ketentuan dan takdir Allah Azza wa jalla.”*

PERSEMBAHAN

Segala puji teruntuk Allah *subhanahu wa ta'ala*, atas karunia-Nya yang menjadikan Thesis ini mampu terselesaikan dengan baik. Thesis ini dipersembahkan kepada:

1. Orangtua, istri tercinta beserta anak-anak yang senantiasa memanjatkan doa beserta dukungannya.
2. Segenap civitas UIN Maulana Malik Ibrahim Malang terkhususnya Fakultas Sains dan Teknologi, Prodi Magister Informatika akan ilmu beserta pengalamannya.
3. Pimpinan serta rekan-rekan BMKG Stasiun Geofisika Nganjuk yang terus membantu dan memberi motivasi untuk penyelesaian Thesis ini.
4. Seluruh rekan-rekan dalam angkatan 5 Program Studi Magister Informatika UIN Maulana Malik Ibrahim Malang atas kebersamaannya.
5. Seluruh pihak yang telah berkontribusi dalam penyelesaian penulisan Thesis ini.

KATA PENGANTAR

Assalamu'alaikum Wr. Wb.

Segala puji syukur penulis haturkan kehadirat Allah *subhanahu wa ta'ala* yang telah memberi limpahan akan rahmat beserta hidayah-Nya, yang menjadikan penulis mampu melakukan penyelesaian studi dalam Program Studi Magister Informatika, Fakultas Sains dan Teknologi Universitas Islam Negeri Maulana Malik Ibrahim Malang dan juga melakukan penyelesaian akan penulisan Thesis ini.

Selanjutnya penulis haturkan ucapan terima kasih teruntuk seluruh pihak yang telah mendukung akan terselesaikannya Thesis ini. Ucapan terima kasih ini penulis sampaikan teruntuk:

- 1) Bp. Dr. M. Faisal dan Bp. Dr. Usman Pagalay selaku dosen pembimbing Thesis, yang telah banyak memberi pengarahan beserta pengalaman yang berharga.
- 2) Ayahanda dan Ibunda *rahimahullah* tercinta yang selalu memanjatkan doa dan restunya teruntuk penulis saat menuntut ilmu.
- 3) Istri dan putri-putri penulis yang senantiasa memberi semangat teruntuk penulis guna menyelesaikan Thesis ini.
- 4) Teman-teman kelas MI A5 dan BMKG yang telah banyak memberi dukungan beserta bantuan dalam proses belajar sampai dengan penulisan thesis ini

Penulis menyadari bahwasanya pada proses penyusunan Thesis ini masih banyak kekurangannya serta penulis memiliki pengharapan semoga Thesis ini mampu menghadirkan manfaat bagi para pembaca, terkhususnya bagi penulis secara pribadi.

Wassalamu'alaikum Wr. Wb.

DAFTAR ISI

| | |
|---|------|
| HALAMAN JUDUL..... | i |
| HALAMAN PENGAJUAN..... | ii |
| HALAMAN PERSETUJUAN..... | iii |
| HALAMAN PENGESAHAN..... | iv |
| HALAMAN PERNYATAAN..... | v |
| MOTTO..... | vi |
| PERSEMBAHAN..... | vii |
| KATA PENGANTAR..... | viii |
| DAFTAR GAMBAR..... | xi |
| DAFTAR TABEL..... | xii |
| ABSTRAK..... | xiii |
| ABSTRACT..... | xiv |
| مستخلص البحث..... | xv |
| BAB I..... | 1 |
| PENDAHULUAN..... | 1 |
| 1.1 Latar Belakang..... | 1 |
| 1.2 Pernyataan Masalah..... | 6 |
| 1.3 Tujuan Penelitian..... | 6 |
| 1.5 Batasan Masalah..... | 7 |
| BAB II..... | 8 |
| STUDI PUSTAKA..... | 8 |
| 2.1 Prediksi Gempa Bumi Berbasis Jaringan Saraf Tiruan..... | 8 |
| 2.2 Kerangka Teoritis..... | 12 |
| BAB III..... | 18 |
| METODE PENELITIAN..... | 18 |
| 3.1 Tahapan Penelitian..... | 18 |
| 3.1.1 Studi Literatur..... | 18 |
| 3.1.2 Pengumpulan Data..... | 19 |
| 3.1.3 Rekayasa Data..... | 20 |

| | | |
|---|--|----|
| 3.1.4 | Desain Sistem..... | 22 |
| 3.1.5 | Implementasi Sistem | 23 |
| 3.1.6 | Eksperimen | 23 |
| 3.1.6 | Evaluasi..... | 26 |
| 3.2 | Instrumen Penelitian | 26 |
| BAB IV | | 27 |
| PREDIKSI MAGNITUDO DENGAN JARINGAN SARAF TIRUAN | | 27 |
| 4.1 | Desain | 27 |
| 4.2 | Implementasi Sistem Prediksi Magnitudo dengan Jaringan Saraf Tiruan..... | 29 |
| 4.2.1 | Algoritma Standar <i>Backpropagation</i> (BPNN)..... | 30 |
| 4.2.3 | Algoritma <i>Resilient Backpropagation</i> (RPROP) | 34 |
| 4.3 | Uji Coba..... | 37 |
| 4.3.1 | Hasil Algoritma <i>Standard Backpropagation Neural Network</i> (BPNN).... | 38 |
| 4.3.2 | Hasil Algoritma <i>Resilient Backpropagation</i> (RPROP)..... | 42 |
| BAB V..... | | 46 |
| PEMBAHASAN | | 46 |
| 5.1 | Perbandingan Performa pada Prediksi Data Magnitudo | 46 |
| 5.1.1 | Perbandingan Performa Berdasarkan Tingkat Kesalahan | 46 |
| 5.1.2 | Pengujian Performa Berdasarkan Waktu Pelatihan | 49 |
| 5.2 | Kaitan Strategi Arsitektur Jaringan dengan Performa Algoritma..... | 51 |
| 5.3 | Pandangan Islam tentang Uji Performa Algoritma untuk Memprediksi Gempa Bumi | 52 |
| BAB VI | | 55 |
| KESIMPULAN DAN SARAN..... | | 55 |
| 6.1 | Kesimpulan..... | 55 |
| 6.2 | Saran | 55 |
| DAFTAR PUSTAKA | | 56 |

DAFTAR GAMBAR

| | |
|---|----|
| Gambar 1. 1 Jumlah Kejadian Gempa Bumi Jawa Timur 2008-2020 | 1 |
| Gambar 2. 1 Kerangka Teori..... | 17 |
| Gambar 3. 1 Tahapan Penelitian | 18 |
| Gambar 3. 2 Cara Pengumpulan Data..... | 19 |
| Gambar 3. 3 Diagram Data Engineering..... | 20 |
| Gambar 3. 4 Desain Sistem..... | 22 |
| Gambar 4. 1 Desain Jaringan Saraf Tiruan | 27 |
| Gambar 4. 2 Diagram Alir Desain Jaringan Saraf Tiruan Backpropagation | 28 |
| Gambar 4. 3 Tampilan Aplikasi Prediksi Magnitudo Dengan Neural Network... | 37 |
| Gambar 4. 4 Arsitektur Jaringan BP-M15 | 39 |
| Gambar 4. 5 Korelasi Nilai MSE dan Jumlah Node Input..... | 40 |
| Gambar 4. 6 Korelasi Nilai Error dan Jumlah Neuron Lapisan Tersembunyi..... | 40 |
| Gambar 4. 7 Perbandingan Nilai Aktual dan Prediksi Pada Jaringan BP-M15 | 41 |
| Gambar 4. 8 Desain Arsitektur Jaringan RP-M16 | 42 |
| Gambar 4. 9 Korelasi Error Dan Jumlah Input Node..... | 43 |
| Gambar 4. 10 Korelasi Nilai Error dan Jumlah Neuron Pada Hidden Layer..... | 44 |
| Gambar 4. 11 Perbandingan Nilai Aktual dan Prediksi Pada Jaringan RP-M16.. | 44 |
| Gambar 5. 2 Grafik Tingkat Error Pada Variasi Jumlah Input | 46 |
| Gambar 5. 3 Grafik Tingkat Error Pada Variasi Jumlah Neuron Hidden | 47 |
| Gambar 5. 4 Grafik Waktu Pelatihan Jaringan Dengan Variasi Jumlah Input | 50 |
| Gambar 5. 5 Waktu Pelatihan Jaringan Dengan Variasi Jumlah Neuron Hidden | 50 |

DAFTAR TABEL

| | |
|--|----|
| Tabel 2. 1 Studi Literatur | 13 |
| Tabel 2. 2 Performa Kinerja Sistem Prediksi Gempa Bumi Berbasis JST | 16 |
| Tabel 3. 1 Detail Dataset..... | 21 |
| Tabel 3. 2 Penggalan Data Akhir | 21 |
| Tabel 3. 3 Desain Pelatihan Resilient Backpropagation untuk Data Magnitudo.. | 25 |
| Tabel 4. 1 Sampel Data Hasil Normalisasi | 29 |
| Tabel 4. 2 Inisialisasi Bobot dan Bias Input Ke Hidden Layer (W_{ij})..... | 30 |
| Tabel 4. 3 Inisialisasi Bobot pada Hidden Layer Ke Output Layer (V_{jk}) | 30 |
| Tabel 4. 4 Nilai Bobot Baru dari Input Layer Ke Hidden Layer | 33 |
| Tabel 4. 5 Nilai Bobot Baru dari Hidden Layer Ke Output Layer..... | 34 |
| Tabel 4. 6 Nilai Function, Error dan Gradien Error | 35 |
| Tabel 4. 7 Hasil Pembaruan Bobot dari Hidden Ke Output Layer | 36 |
| Tabel 4. 8 Nilai Gradien Error pada Hidden Layer..... | 36 |
| Tabel 4. 9 Nilai Pembaruan Bobot pada Input Ke Hidden Layer | 36 |
| Tabel 4. 10 Hasil Performa Algoritma BPNN | 38 |
| Tabel 4. 11 Hasil Rata-Rata Error Per Kelompok Jaringan Bpnn | 39 |
| Tabel 4. 12 Hasil Performa Algoritma RPROP | 42 |
| Tabel 4. 13 Rata-Rata Error Per Kelompok Jaringan RPROP..... | 43 |
| Tabel 5. 1 Perbandingan Nilai Error Rata-Rata Pada Data Magnitudo | 48 |
| Tabel 5. 2 Lama Waktu Pelatihan Per Kelompok Jaringan Bpnn | 49 |
| Tabel 5. 3 Lama Waktu Pelatihan Per Kelompok Jaringan Rprop | 49 |
| Tabel 5. 4 Perbandingan Performa Waktu Pembelajaran Pada Data Magnitudo | 51 |
| Tabel 5. 5 Tingkat Korelasi Error dan Variasi Arsitektur BPNNdan RPROP..... | 51 |

ABSTRAK

Permana, M. A. 2024. **Uji Performa Algoritma Jaringan Saraf Tiruan Untuk Memprediksi Magnitudo Gempa Bumi di Wilayah Jawa Timur**. Thesis. Program Studi Magister Informatika, Fakultas Sain dan Teknologi, Universitas Islam Negeri Maulana Malik Ibrahim, Malang. Pembimbing: (I) Dr. M. Faisal, M.T. Pembimbing (II) Dr. Usman Pagalay, M.Si.

Provinsi Jawa Timur yakni sebuah provinsi Indonesia yang berhadapan langsung dengan zona sumber gempa bumi. Hal ini menyebabkan wilayah Provinsi Jawa Timur menjadi wilayah dengan tingkat seismisitas yang cukup tinggi. Prediksi mengenai magnitudo gempa bumi penting dilakukan sebagai salah satu upaya kesiapsiagaan dalam mengurangi risiko gempa bumi. Algoritma jaringan saraf tiruan terus mengalami perkembangan dengan berbagai macam model maupun teknik pembaruan bobot. Algoritma *resilient backpropagation* (RPROP) yakni sebuah teknik yang dikembangkan melalui algoritma *standart backpropagation* (BPNN). Uji performa algoritma jaringan saraf tiruan perlu dilakukan untuk mengetahui algoritma dan model arsitektur yang paling akurat dan efektif untuk memprediksi magnitudo gempa bumi. Data yang digunakan pada penelitian ini merupakan data magnitudo gempa bumi di wilayah Jawa Timur dan sekitaran tahun 2016-2023. Berdasarkan hasil pengujian, algoritma RPROP menghasilkan performa tingkat *error* yang lebih baik, dimana membentuk *error* yang kecil dibanding $MSE=0,016167$, dibandingkan BPNN dengan $MSE=0,020732$. Selain itu berdasarkan performa waktu pelatihan, algoritma RPROP juga membutuhkan waktu yang lebih cepat dengan lama waktu pelatihan $t=0,018919$ s, dibandingkan BPNN dengan $t=0,045818$ s.

Kata kunci: *jaringan saraf tiruan, backpropagation, resilient backpropagation, gempa bumi*

ABSTRACT

Permana, M. A. 2024. **The Artificial Neural Network Algorithm Performance Test to Predict Earthquake Magnitude in East Java.** Thesis. Magister of Informatics, Faculty of Science and Technology, Universitas Islam Negeri Maulana Malik Ibrahim, Malang. Advisor: (I) Dr. M. Faisal, M.T., Advisor (II) Dr. Usman Pagalay, M.Si.

East Java is a province in Indonesia that directly faces an earthquake focus zone. It leads the province to have a high seismicity. Earthquake magnitude prediction is necessary to conduct as a preparation to lessen the earthquake risks. Artificial Neural Network algorithm has improved in various weight update models and techniques. The resilient backpropagation (RPROP) algorithm is developed from the standard backpropagation (BPNN) algorithm. An Artificial Neural Network Algorithm performance test is important to determine the most accurate and effective algorithm and architectural models to predict earthquake magnitude. The research data consisted of earthquake magnitude data of the East Java Province and its surrounding from 2016 to 2023. Based on the test result, the RPROP algorithm produces performance with a better error level. It has a lower error level with $MSE=0.016167$ than BPNN with $MSE=0.020732$. In addition, based on the training time performance. The RPROP algorithm also needs a shorter training time with $t=0.018919$ s, compared to BPNN with $t=0.045818$ s.

Keywords: *artificial neural network, backpropagation, resilient backpropagation, earthquake*

مستخلص البحث

برمانا، م. أ. 2024. اختبار أداء خوارزمية الشبكة العصبية الاصطناعية للتنبؤ بحجم الزلزال في منطقة جاوى الشرقية. رسالة الماجستير. قسم المعلومات، كلية العلوم والتكنولوجيا بجامعة مولانا مالك إبراهيم الإسلامية الحكومية مالانج. المشرف الأول: د. محمد فيصل، الماجستير. المشرف الثاني: د. عثمان باغالاي، الماجستير.

