

Uji Performa Prediksi Gempa Bumi di Jawa Timur dengan *Artificial Neural Network*

Muhammad Aji Permana^{1*}, M. Faisal²

^{1,2}Jurusan Magister Informatika, UIN Maulana Malik Ibrahim, Malang, 65144, Indonesia

*Penulis Korespondensi. Email: ajipermana@gmail.com

Abstrak

Provinsi Jawa Timur merupakan wilayah yang berbatasan langsung dengan zona subduksi lempeng Eurasia dan Indo-Australia, hal ini mengakibatkan provinsi Jawa Timur menjadi daerah yang rawan terjadi bencana gempa bumi. Prediksi mengenai frekuensi kejadian gempa sangat menarik untuk diteliti. Hal ini perlu dilakukan guna meningkatkan kesiapsiagaan kita dalam upaya mengurangi risiko gempa bumi. Penelitian mengenai prediksi gempa bumi telah banyak dilakukan salah satunya dengan metode *artificial neural network*. Tujuan dari penelitian ini adalah memperoleh arsitektur jaringan terbaik yang diterapkan pada data frekuensi kejadian gempa bumi per bulan di Provinsi Jawa Timur. Data kejadian gempa bumi tersebut bersumber dari BMKG Stasiun Geofisika Nganjuk, yang tercatat selama periode tahun 2016-2021. Data tersebut kemudian dikelompokkan menjadi data frekuensi kejadian per bulan. Kriteria pemilihan arsitektur jaringan terbaik dilakukan dengan membandingkan nilai *error* dari setiap kemungkinan arsitektur yang terbentuk. Metode pengujian menggunakan kriteria SSE (*sum square error*) pada tiap model arsitektur *artificial neural network*. Hasil uji menunjukkan bahwa variasi input mempunyai kontribusi yang signifikan dan korelasi yang lebih besar daripada variasi jumlah neuron tersembunyi. Hasil prediksi terbaik didapatkan pada model dengan arsitektur 9-30-1 dengan nilai error 0.1958.

Kata Kunci: Prediksi; Gempa Bumi; Artificial Neural Network

Abstract

East Java Province is an area directly adjacent to the Eurasian and Indo-Australian plate subduction zones, this has resulted in East Java province being an area prone to earthquakes. Predictions regarding the frequency of earthquake occurrences are very interesting to study. This needs to be done in order to increase our preparedness in an effort to reduce the risk of earthquakes. Research on earthquake prediction has been carried out, one of which is the artificial neural network method. The purpose of this study is to obtain the best network architecture that is applied to the data on the frequency of earthquake occurrences per month in East Java Province. Data on earthquake occurrences come from the BMKG Nganjuk Geophysics Station, which was recorded during the 2016-2021 period. The data was then grouped into the total frequency of events per month. The criteria for selecting the best network architecture are carried out by comparing each possible architecture's error values. The test method uses SSE (*sum square error*) criteria for each architectural model of the artificial neural network. The test results show that the input variation has a significant contribution and a greater correlation than the variation in the number of hidden neurons. The best prediction results are obtained in the model with 9-30-1 architecture with an error value of 0.1958.

Keywords: Prediction; Earthquake; Artificial Neural Network

1. Pendahuluan

Provinsi Jawa Timur merupakan salah satu wilayah di Indonesia yang cukup rentan terjadi bencana gempa bumi. Wilayah Jawa Timur yang secara geografis dekat dengan sumber-sumber penyebab gempa bumi meningkatkan resiko akan bencana gempa bumi. Sumber gempa bumi tersebut antara lain dari sebelah selatan Pulau Jawa yaitu akibat adanya subduksi lempeng indo Australia di

Samudra Hindia dan di sekitar sesar kendeng, yang berada di darat sisi utara Jawa Timur yang menyimpan potensi terjadinya bencana gempa bumi sewaktu-waktu [1].

Pendekatan prediksi mengenai jumlah kejadian gempa bumi cukup menarik untuk di teliti. Hal ini disebabkan karena perhitungan prediksi kejadian gempa bumi yang meliputi: besar kekuatan, waktu terjadi, dan lokasi pusat gempa bumi, belum bisa dilakukan secara tepat hingga saat ini. Penyebabnya adalah faktor ketidakpastian yang cukup besar dan berisiko dapat menimbulkan kepanikan di tengah masyarakat. Dengan demikian, pendekatan prediksi jumlah kejadian gempa bumi bulanan lebih ideal untuk dilakukan. Salah satu metode yang dapat dipakai adalah dengan memprediksi jumlah kejadian gempa bumi adalah dengan menggunakan metode *artificial intelligence* atau kecerdasan buatan.

