

# PERBANDINGAN KOMBINASI FUNGSI PELATIHAN JARINGAN SYARAF TIRUAN *BACKPROPAGATION* PADA PERAMALAN BEBAN

Gede Teguh Pradnyana Yoga<sup>1</sup>, Gede Dyana Arjana<sup>2</sup>, I Made Mataram<sup>3</sup>

<sup>1,2,3</sup> Program Studi Teknik Elektro, Fakultas Teknik, Universitas Udayana

Email : [teguhpradnyana76@gmail.com](mailto:teguhpradnyana76@gmail.com)<sup>1</sup>, [dyanaarjana@ee.unud.ac.id](mailto:dyanaarjana@ee.unud.ac.id)<sup>2</sup>

, [mataram@unud.ac.id](mailto:mataram@unud.ac.id)<sup>3</sup>

## Abstrak

Perencanaan sistem tenaga listrik sangat penting bagi penyedia tenaga listrik (PLN). Salah satunya adalah peramalan beban listrik. Jaringan syaraf tiruan *backpropagation* merupakan salah satu metode yang baik digunakan pada peramalan beban listrik karena dapat memberikan nilai akurasi yang tinggi. Pada penerapannya, jaringan syaraf tiruan *backpropagation* sering kali memberikan kecepatan konvergensi yang buruk pada proses pelatihan. Oleh karena itu, perlu dilakukan berbagai kombinasi fungsi pelatihan untuk mempercepat konvergensi pelatihan jaringan. Pada penelitian ini, model jaringan syaraf tiruan *backpropagation* dikembangkan dengan kombinasi fungsi pelatihan penurunan gradien (*traingdm*, *traingda*, *traingdx*). Perancangan arsitektur model jaringan ini menggunakan menggunakan 24 input, 1 *hidden layer* yang terdiri dari 16 neuron dan 1 output. Model ini menggunakan data beban puncak dari Gardu Induk Pemecutan Kelod dan jumlah kWh terjual di area Bali Selatan sebagai variable input. Hasil menunjukkan bahwa model terbaik menggunakan fungsi pelatihan *traingdx*. Pada model ini, Nilai MSE pelatihan yang diperoleh sebesar  $1.03 \times 10^{-8}$  dan dengan kecepatan konvergensi pelatihan selama 4 detik serta nilai MAPE pengujian sebesar 6.24% dengan akurasi jaringan sebesar 93.75%.

**Kata kunci** : Peramalan Beban, Jaringan Syaraf Tiruan, *Backpropagation*, Algoritma Pelatihan

## Abstract

*Electricity system planning is very important for electricity providers (PLN). One of them is electricity load forecasting. Backpropagation artificial neural network is one of the best methods used in electricity load forecasting because it can give high accuracy values. In application, backpropagation neural networks often provide poor convergence speed values during the training process. Therefore, it is necessary to do various combinations of training functions to accelerate the convergence of network training. In this study, a backpropagation neural network model was developed with a combination of gradient descent training functions (traingdm, traingda, traingdx). The architecture of this network model uses 24 inputs, 1 hidden layer consisting of 16 neurons and 1 output. This model uses peak load data from Pemecutan Kelod Substation and the number of kWh sold in the South Bali area as an input variable. The results show that the best model of the neural network is using the traingdx training function. In this model, the MSE training is  $1.03 \times 10^{-8}$  and with a training convergence speed is 4 seconds and MAPE testing is 6.24% with a network accuracy is 93.75%.*

**Keywords**: Load Forecasting, Artificial Neural Networks, *Backpropagation*, Training Algorithms

## 1. PENDAHULUAN

Perencanaan sistem tenaga listrik sangat penting bagi penyedia tenaga listrik (PLN). Salah satu perencanaan sistem tenaga listrik adalah peramalan beban. Peramalan beban di gardu induk pemecutan kelod bertujuan untuk mengetahui kemampuan gardu induk dalam memikul beban mengikuti tren pertumbuhan beban disisi

konsumen (pelanggan), sehingga PLN siap dengan kondisi beban listrik di gardu induk pemecutan kelod yang akan terjadi dalam periode beberapa tahun ke depan. Hal ini dapat membantu membangun lebih banyak perencanaan, pemeliharaan yang lebih efisien dan meningkatkan keandalan pada sistem tenaga listrik.