مقاطعة جاوى الشرقية هي واحدة من المقاطعات في إندونيسيا التي تواجه مباشرة منطقة مصدر الزلزال. وهذا يتسبب في أن تصبح منطقة مقاطعة جاوى الشرقية منطقة ذات مستوى عالٍ إلى حد ما من الزلازل. يعد التنبؤ بحجم الزلزال أمراً مهماً كأحد جهود التأهب للحد من مخاطر الزلازل. تستمر خوارزمية الشبكة العصبية الاصطناعية في التطور مع مجموعة متنوعة من النماذج وتقنيات تحديث الوزن. خوارزمية الانتشار العكسي المرن (RPROP) هي إحدى التقنيات التي تم تطويرها من خوارزمية الانتشار العكسي (BPNN). يجب إجراء اختبار أداء خوارزمية الشبكة العصبية الاصطناعية لمعرفة الخوارزمية والنموذج المعماري الأكثر دقة وفعالية للتنبؤ بحجم الزلزال. البيانات المستخدمة في هذه الرسالة هي بيانات عن حجم الزلازل في منطقة جاوى الشرقية والمناطق المحيطة بها من 2016-2023. استناداً إلى نتائج الاختبار، أنتجت خوارزمية RPROP أداءً أفضل لمعدل الخطأ، حيث تنتج أصغر الأخطاء مع قيمة $MSE = 0.016167$ ، مقارنة بـ BPNN مع قيمة $MSE = 0.020732$. بالإضافة إلى ذلك، بناءً على أداء وقت التدريب، استغرقت خوارزمية RPROP أيضاً أسرع وقتاً مع وقت تدريب يبلغ $t = 0.018919$ ثوان، مقارنة بـ BPNN مع $t = 0.045818$ ثوان.

الكلمات الرئيسية: شبكة عصبية اصطناعية، انتشار عكسي، انتشار عكسي مرن، زلزال.

BAB I PENDAHULUAN

1.1 Latar Belakang

Provinsi Jawa Timur yakni sebuah wilayah di Indonesia dengan tingkat seismo-vulkanik yang cukup tinggi. Peluang terjadi gempa bumi pada wilayah ini cukup tinggi sebab wilayah ini secara geografis berhadapan langsung dengan zona sumber gempa bumi. Widiyantoro *et al.* (2022) menyebutkan sumber-sumber gempa tersebut antara lain zona subduksi *megathrust* dan sesar-sesar yang ada di darat, seperti zona sesar Kendeng.

Berdasarkan catatan BMKG pada Gambar 1.1, sejak tahun 2008 sampai dengan tahun 2020 frekuensi total kejadian gempa bumi di Jawa Timur mengemban tren yang senantiasa mengalami peningkatan. Hal ini memberikan gambaran potensi yang besar akan terjadinya gempa bumi di Provinsi Jawa Timur di kemudian hari.



Gambar 1. 1 Jumlah Kejadian Gempa Bumi Jawa Timur 2008-2020 (sumber: BMKG)

Pendekatan estimasi mengenai jumlah kejadian gempa bumi maupun skala kekuatan atau magnitudo merupakan hal yang krusial dalam bidang mitigasi bencana. Penelitian yang bertujuan untuk memprediksi secara akurat kejadian seismik, termasuk waktu, magnitudo, dan lokasi pusat gempa, hingga saat ini belum dapat dilakukan dengan tepat. Hal ini disebabkan oleh tingginya tingkat ketidakpastian terkait gempa bumi, yang juga berpotensi menimbulkan risiko keresahan sosial di kalangan masyarakat (Suryanto, 2019). Pendekatan dengan cara memperkirakan frekuensi kejadian gempa bulanan maupun rata-rata magnitudo perbulan lebih efektif untuk dilaksanakan (Permana *et al.*, 2023). Sebuah model pendekatan yang mampu dijalankan penerapannya yakni melalui langkah memanfaatkan metode pembelajaran mesin (*machine learning*).

Pendekatan estimasi frekuensi dan magnitudo gempa bumi menjadi sangat penting dalam kerangka kesiapsiagaan menghadapi bencana, diantara manfaatnya sebagai berikut:

1. Prediksi atau estimasi frekuensi dan magnitudo gempa bumi memungkinkan untuk pengembangan perencanaan mitigasi bencana dan infrastruktur yang dapat meningkatkan keselamatan publik.
2. Estimasi frekuensi dan magnitudo gempa bumi membantu dalam menilai risiko terhadap infrastruktur kritis seperti bendungan, jembatan, rumah sakit, dan pusat transportasi.
3. Prediksi frekuensi dan magnitudo gempa bumi diperlukan dalam perencanaan pembangunan kota dan wilayah.

Dengan demikian, urgensi prediksi frekuensi kejadian magnitudo gempa bumi tidak hanya berdampak pada keselamatan masyarakat, tetapi juga pada pembangunan berkelanjutan, perlindungan aset infrastruktur, dan penanganan bencana secara keseluruhan.

Mengingat urgensi hal tersebut, telah banyak dilakukan penelitian yang terkait dengan prediksi maupun estimasi kejadian gempa bumi. Al Banna *et al.* (2020) telah mengumpulkan dan melakukan studi literatur jurnal ilmiah yang terdapat pada database IEEE Xplore, Science Direct, dan Google Scholar yang terkait dengan prediksi gempa bumi berbasis kecerdasan buatan (*artificial intellegence*) dan didapatkan sebanyak 292 jurnal ilmiah. Dari kesemua jurnal tersebut, metode jaringan saraf tiruan (ANN) yakni metode yang terpopuler serta paling sering dipergunakan, dengan persentase sebesar 33% (Al Banna *et al.*, 2020).

Seiring dengan kepopuleran algoritma tersebut, algoritma jaringan saraf tiruan terus berkembang dengan teknik dan model pembaharuan bobot yang baru. Pada penelitian prediksi gempa bumi berbasis jaringan saraf tiruan di Indonesia, telah coba dilakukan antara lain dengan algoritma seperti *standard backpropagation* dan *resilient backpropagation*. Implementasi model jaringan saraf tiruan *backpropagation* (BPNN) telah coba diterapkan untuk memprediksi jumlah kejadian gempa bumi per periode di Bengkulu. Penelitian itu memanfaatkan katalog data dari USGS, melalui hasil terbaiknya diperoleh melalui kombinasi arsitektur jaringan yang terdiri dari 12-4-1 (Agwil *et al.*, 2020). Metode

jaringan saraf tiruan *backpropagation* juga telah diuji tingkat performanya pada wilayah yang sama oleh Firdausa (2020) dengan hasil *error* terbaik 2,93.

Riedmiller *et al.*, (1992) telah coba mengembangkan algoritma *resilient backpropagation* (RPROP) untuk menyempurnakan algoritma *backpropagation* yang terdahulu. Algoritma ini dilakukan pengembangannya melalui cara memodifikasi bobot serta bias jaringan melalui proses adaptasi langsung berdasar pada informasi gradien lokal pada setiap iterasi pelatihan. Dalam beberapa penelitian sebelumnya, algoritma *resilient backpropagation* (RPROP) terbukti unggul karena mampu mempercepat proses pembelajaran dan menghasilkan tingkat kesalahan yang lebih rendah (Saputra *et al.*, 2017).

Maka dari hal tersebut, pada penelitian ini coba diterapkan uji performa algoritma jaringan saraf tiruan *resilient backpropagation* dan membandingkannya dengan algoritma *standard backpropagation* untuk mengestimasi skala kekuatan (magnitudo) gempa bumi dalam wilayah Jawa Timur. Penelitian ini menggunakan sumber katalog data lokal BMKG dan eksperimen beberapa kombinasi variabel arsitektur jaringan saraf tiruan, sehingga diharapkan akan didapatkan algoritma prediksi yang lebih akurat, efektif dan efisien yang nantinya dapat diaplikasikan di Jawa Timur.

Dalam perpektif agama Islam, dimana Al-Quran sebagai sumber pokok ajaran umat Islam, didalamnya juga mengandung ayat-ayat yang berkaitan dengan bencana. Ayat ini menjadi landasan keyakinan bagi seorang muslim dalam menyikapi dan menghadapi bencana yang terjadi. Diantaranya, dalam QS. Al Hadiid ayat 22 sebagai berikut.

مَا أَصَابَ مِنْ مُصِيبَةٍ فِي الْأَرْضِ وَلَا فِي أَنْفُسِكُمْ إِلَّا فِي كِتَابٍ مِنْ قَبْلِ أَنْ نَبْرَأَهَا إِنَّ ذَلِكَ عَلَى

اللَّهِ يَسِيرٌ

Artinya: “Tiada suatu bencanapun yang menimpa di bumi dan (tidak pula) pada dirimu sendiri melainkan telah tertulis dalam kitab (Lauh Mahfuzh) sebelum Kami menciptakannya. Sesungguhnya yang demikian itu adalah mudah bagi Allah.” (QS. Al-Hadiid:22).

Berdasarkan tafsir *tahlili* Kemenag RI (2022), ayat ini mengandung hikmah bahwa kejadian bencana terjadi atas kehendak beserta takdir yang dihadirkan oleh Allah *subhanahu wa ta’ala*. Pemahaman ini sangat penting, agar manusia tidak percaya pada tenung, ramalan dukun, dan agar manusia lebih mengedepankan evaluasi dan muhasabah diri atas bencana yang terjadi. Evaluasi dan muhasabah diri tersebut, diantaranya yakni dengan berikhtiar dalam melakukan mitigasi pencegahan dan kesiapsiagaan.

Didalam kerangka efektivitas dan efisiensi performa kerja, Allah *azza wa jalla* telah memberikan petunjuk yang disebutkan dalam surat Ar-Ra’d ayat 11 sebagai berikut,

إِنَّ اللَّهَ لَا يُغَيِّرُ مَا بِقَوْمٍ حَتَّى يُغَيِّرُوا مَا بِأَنْفُسِهِمْ

Artinya: “Sesungguhnya Allah tidak mengubah keadaan suatu kaum hingga mereka mengubah apa yang ada pada diri mereka.” (QS. Ar-Ra’d:11)

Menurut tafsir *tahlili* Kemenag RI (2022), sesungguhnya Allah Yang Mahakuasa tidak akan mengubah keadaan dalam sebuah kaum dari satu kondisi menuju pada kondisi yang lain, sebelum mereka melakukan perubahan pada keadaan diri yang bersangkutan dengan sikap mental beserta pemikiran mereka sendiri. Hal ini menunjukkan bahwasanya manusia wajib berusaha secara

maksimal melakukan yang terbaik, sebab Allah *subhanahu wa ta'ala* tidak akan menghadirkan hasil terbaiks selain apa yang telah diusahakan oleh manusia. Maka dari itu uji performa algoritma untuk pemilihan metode yang lebih akurat, efektif dan efisien perlu dilakukan, sebagai salah satu ikhtiar manusia dalam menghadapi bencana gempa bumi, agar didapatkan hasil yang akurat dengan cara kerja yang paling efektif dan efisien.

1.2 Pernyataan Masalah

Algoritma jaringan saraf tiruan sebagai salah satu metode *machine learning*, terus dikembangkan dengan berbagai macam teknik dan model pembaruan bobot. Maka dari itu diperlukan studi uji performa dari algoritma jaringan saraf tiruan untuk mengetahui algoritma dan model arsitektur yang paling efektif dan akurat dalam memprediksi gempa bumi berdasarkan tingkat kesalahan maupun lama waktu pembelajaran. Pernyataan permasalahan yang kemudian menjadi fokus pada pembahasan penelitian ini yang mencakupi :

- a. Bagaimana hasil pengujian performa algoritma jaringan saraf tiruan berdasarkan tingkat kesalahan dan lama waktu pelatihan jaringan.
- b. Bagaimana pengaruh strategi variasi arsitektur jaringan dengan performa jaringan saraf tiruan dalam memprediksi gempa bumi.

1.3 Tujuan Penelitian

Berdasar latar belakang serta pernyataan permasalahan yang sebelumnya, maka tujuan atas penelitian ini sebagai berikut:

- a. Mendapatkan hasil kinerja performa algoritma jaringan saraf tiruan *backpropagation* dan *resilient backpropagation* yang paling optimal, berdasarkan tingkat kesalahan dan lama waktu pelatihan.
- b. Menganalisis keterkaitan antara variasi arsitektur jaringan saraf tiruan dengan performa jaringan saraf tiruan, untuk mendapatkan hasil yang paling optimal.

1.4 Manfaat Penelitian

Secara umum manfaat penelitian ini yakni teruntuk kemajuan riset jaringan saraf tiruan, khususnya tentang performa kinerja jaringan saraf tiruan dalam memprediksi gempa bumi. Selain daripada itu manfaat penelitian ini diantaranya:

- a. Hasil penelitian dapat dimanfaatkan oleh pihak terkait, seperti BPBD, BNPB untuk kajian risiko gempa bumi di wilayah Jawa Timur.
- b. Hasil penelitian dapat dimanfaatkan BAPPEDA maupun Dinas PUPR dalam kaitannya dengan kajian perencanaan tata wilayah kota dan perencanaan kekuatan bangunan infrastruktur vital.

1.5 Batasan Masalah

Batasan masalah dalam prediksi gempa bumi ini yakni mencakup pada prediksi magnitudo gempa bumi di Jawa Timur melalui pertimbangan adanya potensi gempa bumi dikemudian hari pada wilayah ini. Penelitian ini menggunakan data kejadian gempa bumi di Jawa Timur mulai 1 Januari 2016 sampai 31 Desember 2023. Data ini yang nantinya digunakan untuk mengidentifikasi tren aktivitas seismik di masa yang akan datang nantinya.

BAB II

STUDI PUSTAKA

2.1 Prediksi Gempa Bumi Berbasis Jaringan Saraf Tiruan

Muzakir (2014) telah menerapkan jaringan saraf tiruan algoritma genetik (NNGA) dan ARIMA teruntuk memberi prediksi akan kekuatan gempa bumi di wilayah Maluku. NNGA adalah algoritma jaringan saraf tiruan yang dioptimalisasi dengan metode penurunan gradien agar diperoleh parameter yang lebih akurat. Hasil prediksi menunjukkan bahwa ARIMA memiliki nilai MSE sebesar 1,0125, sementara NNGA sebesar 0,9196. Nilai ini mengindikasikan bahwa model NNGA lebih unggul dibandingkan model ARIMA untuk memprediksi magnitudo gempa bumi.

Bhatia *et al.* (2018) telah mencoba mengembangkan teknik *nowcasting*, sebuah teknik baru peramalan gempa bumi di wilayah India yang didasariakan keterbatasan data gempa. Teknik ini memprediksi periode ulang gempa bumi dengan magnitudo yang lebih tinggi dengan memperhitungkan jumlah kejadian gempa yang lebih kecil di wilayah yang sama. Untuk menerapkan metode *nowcasting*, digunakan arsitektur jaringan saraf tiruan *Long Short Term Memory* (LSTM) karena jaringan tersebut yakni sebuah arsitektur yang cukup menjanjikan dalam analisis deret waktu. Hasil terbaik dari berbagai eksperimen didapatkan dengan akurasi 76.9%.

González *et al.* (2019) telah mencoba memprediksi magnitudo terbesar dari peristiwa yang terjadi dalam satu jam ke depan dengan menggunakan model *Recurrent Neural Network* (RNN) dan diterapkan pada katalog seismik Italia dari

tahun 1995 hingga 2018. Model jaringan saraf tiruan ini terbukti baik cukup baik untuk membuat prediksi magnitudo gempa bumi dengan selang waktu tertentu, walau hanya dengan mengambil satu informasi yang tersedia yakni magnitudo. Namun, karena gempa bumi dicirikan oleh beberapa variabel, kedepan variabel-variabel lain ini dapat ditambahkan ke dalam pola jaringan dan mungkin dapat membentuk pola yang lebih kuat yang dapat meminimalkan kesalahan prediksi.