Beberapa hasil penelitian yang berkaitan dengan prediksi gempabumi kerap dilakukan dan dipublikasikan sebelumnya. Lakhsmi dan Tiwari [2] menerapkan metode *neural network* berdasarkan algoritma *back-propagation* (BPA) untuk membangun model jaringan saraf menggunakan frekuensi gempa bulanan *time series* yang diperoleh dari katalog NOAA dan USGS untuk periode 1960-2003. Analisis komparatif menunjukkan bahwa hasil yang diperoleh metode tersebut stabil. Analisis metode jaringan saraf tiruan memiliki koefisien korelasi 0,52. Selanjutnya, Reyes [3] menguji penggunaan *neural network* untuk digunakan dalam prediksi gempa di Chile. Dengan menggunakan metode ini, ia membandingkan kinerjanya dengan metode lain seperti KNN, SVM dan K-Means. Hasil pengujian kinerja dari metode tersebut cukup bervariasi di setiap wilayah, dan metode *neural network* cukup konsisten dan cukup baik dengan akurasi sebesar 78,60%, sedangkan metode KNN 54,30% dan SVM 74,00%.

Untuk menguji kinerja kecerdasan buatan (*artificial intelligence*) dalam model deret waktu (*time series*), Kaftan, dkk [4] melakukan prediksi frekuensi gempa bulanan wilayah Turki Barat yang dihitung menggunakan data katalog dari wilayah tersebut dan kemudian kumpulan data bulanan yang diperoleh dievaluasi dengan dua jaringan saraf tiruan yaitu jaringan saraf multilayer perceptron (MLPNNs) dan jaringan saraf fungsi dasar radial (RBFNNs) dan sistem inferensi neuro-fuzzy adaptif (ANFIS). Hasil penelitian menunjukkan bahwa untuk prediksi data frekuensi gempa bulanan, RBFNN yang diusulkan memberikan koefisien korelasi yang lebih baik dan nilai kesalahan yang lebih kecil. MLPNN menghasilkan nilai RMSE sebesar 39,60, RBFNN 19,6, dan ANFIS 33,70.

Pada kasus lain, Al Banna [5] merangkum metode *artificial intelligence* yang digunakan dalam makalah prediksi gempa dari tahun 2005 hingga 2019. Berdasarkan penelitiannya, setiap metode memiliki kelebihan dan kekurangannya masing-masing. Ia mengkategorikan metode *artificial intelligence* menjadi 3 kategori, yaitu *Rule based* dengan RMSE terbaik adalah ANFIS, *Shallow ML* dengan RMSE terbaik adalah ANN, Adaboost, dan Kategori *Deep ML* dengan akurasi terbaik adalah DNN (*deep neural network*), LSTM (*long short-term memory*). Sementara itu, Pandit dan Panda [6] melakukan investigasi dalam prediksi gempa membandingkan metode *Neural Network* dan ANFIS dengan memasukkan waktu kejadian, koordinat lokasi, kedalaman dan magnitudo. Dari hasil analisis yang dilakukan, metode *neural network* menghasilkan akurasi dan efisiensi yang lebih baik dibandingkan ANFIS. *Neural network* memiliki RMS 0,20 sedangkan ANFIS 0,60.

Selanjutnya, jumlah kejadian gempa bumi di masa mendatang dari masing-masing magnitudo untuk tahun 2018 hingga 2022 di seluruh dunia coba diprediksi dengan menggunakan model *ARIMA*(1,0,6). Todelo dan Aliac [7] menunjukkan hasil simulasi, bahwa jumlah kejadian gempa bumi tertinggi diramalkan pada tahun 2022 dengan perkiraan jumlah 1.580 kali pada tingkat magnitudo 5,0-5,9. Pada tingkat magnitudo 7,0-7,9 menunjukkan RMSE 4.61. Terbukti bahwa model *ARIMA* (1,0,6) efektif dalam memprediksi kejadian gempa bumi. Pada tahun 2018, Bhatia, dkk [8] untuk pertama kali melakukan peramalan gempa bumi di wilayah India dengan teknik *nowcasting*. Metode ini dilakukan dengan memanfaatkan *artificial neural network* dengan teknik LSTM. Hal ini coba dilakukan karena teknik *tuning hyper-parameter* memiliki keterbatasan pada dataset gempa

bumi. Sementara itu, Cekim, dkk [9] menyelidiki besarnya seismisitas berdasarkan metode *time series* di Turki. Teknik SSA (*singular spectrum analysis*) sudah dikenal sebagai alat yang ampuh dalam analisis deret waktu. Dalam studi ini, performa prediksi SSA dinilai dan dibandingkan dengan model *ARIMA* pada rangkaian waktu magnitudo gempa bumi. Studi ini menggambarkan bahwa teknik SSA dapat digunakan sebagai algoritma peramalan untuk prediksi kekuatan gempa dengan RMSE 0,551 sedangkan *ARIMA* 0,571. SSA mampu memodelkan struktur dan memprediksi besarnya gempa di masa mendatang lebih akurat daripada model *ARIMA*. Adapun Alarifi, dkk [10] dalam studinya tentang prediksi kekuatan magntudo gempa bumi di kawasan Laut Merah, menunjukkan bahwa metode *artificial neural network* menunjukkan hasil yang lebih baik kurang lebih 32% daripada metode lainnya seperti *moving average*, *normal distributed random predictor*, dan *uniformal distributed random predictor*. Ia menjelaskan bahwa, hal ini disebabkan karena fungsi jaringan saraf tiruan mampu menangkap hubungan non-linear dari metode statistik lebih baik dari metode lain yang diusulkan.