Berbagai metode peramalan berbasis statistik dikembangkan oleh PLN dan memberikan *error* peramalan dengan rentang 8-10% jika pola beban listrik yang terbentuk mempresentasikan pola yang linear [1]. Namun pola beban listrik yang aktual dipengaruhi oleh faktor-faktor yang mendasarinya, seperti suhu, kelembaban, jumlah energi terjual dan faktor ekonomi lainnya yang memiliki hubungan nonlinear. Solusi untuk mengatasi masalah tersebut dapat menggunakan bantuan kecerdasan buatan yaitu jaringan syaraf tiruan [2][14].

Jaringan syaraf tiruan *backpropagation* (BPNN) dapat diterapkan pada peramalan beban listrik dan memberikan nilai akurasi yang tinggi, namun pada penerapannya kelemahan utama yang sering dihadapi adalah kecepatan konvergensinya yang buruk pada saat pelatihan dilakukan, hal ini dikarenakan tercapainya titik lokal minimum saat pelatihan jaringan. Kinerja jaringan syaraf tiruan *backpropagation* dipengaruhi pada parameter tingkat pembelajaran dan kompleksitas masalah yang akan dimodelkan. Sehingga diperlukan algoritma fungsi pelatihan untuk mempercepat konvergensi dan memberikan nilai *error* yang kecil yang didasarkan atas MSE (*Mean Square Error*) dan MAPE (*Mean Absolute Percentage Error*), yaitu dengan menerapkan suatu kombinasi fungsi pelatihan penurunan gradien (*gradient descent*) [3][15].

## 2. TINJAUAN PUSTAKA

### 2.1 Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) disebut juga *Artificial Neural Network* (ANN) adalah bagian dari kecerdasan buatan atau *Artificial Intelligence* (AI) yang sering digunakan dalam berbagai aplikasi salah satunya adalah peramalan/prediksi.

Dalam bahasa sederhananya jaringan syaraf tiruan merupakan tiruan/representasi dari otak manusia, dimana terdapat suatu sinyal informasi yang diproses berdasarkan karakteristik jaringan syaraf biologi [4][5]. Pada dasarnya struktur jaringan syaraf tiruan ditentukan oleh tiga hal dasar sebagai berikut:

1. Arsitektur, dimana terdapat pola neuron yang saling berhubungan yang terdiri dari: lapisan input, lapisan *hidden* dan lapisan output.
2. penentuan bobot penghubung pada masing-masing lapisan input, *hidden*

dan output yang disebut sebagai (*training/learning/algorithm*).

3. Fungsi aktivasi, dimana fungsi yang paling umum digunakan adalah sigmoid.

### 2.2 Metode *Backpropagation*

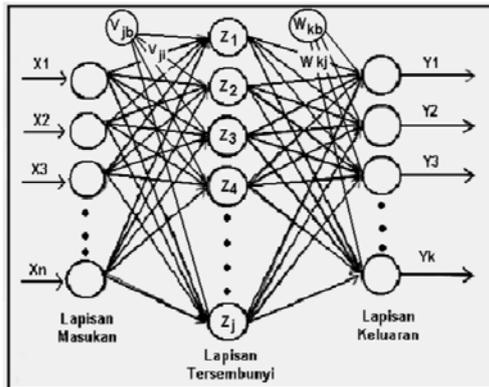
Pada jaringan syaraf tiruan *backpropagation* (BPNN), pelatihan jaringan dilakukan dengan menerapkan metode pelatihan terawasi (*supervised training*) dan arsitektur umpan maju (*feed-forward*) yang merupakan salah satu teknik untuk peramalan/prediksi. Jika disediakan dengan jumlah lapisan unit tersembunyi yang sesuai, maka jaringan dapat meminimalkan kesalahan pada fungsi nonlinear dengan kompleksitas yang tinggi.