Agwil *et al.* (2020) telah menerapkan jaringan saraf tiruan *backpropagation* dalam data *time series* magnitudo gempa bumi dan jumlah kejadian di Provinsi Bengkulu. Arsitektur yang terbentuk pada BPNN dipilih yang terbaik, dengan cara membandingkan hasil RMSE pada setiap arsitektur yang diuji. Hasil proses training yang dilakukan menunjukkan arsitektur 12-4-1 menghasilkan nilai RMSE terkecil sebesar 0,188.

Firdausa (2020) dengan metode *neural network* coba memprediksi kejadian gempa bumi juga telah dilakukan di Bengkulu. Sedikit berbeda dengan prediksi yang dilakukan sebelumnya, prediksi ini dilakukan dengan memasukkan tanggal, bulan dan magnitudo kejadian sebagai target, dengan durasi data selama satu tahun. Berdasarkan hasil uji, metode ini dapat diterapkan pada data deret waktu gempa bumi, dengan hasil error terbaik didapatkan sebesar 2,93.

Priambodo *et al.* (2020) menggunakan algoritma *resilient backpropagation* (RPROP) teruntuk memberi prediksi terkait magnitudo gempa bumi di Indonesia. Algoritma ini dipilih karena mempunyai kelebihan dalam kecepatan proses pelatihan dan tidak bergantung pada laju pembelajaran. Dengan algoritma ini, setiap bobot diperbarui secara spesifik, sehingga mampu memberikan akurasi

prediksi yang maksimal. Berdasarkan uji hasil percobaan yang dilakukan Priambodo *et al.* (2020), algoritma RPROP dapat menghasilkan RMSE minimum 0,093 dalam waktu 34,475 detik. Error ini sedikit lebih baik daripada menggunakan algoritma BPNN standar, dimana menghasilkan error sebesar 0,095, tetapi waktu yang dibutuhkan lebih cepat yakni 32,645 detik.

Pandit *et al.* (2021) coba menerapkan metode ANN dan ANFIS untuk memprediksi gempa bumi di Amerika Serikat. Data gempa bumi dari tahun 1906 hingga 2021 digunakan untuk membandingkan kinerja dari dua metode tersebut yakni ANN dan ANFIS. Dengan data input berupa waktu kejadian, lokasi, magnitudo dan kedalaman, didapatkan bahwa metode ANN memberikan hasil yang lebih akurat dan lebih efisien dibandingkan ANFIS. ANN menghasilkan RMSE sebesar 0,2 sementara ANFIS sebesar 0,6.

Somantri (2021) telah melakukan prediksi magnitudo gempa bumi di Indonesia melalui langkah mempergunakan metode jaringan syaraf tiruan yang sebelumnya dijalankan optimasi nilai parameter yang digunakan menggunakan *genetic algorithm*. Berdasarkan hasil pengujian, nilai RMSE model jaringan saraf tiruan yang dihasilkan sebesar 0,718. Usaha peningkatan akurasi setelah dilakukan optimasi *genetic algorithm* (GA) menghasilkan RMSE sebesar 0,708. Berdasarkan hasil pengujian, terjadi perbaikan nilai akurasi yang ditandai dengan menurunnya nilai RMSE yang diperoleh. Model yang didapatkan adalah model terbaik, yang nantinya dapat dimanfaatkan guna memberi prediksi akan magnitudo gempa bumi.

Pada studi kasus-kasus lain, metode BP juga telah dilakukan uji optimasi dengan menggunakan metode lainnya, mencakupi Genetic Algorithm (NNGA), *Particle Swarm Optimization* (PSO), Nguyen-Widrow (NW), Levenberg-Marquard (LM), dan juga *Resilient Backpropagation* (RPROP).

Nikentari *et al.* (2018) menggunakan algoritma *Particle Swarm Optimization* (PSO) untuk mengoptimalkan jaringan saraf tiruan teruntuk memprediksi ketinggian pasang surut. PSO dimanfaatkan untuk memperbaiki error minimum pada jaringan, sehingga bobot jaringan Artificial Neural Network (ANN) yang dihasilkan menjadi lebih optimal. Dataset yang dipergunakan berjumlah 1000 data, yang terbagi atas 70% teruntuk data latih serta 30% teruntuk data uji. Hasil eksperimen menunjukkan akurasi prediksi sebesar 91,56%.

Chrystiaditama (2019) melakukan penelitian jaringan saraf tiruan (JST) *backpropagation* mempergunakan metode Nguyen-Widrow untuk memprediksi pemilih nminat dan kompetensi keahlian siswa SMK. Algoritma Nguyen-Widrow diterapkan untuk mengatasi kelemahan JST, khususnya kesulitan dalam menginisialisasi bobot awal. Hasil pengujian data latih menunjukkan bahwa jaringan saraf tiruan Nguyen-Widrow mencapai rata-rata error Mean Squared Error (MSE) terkecil sebesar 0,002 dan rata-rata akurasi tertinggi sebesar 96,38%. Sedangkan, pada pengujian data uji, model ini memperoleh rata-rata error MSE terkecil sebesar 0,026 dan rata-rata akurasi tertinggi sebesar 87,85%.

Setiyaris *et al.* (2023) melakukan pelatihan beserta pengujian akan jaringan dalam memberi prediksi pada curah hujan melalui memadukan JST

backpropagation dengan LV-MQ. Performa MSE terbaik yang diperoleh berjumlah 0,02900 yang didapat dalam epoch 3 dengan lama pelatihan tidak sampai satu detik. Berdasarkan nilai MSE kinerja yang didapatkan selama pengujian, mengindikasikan performa kinerja jaringan saraf tiruan algoritma Levenberg-Marquardt, cocok diterapkan sebagai metode prediksi jumlah curah hujan..

Wati (2022) menyatakan bahwa metode RPROP terbukti mampu meningkatkan performa kinerja algoritma dari BPNN. Hal ini didasarkan pada perbandingan hasil akurasi model arsitektur terhadap data prediksi Indeks Pembangunan Manusia. Hasil pengujian terhadap empat model arsitektur, didapatkan satu model arsitektur terbaik, yakni dengan arsitektur 4-4-1. Pengujian dengan menggunakan metode BPNN menghasilkan nilai MSE berjumlah 0,0086485 bersama lama pelatihan 5 detik. Sementara melalui algoritma RPROP didapat nilai MSE 0,0082274 dengan lama pelatihan 1 detik. Pada optimasi dengan *resilient backpropagation* didapat waktu pengujian yang lebih cepat, MSE yang lebih rendah, dan peningkatan akurasi prediksi.

2.2 Kerangka Teoritis

Penelitian ini menggunakan pendekatan sistematis berdasarkan literatur jurnal dan karya-karya ilmiah terkait prediksi dengan menggunakan algoritma jaringan saraf tiruan, terutama yang berkaitan dengan prediksi gempa bumi.

Karya ilmiah tersebut, digunakan sebagai referensi dalam penulisan ini. Adapun karya ilmiah tersebut dirangkum melalui Tabel 2.1.

Tabel 2. 1 Studi Literatur

| No | Judul | Penulis | Metode | Variabel Input | Hasil |
|----|---|----------------------------|----------------|----------------------------------|---|
| 1 | Optimasi Parameter Neural Network Pada Data <i>Time Series</i> untuk Memprediksi Kekuatan Gempa Per Periode | Muzakir Hi Sultan (2014) | NNGA dan ARIMA | Magnitudo | Model NNGA menghasilkan <i>error</i> lebih baik dari model ARIMA untuk prediksi rata-rata magnitudo gempa bumi. |
| 2 | <i>Earthquake forecasting using artificial neural networks</i> | Bhatia, A (2018) | ANN (LSTM) | Magnitudo | Optimasi ANN dengan metode <i>deep learning</i> LSTM cukup menjanjikan untuk analisis deret waktu. |
| 3 | <i>Earthquake Magnitude Prediction Using Recurrent Neural Networks</i> | Gonzales (2019) | RNN | Magnitudo | Metode RNN cukup baik dalam memprediksi magnitudo dalam selang waktu tertentu. |
| 4 | Penerapan Jaringan Saraf Tiruan Pada Data Gempa Bumi Di Provinsi Bengkulu | Agwil <i>et al.</i> (2020) | BPNN | Jumlah kejadian GB dan Magnitudo | Hasil prediksi dengan arsitektur 12-3-1 menghasilkan nilai RMSE terkecil sebesar 0.188 |

| No | Judul | Penulis | Metode | Variabel Input | Hasil |
|----|---|---------------------------------------|------------------|---------------------------|---|
| 5 | <i>Prediction of earthquake magnitude using soft computing techniques: ANN and ANFIS</i> | Pandit <i>et al.</i> (2021) | ANN dan ANFIS | Parameter GB | ANN menghasilkan efisiensi dan akurasi lebih baik dibandingkan ANFIS. |
| 6 | Prediksi Kekuatan Gempa Bumi Indonesia Berdasarkan Nilai Magnitudo Menggunakan Neural Network | Soemantri (2021) | NN-GA | Magnitudo | Optimasi NNGA mampu menghasilkan kenaikan akurasi dalam prediksi magnitudo |
| 7 | Optimasi Jaringan Syaraf Tiruan Dengan Particle Swarm Optimization Untuk Prediksi Pasang Surut Air Laut | Nikentari (2018) | NN-PSO | Tinggi Pasut Air Laut | Optimasi PSO menghasilkan akurasi prediksi yang cukup baik dalam memprediksi ketinggian pasut air laut. |
| 8 | Optimasi Jaringan Syaraf Tiruan untuk Meningkatkan Akurasi Prediksi Pemilihan Kompetensi Keahlian Peserta Didik SMK Menggunakan Nguyen-widrow | Chrystiadit ama, <i>et al.</i> (2019) | NN-Nguyen Widrow | Kompetensi keahlian siswa | Penggunaan optimasi Nguyen-Widrow untuk mengatasi kelemahan JST dalam inisialisasi bobot awal, dengan hasil cukup baik. |
| 9 | Prediksi Curah Hujan Bulanan Berdasarkan Parameter Cuaca Menggunakan Jaringan Saraf Tiruan Levenberg Marquardt | Setiyaris <i>et al.</i> (2023) | BPNN dan NN-LVMQ | Parameter Cuaca | JST dengan optimasi Levenberg-Marquardt baik diterapkan dalam memprediksi curah hujan. |
| 10 | Prediksi dan Analisis Data Gempa Bumi di Provinsi Bengkulu dengan Metode Artificial Neural Network | Firdausa, F (2020) | BPNN | Waktu Origin Time GB | Hasil uji pada deret waktu gempa bumi, didapatkan error terbaik sebesar 2.93 |

| No | Judul | Penulis | Metode | Variabel Input | Hasil |
|----|--|------------------|----------------|----------------------------|---|
| 11 | Analisis Backpropagation Dengan Optimasi Metode Resilient Pada Prediksi IPM Berdasarkan Rata-Rata Lama Sekolah | Wati, A. (2022) | BPNN dan RPROP | Indeks Pembangunan Manusia | Metode RPROP terbukti mampu meningkatkan performa kinerja algoritma standar BPNN, baik itu dari segi kecepatan pelatihan dan hasil error yang lebih baik. |
| 12 | Aplikasi Jaringan Syaraf Tiruan Resilient Backpropagation Pada Prediksi Magnitudo Dan Lokasi Gempa Bumi. | Priambodo (2020) | RPROP dan BPNN | Magnitudo | RPROP menghasilkan error yang lebih baik daripada menggunakan algoritma BP standar dan waktu yang dibutuhkan lebih cepat. |

Berdasar pada studi literatur sistem prediksi gempa bumi berbasis jaringan saraf tiruan, algoritma BPNN yakni algoritma jaringan saraf tiruan yang cukup populer dan paling banyak digunakan dibanding algoritma lain (Tabel 2.1). Jaringan saraf tiruan BPNN terus dikembangkan dengan teknik dan model pembobotan baru, seperti algoritma genetik (GA), Nguyen Widrow, *Particle Swarm Optimization* (PSO), Levenberg Marquardt (LV MQ), maupun dengan algoritma *resilient backpropagation* (RPROP).

Data masukan pada sistem prediksi gempa bumi tersebut bersumber dari data historis parameter kejadian gempa bumi. Parameter tersebut tersimpan dalam katalog data gempa bumi yang terdiri dari lokasi, tanggal dan waktu asal kejadian (*origin time*), magnitudo dan kedalaman. Katalog gempa bumi ini bersumber dari lembaga nasional atau internasional terkait, seperti USGS, GFZ, IRIS, BMKG dll.

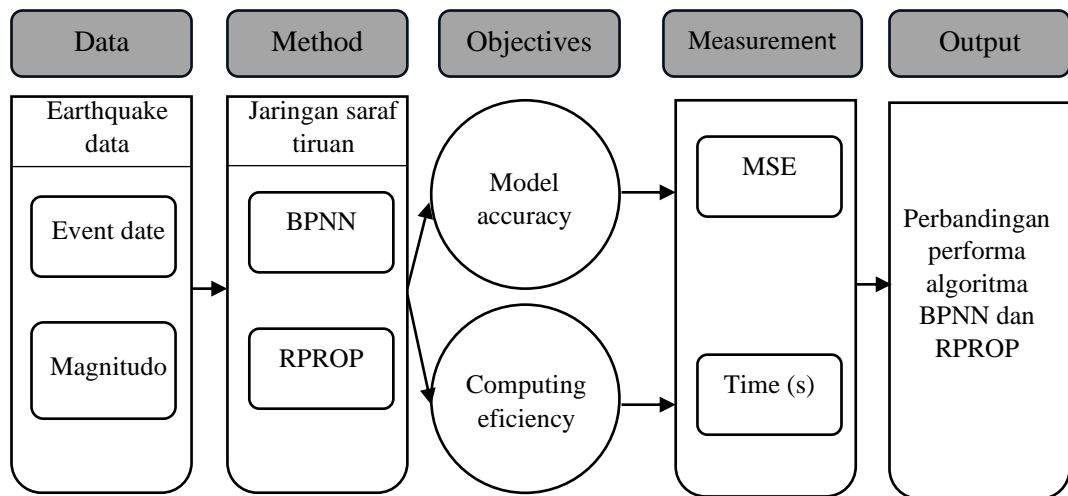
Hasil performa tiap-tiap algoritma penelitian tersebut mampu diperhatikan melalui

Tabel 2.2.

