

# PERAMALAN PELAYANAN SERVICE MOBIL (AFTER SALE) MENGGUNAKAN BACKPROPAGATION NEURAL NETWORK (BPNN)

Novianti Puspitasari<sup>1</sup>, Havaluddin<sup>2</sup>, Arinda Mulawardani Kustiawan<sup>3</sup>,  
Hario Jati Setyadi<sup>4</sup>, dan Gubtha Mahendra Putra<sup>5</sup>

<sup>1,2,3,4,5</sup>Program Studi Informatika Universitas Mulawarman  
Samarinda, Kalimantan Timur, Indonesia

Email: Enovia.ftik.unmul@gmail.com<sup>1</sup>, havaluddin@unmul.ac.id<sup>2</sup>, arinda.mulawardani@gmail.com<sup>3</sup>,  
hario.setyadi@fkti.unmul.ac.id<sup>4</sup>, gubthamp@fkti.unmul.ac.id<sup>5</sup>

## Abstrak

Mobil adalah salah satu alat transportasi darat yang penting, karena mobil dapat membantu manusia dalam beaktivitas khususnya untuk pergi dari satu tempat ke tempat lain. Hal ini membuat para produsen mobil berlomba-lomba untuk menciptakan mobil dengan kelebihan dan keunggulan, sehingga jumlah mobil dipasaran sangat banyak dan bervariasi. Seiring dengan meningkatkan jumlah mobil maka Agen Tunggal Pemegang Merk (ATPM) berlomba-lomba untuk memberikan pelayanan after-sale (service mobile). Namun, pihak perusahaan mengalami kesulitan dalam mengetahui laju pertumbuhan jumlah service mobile yang ditangani, sehingga memberikan kerugian yang berdampak pada sumber pendapatan. Oleh karena itu diperlukan sebuah metode baku dalam menentukan peramalan jumlah service mobil di tahun berikutnya. Penelitian ini mengimplementasikan metode Backpropagation Neural Network (BPNN) dalam peramalan pelayanan service mobil (after-sale) dan Mean Square Error (MSE) untuk metode pengujian akurasi hasil peramalan yang terbentuk. Adapun data yang digunakan pada penelitian ini adalah data pelayanan service mobil (after-sale) selama lima tahun terakhir. Hasil penelitian menunjukkan bahwa arsitektur terbaik untuk peramalan pelayanan after-sale menggunakan BPNN adalah model arsitektur 5-10-5-1 dengan learning rate sebesar 0,2 dan fungsi pembelajaran yaitu trainlm serta MSE sebesar 0,00045581. Hal ini membuktikan bahwa metode BPNN mampu memprediksi pelayanan service mobil (after-sale) dengan nilai akurasi peramalan yang baik.

**Kata Kunci:** after-sale, Backpropagation Neural Network, Mobil, MSE, peramalan

## Abstract

Cars are an important means of land transportation because cars can help humans in their activities, especially to get from one place to another. This makes car manufacturers compete to create cars with advantages and disadvantages so that the number of cars on the market is vast and varied. Along with increasing the number of cars, Brand Holder Sole Agents (ATPM) compete to provide after-sale services (mobile service). However, the company experienced difficulties in knowing the growth rate of the number of mobile services handled, resulting in losses that impacted revenue sources. Therefore we need a standard method to determine the number of car services in the following year. This study implements the Backpropagation Neural Network (BPNN) method in forecasting car service (after sale) services and the Mean Square Error (MSE) for testing the accuracy of the forecast results formed. The data used in this study are car service data (after-sale) for the last five years. The results showed that the best architecture for forecasting after-sale services using BPNN is the 5-10-5-1 architectural model with a learning rate of 0,2 and the learning function of Trainlm and MSE of 0,00045581. This proves that the BPNN method can predict mobile service (after-sale) services with good forecasting accuracy values.

**KeyWords :** after-sale, Backpropagation Neural Network, Cars, MSE, prediction.

## I. PENDAHULUAN

Mobil merupakan salah satu alat transportasi darat yang penting di era saat ini. Mobil dapat membantu manusia dalam beraktivitas khususnya untuk pergi dari satu tempat ke tempat lain. Produsen mobil akhirnya berlomba-lomba untuk menciptakan mobil yang memiliki kelebihan dan keunggulan yang berbeda-beda, sehingga jumlah pertumbuhan mobil semakin meningkat dan bervariasi dipasaran. Agen Tunggal Pemegang Merk (ATPM) sebagai salah satu perusahaan yang memproduksi mobil berlomba-lomba dalam memberikan pelayanan *after-sale* kepada para pemilik mobil yang jumlahnya semakin banyak dipasaran. Pelayanan *after-sale* merupakan pelayanan *service* mobil yang disediakan oleh bengkel resmi dan pengadaan suku cadang kendaraan *original*.