Pada metode pelatihan ini, terdapat sejumlah pasang data masukan/input dan target/output yang digunakan untuk melakukan pelatihan jaringan. Setiap pelatihan dilakukan, nilai bobot pada lapisan input akan diproses oleh suatu fungsi aktivasi hingga menghasilkan keluaran/output. Kesalahan atau *error* yang terjadi selama proses pelatihan ini merupakan selisih antara keluaran jaringan dengan data aktual (*target*) yang ditetapkan, kemudian akan disebarkan mundur untuk memperbaiki bobot neuron pada lapisan sebelumnya yang saling berhubungan [6][7].

#### 2.2.1 Arsitektur JST

##### *Backpropagation*

Sebuah jaringan syaraf tiruan yang dilatih dengan algoritma *backpropagation* memiliki sebuah arsitektur yang terdiri dari tiga macam lapisan: lapisan pertama adalah lapisan masukan/input yang bobotnya sesuai dengan variabel input, lapisan kedua adalah lapisan tersembunyi yang digunakan untuk memproses hubungan nonlinear antar variabel dengan bobot yang sudah diinisialisasikan dan lapisan ketiga adalah lapisan keluaran/output yang digunakan untuk memberikan nilai prediksi/peramalan.



Gambar 1: Arsitektur JST Backpropagation

Struktur suatu JST ditentukan oleh arsitekturnya (unit pemrosesan dan interkoneksi antar neuron serta fungsi aktivasi yang digunakan) [7]. Gambar 1 menunjukkan sebuah arsitektur dari JST Backpropagation dengan n buah masukan, satu hidden layer dengan j buah hidden neuron dan m buah output. Pada Algoritma ini perubahan bobot didasarkan atas nilai kesalahan atau error yang dihasilkan pada arah propagasi mundur (feed-backward), sehingga tahap propagasi maju (feed-forward) dikerjakan terlebih dahulu untuk mendapatkan nilai error tersebut.

**2.2.2 Pelatihan Backpropagation**

Seperti yang disinggung pada sub bab sebelumnya, algoritma pelatihan backpropagation didasarkan atas supervised training pada jaringan syaraf umpan maju multilayer. Pada dasarnya pelatihan backpropagation dilakukan melalui tiga fase: fase maju; fase mundur; dan fase perubahan bobot. [7][8].

Fase I: Propagasi Maju (feed-forward). Pada fase ini, pola masukan/input dengan bobot awal pada setiap neuron yang sudah dinisialisasikan dipropagasikan maju melalui jaringan dengan menerapkan suatu fungsi aktivasi tertentu (sigmoid) ke neuron pada lapisan selanjutnya yang dimulai dari unit hidden layer hingga menghasilkan output di unit lapisan keluaran/output sebagai bentuk respon aktual dari jaringan.

Fase II: Propagasi mundur (feed-backward). Pada fase ini, semua bobot di setiap neuron disesuaikan mengikuti aturan koreksi kesalahan. output aktual dari jaringan kemudian dikurangi dengan target yang diinginkan untuk menghitung nilai error yang terjadi. Error tersebut kemudian dipropagasikan mundur berlawanan arah dengan koneksi propagasi maju, dimulai dari neuron garis yang terkoneksi dengan lapisan keluaran/output layer, ke lapisan tersembunyi/hidden layer hingga sampai ke lapisan masukan/input layer.

Fase III: Pada fase ini, setelah semua error didapatkan, semua bobot garis yang terkoneksi pada setiap neuron unit lapisan dimodifikasi secara bersamaan. Perubahan bobot pada garis yang menuju ke lapisan keluaran/output layer didasarkan atas error yang terjadi di setiap unit neuron pada lapisan keluaran/output layer, begitu seterusnya sampai perubahan bobot didapatkan sampai ke unit neuron pada lapisan masukan/input layer.

Ketiga fase tersebut secara berulang-ulang dilakukuan hingga proses iterasi berhenti dengan ketentuan bahwa error yang didapatkan sudah sesuai dengan batas toleransi error yang diinginkan atau kondisi penghentian (stop condition) sudah terpenuhi.