Secara khusus, penerapan *artificial intelligence* dalam prediksi kejadian gempa bumi di wilayah Indonesia, juga telah dilakukan oleh beberapa peneliti sebelumnya. Murwantara, dkk [11] mencoba menerapkan metode SVM, Naïve Bayes, dan regresi logistik multinomial. Hasil percobaan menunjukkan bahwa, SVM mengungguli metode lain, yang diikuti oleh regresi logistik multinomial kemudian Naïve Bayes. Metode SVM dengan RMSE 0,75 sedangkan regresi multinomial RMSE 0,77. Naïve Bayes menghasilkan performa paling buruk dari semua hasil prediksi dengan RMSE 0,92. Riset dilakukan oleh Sultan [12] mencoba untuk memprediksi kekuatan gempa per periode pada data *time series* selama 36 bulan (periode) untuk wilayah Maluku. Metode *neural network* dan *ARIMA* digunakan dalam penelitian ini. Hasil performa menunjukkan bahwa metode *neural network* lebih baik dari *ARIMA* dengan MSE 0.91 sedangkan *ARIMA* 1.01. Pemilihan parameter dan jumlah iterasi terbukti sangat mempengaruhi tingkat akurasi dari metode yang dipakai. Adapun riset yang dilakukan oleh Agwil, dkk [13] mencoba mengimplementasikan model jaringan saraf tiruan untuk provinsi Bengkulu. Penelitian tersebut menggunakan katalog data USGS, dengan didapatkan arsitektur terbaik pada 8-10-1 untuk wilayah Bengkulu.

Berdasarkan penelitian-penelitian sebelumnya menunjukkan bahwa metode *neural network* terbukti cukup baik digunakan pada data *time series* gempa bumi. Pada penelitian ini, metode *neural network* digunakan untuk kajian estimasi frekuensi kejadian gempa bumi di wilayah Jawa Timur. Dibandingkan penelitian sebelumnya, pada penelitian ini digunakan katalog data terbaru, yang bersumber dari data jaringan *seismograf* lokal sehingga data yang didapatkan lebih lengkap dan detail. Selain itu, dilakukan percobaan beberapa variabel arsitektur *neural network*, sehingga diharapkan akan didapatkan arsitektur yang terbaik dan dengan nilai error yang lebih kecil.

2. Metode Penelitian


Penelitian ini menggunakan data katalog parameter kejadian gempa bumi yang bersumber dari BMKG (Badan Meteorologi, Klimatologi, dan Geofisika), Stasiun Geofisika Nganjuk. Kejadian gempa bumi yang dicatat adalah kejadian gempa bumi yang terjadi di wilayah Jawa Timur dan sekitarnya dengan periode data antara tahun 2016-2021. Jumlah kejadian gempa bumi yang tercatat selama periode tersebut sebanyak 4029 kejadian. Data tersebut kemudian dikelompokkan kedalam jumlah frekuensi kejadian gempa bumi per bulan, sehingga dalam kurun waktu 6 tahun terbentuk 72 dataset. Data frekuensi gempa bumi bulanan tersebut kemudian menjadi variabel input dan output dalam proses pelatihan. Komposisi data dibagi dengan proporsi 70% data latih dan 30% data uji.

Variabel input (x_i) yang dipergunakan adalah data jumlah frekuensi gempa bumi bulanan pada waktu sebelumnya ($x_{t-1}, x_{t-2}, \dots, x_{t-n}$). Variabel output (y_t) adalah data jumlah frekuensi gempa bumi bulanan yang dijadikan data aktual/target ditunjukkan pada Gambar 1.



Gambar 1. Ilustrasi variabel input dan output (target) dengan pola 3 input node dan 1 output

Desain prediksi frekuensi bulanan gempa bumi dilakukan dengan rancangan arsitektur *neural network*, yang terdiri dari 3 jenis layer yaitu *input layer*, *hidden layer* dan *output layer* ditunjukkan pada Gambar 2.



Gambar 2. Contoh desain neural network dengan arsitektur 4-6-1

Input layer sebagai data masukan, dimana pola data input dan target output telah diilustrasikan dalam gambar 1 diatas. Sedangkan *hidden layer* adalah lapisan tersembunyi yang berada diantara input layer dan output layer yang memiliki sekumpulan bobot untuk menghasilkan output layer melalui fungsi aktivasi.

Pada pembahasan ini model arsitektur dibuat dengan variasi jumlah input node (3, 5, 7, dan 9 node input) dan jumlah neuron pada hidden layer (5, 10, 30, 50, 70, 90, dan 100 neuron hidden). Variasi jumlah input node dan neuron hidden ini dilakukan uji untuk mendapatkan desain arsitektur neural network terbaik. Desain arsitektur prediksi frekuensi gempa bumi dengan *neural network* disajikan pada Tabel 1.