Layanan purna jual termasuk perbaikan kendaraan (*service*) pada bengkel resmi merupakan salah satu indikator penting dalam sebuah perusahaan. Jika tingkat pelayanan *service* yang dihasilkan oleh sebuah perusahaan tersebut tinggi, maka perusahaan akan menghasilkan laba yang besar pula, sehingga perusahaan akan bertahan dalam persaingan bisnis.

Berdasarkan data pelayanan *after-sale* ATPM dalam lima tahun terakhir, dari tahun 2014 sampai 2018 mengalami ketidakstabilan. Hal ini menyebabkan perusahaan mengalami kerugian yang berdampak pada sumber pendapatan perusahaan. Oleh karena itu, pentingnya untuk mengetahui hasil pelayanan *after-sale* di masa yang akan datang agar perusahaan dapat mengetahui tingkat pelayanan *service* yang dihasilkan telah sesuai dengan target atau tidak dalam rangka mencegah kerugian. Kesulitan perusahaan dalam mengetahui laju pertumbuhan jumlah *service* mobil dimasa yang akan datang disebabkan belum adanya metode baku dalam menentukan peramalan jumlah penjualan pelayanan after-sale untuk tahun berikutnya.

Peramalan atau prediksi telah banyak dilakukan menggunakan berbagai metode kecerdasan buatan. Diantaranya adalah peramalan kedatangan turis menggunakan metode *Average Based Fuzzy Time Series* yang memiliki kriteria peramalan yang baik dengan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 0,77375% [1], metode *Adaptive Neural Network Backpropagation* (ANNBP) untuk memprediksi tinggi muka air dengan hasil akurasi MSE dan MAPE sebesar 9,7% [2], metode *Naïve Bayes* untuk memprediksi pengunduran diri mahasiswa dengan menghitung sekumpulan probabilitas dengan tingkat akurasi sebesar 77,78% yang menunjukkan bahwa metode *Naïve Bayes* mampu memprediksi dengan baik [3] serta masih banyak lagi penelitian tentang peramalan menggunakan berbagai metode kecerdasan buatan [4]–[11].

Metode Jaringan Syaraf Tiruan (JST) merupakan metode yang sangat baik untuk mendapatkan hasil peramalan yang lebih baik [12]–[19]. Model akurasi peramalan terbaik yang digunakan dalam JST adalah MSE [19], [20]. Hal inilah yang menjadi dasar penelitian ini menerapkan metode *Backpropagation Neural Network* (BPNN) dalam meramalkan data pelayanan *service* mobil (*after-sale*) pada tahun berikutnya. Penelitian ini akan mengeksplorasi arsitektur jaringan dan laju pembelajaran (*learning rate*) yang merupakan parameter BPNN. Hasil penelitian ini diharapkan dapat membantu pihak perusahaan dalam mengambil kebijakan terkait pelayanan *service* mobil (*after-sale*) sehingga perusahaan dapat meningkatkan keuntungan.

## II. METODE

### A. Backpropagation Neural Network (BPNN)

*Backpropagation Neural Network* (BPNN) merupakan salah satu metode pelatihan dari JST yang diperkenalkan oleh Paul Werbos pada tahun 1974, kemudian dikembangkan oleh David Parker pada tahun 1982. Selanjutnya, tahun 1986 dikembangkan lagi oleh Rumelhart dan McClelland. BPNN banyak digunakan untuk memecahkan berbagai persoalan simulasi termasuk peramalan [17]. Pelatihan BPNN terdiri dari tiga tahapan, yaitu umpan maju (*feed-forward*), umpan mundur (*backpropagation*) dan perubahan bobot. Adapun pelatihan BPNN adalah sebagai berikut:

**Tahap 0** : Inisialisasi bobot

**Tahap 1** : Jika kondisi terpenuhi, lakukan tahap 2-8

**Tahap 2** : Untuk setiap pasangan data, lakukan tahap 3-8

#### Fase 1 : Feed Forward

**Tahap 3** : Setiap unit menerima signal masukan dan dikirim ke lapisan tersembunyi

**Tahap 4** : Hitung semua nilai dalam lapisan tersembunyi  $Z_j = (j = 1, 2, \dots, p)$ , kemudian setiap signal masukan dijumlahkan dengan rumus 1

$$z_{netj} = v_{jo} + \sum_{i=1}^n x_i v_{kj} \quad (1)$$

Lebih lanjut hitung fungsi aktivasi untuk menghitung signal keluaran dan dikirim ke semua unit keluaran. Fungsi aktivasi yang biasanya dipakai adalah fungsi *sigmoid*, baik *biner* maupun *bipolar*. Fungsi *sigmoid biner* memiliki range antara 0 sampai dengan 1, untuk fungsi *sigmoid bipolar* memiliki range antara -1 sampai dengan 1. Fungsi aktivasi dihitung menggunakan rumus 2;