**2.2.3 Algoritma Fungsi Pelatihan**

Standar pelatihan pada algoritma backpropagation seringkali terlalu lambat dalam mencapai konvergensi pada saat pelatihan jaringan. Sehingga penerapan variasi dan kombinasi sautu fungsi pelatihan dilakukan untuk mengoptimasi model standar backpropagation. Modifikasi dilakukan untuk mempercepat konvergensi pada proses pelatihan, salah satunya dengan additive momentum dan self-adaptive learning rate yang terdapat pada fungsi pelatihan penurunan gradien (gradient descent) [9][10]. Deskripsi dari algoritma fungsi pelatihan menggunakan algoritma penurunan gradien (gradient descent) ditunjukkan pada tabel 1.

Tabel 1. List of Algorithm

Algoritma	Adaptation	Ket
traingdm	$\Delta w_k = -\alpha_k \cdot g_k + p \cdot \Delta w_{k-1}$	Modifikasi perubahan bobot didasarkan dengan menambahkan suatu nilai yang disebut dengan momentum.

traingda	$\Delta w_k = \alpha \cdot \frac{\Delta E_k}{\Delta w_k}$	Laju pembelajaran merupakan suatu konstanta yang nilainya tidak berubah-ubah selama proses iterasi terjadi. Perubahan bobot dipengaruhi oleh besarnya laju pembelajaran.
traingdx	$\Delta w_k = p \cdot \Delta w_{k-1} + \alpha \cdot p \cdot \frac{\Delta E_k}{\Delta w_k}$	Mengkombinasikan pembelajaran adaptif <i>learning rate</i> dengan penambahan momentum.

Sumber: Salim Lahmiri, 2011

### 2.4 Performansi Metode Peramalan

Dalam pemodelan jaringan syaraf tiruan, validasi berfungsi untuk mengukur kinerja dari model peramalan yang digunakan. Performansi metode peramalan dihitung setelah pengujian dilakukan untuk mengetahui *error* yang dihasilkan pada model peramalan. Kesalahan atau *error* ini merupakan perhitungan selisih antara nilai keluaran/output aktual dari jaringan dengan nilai target yang diinginkan (*output target*). Ketepatan model diukur secara relatif menggunakan MSE (*Mean Square Error*) dan MAPE (*Mean Absolute Percentage Error*) [11][12].

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y_t - Y'_t)^2 \dots\dots\dots (1)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - Y'_t}{Y_t} \right| \dots\dots\dots (2)$$

### 3. METODE PENELITIAN

Penelitian dilakukan di Laboratorium Riset Manajemen Energi Listrik Kampus Teknik Elektro Universitas Udayana dengan data dari PT. PLN (Persero) Area Pengatur Beban Bali, mengikuti alur analisis yang dijabarkan sebagai berikut:

1. Mengumpulkan data historis beban puncak Gardu Induk Pemecutan Kelod dan jumlah kWh terjual muali dari bulan januari 2013 sampai dengan bulan desember 2018.
2. Membangun arsitektur jaringan syaraf tiruan *backpropagation*.
3. Melakukan pelatihan jaringan dengan kombinasi fungsi pelatihan penurunan gradien (traingdm, traingda, traingdx) menggunakan *neural network training tool* pada matlab.
4. Melakukan pengujian jaringan syaraf tiruan *backpropagation* setelah hasil pelatihan didapatkan.
5. Memilih model terbaik dengan *error* terkecil.

### 4. HASIL DAN PEMBAHASAN

### 4.1 Persiapan dan Pengumpulan Data

Tujuan utama dari penelitian ini adalah untuk membandingkan beberapa jenis fungsi pelatihan jaringan syaraf tiruan *backpropagation* dalam membangun model peramalan beban, dan memilih fungsi pelatihan yang paling cocok untuk melatih model jaringan terutama untuk peramalan beban jangka Panjang di Gardu Induk Pemecutan Kelod.

Dataset pada jaringan syaraf tiruan *backpropagation* menggunakan 2 variabel input yaitu data historis beban puncak Gardu Induk Pemecutan Kelod dan jumlah kWh terjual di area Bali Selatan mulai dari januari 2013 sampai desember 2018.