Prediksi frekuensi yang digunakan menggunakan algoritma *backpropagation* dengan tahapan sebagai berikut.

2.1 Fase Propagasi Maju

Didalam setiap input X , terdapat bobot terhadap lapisan tersembunyi Z yang nilainya merupakan bilangan acak yang kecil nilainya antara 0 hingga 1 yaitu:

$$W1-1 \text{ (bobot data } X1 \text{ terhadap } Z1), W1-2, W1-3 \dots W1-9$$

Untuk mencari lapisan tersembunyi Z diperoleh dari penjumlahan nilai input X dikali dengan bobot W ditambah dengan bias.

$$Z_n = \sum_{i=1}^n X_i W_i + B \quad (1)$$

Keterangan:

Z_n : Lapisan tersembunyi ke- n

X_i : Input data ke- i

W_i : Bobot input data ke- i terhadap Z ke- i

Tabel 1. Desain arsitektur uji neural network

No	Arsitektur	Keterangan
1	3-5-1	3 input-5 neuron hidden-1 output
2	3-10-1	3 input-10 neuron hidden-1 output
3	3-30-1	3 input-30 neuron hidden-1 output
4	3-50-1	3 input-50 neuron hidden-1 output
5	3-70-1	3 input-70 neuron hidden-1 output
6	3-90-1	3 input-90 neuron hidden-1 output
7	3-100-1	3 input-100 neuron hidden-1 output
8	5-5-1	5 input-5 neuron hidden-1 output
9	5-10-1	5 input-10 neuron hidden-1 output
10	5-30-1	5 input-30 neuron hidden-1 output
11	5-50-1	5 input-50 neuron hidden-1 output
12	5-70-1	5 input-70 neuron hidden-1 output
13	5-90-1	5 input-90 neuron hidden-1 output
14	5-100-1	5 input-100 neuron hidden-1 output
15	7-5-1	7 input-5 neuron hidden-1 output
16	7-10-1	7 input-10 neuron hidden-1 output
17	7-30-1	7 input-30 neuron hidden-1 output
18	7-50-1	7 input-50 neuron hidden-1 output
19	7-70-1	7 input-70 neuron hidden-1 output
20	7-90-1	7 input-90 neuron hidden-1 output
21	7-100-1	7 input-100 neuron hidden-1 output
22	9-5-1	9 input-5 neuron hidden-1 output
23	9-10-1	9 input-10 neuron hidden-1 output
24	9-30-1	9 input-30 neuron hidden-1 output
25	9-50-1	9 input-50 neuron hidden-1 output
26	9-70-1	9 input-70 neuron hidden-1 output
27	9-90-1	9 input-90 neuron hidden-1 output
28	5-100-1	9 input-100 neuron hidden-1 output

Setelah semua dicari nilai lapisan tersembunyi Z maka nilai Y atau output dapat dicari dengan menjumlahkan nilai lapisan tersembunyi Z dikalikan dengan bobot lapisan tersembunyi V ditambah biasnya.

$$Y = \sum_{i=1}^n Z_i V_i + B \quad (2)$$

Keterangan:

Y : Output

Z_i : Lapisan tersembunyi ke- i

V_i : Bobot lapisan tersembunyi ke- i

Jika diperoleh nilai Y lebih dari 1 maka kita harus melakukan aktivasi sigmoid seperti perhitungan lapisan tersembunyi dengan menggunakan persamaan:

$$Y_k = \frac{1}{1 + e^{-Y}} \quad (3)$$

Hasil output Y dihitung selisihnya dengan nilai target Y' untuk mengetahui errornya. Jika masih maka perlu dilakukan pembobotan ulang dari nilai bobot yang lama, sampai mendapatkan nilai error terkecil ($error = 0$).

2.2 Fase Propagasi Mundur

Fase ini menghitung gradien fungsi kesalahan sehubungan dengan bobot jaringan dari setiap neuron setelah data diproses. Bobot diupdate dan disesuaikan pada hidden layer sehingga akan didapatkan nilai bobot yang baru yang outputnya akan mendekati nilai target yang diinginkan. Lakukan perhitungan faktor kesalahan pada output layer ($y_k \dots y_n$) yang menerima target pola yang berhubungan dengan pola masukan.

$$\delta_k = (t_k - y_k)y_k(1 - y_k) \quad (4)$$

Setelah itu hitung koreksi bobotnya untuk memperbaiki nilai y_{jk} ,

$$\Delta w_{kj} = \alpha \delta_k z_j \quad (5)$$

dan juga koreksi biasnya.

$$\Delta w_{0k} = \alpha \delta_k \quad (6)$$

Hitung errornya tiap hidden layer ($z_j \dots z_n$) dengan menjumlahkan delta inputan δ_k pada lapisan outputnya.