$$z_j = f(z_{netj}) = \frac{1}{1 + e^{-z_{netj}}} \quad (2)$$

**Tahap 5** : Hitung semua nilai keluaran dalam semua jaringan output  $y_k = (k = 1, 2, 3, \dots, m)$ , kemudian setiap signal masukan dijumlahkan dengan rumus 3 berikut;

$$y_{netk} = w_{ko} + \sum_{j=1}^p z_j w_{kj} \quad (3)$$

Hitung fungsi aktivasi untuk menghitung signal keluaran dan dikirimkan ke semua unit keluaran dengan rumus 4 berikut;

$$(y_k) = f(y_{netk}) = \frac{1}{1 + e^{-y_{netk}}} \quad (4)$$

#### Fase 2 : Backpropagation

**Tahap 6** : Hitung faktor  $\delta$  unit keluaran *error*  $y_k, (1, 2, \dots, m)$  seperti terlihat pada rumus 5 berikut;

$$\delta_k = (t_k - y_k) f'(y_{netk}) \quad (5)$$

Dimana :  $t_k$  = target keluaran,  $\delta$  = unit keluaran yang digunakan untuk memperbaharui bobot Hitung perubahan bobot baru dan bias  $w_{kj}$ , dengan nilai laju pembelajaran  $\alpha$ ,

$$\delta_{wji} = \alpha \delta_k z_j (k = 1, 2, \dots, m; j = 0, 1, \dots, p) \quad (6)$$

**Tahap 7 :** Hitung faktor  $\delta$  dalam unit lapisan tersembunyi berdasarkan nilai *error*  $Z_j, (1, 2, \dots, p)$  dengan rumus 7

$$\delta_{netj} = \sum_{k=1}^m \delta_k w_{kj} \tag{7}$$

Hitung faktor dalam unit lapisan tersembunyi dengan rumus 8

$$\delta_j = \delta_{netj} f'(z_{netj}) = \delta_{netj} \cdot Z_j(1 - Z_j) \tag{8}$$

Hitung nilai perubahan bobot dan bias  $v_{ij}$

$$\delta y_{ji} = \alpha \delta_k \cdot Z_j, k = (1, 2, \dots, p); j = (0, 1, \dots, n) \tag{9}$$

**Fase 3 : Perubahan bobot**

**Tahap 8 :** Hitung semua perubahan bobot dan bias yang mengarah ke unit keluaran

$$w_{kj}(new) = w_{kj}(old) + \delta w_{ji}; \tag{10}$$

$$(k = 1, 2, \dots, p; j = 0, 1, \dots, n)$$

Hitung perubahan bobot dan bias di dalam lapisan tersembunyi dengan rumus 11

$$v_{kj}(new) = v_{kj}(old) + \delta v_{ji}; \tag{11}$$

$$(j = 1, 2, \dots, p; w = 0, 1, \dots, n)$$

**B. Metode Akurasi Peramalan**

Pengukuran suatu model peramalan dapat menggunakan beberapa metode statistik diantaranya *Mean Absolute Error* (MAE), *Mean Square Error* (MSE), *Root Mean Squared Error* (RMSE) dan *Normalize Mean Square Error* (NMSE). Tujuan dari pengukuran metode peramalan adalah mendapatkan nilai terbaik antaran nilai asli dan nilai hasil peramalan [21], [22]. Metode untuk mengukur akurasi peramalan yang digunakan dalam penelitian ini adalah MSE [19], [20]. Rumus MSE terlihat pada persamaan 12.

$$MSE = \frac{1}{M} \sum_{t=1}^M (x_t - \hat{x}_t)^2 \tag{12}$$

**C. Data Peramalan**


Data yang digunakan dalam penelitian ini adalah data pelayanan *service* mobil (*after-sale*) yang diperoleh dari PT. Samekarindo Indah Samarinda, Kalimantan Timur sebanyak 60 (enam puluh) bulan, dimulai dari bulan Januari 2014 - Desember 2018. Data penelitian dapat dilihat pada Tabel I dan diplot pada Gambar 1. *Software* yang digunakan untuk melakukan analisa data dalam penelitian ini adalah MATLAB. Berdasarkan prinsip sistem cerdas maka data *after-sale* dilakukan normalisasi terlebih dahulu. Data dalam penelitian ini dinormalisasi dalam ordo [0,1] menggunakan rumus normalisasi seperti terlihat pada persamaan 13.

$$\bar{x} = \frac{0.8 (x - x_{min})}{x_{max} - x_{min}} + 0.1 \tag{13}$$

dimana,  $\bar{x}$  adalah nilai data deret waktu normalisasi dari  $x$ ;  $x$  adalah nilai data deret waktu asli;  $x_{max}$  adalah nilai maksimum data deret waktu, dan  $x_{min}$  adalah nilai minimum data deret waktu. Lebih lanjut, untuk mengembalikan ke data asli maka dilakukan proses denormalisasi. Data *after-sale* yang telah dinormalisasi dapat dilihat pada Tabel II.