Tabel 2. 2 Performa Kinerja Sistem Prediksi Gempa Bumi Berbasis JST

| No | Penulis | Metode | Performa kinerja | |
|----|----------------------|------------------|------------------|------------------|
| | | | Akurasi | Error |
| 1 | Muzakir, 2014 | NN-GA | | 0,9196 |
| | | ARIMA | | 1,0125 |
| 2 | Bhatia dkk., 2018 | NN (LSTM) | 76.9% | |
| 3 | González dkk., 2019 | RNN | | |
| 4 | Agwil, 2020 | BPNN | | 0,180 |
| 5 | Firdausa, 2020 | BPNN | | 2,93 |
| 6 | Pandit & Panda, 2021 | ANN | | 0,2 |
| | | ANFIS | | 0,6 |
| 7 | Priambodo, 2020 | BPNN | | 0,095 |
| | | RPROP | | 0,093 |
| 8 | Somantri, 2021 | BPNN | | 0,718 |
| | | NN-GA | | 0,708 |
| 9 | Nikentari, 2018 | NN-PSO | 91.56% | |
| 10 | Chrystiaditama, 2019 | NN-Nguyen Widrow | 87.85% | |
| 11 | Setiyaris, 2023 | NN-LV MQ | | 0,0290 |
| 12 | Wati, 2022 | BPNN | | 0,0086485 |
| | | RPROP | | 0,0082274 |

Berdasar pada berbagai sebelumnya tersebut, metode jaringan saraf tiruancoba diaplikasikan dalam data historis gempa bumi di Jawa Timur, yakni dengan algoritma standar *backpropagation* (BPNN) dan *resilient backpropagation* (RPROP), yang terbukti populer dan memiliki tingkat akurasi cukup baik. Pemilihan kedua metode ini, selain dikarenakan menghasilkan tingkat error paling kecil (Tabel 2.2), juga diyakini algoritma RPROP mampu meminimalisir waktu pelatihan dibandingkan algoritma yang lain, seperti dijelaskan oleh Priambodo *et al.* (2020) dan Wati (2022). Penerapan algoritma tersebut, dilakukan untuk memprediksi magnitudo di wilayah Jawa Timur.



Gambar 2. 1 Kerangka Teori

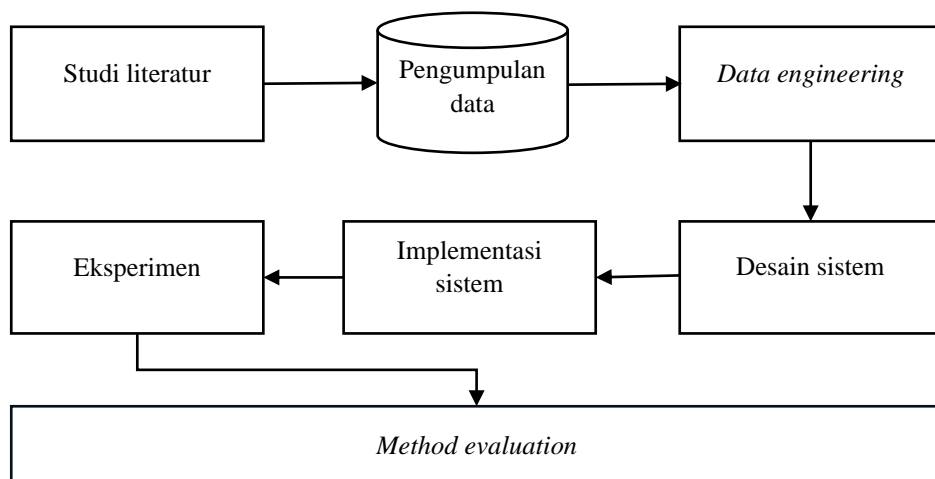
Sumber data pada penelitian ini,mempergunakan katalog data Pusat Gempa Bumi Regional VII BMKG, yang kemudian kita lakukan perhitungan dengan metode BPNN dan RPROP. Dari kedua metode tersebut dilakukan evaluasi performa dengan mengukur akurasi dan efisiensi algoritma berdasarkan MSE dan waktu pelatihan. Sehingga nantinya didapatkan hasil perbandingan uji performa dari kedua metode tersebut (Gambar 2.1).

BAB III

METODE PENELITIAN

3.1 Tahapan Penelitian

Konsep gambaran tahapan penelitian ini tercantum dalam diagram Gambar 3.1. Tahapan pertama yaitu studi literatur, mengumpulkan data gempa bumi dalam katalog gempa bumi, pengembangan sistem (*backpropagation neural network* dan *resilient backpropagation neural network*), eksperimen, komparasi dan terakhir kesimpulan.



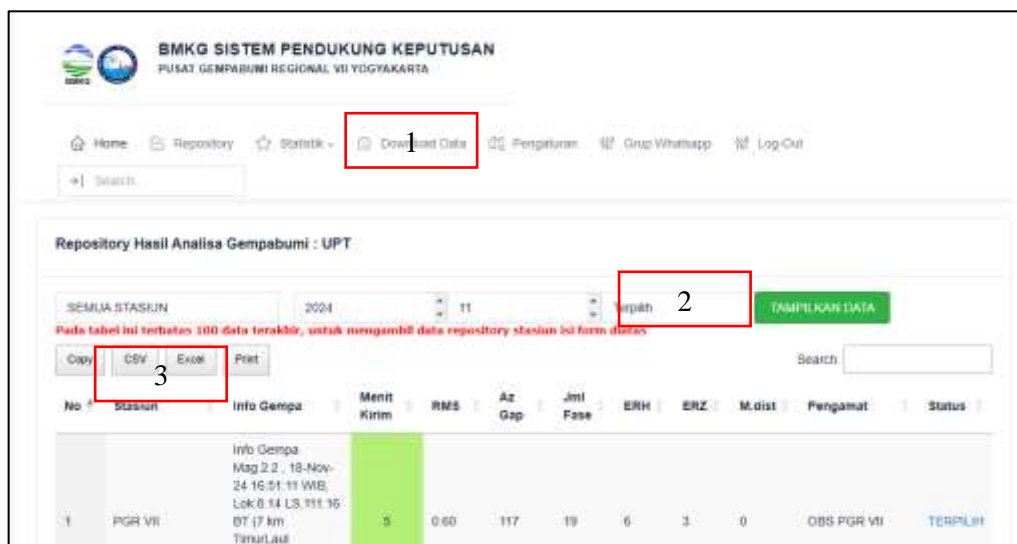
Gambar 3. 1 Tahapan Penelitian

3.1.1 Studi Literatur

Dalam studi literatur ini, dijalankan pengumpulan, kajian, beserta review terhadap karya ilmiah yang membahas tentang prediksi gempa bumi, terutama yang menggunakan metode pembelajaran mesin jaringan saraf tiruan. Karya ilmiah yang digunakan merupakan karya ilmiah terbaru dalam 10 tahun terakhir, yang terindeks dalam *web of science* maupun *google scholar*.

3.1.2 Pengumpulan Data

Data yang dipergunakan untuk penelitian ini adalah data historis parameter gempa bumi melalui BMKG Pusat Gempa Bumi Regional VII (PGR VII). Data tersebut meliputi peristiwa gempa bumi di wilayah Jawa Timur serta sekitarnya, sejak 1 Januari 2016 – 31 Desember 2023. Parameter data gempa terdiri dari waktu kejadian, magnitudo, kedalaman, dan lokasi pusat gempa. Data diambil dengan akses dari Sistem Pendukung Keputusan (SPK) PGR VII.



Gambar 3. 2 Cara Pengumpulan Data (screenshot SPK PGR VII)

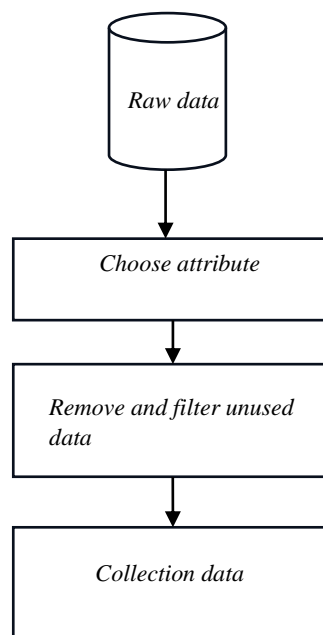
Pada Gambar 3.2, ada alur proses cara pengambilan data secara online melalui SPK PGR VII. Alur pengambilan data dapat dilakukan setelah pengguna melakukan login ke sistem, dengan proses sebagai berikut:

1. Pilih menu download data di menu SPK.
2. Pada bagian repository hasil analisa gempa bumi, tentukan waktu data gempa bumi yang akan diunduh, klik tampilkan data.
3. Klik pada format data csv/excel, lalu data akan terunduh secara otomatis.

Komponen input untuk sistem prediksi magnitudo dari data tersebut berbentuk numerik dengan variabel rata-rata magnitudo bulanan, sehingga data parameter gempa bumi dalam bentuk katalog dikelompokkan menjadi jumlah kejadian gempa bumi per bulan.

3.1.3 Rekayasa Data

Pada tahapan ini, *raw data* hasil pengumpulan data sebelumnya dilakukan proses rekayasa data, karena *raw data* masih bersifat data mentah. Alur proses *data engineering* dijelaskan dalam Gambar 3.3.



Gambar 3. 3 Diagram data engineering

Tahapan pertama yang dijalankan yakni melakukan pemilihan akan atribut data yang dipergunakan sebagai dataset penelitian. Tahapan berikutnya melakukan pemilihan akan masing-masing data tersebut melalui langkah membuang data yang tidak dipergunakan serta dilakukan penyaringan data yang akan digunakan.

Pada proses pemilihan atribut, data yang dipilih yakni data yang dipakai dengan proses utama yang dilangsungkan. Pada tahap ini pemilihan atribut mempergunakan tanggal dan magnitudo (mag). Raw detail dataset pada penelitian ini diperlihatkan melalui Tabel 3.1 berikut:

Tabel 3. 1 Detail Dataset

| No | Atribut | Type | Variabel |
|----|-----------|---------|------------|
| 1 | Station | String | Independen |
| 2 | Tanggal | Date | Independen |
| 3 | Mag | Numeric | Independen |
| 4 | Lat | Numeric | Independen |
| 5 | Long | Numeric | Independen |
| 6 | Depth | Numeric | Independen |
| 7 | Menit ke- | Numeric | Independen |
| 8 | Az Gap | Numeric | Independen |
| 9 | Jml Fase | Numeric | Independen |

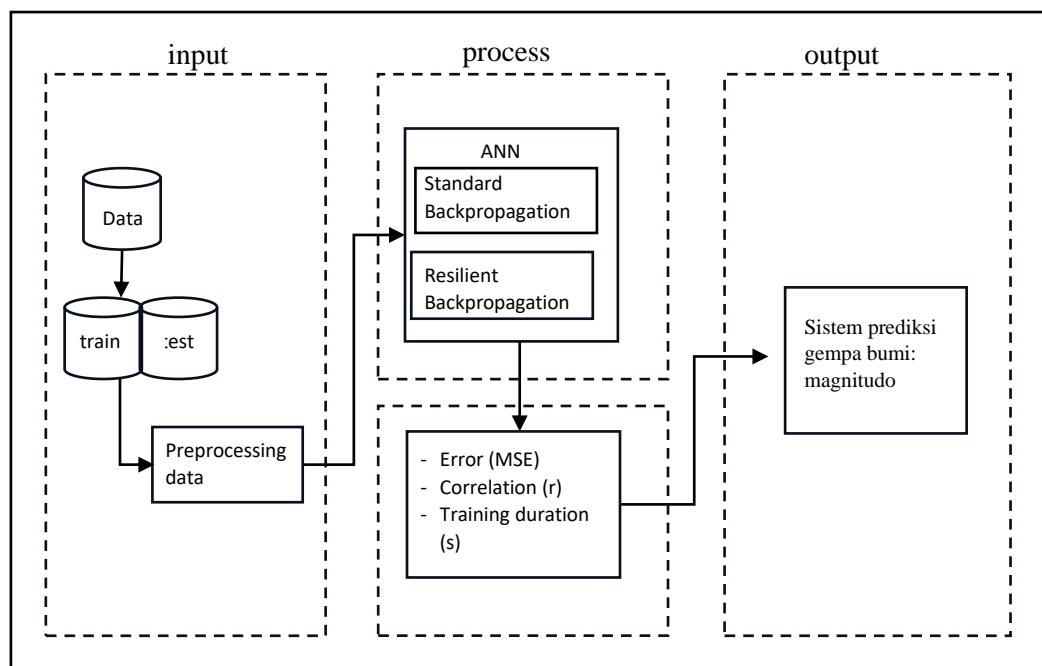
Proses selanjutnya yakni filterisasi data adalah tahapan merakit data agar siap untuk dijalankan proses pelatihan dan pengujian. Bentuk data final seperti diperlihatkan melalui Tabel 3.2.

Tabel 3. 2 Penggalan Data Akhir

| Date | Mag |
|------------|-------|
| 01/01/2016 | 3,377 |
| 01/02/2016 | 2,805 |
| 01/03/2016 | 3,348 |
| ... | |
| ... | |
| ... | |
| 01/10/2023 | 2,517 |
| 01/11/2023 | 2,502 |
| 01/12/2023 | 2,328 |

3.1.4 Desain Sistem

Tahapan perancangan sistem ini menyajikan penjelasan terkait dengan bagaimana sistem memberi prediksi akan magnitudo gempa bumi berdasar model ANN dengan dua algoritma pembaruan bobot yang berbeda, seperti disajikan pada Gambar 3.4 berikut.



Gambar 3. 4 Desain Sistem

Pada Gambar 3.4, sebelum dilakukan proses pengolahan, dataset gempa bumi dilakukan *preprocessing*, yakni dilakukan normalisasi data. Normalisasi ini dilakukan dengan mengubah skala data, agar memudahkan dalam mengolah dan menganalisis data. Untuk desain sistem dalam proses ini, keduanya sama menggunakan algoritma jaringan saraf tiruan. Perbedaannya dalam algoritma *backpropagation* menggunakan metode laju pembelajaran dan *gradien descent* untuk menyesuaikan bobot jaringan, sedangkan dalam metode *resilient backpropagation* tidak bergantung pada laju pembelajaran dan besar gradien,

tetapi hanya memperhatikan tandaarah perubahan yang berbeda (naik atau turun) untuk tiap-tiap bobot.

3.1.5 Implementasi Sistem

Sistem akan dilakukan pengimplementasiannya pada mesin komputer bersama spesifikasi sebagai berikut:

1. CPU 4core, 2.5Ghz.
2. RAM 8GB
3. OS Windows 10

Perbandingan data dalam implementasi antara data *training* dan *testing* sebesar 70:30. Implementasi jaringan dengan bahasa pemrograman R melalui bantuan aplikasi Rstudio. Implementasi lebih detail selanjutnya dibahas pada bab tersendiri.

3.1.6 Eksperimen

Tahap eksperimen ini yakni dengan memprediksi nilai magnitudo di masa mendatang berdasarkan model algoritma dan arsitektur ANN yang telah ditentukan. Setelah diperoleh hasil prediksi, kemudian dijalankan analisis pada hasil prediksi dengan membandingkan hasil prediksi yang berasal dari beberapa arsitektur model yang telah diusulkan.

Dalam metode *neural network*, tidak terdapat aturan pasti untuk penentuan arsitektur model terbaik, sehingga pemilihan suatu desain arsitektur dijalankan berdasar pada kebutuhan model melalui cara modifikasi jumlah input node, maupun neuron pada *hidden layer*, yang berdasar pada studi literatur sebelumnya yang kemudan dievaluasi dengan formula MSE.