$$\delta_{netj} = \sum_{k=1}^n \delta_k w_{kj} \quad (7)$$

Kemudian kalikan nilainya dengan turunan dari fungsi aktivasinya untuk menghitung errornya.

$$\delta_j = \delta_{netj} z_j (1 - z_j) \quad (8)$$

Hitung koreksi bobot yang akan digunakan untuk memperbaiki nilai v_{jt} ,

$$\Delta v_{jt} = \alpha \delta_j x_t \quad (9)$$

dan koreksi biasnya.

$$\Delta v_{0j} = \alpha \delta_j \quad (10)$$

2.3 Fase perubahan bobot dan bias

Setiap unit output (y_k) dilakukan perubahan bobot dan bias yang menuju output layer.

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj} \quad (11)$$

Setiap unit tersembunyi (z_j) dilakukan perubahan bobot dan bias yang menuju hidden layer.

$$v_{kj}(\text{baru}) = v_{kj}(\text{lama}) + \Delta v_{ji} \quad (12)$$

2.4 Pengujian performa neural network

Setelah proses training dilakukan, hasil output aktual dan output hasil prediksi dilakukan pengujian. Pengujian dilakukan berdasarkan perhitungan evaluasi kinerja atau performa menggunakan SSE (*sum of squared error*) [15] dari output aktual dengan output prediksi neural network. Perhitungan nilai error pada setiap arsitektur dengan menggunakan persamaan.

$$E_{sse} = \frac{1}{2} \sum_{l=1}^L \sum_{h=1}^H (y_{lh} - o_{lh})^2 \quad (13)$$

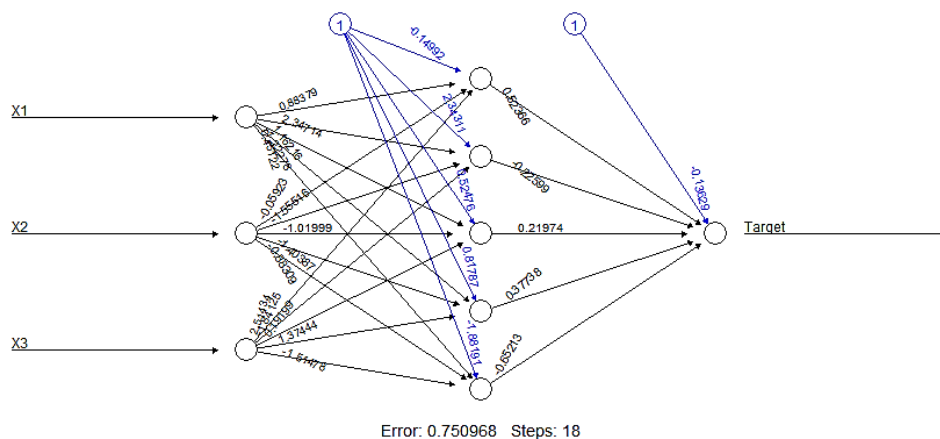
2.5 Implementasi sistem pada konsol R studio

- Instalasi paket “neuralnet”.
- Impor data dan *library*.
- Inisialisasi neural network
- Inisialisasi dilakukan antara lain dengan mendefinisikan hubungan antara input dan output, jumlah node input, jumlah hidden layer, jumlah neuron hidden, jumlah output, dll.
- Pelatihan model
- Setelah model diinisialisasi, dilakukan proses pelatihan dengan menggunakan fungsi “neuralnet”. Fungsi ini akan menyesuaikan bobot dan bias dalam jaringan neural berdasarkan data yang diberikan.
- Prediksi dan evaluasi
- Setelah proses pelatihan selesai, model yang sudah dilatih kita gunakan untuk melakukan prediksi pada data pengujian atau data baru. Selanjutnya dilakukan evaluasi kinerja model dengan membandingkan hasil prediksi dengan nilai yang sebenarnya.

3. Hasil dan Pembahasan

Gempa bumi merupakan kejadian alam yang mempunyai siklus periodik. Data historis kejadian gempa bumi coba diterapkan untuk memprediksi kejadian di masa mendatang dengan metode *backpropagation neural network*. Algoritma metode ini digunakan untuk mengenali pola frekuensi kejadian gempa bumi. Data kejadian gempa bumi Jawa Timur bersumber dari BMKG Nganjuk dengan rentang antara tahun 2016-2021. Dataset kejadian gempa bumi tersebut, lalu dibagi dengan proporsi 70% sebagai data latih dan 30% sebagai data uji. Implementasi sistem prediksi frekuensi gempa bumi dilakukan dengan bantuan software R, dengan *package neuralnet*, Gunther [15].