Tabel I: Data *After-sale*

Bulan/Tahun	2014	2015	2016	2017	2018
Januari	840 unit	860 unit	816 unit	783 unit	720 unit
Februari	792 unit	776 unit	808 unit	626 unit	631 unit
Maret	858 unit	838 unit	813 unit	699 unit	663 unit
April	852 unit	803 unit	789 unit	639 unit	640 unit
Mei	868 unit	781 unit	854 unit	691 unit	649 unit
Juni	853 unit	819 unit	875 unit	648 unit	582 unit
Juli	822 unit	903 unit	760 unit	696 unit	691 unit
Agustus	872 unit	824 unit	777 unit	650 unit	648 unit
September	847 unit	787 unit	743 unit	591 unit	644 unit
Oktober	831 unit	843 unit	761 unit	663 unit	674 unit
November	852 unit	794 unit	742 unit	625 unit	624 unit
Desember	855 unit	803 unit	796 unit	673 unit	708 unit



Gambar 1: Plot Data *after-sale* pada tahun 2014-2018

Tabel II: Data *After-sale* Setelah Dinormalisasi

Bulan/Tahun	Training				Testing
	2014	2015	2016	2017	2018
Januari	0,7429	0,7928	0,6831	0,6009	0,4439
Februari	0,6233	0,5834	0,6632	0,2096	0,2221
Maret	0,7878	0,7380	0,6757	0,3915	0,3018
April	0,7729	0,6507	0,6158	0,2420	0,2445
Mei	0,8127	0,5959	0,7778	0,3716	0,2669
Juni	0,7753	0,6906	0,8302	0,2644	0,1
Juli	0,6981	0,9	0,5436	0,3841	0,3716
Agustus	0,8227	0,7031	0,5859	0,2694	0,2644
September	0,7604	0,6109	0,5012	0,1224	0,2545
Oktober	0,7205	0,7504	0,5461	0,3018	0,3292
November	0,7728	0,6283	0,4987	0,2071	0,2046
Desember	0,7803	0,6507	0,6333	0,3267	0,4140

### III. HASIL

Pada bagian ini menjelaskan tentang hasil pengujian metode BPNN yang diujikan pada data *after-sale*. Berdasarkan aturan pelatihan dalam JST, data *after-sale* sebanyak 60 data sampel dibagi menjadi dua bagian. Data pelatihan (*training*) sebanyak 48 sampel data, dan data pengujian (*testing*) sebanyak 12 data. Lebih lanjut, jumlah masukan (*input layer*) yang digunakan sebanyak lima *neurons*  $P = [p(t - 5), p(t - 4), p(t - 3), p(t - 2), p(t - 1)]$  dan jumlah keluaran (*output layer*) sebanyak satu neuron [*output neurons* T]. Arsitektur metode BPNN yang digunakan dalam penelitian ini terdiri dari dua kategori, yaitu satu lapisan tersembunyi dan dua lapisan tersembunyi. Fungsi aktivasi yang digunakan; untuk satu lapisan tersembunyi; dari lapisan masukan ke lapisan tersembunyi adalah *tansig*, dan dari lapisan tersembunyi ke lapisan keluaran adalah *purelin*. Lebih lanjut, untuk dua lapisan tersembunyi; dari lapisan masukan ke lapisan tersembunyi adalah *tansig* dan *logsig*, dan dari lapisan tersembunyi ke lapisan keluaran adalah *purelin*. Algoritma pelatihan yang digunakan untuk semua arsitektur metode BPNN adalah *gradient descent (traingdm)*. Metode pengujian akurasi peramalan yaitu MSE digunakan untuk membandingkan nilai asli dan nilai hasil peramalan. Nilai MSE yang mendekati 1 merupakan nilai hasil pelatihan metode BPNN dengan arsitektur yang terbaik. Model arsitektur BPNN yang di uji terlihat pada Tabel III.