Dalam penelitian ini dilakukan eksperimen berdasarkan *benchmark* arsitektur terbaik penelitian sebelumnya sekaligus *trial and error* beberapa variasi arsitektur dari jumlah input neuron, maupun jumlah neuron pada *hidden layer*. Hal ini dijalankan guna menganalisis keterkaitan variasi input dan neuron hidden dengan tingkat error. Variasi susunan input pelatihan JST dengan algoritma *standar backpropagation* (BPNN) untuk prediksi data magnitudo seperti tertera pada Tabel 3.2 ini.

Tabel 3. 3 Desain Pelatihan Standar *Backpropagation* untuk Data Magnitudo

| Algoritma | Data | Arsitektur | Kode |
|--------------------------------------|-----------|----------------|---------------|
| <i>Standar Backropagation</i> (BPNN) | Magnitudo | 4-4-1 | BP-M1 |
| | | 4-6-1 | BP-M2 |
| | | 4-10-1 | BP-M3 |
| | | 4-23-1 | BP-M4 |
| | | 8-4-1 | BP-M5 |
| | | 8-6-1 | BP-M6 |
| | | 8-10-1 | BP-M7 |
| | | 8-23-1 | BP-M8 |
| | | 10-4-1 | BP-M9 |
| | | 10-6-1 | BP-M10 |
| | | 10-10-1 | BP-M11 |
| | | 10-23-1 | BP-M12 |
| | | 12-4-1 | BP-M13 |
| | | 12-6-1 | BP-M14 |
| | | 12-10-1 | BP-M15 |
| | | 12-23-1 | BP-M16 |

Variasi susunan input pelatihan JST dengan algoritma *resilient backpropagation* (RPROP) untuk penggunaan data frekuensi seperti tertera melalui Tabel 3.4.

Tabel 3. 4 Desain Pelatihan *Resilient Backpropagation* untuk Data Magnitudo

| Algoritma | Data | Arsitektur | Kode |
|--|-----------|----------------|---------------|
| <i>Resilient Backpropagation</i> (RPROP) | Magnitudo | 4-4-1 | RP-M1 |
| | | 4-6-1 | RP-M2 |
| | | 4-10-1 | RP-M3 |
| | | 4-23-1 | RP-M4 |
| | | 8-4-1 | RP-M5 |
| | | 8-6-1 | RP-M6 |
| | | 8-10-1 | RP-M7 |
| | | 8-23-1 | RP-M8 |
| | | 10-4-1 | RP-M9 |
| | | 10-6-1 | RP-M10 |
| | | 10-10-1 | RP-M11 |
| | | 10-23-1 | RP-M12 |
| | | 12-3-1 | RP-M13 |
| | | 12-6-1 | RP-M14 |
| | | 12-10-1 | RP-M15 |
| | | 12-23-1 | RP-M16 |

3.1.6 Evaluasi

Tingkat akurasi beserta kecepatan proses pelatihan dapat memperlihatkan kinerja algoritma yang telah dijalankan dalam proses pelatihan. Pada tahap ini dijalankan rekapitulasi hasil melalui uji coba serta dianalisis mempergunakan tabel dan grafik, sehingga dapat digunakan untuk penelitian lebih lanjut.


Nilai *loss function* yang didapat akan dievaluasi dengan menggunakan MSE, sehingga dapat dibandingkan besar selisish antara nilai prediksi dan nilai aktual.

$$MSE = \frac{\sum_{i=1}^n (tk - yk)^2}{n} \quad (3.1)$$

Dimana *tk* merupakan nilai aktual observasi, *yk* merupakan nilai prediksi, dengan *n* adalah jumlah data observasi.

3.2 Instrumen Penelitian

Instrumen penelitian ini yakni data magnitudo gempa bumi tahun 2016-2023 yang bersumber dari PGR VII BMKG. Variabel bebas dalam penelitian ini yakni nilai magnitudo, sedangkan variabel terikat dalam penelitian ini yakni MSE (*mean squared error*), *t* (waktu pelatihan), dan *r* (korelasi). Variabel intervening dari penelitian ini adalah sistem prediksi magnitudo gempa bumi. Instrumen penelitian selengkapnya seperti pada Gambar 3.5 berikut.




Gambar 3. 5 Instrumen penelitian

BAB IV

PREDIKSI MAGNITUDO DENGAN JARINGAN SARAF TIRUAN

4.1 Desain

Desain input data untuk jaringan saraf tiruan pada penelitian ini adalah data parameter gempa bumi berupa magnitudo gempa bumi sebagai input (x_i), data bobot lapisan input menuju layer (w_{ij}), hasil output pada *hidden layer* (z_j), nilai bobot antar *hidden layer* menuju output (v_{jk}) dan nilai output berupa prediksi nilai magnitudo gempa bumi (y_k).

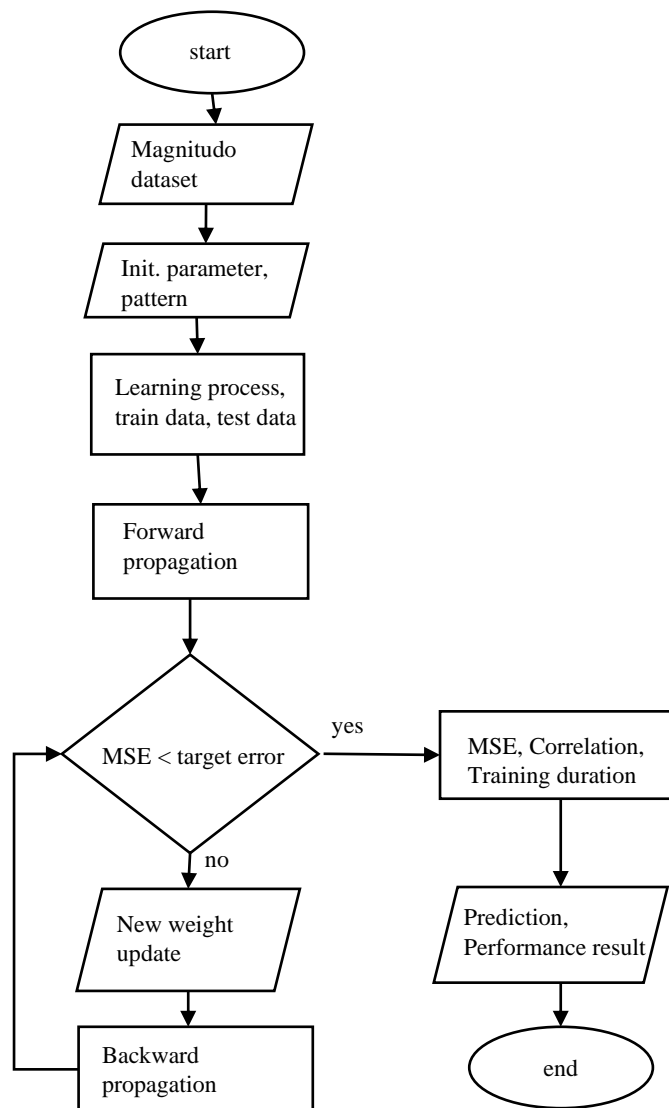


Gambar 4. 1 Desain Jaringan Saraf Tiruan

Desain jaringan saraf tiruan melalui Gambar 4.1, dilakukan perubahan variasi jumlah input data (X) dan variasi jumlah neuron dalam hidden layer (Z). Sedangkan jumlah neuron dalam lapisan output data (Y) dan *hidden layer* tetap

berjumlah satu. Variasi ini dilakukan agar didapatkan desain arsitektur terbaik pada jaringan saraf tiruan, selain itu diperlukan untuk menganalisis kaitan desain arsitektur tersebut dengan performa jaringan.

Diagram alir dari model prediksi magnitudo dengan jaringan saraf tiruan backpropagation ditunjukkan pada Gambar 4.2 berikut.



Gambar 4. 2 Diagarm Alir Desain Jaringan Saraf Tiruan *Backpropagation*

4.2 Implementasi Sistem Prediksi Magnitudo dengan Jaringan Saraf Tiruan

Pada tahapan implementasi algoritma jaringan saraf tiruan *backpropagation*, langkah utama yang perlu dilangsungkan yakni normalisasi data. Normalisasi diperlukan dalam pengolahan dengan algoritma *backpropagation* dan *resilient backpropagation* karena menggunakan fungsi aktivasi sigmoid. Normalisasi dilakukan dengan menggunakan nilai maksimum dan minimum dari seluruh data (Adi *et al.*, 2018).

$$x' = 0,1 + \frac{0,8(x-y)}{(z-y)} \quad (4.1)$$

Data x' merupakan data normalisasi, x adalah data ke- n yang dinormalisasikan, y data minimum, dan z merupakan data maksimum.

Berdasarkan dataset magnitudo yang digunakan, didapatkan $y= 2,328$ dan $z= 3,929$. Berikut contoh sampel perhitungan normalisasi dan sampel data normalisasi.

$$x1 = 0,1 + (0,8*(3,377-2,328)/(3,929-2,328)) = 0,624215$$

$$x2 = 0,1 + (0,8*(2,805-2,328)/(3,929-2,328)) = 0,338108$$

$$x3 = 0,1 + (0,8*(3,348-2,328)/(3,929-2,328)) = 0,609448$$

Tabel 4. 1 Sampel Data Hasil Normalisasi

| Pola | $x1$ | $x2$ | $x3$ | $x4$ | Target |
|------|----------|------------|----------|----------|----------|
| 1 | 0,624215 | 0,33810804 | 0,609448 | 0,739486 | 0,692769 |
| 2 | 0,338108 | 0,60944806 | 0,739486 | 0,692769 | 0,867271 |
| 3 | 0,609448 | 0,73948559 | 0,692769 | 0,867271 | 0,729939 |
| 4 | 0,739486 | 0,69276865 | 0,867271 | 0,729939 | 0,727376 |
| ... | ... | ... | ... | ... | ... |
| n | 0,307048 | 0,29539643 | 0,264835 | 0,194486 | 0,186839 |

4.2.1 Algoritma Standar *Backpropagation* (BPNN)

Pada jaringan saraf tiruan *backpropagation*, terdapat 4 tahap proses utama, yakni inisialisasi, fungsi aktivasi, pembaruan bobot, dan iterasi. Pada contoh implementasi ini, digunakan desain arsitektur 4-4-1, *learning rate* 0,1 beserta target error 0,05.

a) Inisialisasi bobot dan bias.

Inisialisasi bobot dilakukan mempergunakan bilangan acak kecil antara 0-

1. Inisialisasi bobot yang dilakukan pada lapisan input ke *hidden layer* seperti melalui Tabel 4.2.

Tabel 4. 2 Inisialisasi Bobot dan Bias Input ke *Hidden Layer* (w_{ij})

| variabel | <i>z1</i> | <i>z2</i> | <i>z3</i> | <i>z4</i> |
|-----------|-------------|------------|------------|------------|
| <i>x1</i> | 0,973446949 | 0,44751798 | 0,20951026 | 0,04195624 |
| <i>x2</i> | 0,301331956 | 0,18628498 | 0,849048 | 0,87981882 |
| <i>x3</i> | 0,391869385 | 0,24136687 | 0,16333439 | 0,88969591 |
| <i>x4</i> | 0,808800688 | 0,64659693 | 0,75872988 | 0,28239011 |
| B | 0,859945291 | 0,3002092 | 0,78806007 | 0,89378696 |

Inisialisasi selanjutnya dilakukan pada hidden layer ke output layer seperti melalui Tabel 4.3 berikut.

Tabel 4. 3 Inisialisasi Bobot pada *Hidden Layer* ke *Output Layer* (v_{jk})

| bobot | Y1 |
|-----------|-----------|
| z1 | 0,755457 |
| z2 | 0,056219 |
| z3 | 0,284221 |
| z4 | 0,118967 |
| B | 0,32524 |

b) Fase propagasi maju

Ketika setiap *input node* melakukan penerimaan akan sinyal, sinyal lalu dilakukan penerusannya ke *hidden layer*. Kemudian hitung nilai *output* dari *hidden layer* ($z_{net j}$), sebagai berikut :

$$z_{net j} = \sum_{i=1}^n X_i W_{ij} + W_{0j} \quad (4.2)$$

$$z_{net j}$$

$$= (0,9734 * 0,6242) + (0,3013 * 0,3381) + (0,3918 * 0,6094) + (0,8088 * 0,7394) + 0,8599$$

$$= 2,4064$$

Kemudian hitung seluruh output pada *hidden layer* bersama fungsi aktivasi, sebagai berikut.

$$z_j = f(z_{net j}) = \frac{1}{1 + e^{-z_{net j}}} \quad (4.3)$$

$$z_j = f(z_{net j}) = \frac{1}{1 + e^{-2,4064}}$$

$$z_j = 0,9173$$

Ketika nilai tiap neuron pada hidden layer telah didapat, lalu hitung hasil pada output neuron $y_{net k}$.

$$y_{net k} = v_{0k} + \sum_{j=1}^k z_j v_{jk} \quad (4.4)$$

$$y_{net k} =$$

$$0,3252 + (2,4064 * 0,7554) + (1,2678 * (0,0562)) + (1,8665 * (0,2842)) + (1,9685 * 0,1189)$$

$$= 2,9791$$

Fungsi aktivasi *sigmoid biner* kita gunakan untuk menghitung sinyal output, sebagai berikut.

$$y_j = f(y_{net k}) = \frac{1}{1 + e^{-y_{net k}}} \quad (4.5)$$

$$y_j = \frac{1}{1 + e^{-(2,9791)}}$$

$$y_j = 0,9516$$

c) Fase Propagasi mundur

Menghitung faktor kesalahan (δ_k) dalam *output layer* (y_k).

$$\delta_k = (t_k - y_k) f'(y_{net_k}) \quad (4.6)$$

Dengan,

$$f'(y_{net_k}) = (1 - f(y_{net_k})) f(y_{net_k}) \quad (4.7)$$

$$\delta_k = (0,6926 - 0,9516) * ((1 - 0,9516) * 0,9516)$$

$$\delta_k = -0,01192$$

Hitung besarnya koreksi tambahan pada bobot lama dengan galat yang telah didapat sebelumnya sebagai berikut.

$$\Delta w_{ij} = \alpha \delta_j x_i \quad (4.8)$$

$$\Delta w_{1,0} = 0,1 * (-0,1192) * 1$$

$$= -0,00119$$

$$\Delta w_{1,1} = 0,1 * (-0,1192) * 0,24064$$

$$= -0,00287$$

Hitung galat yang terdapat di *input layer* beserta *hidden layer*.

$$\delta_j = \delta_{net_j} f'(z_{net_j}) \quad (4.9)$$

Dimana:

$$\delta_{net_j} = \sum_{k=1}^m \delta_k v_{jk} \quad (4.10)$$

$$f'(z_{net_j}) = (1 - f(z_{net_j})) f(z_{net_j}) \quad (4.11)$$

$$\begin{aligned}\delta_{net j} &= -0,01192 * 0,75545 \\ &= -0,00900\end{aligned}$$

$$\delta_1 = -0,00900 * 0,9173(1-0,9173)$$

$$\delta_1 = -0,00068$$

Hitung koreksi bobot.

$$\Delta w_{ij} = \alpha \delta_k z_j \quad (4.12)$$

$$\Delta w_{ij} = 0,1 * (-0,00019) * 0,6242$$

$$\Delta w_{ij} = -0,000011$$

d) Fase perubahan bobot

Hitung perubahan bobot yang menuju ke *hidden layer*.

$$w_{ij}(\text{baru}) = w_{ij}(\text{lama}) + \Delta w_{ij} \quad (4.13)$$

$$w_{ij}(\text{baru}) = 0,97344 + (-0,000011)$$

$$w_{ij}(\text{baru}) = 0,973429$$

Berikut hasil bobot baru dari input ke hidden layer, seperti pada Tabel 4.4.