Data dibagi menjadi menjadi 2 bagian yang terdiri dari data *training* muali dari januari 2013 sampai desember 2016, sehingga terdapat 864 data untuk pelatihan dan data *testing* mulai dari januari 2016 sampai desember 2017, dengan total data pengujian/*testing* sebanyak 288 data. Sedangkan data beban aktual pada tahun 2018 akan digunakan sebagai perbandingan hasil peramalan beban untuk mengevaluasi model jaringan yang telah dirancang. Data akan mengalami normalisasi agar kestabilan taburan data dapat tercapai. Data input akan disusun hingga memebentuk pola pelatihan dan pengujian [13]. Sesuai dengan tabel berikut.

**Tabel 2.** Normalisasi Data Pelatihan

Input	Pola 1	Pola 2	Pola 3	...	Pola 36	
Pin	X1	-1,8271	-1,7291	-1,6275	...	1,6395
	X2	-1,7993	-1,7002	-1,5995	...	2,2076
	X3	-1,7702	-1,672	-1,5704	...	2,1807
	...	...	...	...	...	...
	X22	-1,3391	-1,3995	-1,1344	...	1,1656
	X23	-1,4843	-1,2157	-1,1115	...	0,9772
X24	-1,311	-1,2045	-1,5226	...	0,9219	
<b>Target</b>						
Ptn	Y	-0,7494	-1,9437	0,1516	...	1,4041

**Tabel 3.** Normalisasi Data Pengujian

Input	Pola 1	Pola 2	Pola 3	...	Pola 12
X1	2,3815	2,5127	2,5301	...	2,5963
X2	2,3351	2,352	2,3282	...	2,8535
X3	2,1809	2,1577	2,3076	...	2,2937
X4	1,9957	2,1421	2,0001	...	2,5487
⋮	⋮	⋮	⋮	⋮	⋮
X22	1,0306	1,0245	0,9842	...	1,0296
X23	0,9711	0,9302	0,2819	...	1,7981
X24	0,8802	0,2182	1,4462	...	1,1714

#### 4.2 Rancangan Model Jaringan Syaraf Tiruan Backpropagation

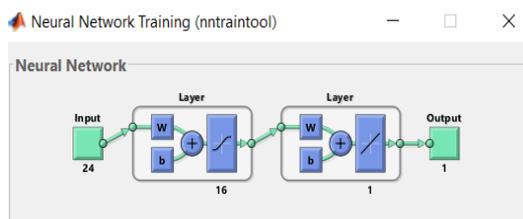
Rancangan model jaringan yang akan dikembangkan dimulai dengan menginisialisasi parameter jaringan. Setelah itu, penentuan bobot awal pada jaringan dapat ditentukan dengan bilangan acak kecil sesuai dengan kaidah Nguyen dan Widrow.

Perancangan model jaringan dapat dilakukan dengan memanfaatkan *toolbox nntool* pada program MATLAB seperti yang ditunjukkan pada tabel 4.

Tabel 4. Inisialisasi Parameter Neural Network Backpropagation

Architecture Neural Network Backpropagation	
Jumlah Hidden Layer	: 1
Hidden Neuron	: 16
Fungsi Aktivasi	: sigmoid
Fungsi Pelatihan	: traingdm, traingda, traingdx
Maksimum Epoch	: 5000
Goal	: 0

Dari tabel 4, nilai *hidden* neuron yang digunakan sebanyak 16 *hidden* neuron, sehingga arsitektur jaringan yang dibangun ditunjukkan pada gambar 2.



Gambar 2: Arsitektur JST Backpropagation

Seperti yang ditunjukkan pada gambar 2 arsitektur jaringan syaraf tiruan *backpropagation* yang dibangun memiliki 24 masukan/input, 1 lapisan tersembunyi/*hidden layer* yang terdiri dari 16 *hidden* neuron serta 1 keluaran/output.

#### 4.3 Pelatihan Model Jaringan

Pelatihan jaringan dilakukan dengan menggunakan skenario kombinasi fungsi pelatihan penurunan gradien

(*gradient descent*) yaitu, *traingdm*, *traingda* dan *traingdx*. Hasil pelatihan model jaringan dengan kombinasi algoritma fungsi pelatihan dapat dilihat seperti tabel berikut.