Tabel III: Model Arsitektur BPNN

Variabel	Nilai
Arsitektur <i>Hidden Layer</i>	3, 3, 3, 2, 2, 2 5-5-5-5-1; 5-5-6-6-1; 5-5-10-10-1; 5-10-5-1; 5-10-7-1; 5-10-9-1 trainlm; traingd; traingdx
Fungsi Pembelajaran	logsig; purelin
Fungsi Aktivasi	0,2 0,3 0,9
Laju Pembelajaran	5-5-5-5-1; 5-5-6-6-1; 5-5-10-10-1; 5-10-5-1; 5-10-7-1; 5-10-9-1

Tahap selanjutnya adalah melakukan pengujian model arsitektur yang telah ditentukan. Pengujian ini dilakukan dengan menggunakan metode *try-and-error*. Hal ini berarti nilai akhir setiap kali pengujian disimpan dan menjadi perbandingan model

sampai mendapat model arsitektur yang baik untuk prediksi. Hasil pengujian model arsitektur BPNN dapat dilihat pada Tabel IV.

Tabel IV: Hasil Pengujian Model Arsitektur BPNN

No.	Parameter		MSE		
	Model Arsitektur	Fungsi Pembelajaran	LR	Pelatihan	Pengujian
1	5-5-5-5-1	TRAINLM	0,2	0,0021487	0,00053394
2		TRAINGD	0,2	0,0095134	0,0042284
3		TRAINGD	0,2	0,011162	0,0076683
4		TRAINLM	0,3	0,0037026	0,01697
5		TRAINGD	0,3	0,0085026	0,0001958
6		TRAINGD	0,3	0,011132	0,00064377
7		TRAINLM	0,9	0,0028339	0,00015131
8		TRAINGD	0,9	0,0095473	0,0085697
9		TRAINGD	0,9	0,0061053	0,010013
10	5-5-6-6-1	TRAINLM	0,2	0,0038534	0,0026907
11		TRAINGD	0,2	0,014971	0,0046498
12		TRAINGD	0,2	0,008699	0,0086819
13		TRAINLM	0,3	0,0051347	0,0082093
14		TRAINGD	0,3	0,010365	0,003274
15		TRAINGD	0,3	0,011298	0,0004512
16		TRAINLM	0,9	0,0070278	0,0011997
17		TRAINGD	0,9	0,0086084	0,003397
18		TRAINGD	0,9	0,0097336	0,0058092
19	5-5-10-10-1	TRAINLM	0,2	0,0088314	0,0010997
20		TRAINGD	0,2	0,0094109	0,0032566
21		TRAINGD	0,2	0,0078561	0,0027335
22		TRAINLM	0,3	0,0080935	0,0033326
23		TRAINGD	0,3	0,009594	0,0013082
24		TRAINGD	0,3	0,010393	0,0038013
25		TRAINLM	0,9	0,0056065	0,0085379
26		TRAINGD	0,9	0,018702	0,0024079
27		TRAINGD	0,9	0,0093755	0,0088095
28	5-10-5-1	TRAINLM	0,2	0,0016632	0,00025718
29		TRAINGD	0,2	0,009171	0,00094251
30		TRAINGD	0,2	0,017845	0,00067779
31		TRAINLM	0,3	0,00083401	0,0016793
32		TRAINGD	0,3	0,00794141	0,0027773
33		TRAINGD	0,3	0,0092636	0,0070622
34		TRAINLM	0,9	0,0032714	0,0048179
35		TRAINGD	0,9	0,0099905	0,0041116
36		TRAINGD	0,9	0,031785	0,00064535
37	5-10-7-1	TRAINLM	0,2	0,0094055	0,0053769
38		TRAINGD	0,2	0,0093389	0,008574
39		TRAINGD	0,2	0,0070697	0,009047
40		TRAINLM	0,3	0,0081332	0,0018103
41		TRAINGD	0,3	0,0085616	0,0006072
42		TRAINGD	0,3	0,008826	0,0024631
43		TRAINLM	0,9	0,0014591	0,0036185
44		TRAINGD	0,9	0,0076877	0,0007095
45		TRAINGD	0,9	0,010232	0,0044151
46	5-10-9-1	TRAINLM	0,2	0,0040588	0,0010082
47		TRAINGD	0,2	0,0080645	0,0097648
48		TRAINGD	0,2	0,021152	0,0004501
49		TRAINLM	0,3	0,0068399	0,002719
50		TRAINGD	0,3	0,0068869	0,007943


Tabel IV: (continued)

No.	Parameter			MSE	
	Model Arsitektur	Fungsi Pembelajaran	LR	Pelatihan	Pengujian
51		TRAINGDX	0,3	0,0088565	0,0012978
52		TRAINLM	0,9	0,006209	0,0024579
53		TRAINGD	0,9	-	-
54		TRAINGDX	0,9	0,013497	0,0042891

Plot grafik hasil pelatihan dapat dilihat pada Gambar 2a. Dari Gambar 2a terlihat bahwa nilai MSE yang didapatkan sebesar 0,0028339. Hal ini menunjukkan bahwa hasil pelatihan hampir mendekati dengan target yang diinginkan. Lebih lanjut, plot grafik hasil pengujian menghasilkan nilai MSE sebesar 0,00015131 seperti terlihat pada Gambar 2b. Hal ini menunjukkan bahwa hasil pengujian hampir mendekati dengan target yang diinginkan.