Neural network plot



Gambar 3. Proses training arsitektur 3-5-1

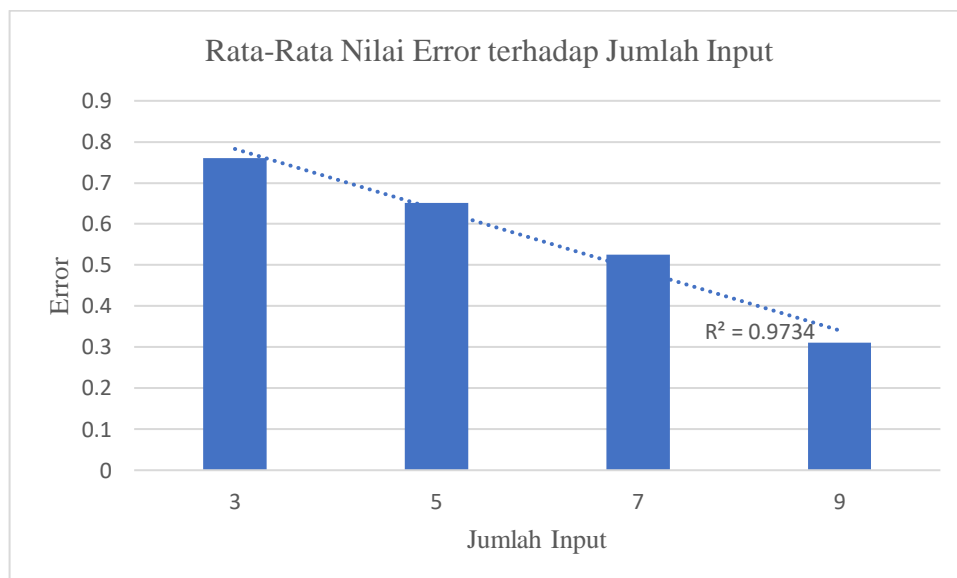
Kombinasi variasi jumlah node input dan jumlah neuron hidden digunakan sebagai variabel arsitektur *neural network*. Beberapa arsitektur tersebut kemudian diuji, sehingga nanti didapatkan model dengan arsitektur terbaik. Berikut proses pelatihan salah satu model arsitektur neural network dengan 3 input dan 5 neuron hidden (Gambar 3). Dari arsitektur ini didapatkan proses perulangan pelatihan sebanyak 18 kali dengan hasil nilai error 0.7509.

Hasil pengujian dihitung berdasarkan nilai SSE (*sum squared error*) pada tiap-tiap model arsitektur neural network yang diuji. Nilai error tersebut disajikan pada Tabel 2.

Tabel 2. Nilai error (SSE) tiap arsitektur uji

Input node	3	5	7	9	Rata-rata
Jumlah neuron hidden					
5	0,7509	0,6571	0,5271	0,2478	0,5457
10	0,7676	0,6799	0,459	0,2549	0,5403
30	0,786	0,6376	0,5212	0,1958	0,5351
50	0,8011	0,6807	0,5899	0,3733	0,6112
70	0,7404	0,6671	0,4891	0,2682	0,5412
90	0,7508	0,5954	0,4982	0,3547	0,5497
100	0,7256	0,6378	0,5888	0,4817	0,6084
Rata-rata	0,7603	0,6508	0,5247	0,3109	

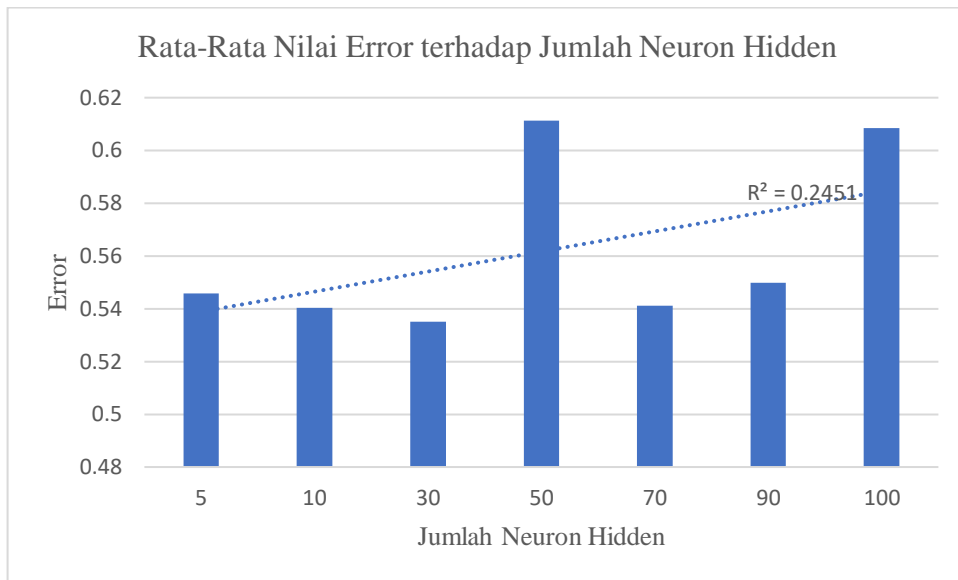
Hasil uji rata-rata error variasi jumlah input node menunjukkan hasil yang konsisten. Semakin banyak jumlah input node, akan menghasilkan nilai error yang semakin kecil. Hal ini diperkuat dengan nilai korelasi yang cukup tinggi $R^2=0.9734$ (Gambar 4). Ini menunjukkan bahwa semakin banyak pola data frekuensi yang dimasukkan sebagai input akan meningkatkan kemampuan *neural network* dalam mengenali pola data *time series* sehingga meningkatkan akurasi dalam prediksi data target.