Tabel 4. 4 Nilai Bobot Baru dari Input Layer ke Hidden Layer

| variabel | z1 | z2 | z3 | z4 |
|----------|---------|---------|---------|---------|
| x1 | 0.97343 | 0.44748 | 0.20947 | 0.04191 |
| x2 | 0.30133 | 0.18628 | 0.84904 | 0.87981 |
| x3 | 0.39185 | 0.24134 | 0.16331 | 0.88967 |
| x4 | 0.80879 | 0.64659 | 0.75872 | 0.28238 |
| B | 0.85956 | 0.29982 | 0.78767 | 0.89340 |

Selanjutnya melakukan pembaruan bobot dari hidden layer menuju output layer.

$$v_{jk}(\text{baru}) = v_{jk}(\text{lama}) + \Delta w_{jk} \quad (4.14)$$

$$v_{jk}(\text{baru}) = 0,75546 + (-0,00287)$$

$$v_{jk}(\text{baru}) = 0,75259$$

Berikut hasil update bobot atas hidden layer menuju output layer seperti dalam Tabel 4.5.

Tabel 4. 5Nilai Bobot Baru dari Hidden Layer ke Output Layer

| bobot | Y1 |
|--------------|-----------|
| Z1 | 0.75259 |
| Z2 | 0.05471 |
| Z3 | 0.28200 |
| Z4 | 0.11662 |
| B | 0.32405 |

4.2.3 Algoritma *Resilient Backpropagation*(RPROP)

Proses pelatihan pada algoritma *resilient backpropagation* mirip dengan pelatihan algoritma *standard backpropagation*, perbedaannya terletak pada proses pembaharuan bobotnya. Penerapan algoritma *resilient backpropagation*, diyakini mampu memberikan hasil yang lebih akurat dan proses pelatihan yang lebih singkat. Hal ini disebabkan salah satunya adalah adanya penerapan adaptasi laju pembelajaran. Pada *backpropagation* standar, laju belajar tetap konstan atau menurun secara linier sepanjang pelatihan. Pada algoritma *resilient backpropagation* (RPROP) secara adaptif menyesuaikan laju belajar untuk setiap bobot secara individu. Jika gradien tetap pada tanda yang sama setelah beberapa iterasi, laju pembelajaran untuk bobot tersebut akan ditingkatkan. Jika tanda gradien berubah, ini menunjukkan bahwa bobot telah melewati minimum lokal, sehingga laju pembelajaran akan dikurangi.

Adapun proses pembaharuan bobot dari *hidden layer* menuju *output layer* sebagai berikut.

a) Fase Propagasi Mundur

Nilai fungsi aktifasi yang dihasilkan *hidden layer* pada tiap node diteruskan ke *output layer*. Kemudian hitung error (Nz_1) dan gradien error (δo (Nz_1)).

$$(Nz_1) = (ez_1) - (fz_1) \quad (4.15)$$

$$(Nz_1) = 1 - 0.9516 = 0,0484$$

$$\begin{aligned} \delta o (Nz_1) &= (ez_1) \times [1 - (ez_1)] \times (Nz_1) & (4.16) \\ &= 0,9516 * (1 - 0,9516) * 0,0484 \\ &= 0,002227 \end{aligned}$$

Nilai function, error dan gradien error tercantum pada Tabel 4.6 berikut.

Tabel 4. 6 Nilai Function, Error dan Gradien Error

| Neuron | Function | Error | Gradien error |
|--------|----------|--------|---------------|
| 1 | 0,9516 | 0.0484 | 0.002227 |

Cari nilai delta untuk melakukan perubahan bobot.

$$\Delta j(t) = -\text{sign}(\text{gradient error}) * 0.1 \quad (4.17)$$

$$\Delta j(t) = -\text{sign}(0.002227) * 0.1 = -0.1$$

b) Pembaruan bobot

Pembaruan bobot dari *hidden layer* ke *output layer*.

$$\Delta v_{1.1} = \Delta v(t) + \Delta I(t) \quad (4.18)$$

$$\Delta v_{1.1} = 0.7554 + (-0.1) = 0.6554$$

Nilai bobot baru dari hidden layer ke output layer seperti dalam Tabel 4.7.

Tabel 4. 7 Hasil Pembaruan Bobot dari Hidden ke Output Layer

| <i>bobot</i> | <i>Y1</i> |
|--------------|-----------|
| <i>Z1</i> | 0.65546 |
| <i>Z2</i> | -0.04378 |
| <i>Z3</i> | 0.18422 |
| <i>Z4</i> | 0.01897 |

Hitung hasil gradien error pada input layer ke hidden layer (Tabel 4.8).

$$\delta h(Ny1) = f(Ny1) \times [1 - f(Ny1)] \times \sum \delta o(p). w_0 \quad (4.19)$$

$$\delta h(Ny1) = 0,9173 * (1-0,9173) * (0,002227*0,65546) = 0,00011$$

Tabel 4. 8 Nilai Gradien Error pada Hidden Layer

| <i>Neuron</i> | <i>Nilai Gradien Error</i> |
|---------------|----------------------------|
| 1 | 0,00011 |
| 2 | 0,00025 |
| 3 | 0,00017 |
| 4 | 0,00016 |

Cari nilai delta untuk perubahan bobot pada input ke hidden layer.

$$\Delta wh1 = -\text{sign}(\text{gradient error}) * 0.1 \quad (4.20)$$

$$\Delta wh1 = -\text{sign}(0,00011) * 0,1 = -0,1$$

Hasil pembaruan bobot pada jaringan dari input layer ke hidden layer seperti tercantumkan melalui Tabel 4.9.

$$\Delta wh1.1 = \Delta wh1 + \Delta wh1.1(\text{lama}) \quad (4.21)$$

$$\Delta wh1.1 = -0,1 + 0,97344 = 0,87344$$

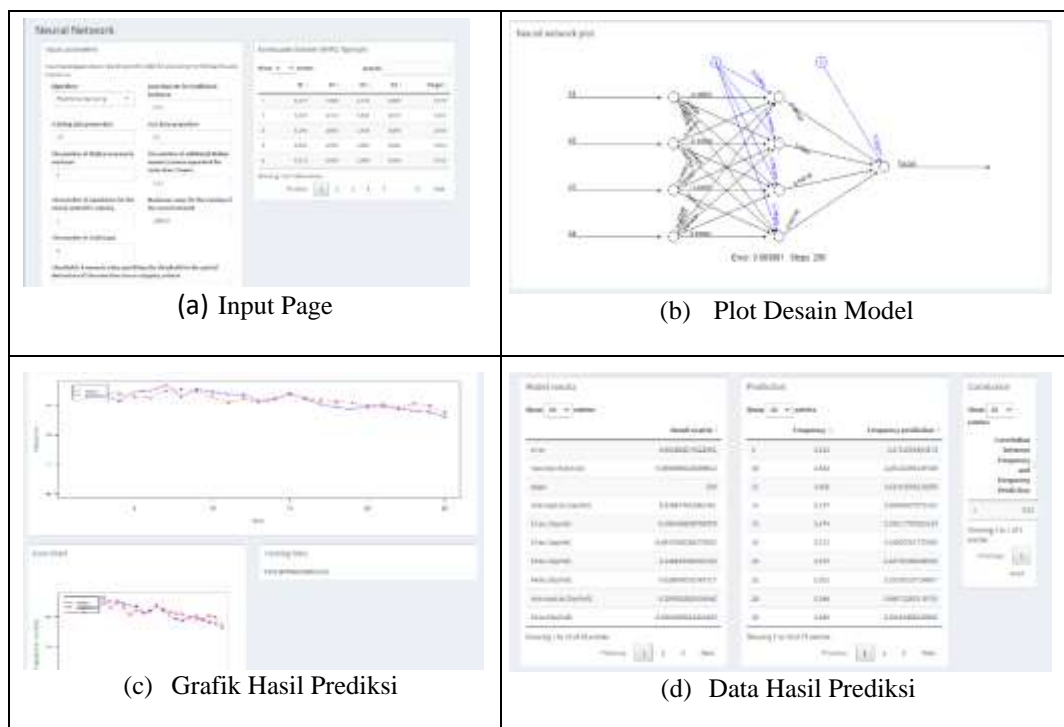
Tabel 4. 9 Nilai Pembaruan Bobot pada Input ke Hidden Layer

| Variabel | Z1 | Z2 | Z3 | Z4 |
|-----------------|-----------|-----------|-----------|-----------|
| X1 | 0,87344 | 0,4475 | 0,1095 | -0,0580 |
| X2 | 0,20133 | 0,1863 | 0,7490 | 0,7798 |
| X3 | 0,29186 | 0,2414 | 0,0633 | 0,7897 |
| X4 | 0,70880 | 0,6466 | 0,6587 | 0,1824 |

4.3 Uji Coba

Pengujian baik pada algoritma standar *backpropagation* maupun *resilient backpropagation* dilakukan masing-masing dengan 16 skenario arsitektur yang berbeda, dengan komposisi data *training* dan *testing* tetap sebesar 70:30. Pada setiap skenario dilakukan variasi jumlah input node, beserta jumlah neuron pada *hidden layer*. Hal ini dijalankan guna mengetahui desain pola arsitektur yang paling baik sekaligus menganalisis hubungan antara perubahan arsitektur dengan performa kinerja algoritma.

Pengujian dengan library *neuralnet* dengan kombinasi library *shiny* pada bahasa R. Tampilan halaman antarmuka aplikasi yang tampak melalui Gambar 4.3. Pada Gambar 4.3 bagian (a) merupakan halaman input, untuk melakukan inisialisasi parameter, bagian (b) merupakan plot desain arsitektur *neural network*, bagian (c) grafik perbandingan hasil prediksi, bagian (d) data hasil model ANN.



Gambar 4. 3 Tampilan Aplikasi Prediksi Magnitudo dengan *Neural Network*

4.3.1 Hasil Algoritma *Standard Backpropagation Neural Network* (BPNN)

Hasil penerapan dan pengujian jaringan *backpropagation* pada data magnitudo, seperti tertera melalui Tabel 4.10 sebagai berikut.


Tabel 4. 10 Hasil Performa Algoritma BPNN

| Arsitektur | Kode | MSE | Time (s) | Epoch |
|----------------|---------------|--------------------|------------------|----------|
| 4-4-1 | BP-M1 | 0,023355247 | 0,033498049 | 250 |
| 4-6-1 | BP-M2 | 0,022547349 | 0,04645896 | 318 |
| 4-10-1 | BP-M3 | 0,022963598 | 0,030604124 | 224 |
| 4-23-1 | BP-M4 | 0,025273971 | 0,121368885 | 428 |
| 8-4-1 | BP-M5 | 0,020923656 | 0,0292871 | 204 |
| 8-6-1 | BP-M6 | 0,020623556 | 0,016737938 | 96 |
| 8-10-1 | BP-M7 | 0,024778252 | 0,027597904 | 98 |
| 8-23-1 | BP-M8 | 0,025531466 | 0,148952007 | 508 |
| 10-4-1 | BP-M9 | 0,020001648 | 0,014853001 | 80 |
| 10-6-1 | BP-M10 | 0,015392001 | 0,015912056 | 85 |
| 10-10-1 | BP-M11 | 0,019747557 | 0,041084051 | 212 |
| 10-23-1 | BP-M12 | 0,029995733 | 0,102079868 | 334 |
| 12-4-1 | BP-M13 | 0,013237956 | 0,031239986 | 139 |
| 12-6-1 | BP-M14 | 0,014328101 | 0,041043997 | 280 |
| 12-10-1 | BP-M15 | 0,012414202 | 0,0000000 | 9 |
| 12-23-1 | BP-M16 | 0,020596577 | 0,06635499 | 193 |

Sumber: Data hasil pengolahan

Berdasarkan tabel tersebut, arsitektur jaringan terbaik yaitu **BP-M15**, dengan arsitektur 12 input neuron dan 10 neuron dalam *hidden layer*. Pada jaringan ini menghasilkan nilai **MSE terkecil** berjumlahkan **0.012414202** dan waktu tercepat mendekati 0 detik dan hanya membutuhkan 9 epoch.

Arsitektur jaringan dengan performa terbaik BP-M15 dengan 10 jumlah input *nodes*, 10 neuron pada hidden layer beserta 1 output tersaji pada Gambar 4.4 berikut.



Gambar 4. 4 Arsitektur Jaringan BP-M15

Berdasar pada Tabel 4.10, apabila kita hitung rata-rata berdasar per kelompok jumlah input beserta jumlah neuron hidden, maka mampu didapat hasil sebagaimana Tabel 4.11 sebagai berikut.


Tabel 4. 11 Hasil Rata-Rata Error Per Kelompok Jaringan BPNN

| Neuron | Jumlah Input | | | | Rata-rata |
|------------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| | 4 | 8 | 10 | 12 | |
| 4 | 0,02336 | 0,02092 | 0,02 | 0,01324 | 0,01938 |
| 6 | 0,02255 | 0,02062 | 0,01539 | 0,01433 | 0,018223 |
| 10 | 0,02296 | 0,02478 | 0,01975 | 0,01241 | 0,019976 |
| 23 | 0,02527 | 0,02553 | 0,03 | 0,0206 | 0,025349 |
| Rata-rata | 0,023535 | 0,022964 | 0,021284 | 0,015144 | |

Sumber: Data hasil pengolahan

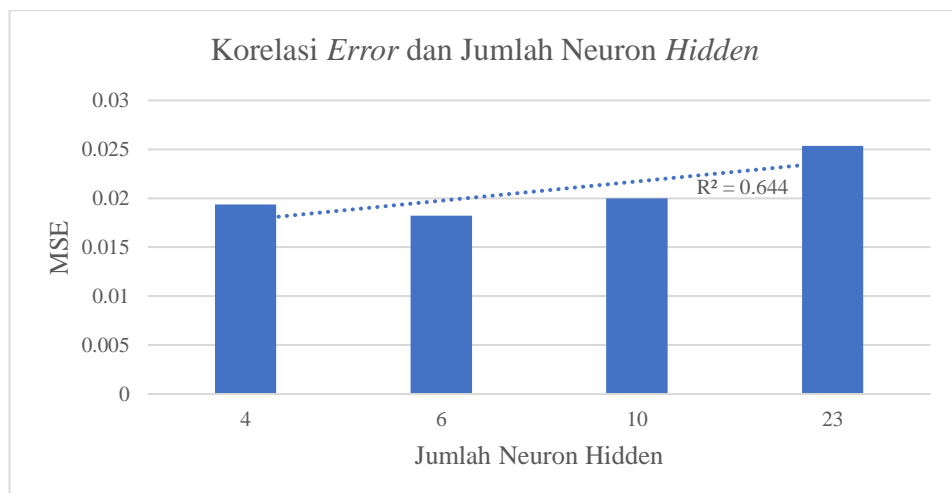
Hasil pengujian untuk perubahan jumlah *node input* menghasilkan nilai yang stabil. Ketika jumlah *node input* diperbanyak, maka tingkat error akan semakin rendah. Perihal ini ditunjukkan dengan tingkat korelasi yang **kuat** dengan $r = 0,7637$ (Gambar 4.5). Sehingga hal ini mengindikasikan bahwasanya makin banyak sampel pola data magnitudo yang dipakai menjadi input, maka

kemampuan jaringan untuk mengenali sampel data deret waktu akan semakin meningkat, sehingga meningkatkan keakuratan prediksi data target.