(a) Plot Grafik Hasil Pelatihan Model Arsitektur




(b) Plot Grafik Hasil Pengujian Model Arsitektur

Gambar 2: Plot Grafik Hasil pelatihan dan Pengujian Model Arsitektur


Tahap selanjutnya adalah memilih model terbaik dari hasil uji coba untuk meramalkan pelayanan *service* mobil (*after-sale*) pada tahun berikutnya (tahun 2019). Berdasarkan hasil uji coba menggunakan *Learning Rate* (LR) 0,3 dengan 5 inputan, 3 *hidden layer* dengan masing-masing *neuron* yaitu 5-5-5 dan 1 *output*, *epoch* maksimal sebesar 1000 dan *epoch* berhenti pada iterasi ke lima puluh dengan waktu eksekusi selama kurang dari satu detik.

Gambar 3 merupakan analisis pasca pelatihan (*post-training analysis*) yang menghasilkan koefisien kecocokan sebesar 0,68 dari nilai aktual dan nilai prediksi. Sedangkan, intersep kesesuaian dari nilai aktual dan nilai prediksi sebesar 0,2. Koefisien korelasi antara nilai aktual dan nilai prediksi didapatkan sebesar 0,87452. Dari Gambar 3 terdapat garis putus-putus yang merupakan target dan garis merah yang merupakan hasil prediksi memiliki sedikit kesamaan dikarenakan koefisien relasinya kurang mendekati angka 1 yang berarti hasil prediksi kurang mendekati target.




Gambar 3: Post Training Analysis Jaringan BPNN (*learning rate 0,3*)

Plot grafik hasil pelatihan Jaringan menggunakan arsitektur terbaik pada pengujian Jaringan BPNN dengan LR 0,3 ditunjukkan oleh Gambar 4a. dengan nilai MSE sebesar 0,0094242. Gambar 4b. menampilkan plot grafik hasil pengujian menggunakan arsitektur terbaik yang memperoleh nilai MSE sebesar 0,0084325. Berdasarkan hasil uji coba menggunakan LR 0,9 dengan 5 inputan, 3 hidden layer dengan masing-masing neuron yaitu 5-5-5 dan 1 output, epoch maksimal sebesar 1000 dan epoch berhenti pada iterasi kesatu dengan waktu eksekusi selama kurang dari satu detik. Analisis pasca pelatihan (post-training analysis) dengan LR 0,9 menghasilkan koefisien kecocokan sebesar 0,75 dari nilai aktual dan nilai prediksi seperti yang terlihat pada Gambar 5. Intersep kesesuaian dari nilai aktual dan nilai prediksi sebesar 0,1. Koefisien korelasi antara nilai aktual dan nilai prediksi sebesar 0,93435. Dilihat dari Gambar 5 target yang digambarkan sebagai garis putus-putus dan hasil prediksi yang digambarkan dengan garis berwarna merah, memiliki sedikit perbedaan dan dikarenakan koefisien korelasinya mendekati 1 sehingga hasil prediksi cukup baik.




(a) Plot Grafik Hasil Pelatihan Jaringan BPNN (*learning rate 0,3*)




(b) Plot Grafik Hasil Pengujian Jaringan BPNN (*learning rate 0,3*)

Gambar 4: Plot Grafik Hasil Pelatihan dan pengujian Jaringan BPNN LR 0.3 (*learning rate 0,3*)

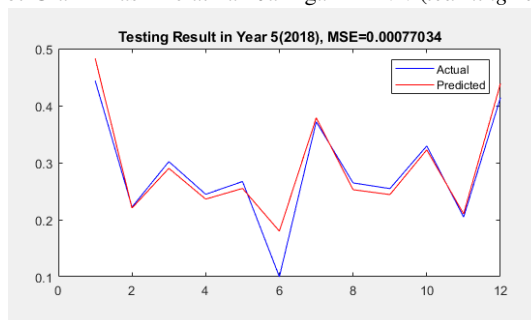


Gambar 5: Post Training Analysis Jaringan BPNN (learning rate 0,9)

Plot grafik hasil pelatihan Jaringan menggunakan arsitektur terbaik pada pengujian Jaringan BPNN dengan LR 0,9 ditunjukkan oleh Gambar 6a. plot grafik hasil pelatihan menggunakan arsitektur terbaik didapatkan nilai MSE sebesar 0,0074305. Gambar 6b. menampilkan plot grafik hasil pengujian menggunakan arsitektur terbaik yang memperoleh nilai MSE sebesar 0,00077034.