Gambar 4. Grafik rata-rata nilai error terhadap Jumlah Input

Disisi lain variasi jumlah neuron tersembunyi pada *hidden layer* menunjukkan hasil yang inkonsisten terhadap nilai error. Berdasarkan hasil pengujian diatas (Gambar 5), terlihat bahwa variasi

jumlah neuron tersembunyi menunjukkan pengaruh yang cukup lemah dengan $R^2=0.2451$. Ini menunjukkan bahwa jumlah neuron tidak berkontribusi signifikan terhadap kualitas uji data target.



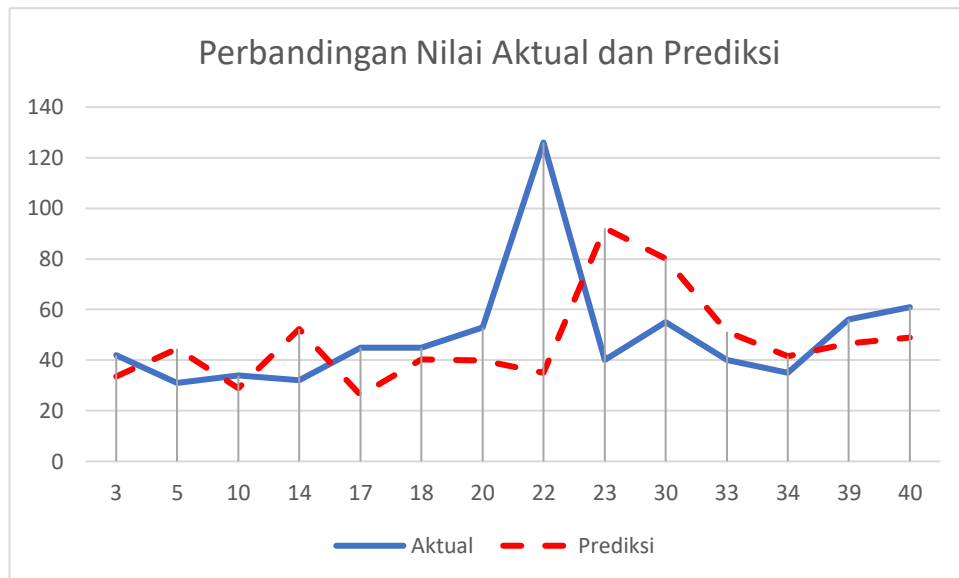
Gambar 5. Grafik rata-rata nilai error terhadap jumlah neuron tersembunyi

Dari uji performa diatas didapatkan bawa arsitektur terbaik didapatkan pada arsitektur 9-30-1, yakni dengan jumlah node input 9, jumlah hidden layer 30 dan 1 target output. Tabel 4 dibawah merupakan hasil perhitungan nilai prediksi dan perbandingannya dengan nilai aktual pada jaringan saraf tiruan dengan arsitektur 9-30-1.

Tabel 3. Hasil Perbandingan nilai aktual dan prediksi

Row	Aktual	Prediksi
3	42	33,5
5	31	44,4
10	34	29,0
14	32	52,2
17	45	26,2
18	45	40,3
20	53	39,9
22	126	35,1
23	40	92,2
30	55	80,2
33	40	51,3
34	35	41,5
39	56	46,7
40	61	49,0

Dari tabel tersebut, dapat digambarkan dalam grafik perbandingan nilai prediksi dan nilai aktual dibawah (Gambar 6). Warna biru merupakan nilai aktual, sedangkan warna merah merupakan nilai prediksi.



Gambar 6. Grafik perbandingan nilai prediksi dan aktual pada arsitektur 9-30-1

Dari gambar 6 diatas, arsitektur 9-30-1 cukup baik dalam memprediksi frekuensi gempa bumi, dimana nilai prediksi mengikuti pola data aktual, dengan nilai error sebesar 0.1958

4. Kesimpulan

Gempa bumi merupakan salah satu bencana alam yang tidak bisa kita hindari. Namun disisi lain risiko dari bencana tersebut dapat kita minimalisir, salah satunya dengan mitigasi risiko dan kesiapsiagaan masyarakat. Salah satu bentuk upaya tersebut, yakni dengan pengembangan sistem peringatan dini dan prediksi gempa bumi. Sistem prediksi gempa bumi terus dikembangkan dengan berbagai macam model dan metode. Pada penelitian ini, metode *artificial neural network* diterapkan dalam prediksi frekuensi gempa bumi di Jawa Timur. Beberapa variasi jumlah input node dan jumlah neuron tersembunyi telah dilakukan pengujian untuk mendapatkan hasil arsitektur terbaik. Hasil uji menunjukkan, variasi jumlah node input terhadap nilai error mempunyai nilai yang konsisten dan memberikan kontribusi yang cukup signifikan, dimana semakin banyak input node yang diberikan akan memberikan nilai error yang lebih baik. Arsitektur 9-30-1 merupakan arsitektur terbaik dengan nilai error 0.1958.