Gambar 4. 5 Korelasi Nilai MSE dan Jumlah *Node Input*

Sebaliknya perubahan jumlah *hidden neuron* pada lapisan tersembunyi menghasilkan nilai error yang tidak konsisten. Hasil pengujian menunjukkan bahwa perubahan jumlah *hidden neuron* memiliki nilai korelasi **sedang** dengan $r=0,644$ (Gambar 4.6). Hal ini mengindikasikan bahwa jumlah *hidden neuron* tidak memberikan kontribusi yang signifikan terhadap performa pengujian data target.



Gambar 4. 6 Korelasi Nilai Error dan Jumlah Neuron pada Lapisan Tersembunyi

Pada Gambar 4.7 berikut, merupakan grafik perbandingan antara nilai prediksi dan nilai sebenarnya (*ground truth*) pada algoritma BPNN dengan menggunakan kode BP-M15 (12-10-1).



Gambar 4. 7 Perbandingan Nilai Aktual dan Prediksi pada Jaringan BP-M15

Dari hasil perhitungan, didapatkan nilai korelasi (r) antara nilai aktual dan nilai prediksi sebesar **0,826481** atau dengan tingkat hubungan **kuat**. Berdasarkan tingkat error, nilai korelasi dan trend pola nilai aktual dan prediksi (Gambar 4.7) yang mirip dapat diartikan jaringan saraf tiruan BPNN mampu memprediksi data magnitudo dengan baik.

4.3.2 Hasil Algoritma *Resilient Backpropagation* (RPROP)


Hasil penerapan jaringan RPROP pada data magnitudo, selengkapnya tercantumkan melalui Tabel 4.12 berikut.

Tabel 4. 12 Hasil Performa Algoritma RPROP

| Arsitektur | Kode | Error | Time | Epoch |
|----------------|---------------|----------------|-----------------|-----------|
| 4-4-1 | RP-M1 | 0,024042 | 0,017771 | 24 |
| 4-6-1 | RP-M2 | 0,021683 | 0,013727 | 55 |
| 4-10-1 | RP-M3 | 0,0209 | 0,020683 | 49 |
| 4-23-1 | RP-M4 | 0,021648 | 0,023743 | 49 |
| 8-4-1 | RP-M5 | 0,017724 | 0,013517 | 62 |
| 8-6-1 | RP-M6 | 0,016905 | 0,012701 | 58 |
| 8-10-1 | RP-M7 | 0,021254 | 0,025286 | 58 |
| 8-23-1 | RP-M8 | 0,017297 | 0,018364 | 70 |
| 10-4-1 | RP-M9 | 0,016193 | 0,020041 | 43 |
| 10-6-1 | RP-M10 | 0,013284 | 0,016044 | 46 |
| 10-10-1 | RP-M11 | 0,01400 | 0,016218 | 60 |
| 10-23-1 | RP-M12 | 0,013235 | 0,040985 | 94 |
| 12-4-1 | RP-M13 | 0,011327 | 0,00000 | 24 |
| 12-6-1 | RP-M14 | 0,010689 | 0,013013 | 41 |
| 12-10-1 | RP-M15 | 0,009416 | 0,004683 | 41 |
| 12-23-1 | RP-M16 | 0,00907 | 0,045929 | 82 |

Sumber: Data hasil pengolahan

Berdasarkan Tabel 4.12, arsitektur jaringan terbaik yaitu **RP-M16**, dengan arsitektur 12 input neuron dan 23 neuron dalam *hidden layer*. Pada jaringan ini didapatkannya nilai **MSE** terkecil berjumlahkan **0,00907** dengan lama waktu pelatihan 0,045929 detik dan hanya membutuhkan 82 epoch. Arsitektur jaringan RP-M16 seperti yang tampak melalui Gambar 4.8 berikut.



Gambar 4. 8 Desain Arsitektur Jaringan RP-M16


Berdasarkan Tabel 4.12, apabila kita hitung error berdasar kelompok jumlah *hidden neuron* beserta jumlah *node input*, maka akan didapat hasil rata-rata error per kelompok seperti melalui 4.13.

Tabel 4. 13 Rata-Rata Error Per Kelompok Jaringan RPROP

| Neuron | Jumlah Input | | | | Rata-rata |
|------------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| | 4 | 8 | 10 | 12 | |
| 4 | 0,02404 | 0,01772 | 0,01619 | 0,01133 | 0,017321 |
| 6 | 0,02168 | 0,01691 | 0,01328 | 0,01069 | 0,01564 |
| 10 | 0,0209 | 0,02125 | 0,014 | 0,00942 | 0,016393 |
| 23 | 0,02165 | 0,0173 | 0,01324 | 0,00907 | 0,015313 |
| Rata-rata | 0,022068 | 0,018295 | 0,014178 | 0,010125 | |

Sumber: Data hasil pengolahan


Hasil pengujian untuk perubahan jumlah *node input* menunjukkan nilai error yang stabil. **Ketika jumlah *node input* diperbanyak, maka tingkat errornya akan semakin rendah.** Hal ini ditunjukkan melalui nilai korelasi yang **sangat kuat** dengan $r=0,9997$ (Gambar 4.9). Ini mengindikasikan bahwasanya, makin banyak input sampel data magnitudo yang digunakan, maka kemampuan jaringan



Gambar 4. 9 Korelasi Error dan Jumlah Input Node


dalam mengenali data deret waktu akan semakin meningkat, sehingga meningkatkan keakuratan prediksi data target.

Sebaliknya perubahan jumlah *hidden neuron* pada *hidden layer* menunjukkan hasil yang berubah-ubah dilihat dari tingkat *error*. Berdasar hasil pengujian seperti pada Gambar 4.10 terlihat bahwa **perubahan jumlah *hidden neuron*** memiliki nilai korelasi **sedang** dengan **$r=0,5816$** . Hal ini mengindikasikan bahwa jumlah neuron tersembunyi tidak memberikan kontribusi yang berarti terhadap performa jaringan algoritma.



Gambar 4. 10 Korelasi Nilai Error dan Jumlah Neuron pada Hidden Layer

Pada Gambar 4.11 berikut, tersaji grafik perbandingan diantara nilai prediksi bersama nilai aktual dalam jaringan RPROP dengan kode RP-M16 (12-23-1).



Gambar 4. 11 Perbandingan Nilai Aktual dan Prediksi pada Jaringan RP-M16

Dari hasil perhitungan, didapatkan nilai korelasi (r) antara nilai aktual dan nilai prediksi sebesar **0,8509** atau dengan tingkat hubungan sangat kuat. Berdasarkan tingkat error, nilai korelasi dan trend pola nilai aktual dan prediksi pada Gambar 4.11 yang cukup mirip dapat diartikan jaringan saraf tiruan dapat memprediksi data magnitudo dengan baik.

BAB V

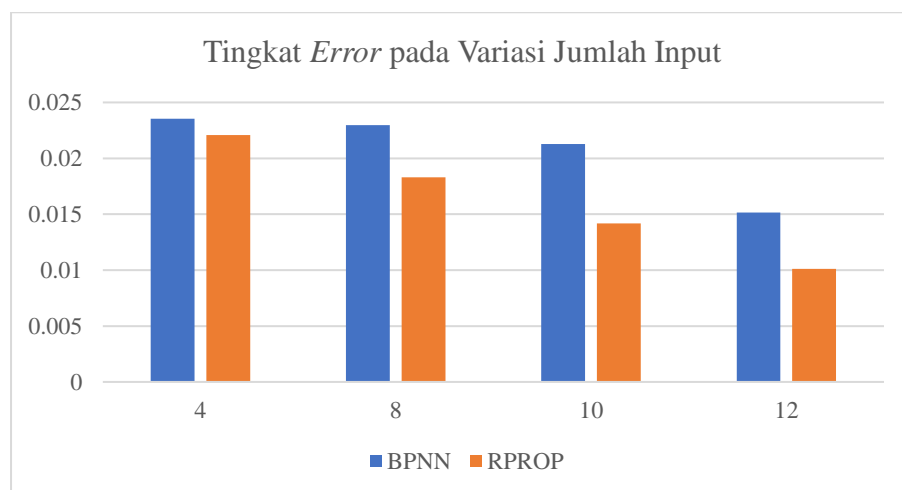
PEMBAHASAN

5.1 Perbandingan Performa pada Prediksi Data Magnitudo

Pada perbandingan performa algoritma BPNN dan RPROP, metrik indikator performa yang digunakan adalah tingkat kesalahan (MSE) dan lama durasi waktu pelatihan (detik).


5.1.1 Perbandingan Performa Berdasarkan Tingkat Kesalahan

Hasil pengujian nilai error pada algoritma BPNN (Tabel 4.11) dan algoritma RPROP (Tabel 4.13), jika kita perbandingan tingkat error pada **variasi jumlah input** antara BPNN dan RPROP dalam bentuk grafik mampu diperhatikan melalui Gambar 5.1. Pada tiap variasi jumlah input, kesemua arsitektur dengan algoritma *Resilient Backpropagation* (RPROP) mempunyai tingkat error yang lebih rendah daripada algoritma *Standart Backpropagation*(BPNN).



Gambar 5. 1 Grafik Tingkat Error Pada Variasi Jumlah Input

Berdasarkan hasil percobaan tersebut, makin banyak jumlah *inputnodes*, jaringan menjadi menghasikan tingkat *error* yang lebih baik. Hal tersebut berarti dengan penambahan jumlah input yang memadai dan relevan, jaringan akan memiliki lebih banyak informasi untuk digunakan dalam pembelajaran. Hal ini dapat membantu mengurangi tingkat *error* karena model dapat lebih akurat memetakan input ke output yang benar.



Gambar 5. 2 Grafik Tingkat Error pada Variasi Jumlah Neuron Hidden

Sementara itu, perbandingan tingkat error pada **variasi jumlah neuron pada *hidden layer*** antara BPNN dan RPROP mampu diperhatikan melalui Gambar 5.3. Hasilnya terlihat bahwa algoritma *Resilient Backpropagation* (RPROP) mempunyai tingkat error yang lebih baik daripada algoritma *Standart Backpropagation* (BPNN).

Pada hasil percobaan, didapat hasil error terbaik pada arsitektur dengan 6 neuron hidden. Berdasarkan hasil percobaan tersebut, penentuan jumlah neuron *hidden* terbaik berbeda dengan variasi jumlah input. Dimana jumlah input

semakin banyak akan menambah tingkat keakuratan prediksi. Sedangkan variasi jumlah neuron *hidden* paling optimal, didapat bukan pada jumlah terbanyak.

Jumlah neuron *hidden* optimal didapatkan pada jumlah neuron *hidden* yang cukup. Ketika jumlah neuron *hidden* terlalu sedikit, akan terjadi kasus *underfitting*, yakni kasus dimana jumlah neuron tersembunyi terlalu sedikit. Model tidak memiliki kapasitas yang cukup untuk menangkap pola yang ada dalam data. Hal ini menyebabkan model memiliki error yang tinggi pada data pelatihan dan data uji.

Disisi lain, ketika jumlah neuron tersembunyi terlalu banyak, akan terjadi kasus *overfitting*, dimana model memiliki kapasitas yang sangat besar dan mulai menangkap noise atau detail tidak relevan dari data pelatihan. Hal ini menyebabkan performa model buruk pada proses pengujian. Dengan kata lain, jumlah neuron *hidden* harus cukup untuk menangkap pola dalam data, tetapi tidak terlalu banyak sehingga model menjadi *overfitting* yang menyebabkan jaringan menangkap *noise* dan mengurangi tingkat akurasi dari prediksi.

Tabel 5. 1 Perbandingan Nilai Error Rata-Rata pada Data Magnitudo

| | BPNN | RPROP |
|-----|-------------|--------------|
| MSE | 0,020732 | 0,016167 |

Sumber : Data hasil pengolahan

Dari hasil rata-rata error pengujian (Tabel 5.1), nilai rata-rata *error* (MSE) standar *backpropagation* sebesar $MSE = 0,020732$, dan nilai rata-rata error (MSE) *resilient backpropagation* sebesar $MSE = 0,016167$. Berdasarkan hasil tersebut, algoritma dengan menggunakan *resilient backpropagation*, mampu menghasilkan performa yang lebih baik.

5.1.2 Pengujian Performa Berdasarkan Waktu Pelatihan

Berdasarkan data hasil pengujian algoritma BPNN pada Tabel 4.10, apabila kita sajikan lama waktu pelatihan berdasar kelompok jumlah input dan jumlah neuron *hidden*, maka mampu diperoleh hasil seperti pada Tabel 5.2 berikut.

Tabel 5. 2 Lama Waktu Pelatihan Per Kelompok Jaringan BPNN


| Neuron | Jumlah Input | | | | Rata-rata |
|------------------|-----------------|-----------------|----------------|----------------|-----------------|
| | 4 | 8 | 10 | 12 | |
| 3 | 0,033498 | 0,02929 | 0,01485 | 0,03124 | 0,02722 |
| 6 | 0,046459 | 0,01674 | 0,01591 | 0,04104 | 0,030038 |
| 10 | 0,030604 | 0,0276 | 0,04108 | 0,00000 | 0,024822 |
| 23 | 0,121369 | 0,14895 | 0,102079 | 0,06635 | 0,112225 |
| Rata-rata | 0,057983 | 0,055644 | 0,02395 | 0,03466 | |

Disisi lain pada data hasil pengujian algoritma RPROP pada Tabel 4.12, apabila kita sajikan lama waktu pelatihan berdasar kelompok jumlah input dan jumlah neuron hidden, maka akan didapat hasil seperti pada Tabel 5.3 berikut.

Tabel 5. 3 Lama Waktu Pelatihan Per Kelompok Jaringan RPROP


| Neuron | Jumlah Input | | | | Rata-rata |
|------------------|----------------|----------------|----------------|----------------|----------------|
| | 4 | 8 | 10 | 12 | |
| 3 | 0,01777 | 0,01352 | 0,02004 | 0,00000 | 0,01283 |
| 6 | 0,01373 | 0,01270 | 0,01604 | 0,01301 | 0,01387 |
| 10 | 0,02068 | 0,02529 | 0,01622 | 0,00468 | 0,01672 |
| 23 | 0,02374 | 0,01836 | 0,04099 | 0,04593 | 0,03226 |
| Rata-rata | 0,01898 | 0,01747 | 0,02332 | 0,01591 | |

Perbandingan lama waktu pelatihan pada variasi jumlah input antara BPNN dan RPROP dapat dilihat pada Gambar 5.4. Pada tiap variasi jumlah input, kesemua arsitektur dengan algoritma *Resilient Backpropagation* (RPROP) membutuhkan waktu pelatihan yang lebih singkat daripada algoritma standar *Backpropagation*(BPNN).