(a) Plot Grafik Hasil Pelatihan Jaringan BPNN (learning rate 0,9)




(b) Plot Grafik Hasil Pengujian Jaringan BPNN (learning rate 0,9)

Gambar 6: Plot Grafik Hasil Pelatihan dan Pengujian Jaringan BPNN (learning rate 0,3)

Berdasarkan hasil uji coba menggunakan LR 0,2 dengan 5 inputan, 2 hidden layer dengan masing-masing neuron yaitu 10-5 dan 1 output, epoch maksimal sebesar 1000 dan epoch berhenti pada iterasi kedua dengan waktu eksekusi selama kurang dari satu detik.


Analisis pasca pelatihan (*post-training analysis*) dengan LR 0,2 menghasilkan koefisien kecocokan sebesar 0,94 dari nilai aktual dan nilai prediksi seperti yang terlihat pada Gambar 7. Intersep kesesuaian dari nilai aktual dan nilai prediksi sebesar 0,025. Koefisien korelasi antara nilai aktual dan nilai prediksi sebesar 0,97796. Dilihat dari Gambar 7, target yang digambarkan sebagai garis putus-putus dan hasil prediksi yang digambarkan dengan garis berwarna merah, memiliki sedikit perbedaan dan dikarenakan koefisien korelasinya mendekati 1 sehingga hasil prediksi dengan baik.





Gambar 7: Post Training Analysis Jaringan BPNN (*learning rate* 0,2)

Plot grafik hasil pelatihan Jaringan menggunakan arsitektur terbaik pada pengujian Jaringan BPNN dengan LR 0,2 ditunjukkan oleh Gambar 8a. plot grafik hasil pelatihan menggunakan arsitektur terbaik didapatkan nilai MSE sebesar 0,0051096. Gambar 8b. menampilkan plot grafik hasil pengujian menggunakan arsitektur terbaik yang memperoleh nilai MSE sebesar 0,00045581.



(a) Plot Grafik Hasil Pelatihan Jaringan BPNN (*learning rate* 0,2)



(b) Plot Grafik Hasil Pengujian Jaringan BPNN (*learning rate* 0,2)

Gambar 8: Plot Grafik Hasil Pelatihan dan Pengujian Jaringan BPNN (*learning rate* 0,2)

#### IV. PEMBAHASAN

Dari hasil pelatihan model pada data after-sale yang ditunjukkan oleh Tabel V, memperlihatkan arsitektur terbaik pada pengujian variabel dengan menggunakan LR 0,3 didapatkan nilai MSE sebesar 0,0084325; LR 0,9 didapatkan MSE 0,00077034 dan untuk LR 0,2 didapatkan nilai MSE 0,00045581. Dalam percobaan ini, arsitektur terbaik untuk memprediksi pelayanan *service* mobil (*after-sale*) tahun 2019 yaitu 5-10-5-1; trainlm; LR 0,2 dengan nilai MSE sebesar 0,00045581.

Tabel V: Nilai MSE Peramalan

Model Arsitektur	Fungsi Pembelajaran	Learning Rate	MSE (Pengujian)
5-5-5-1	TRAINGD	0,3	0,0084325
5-5-5-1	TRAINILM	0,9	0,00077034
5-10-5-1	TRAINLM	0,2	0,00045581

Tabel VI menampilkan hasil prediksi pelayanan service mobil (*after-sale*) pada tahun 2018 kemudian dihitung berdasarkan data aktual. Dari hasil perbandingan data aktual diperoleh total *error* sebesar 0,005469693 dan rata-rata *error* yang diperoleh adalah 0,000455808.


Tabel VI: Nilai MSE Peramalan

Bulan	Prediksi 2018 ( $Y'$ )	Prediksi 2018 ( $Y$ )	Aktual 2018 ( $X'$ )	Aktual 2018 ( $X$ )	Selisih ( $X' - Y'$ )	Error ( $((X' - Y')^2)$ )
Januari	0,416768303	709	0,443925234	720	0,02715693	0,000737499
Februari	0,210174189	626	0,22211838	631	0,011944191	0,000142664
Maret	0,27929194	653	0,301869159	663	0,022577219	0,000509731
April	0,228784639	633	0,244548287	640	0,015763648	0,000248493
Mei	0,248094925	641	0,266978193	649	0,018883268	0,000356578
Juni	0,126513711	592	0,1	582	0,026513711	0,000702977
Juli	0,345045251	680	0,37165109	691	0,026605839	0,000707871
Agustus	0,245918121	640	0,264485981	648	0,01856786	0,000344765
September	0,237287113	637	0,254517134	644	0,017230021	0,000296874
Oktober	0,304638891	664	0,329283489	674	0,024644598	0,000607356
November	0,196259399	620	0,204672897	624	0,008413499	0,000070786
Desember	0,386740501	697	0,414018692	708	0,027278191	0,0007441
Total	3,225516982	-	3,418068536	-	0,192551554	0,005469693
Rata-Rata	0,268793082	-	0,284839045	-	0,01604596	0,000455808