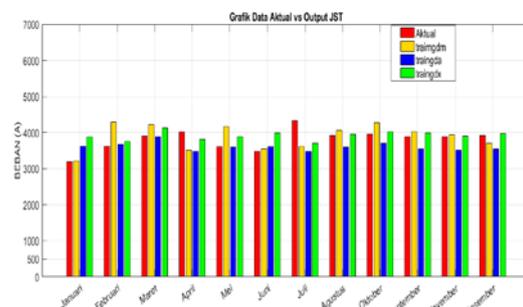
Tabel 5. Hasil Pelatihan Model Jaringan

Fungsi Pelatihan	MSE	Epoch	Time (s)
<i>traingdm</i>	$3.37 \times 10^{-8}$	4630	5
<i>traingda</i>	$2.58 \times 10^{-6}$	5000	8
<i>traingdx</i>	$1.03 \times 10^{-8}$	3317	4

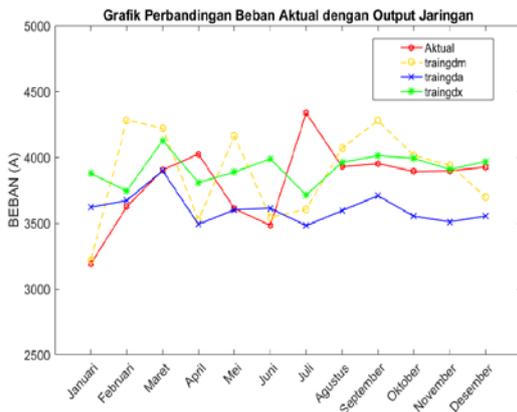
Tabel 5 menunjukkan hasil pelatihan fungsi pelatihan dengan nilai MSE pelatihan paling kecil yang didapatkan sebesar  $1.03 \times 10^{-8}$  pada fungsi pelatihan *traingdx* dengan kecepatan konvergensi selama 4 detik. Berdasarkan pada hasil tersebut menunjukkan bahwa kecepatan konvergensi pelatihan pada fungsi pelatihan *traingdx* adalah yang tercepat. Hal ini diakibatkan penambahan suatu variabel momentum sehingga perubahan bobot yang dilakukan selama proses pelatihan didasarkan pada nilai perubahan bobot pada iterasi sebelumnya. Selain itu, laju pembelajaran/*learning rate* nilainya dapat berubah-ubah selama iterasi berlangsung sampai kondisi penghentian sudah terpenuhi. Proses selanjutnya adalah pengujian jaringan untuk mevalidasi hasil pelatihan.

#### 4.4 Pengujian Model Jaringan

Pada proses ini, hasil pelatihan jaringan diujikan dengan data *testing* yang telah ditentukan. pengujian jaringan dilakukan untuk memvalidasi dan melihat persentase keakuratan jaringan dari model yang dirancang berdasarkan pada nilai MAPE. Hasil pengujian jaringan dapat dilihat pada gambar 3 dan 4.



Gambar 3: Grafik Batang Data Aktual vs JST



Gambar 4: Kurva Perbandingan Beban Aktual (A) dengan Output Jaringan

Gambar 2 dan 3 menunjukkan hasil perbandingan antara beban aktual dengan output dari jaringan menggunakan fungsi pelatihan yang berbeda (traingdm, traingda, traingdx). Hasil menunjukkan bahwa fungsi pelatihan traingdx memberikan nilai yang paling mendekati data beban aktual, dengan nilai MAPE yang ditunjukkan seperti tabel 6.

Tabel 6. Nilai MAPE dan Akurasi Jaringan

Fungsi Pelatihan	MAPE	Akurasi
traingdm	7.90%	92.09%
traingda	9.66%	91.33%
traingdx	6.24%	93.75%

Pemilihan fungsi pelatihan didasarkan pada nilai MAPE yang paling kecil. Hasil menunjukkan bahwa fungsi pelatihan traingdx memiliki MAPE terkecil, yaitu sebesar 6.24% dengan akurasi jaringan sebesar 93.75%. Hal ini menunjukkan bahwa jaringan syaraf tiruan *backpropagation* dengan fungsi pelatihan traingdx sudah mampu mengurangi nilai *error* peramalan yang dilakukan oleh PLN menggunakan metode pendekatan deret waktu statistik regresi-ekonometri yang dikenal dengan metode koefisien beban, dimana pada metode tersebut *error* prediksi yang dihasilkan memiliki rentang antara 8-10%.