Gambar 5. 3 Grafik Waktu Pelatihan Jaringan dengan Variasi Jumlah Input

Berdasarkan hasil grafik pada Gambar 5.4 tersebut, jumlah input node tidak berpengaruh terhadap lama waktu yang dibutuhkan untuk pelatihan jaringan. Namun disisi lain, pemilihan algoritma pembelajaran berpengaruh cukup signifikan. Hal ini terlihat dari rata-rata lama waktu pelatihan jaringan BPNN selama 0,043058922 detik, sedangkan waktu pelatihan jaringan RPROP selama 0,018919066 detik.



Gambar 5. 4 Waktu Pelatihan Jaringan dengan Variasi Jumlah Neuron Hidden

Sama seperti grafik sebelumnya, berdasarkan Gambar 5.5 tersebut, jumlah neuron *hidden* juga tidak berkaitan erat dengan lama waktu pelatihan jaringan, sedangkan pemilihan algoritma pembelajaran berpengaruh cukup signifikan terhadap waktu pelatihan jaringan.

Secara keseluruhan, hasil perbandingan yang tercantum pada Tabel 5.4, rata-rata waktu pembelajaran BPNN adalah selama 0,045818 detik, sedangkan RPROP selama 0,018919 detik, sehingga dapat disimpulkan algoritma RPROP membutuhkan waktu pelatihan yang lebih singkat daripada algoritma BPNN.

Tabel 5. 4 Perbandingan Performa Waktu Pembelajaran pada Data Magnitudo

| | BPNN | RPROP |
|----------------------------|-------------|--------------|
| Waktu Rata-rata (s) | 0,045818 | 0,018919 |

Sumber : Data hasil pengolahan

5.2 Kaitan Strategi Arsitektur Jaringan dengan Performa Algoritma

Pada pembahasan Bab IV sebelumnya, telah didapatkan bahwa variasi jumlah input mempunyai korelasi yang lebih kuat terhadap performa algoritma bila dibandingkan dengan variasi jumlah neuron pada lapisan tersembunyi. Hal tersebut berlaku baik pada algoritma BPNN maupun RPROP. Perbandingan hubungan tingkat korelasi dari kedua variabel tersebut seperti terlihat pada Tabel 5.5.

Tabel 5. 5 Tingkat Korelasi antara Error dan Variasi Arsitektur pada BPNN dan RPROP

| Variasi | BPNN | RPROP | Keterangan |
|----------------------|--------|--------|--------------------|
| Jumlah Input | 0,7637 | 0,9997 | Sangat Kuat |
| Neuron <i>Hidden</i> | 0,644 | 0,5816 | Sedang |

Sumber : Data hasil pengolahan

Berdasarkan data tersebut, variasi jumlah input berpengaruh signifikan terhadap performa tingkat kesalahan algoritma. Perihal ini ditunjukkan dengan tingkat korelasi yang kuat ($r = 0,76-0,99$). Pada pengujian juga didapatkan bahwa,

penambahan jumlah input nodes akan menghasilkan error yang lebih baik (Gambar 5.1). Sementara itu perubahan jumlah input nodes terhadap performa lama waktu pelatihan, tidak berkaitan dan tidak berkontribusi secara signifikan (Gambar 5.3).

Disisi lain, variasi jumlah neuron pada hidden layer tidak berpengaruh signifikan terhadap performa tingkat kesalahan algoritma (Gambar 5.2) maupun performa lama waktu pelatihan (Gambar 5.4).

5.3 Pandangan Islam tentang Uji Performa Algoritma untuk Memprediksi Gempa Bumi

Islam telah mendorong umatnya untuk terus menuntut ilmu dan berusaha memahami fenomena alam. Hal ini sesuai firman Allah dalam surat Al-Mujadilah:11, bahwasanya Allah *subhanahu wa taala* akan meninggikan orang yang berilmu beberapa derajat.

يَا أَيُّهَا الَّذِينَ ءَامَنُوا إِذَا قِيلَ لَكُمْ تَفَسَّحُوا فِي الْمَجَالِسِ فَافْسَحُوا يَفْسَحِ اللَّهُ لَكُمْ وَإِذَا قِيلَ فَأَنْشُرُوا فَأَنْشُرُوا
يَرْفَعِ اللَّهُ الَّذِينَ ءَامَنُوا مِنْكُمْ وَالَّذِينَ أُوتُوا الْعِلْمَ دَرَجَاتٍ ۗ وَاللَّهُ بِمَا تَعْمَلُونَ خَبِيرٌ

Artinya: "Hai orang-orang beriman apabila dikatakan kepadamu: "Berlapang-lapanglah dalam majelis", maka lapangkanlah niscaya Allah akan memberi kelapangan untukmu. Dan apabila dikatakan: "Berdirilah kamu", maka berdirilah, niscaya Allah akan meninggikan orang-orang yang beriman di antaramu dan orang-orang yang diberi ilmu pengetahuan beberapa derajat. Dan Allah Maha Mengetahui apa yang kamu kerjakan." (QS. Surat Al-Mujadilah:11).

Dalam tafsir Al Misbah, Shihab (2002) menjelaskan ayat ini membagi kaum beriman menjadi dua kelompok, kelompok pertama hanya beriman dan beramal saleh, kemudian kelompok kedua beriman, beramal saleh, dan memiliki pengetahuan. Derajat kelompok kedua lebih tinggi, bukan hanya karena nilai ilmu

yang mereka miliki tetapi karena amal mereka, penyebaran dan pemanfaatan ilmu tersebut yang berguna bagi masyarakat banyak. Ilmu yang dimaksud bukan hanya ilmu agama, tetapi ilmu apapun yang bermanfaat. Ilmu haruslah menghasilkan rasa takut dan kagum kepada Allah *subhanahu wa ta'ala*, yang pada muaranya mendorong manusia berilmu dan mengamalkan ilmunya tersebut untuk kebaikan dan kesejahteraan makhluk.

Perkembangan metode dan teknik dalam prediksi gempa bumi termasuk didalamnya algoritma jaringan saraf tiruan, menuntut kita agar dapat bekerja secara efektif dan efisien. Allah azza wa jalla telah berfirman:

وَقُلْ اَعْمَلُوا فَسَيَرَى اللّٰهُ عَمَلَكُمْ وَرَسُولُهُ وَالْمُؤْمِنُونَ وَسَتُرَدُّونَ اِلَىٰ عِلْمِ الْغَيْبِ وَالشَّهَادَةِ فَيُنَبِّئُكُمْ بِمَا كُنْتُمْ تَعْمَلُونَ

Artinya: “Katakanlah (Nabi Muhammad), “Bekerjalah! Maka, Allah, rasul-Nya, dan orang-orang mukmin akan melihat pekerjaanmu. Kamu akan dikembalikan kepada (Zat) yang mengetahui yang gaib dan yang nyata. Lalu, Dia akan memberitakan kepada kamu apa yang selama ini kamu kerjakan.”(QS. At-Taubah:105).

Dalam tafsir ringkas Kemenag RI (2016), disebutkan bahwa Allah memerintahkan kepada orang-orang yang bertaubat agar bekerja dengan berbagai pekerjaan yang mendatangkan manfaat, dan Allah akan melihat dan memberi penghargaan atas pekerjaan, begitu juga Rasul dan orang-orang mukmin akan menyaksikan dan menilai pekerjaanmu.

Firman Allah dalam surat ini jelas, agar kita terus bekerja dengan pekerjaan yang mendatangkan manfaat, baik bagi diri kita sendiri maupun orang lain. Bekerja tentunya dapat lebih bermanfaat jika dilakukan dengan cara dan metode yang efektif dan efisien. Berkaitan dengan perkembangan metode dan teknik yang

terus berkembang, uji performa dalam rangka pemilihan metode algoritma yang efektif dan efisien perlu dilakukan agar mendapatkan hasil prediksi gempa yang akurat. Hal ini penting diupayakan sebagai bagian ikhtiar kita, sebagai insan yang beriman, berilmu dalam rangka memberikan manfaat bagi masyarakat luas dengan melakukan kesiapsiagaan mitigasi bencana gempa bumi.

BAB VI

KESIMPULAN DAN SARAN

6.1 Kesimpulan

Hasil pelatihan dan pengujian algoritma standar *backpropagation* (BPNN) dan *resilient backpropagation* (RPROP) dengan penerapan data magnitudo gempa bumi di wilayah Jawa Timur, didapatkan bahwa:

- a. Algoritma RPROP menghasilkan performa tingkat *error* yang lebih baik, dimana menghasilkan error yang lebih kecil dengan $MSE=0,016167$, dibandingkan BPNN dengan $MSE=0,020732$. Selain itu berdasarkan performa waktu pelatihan, algoritma RPROP juga membutuhkan waktu yang lebih cepat dengan lama waktu pelatihan $t=0,018919$ s, dibandingkan BPNN dengan $t=0,045818$ s.
- b. Berdasar hasil pengujian pada algoritma BPNN dan RPROP, jumlah input nodes jaringan berpengaruh secara signifikan terhadap performa algoritma dengan tingkat korelasi sangat kuat ($r= 0,76-0,99$). Semakin banyak input nodes, tingkat error akan semakin kecil. Sedangkan perubahan jumlah neuron pada *hidden layer* tidak berpengaruh secara signifikan terhadap performa tingkat kesalahan dengan tingkat korelasi sedang ($r= 0,58-0,64$).

6.2 Saran

Berdasarkan hasil pengujian, algoritma RPROP mempunyai performa lebih baik untuk diaplikasikan pada prediksi magnitudo gempa bumi. Algoritma ini dapat ditingkatkan performanya antara lain dengan melakukan variasi desain arsitektur, terutama melakukan variasi perubahan jumlah node input.

DAFTAR PUSTAKA

- Adi, M., Hutabarat, P., Julham, M., Wanto, A., Studi, P., Informatika, T., Tunas, S., & Pematangsiantar, B. (2018). Penerapan Algoritma Backpropagation Dalam Memprediksi Produksi Tanaman Padi Sawah Menurut Kabupaten/Kota di Sumatera Utara. *SemanTIK*, 4(1), 77–86.
- Agwil, W., Novianti, P., & Hidayati, N. (2020). Penerapan Jaringan Saraf Tiruan Pada Data Gempa Bumi Di Provinsi Bengkulu. *Statistika*, 8(2), 152–158.
- Al Banna, M. H., Taher, K. A., Kaiser, M. S., Mahmud, M., Rahman, M. S., Hosen, A. S. M. S., & Cho, G. H. (2020). Application of Artificial Intelligence in Predicting Earthquakes: State-of-the-Art and Future Challenges. *IEEE Access*, 8, 192880–192923. <https://doi.org/10.1109/ACCESS.2020.3029859>
- Bhatia, A., Pasari, S., & Mehta, A. (2018). Earthquake forecasting using artificial neural networks. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, 42(5), 823–827. <https://doi.org/10.5194/isprs-archives-XLII-5-823-2018>
- Chrystiaditama, I. G. P. (2019). *Optimasi Jaringan Syaraf Tiruan untuk Meningkatkan Akurasi Prediksi Pemilihan Kompetensi Keahlian Peserta Didik SMK Menggunakan Nguyen-widrow*. Universitas Pendidikan Ganesha.
- Firdausa, F. (2020). Prediksi dan Analisis Data Gempa Bumi di Provinsi Bengkulu dengan Metode Artificial Neural Network. *CANTILEVER*, 8(2), 45–49. <https://doi.org/10.35139/cantilever.v8i2.5>
- González, J., Yu, W., & Telesca, L. (2019). *Earthquake Magnitude Prediction Using Recurrent Neural Networks*. 22. <https://doi.org/10.3390/iecg2019-06213>
- Kemenag RI. (2022). Tafsir Tahlili Al Qur'an Dan Tafsirnya. *Lajnah Pentashihan Mushaf Al-Qur'an*
- Kemenag RI. (2016). Tafsir Ringkas Al Quran Al Karim. *Lajnah Pentashihan Mushaf Al-Qur'an*
- Muzakir Hi Sultan. (2014). Optimasi Parameter Neural Network Pada Data Time Series untuk Memprediksi Kekuatan Gempa Per Periode. *Jurnal Cauchy*, 3(2), 59–71.
- Nikentari, N., Kurniawan, H., Ritha, N., & Kurniawan, D. (2018). Optimasi Jaringan Syaraf Tiruan Dengan Particle Swarm Optimization Untuk Prediksi Pasang Surut Air Laut. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 5(5), 605–612. <https://doi.org/10.25126/jtiik2018551055>

- Pandit, A., & Panda, S. (2021). Prediction of earthquake magnitude using soft computing techniques: ANN and ANFIS. *Arabian Journal of Geoscience*, 14(1260), 1–10. <https://doi.org/10.1007/s12517-021-07594-2/Published>
- Permana, M. A., & Faisal, M. (2023). Uji Performa Prediksi Gempa Bumi di Jawa Timur dengan Artificial Neural Network. *Euler : Jurnal Ilmiah Matematika, Sains Dan Teknologi*, 11(1), 44–54. <https://doi.org/10.34312/euler.v11i1.19291>
- Priambodo, B., & Mahmudy, W. F. (2020). *Aplikasi Jaringan Syaraf Tiruan Resilient Backpropagation Pada Prediksi Magnitudo Dan Lokasi Gempa Bumi*. Brawijaya University.
- Riedmiller, M., & Braun, H. (1992). A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm. *IEEE International Conference on Neural Networks*, 586–591.
- Saputra, W., Tulus, T., Zarlis, M., Sembiring, R. W., & Hartama, D. (2017). Analysis Resilient Algorithm on Artificial Neural Network Backpropagation. *Journal of Physics: Conference Series*, 930(1). <https://doi.org/10.1088/1742-6596/930/1/012035>
- Setiyaris, S., Hariyadi, M. A., & Chrysdian, C. (2023). Prediksi Curah Hujan Bulanan Berdasarkan Parameter Cuaca Menggunakan Jaringan Saraf Tiruan Levenberg Marquardt. *Jurnal Media Informatika Budidarma*, 7(3), 1125–1133.
- Shihab, Quraish. (2022). Tafsir Al-Misbah. *Lentera Hati*.
- Somantri, O. (2021). Prediksi Kekuatan Gempa Bumi Indonesia Berdasarkan Nilai Magnitudo Menggunakan Neural Network. *Prosiding Seminar Nasional Informatika Bela Negara*, 2, 203–207. <https://doi.org/10.33005/santika.v2i0.124>
- Suryanto. (2019). *Manajemen Risiko dan Asuransi* (2nd ed.). Universitas Terbuka.
- Wati, A. (2022). Analisis Backpropagation Dengan Optimasi Metode Resilient Pada Prediksi IPM Berdasarkan Rata-Rata Lama Sekolah. *Seminar Nasional Sistem Informasi, 2022*. <https://siantarkota.bps.go.id>.
- Widiyantoro, S., Irsyam, M., Faizal, L., & Adi Prakoso, W. (2022). *Peta Deagregasi Bahaya Gempa Indonesia Untuk Perencanaan dan Evaluasi Infrastruktur Tahan Gempa* (S. Widiyantoro, M. Irsyam, & F. Lutfi, Eds.; 1st ed.). Direktorat Bina Teknik Permukiman dan Perumahan Direktorat Jenderal Cipta Karya Kementerian Pekerjaan Umum dan Perumahan Rakyat.