Ucapan Terima Kasih

Penulis menyampaikan terima kasih kepada BMKG Nganjuk yang telah menyediakan data yang penulis gunakan dalam penelitian ini.

Referensi

- [1] Pusat Studi Gempa Nasional (Indonesia) and Pusat Penelitian dan Pengembangan Perumahan dan Permukiman (Indonesia), *Peta sumber dan bahaya gempa Indonesia tahun 2017*. 2017.
- [2] S. Sri Lakshmi and R. K. Tiwari, "Model dissection from earthquake time series: A comparative analysis using modern non-linear forecasting and artificial neural network approaches," *Comput Geosci*, vol. 35, no. 2, pp. 191–204, Feb. 2009, doi: 10.1016/j.cageo.2007.11.011.
- [3] J. Reyes, A. Morales-Esteban, and F. Martínez-Álvarez, "Neural networks to predict earthquakes in Chile," *Applied Soft Computing Journal*, vol. 13, no. 2, pp. 1314–1328, 2013, doi: 10.1016/j.asoc.2012.10.014.

- [4] I. Kaftan, M. Şalk, and Y. Şenol, "Processing of earthquake catalog data of Western Turkey with artificial neural networks and adaptive neuro-fuzzy inference system," *Arabian Journal of Geosciences*, vol. 10, no. 11, Jun. 2017, doi: 10.1007/s12517-017-3021-1.
- [5] M. H. Al Banna *et al.*, "Application of Artificial Intelligence in Predicting Earthquakes: State-of-the-Art and Future Challenges," *IEEE Access*, vol. 8, pp. 192880–192923, 2020, doi: 10.1109/ACCESS.2020.3029859.
- [6] A. Pandit and S. Panda, "Prediction of earthquake magnitude using soft computing techniques: ANN and ANFIS", doi: 10.1007/s12517-021-07594-2/Published.
- [7] T. L. Todelo and C. J. G. Aliac, "Predictability of Earthquake Occurrence Using Auto Regressive Integrated Moving Average (ARIMA) Model," in *International MultiConference of Engineers and Computer Scientists*, Hong Kong: IMECS, Mar. 2019.
- [8] A. Bhatia, S. Pasari, and A. Mehta, "Earthquake forecasting using artificial neural networks," in *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*, International Society for Photogrammetry and Remote Sensing, Nov. 2018, pp. 823–827. doi: 10.5194/isprs-archives-XLII-5-823-2018.
- [9] H. O. Cekim, S. Tekin, and G. Özel, "Prediction of the earthquake magnitude by time series methods along the East Anatolian Fault, Turkey," *Earth Sci Inform*, vol. 14, no. 3, pp. 1339–1348, Sep. 2021, doi: 10.1007/s12145-021-00636-z.
- [10] A. S. N. Alarifi, N. S. N. Alarifi, and S. Al-Humidan, "Earthquakes magnitude predication using artificial neural network in northern Red Sea area," *J King Saud Univ Sci*, vol. 24, no. 4, pp. 301–313, 2012, doi: 10.1016/j.jksus.2011.05.002.
- [11] I. M. Murwantara, P. Yugopuspito, and R. Hermawan, "Comparison of machine learning performance for earthquake prediction in Indonesia using 30 years historical data," *Telkomnika (Telecommunication Computing Electronics and Control)*, vol. 18, no. 3, pp. 1331–1342, 2020, doi: 10.12928/TELKOMNIKA.v18i3.14756.
- [12] M. H. Sultan, "Optimasi Parameter Neural Network Pada Data Time Series untuk Memprediksi Kekuatan Gempa Per Periode," *Jurnal Cauchy*, vol. 3, no. 2, pp. 59–71, 2014.
- [13] W. Agwil, P. Novianti, and N. Hidayati, "Penerapan Jaringan Saraf Tiruan Pada Data Gempa Bumi di Bengkulu," *Jurnal Statistika*, vol. 8, no. 2, pp. 152–158, 2020.
- [14] B. P. Yafitra and A. R. Atiqi, "Perbandingan Prediksi Harga Saham Dengan Model ARIMA Dan Artificial Neural Network," *Indonesia Journal on Computing*, vol. 4, no. 2, pp. 189–198, 2019, doi: 10.21108/indojc.2019.4.2.344.
- [15] F. Günther and S. Fritsch, "neuralnet: Training of Neural Networks," *R J*, vol. 2, no. 1, pp. 30–38, Jun. 2010.