### 5. SIMPULAN

Model jaringan syaraf tiruan *backpropagation* yang dirancang menggunakan kombinasi algoritma fungsi pelatihan penurunan gradien (*gradient descent*), diperoleh model terbaik menggunakan algoritma fungsi pelatihan traingdx dengan nilai MSE pelatihan sebesar  $1.03 \times 10^{-8}$  dan kecepatan

konvergensi selama 4 detik serta MAPE pengujian sebesar 6.24% dengan akurasi jaringan sebesar 93.75%.

### 6. DAFTAR PUSTAKA

- [1] Abdullah, A. D. dan Mulyadi, Y. 2011. Peramalan Beban Listrik Jangka Pendek Melalui Pendekatan Statistik dan *Soft Computing*. Konferensi Nasional Teknologi Informasi dan Aplikasinya (KNTIA).
- [2] Samuel, IA., Emmanuel, A., Odigwe, IA. and Felly- Njoku, CF. 2017. *A Comparative Study of Regression Analysis and Artificial Neural network Methods for Medium-Term Load Forecasting*. *Indian Journal of Science and Technology*, 10(10): 1-7.
- [3] Suhendra, CD. dan Wardoyu, R. 2015. Penentuan Arsitektur Jaringan Syaraf Tiruan *Backpropagation* (Bobot Awal dan Bias Awal) Menggunakan Algoritma Genetika. *Indonesian Journal of Computing and Cybernetics Systems (IJCCS)*, 9(1). 77-88.
- [4] Fauset, L. 1994. *Fundamentals of Neural Network Architectures, Algorithms and Application*, London: Prantice-Hall, Inc.
- [5] Singla, M., 2018. *Load Forecasting Using Artificial Neural Network (Doctoral dissertation)*.
- [6] Ramadoni, S. 2018. *Application of Artificial Neural network for Power Transformer Peak Load Prediction*. *Journal of Theoretical and Applied Information Technology*, 96(22). 7643-7653.
- [7] Siang, J., J. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Yogyakarta: Andi.
- [8] Kusumadewi, S. 2004. *Membangun Jaringan Syaraf Tiruan*. Yogyakarta: Graha Ilmu
- [9] Pan, X., Lee, B., & Zhang, C. 2013. *A Comparison of Neural Network Backpropagation Algorithms for Electricity Load Forecasting*. 2013 *IEEE International Workshop on Intelligent Energy Systems*, 22-27.
- [10] Lahmiri, S. 2011. *A Comparative Study of Backpropagation Algorithms in Financial Prediction*. *International Journal of Computer Science, Engineering and Applications (IJCSA)*, 1(4). 15-21.

- [11] Wihardono, JD., Dharma, A., & Mataram, IMD. 2016. Peramalan Beban Jangka Pendek Pada Hari Libur Di Bali Menggunakan Metode *Generalized Regression Neural Network* (GRNN). *E-Journal SPEKTRUM*, 3(2). 71-76.
- [12] Montañó Moreno, JJ., Palmer Pol, A., Sesé Abad, A., & Cajal Blasco, B. 2013. *Using The R-MAPE Index as A Resistant Measure of Forecast Accuracy*. *Psicothema* 2013, 25(4). 500-506.
- [13] Saija, S., H., Lesnussa, Y., A., & Kondolembang, F. 2017. *Application of Artificial Neural Network Backpropagation to Predict Household Consumption of Electricity in Ambon. Proceedings of the 3rd International Seminar of Basic Sciences*. 131-138.
- [14] Manish Kumar Singla, Jyoti Gupta. 2018. *Load Forecasting Using Back Propagation Algorithm. International Journal of Engineering and Techniques*, 4(4). 169-175.
- [15] Zhuang, L., Liu, H., Zhu, J., Wang, S., & Song, Y. 2016. *Comparison of Forecasting Methods for Power System Short-term Load Forecasting Based on Neural Networks*. 2016 *IEEE International Conference on Information and Automation (ICIA)*