Hasil peramalan pelayanan *service* mobil (*after-sale*) pada tahun 2019 dapat dilihat pada Tabel VII dan plot hasil peramalana terlihat pada Gambar 9. Gambar 9 menunjukkan bahwa pelayanan *service* mobil (*after-sale*) pada bulan Februari dan Maret akan mengalami penurunan dan pada bulan April akan mengalami peningkatan, lalu pada bulan Mei akan terjadi penurunan terendah. Pada bulan Juni akan mengalami peningkatan sampai dengan bulan Juli, dibulan Agustus dan September akan mengalami penurunan, lalu dibulan Oktober akan mengalami kenaikan sedikit, dan kembali menurun dibulan November, lalu pada Bulan Desember akan mengalami kenaikan kembali. Kenaikan pelayanan *service* mobil (*after-sale*) terjadi apabila memasuki bulan liburan, karena saat memasuki liburan banyak konsumen yang melakukan *service*, sehingga pelayanan *service* mobil (*after-sale*) menjadi meningkat. Faktor penurunan terjadi karena faktor ekonomi, jika pertumbuhan ekonomi menurun, maka mengakibatkan penurunan daya beli karena konsumen lebih mementingkan kebutuhan primernya.

Tabel VII: Hasil Peramalan After-Sale Tahun 2019

Bulan	Jumlah Mobil (Unit)
Januari	680
Februari	640
Maret	637
April	664
Mei	620
Juni	697
Juli	670
Agustus	634
September	631
Oktober	654
November	618
Desember	686



Gambar 9: Grafik Hasil Peramalan Data after-sale tahun 2019

V. SIMPULAN DAN SARAN

Prediksi pelayanan *service* mobil (*after-sale*) dengan menggunakan metode *Backpropagation Neural Network* (BPNN) telah dilakukan. Hasil peramalan menunjukkan bahwa pelayanan *service* mobil (*after-sale*) terbesar terdapat di bulan Juni 2019 sebesar 697 unit mobil dan jumlah hasil peramalan terendah pada bulan Mei 2019 yaitu sebesar 620 unit mobil. Berdasarkan hasil percobaan, metode BPNN dengan parameter arsitektur 5-10-1; fungsi pembelajaran adalah *trainlm*; fungsi aktivasi adalah *logsig* dan *purelin*; laju pembelajaran adalah 0,2 mampu menghasilkan tingkat kesalahan prediksi yang baik dengan nilai MSE sebesar 0,000455808. Hal ini menunjukkan bahwa metode BPNN dapat menjadi alternatif metode dalam memprediksi pelayanan *service* mobil (*after-sale*) dengan data yang berjenis *time series*.

PUSTAKA

- [1] J. A. Widians, N. Puspitasari, and A. F. A. Sari, "The prediction of tourist visiting with average based fuzzy time series method," *Int. J. Eng. Adv. Technol.*, vol. 8, no. 5, 2019, doi: 10.35940/ijeat.E1215.0585C19.
- [2] Mislan, A. F. O. Gaffar, Havaluddin, and N. Puspitasari, "Water Level Prediction of Lake Cascade Mahakam Using Adaptive Neural Network Backpropagation (ANNBP)," in *IOP Conference Series: Earth and Environmental Science*, 2018, vol. 144, no. 1, doi: 10.1088/1755-1315/144/1/012009.
- [3] A. Mahanggara and A. D. Laksito, "Prediksi Pengunduran Diri Mahasiswa Universitas AMIKOM Yogyakarta Menggunakan Metode Naive Bayes," *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 10, no. 1, pp. 273–280, 2019, doi: 10.24176/simet.v10i1.2967.
- [4] M. Minarni and F. Aldyanto, "Prediksi Jumlah Produksi Roti Menggunakan Metode Logika Fuzzy (Studi Kasus: Roti Malabar Bakery)," *J. TeknoIf*, vol. 4, 2016, [Online]. Available: internal-pdf://74.101.9.59/548-1601-1-PB.pdf.
- [5] M. Wati, W. Indrawan, J. A. Widians, and N. Puspitasari, "Data mining for predicting students' learning result," in *Proceedings of the 2017 4th International Conference on Computer Applications and Information Processing Technology, CAIPT 2017*, 2018, vol. 2018-Janua, doi: 10.1109/CAIPT.2017.8320666.
- [6] C. Ardianto, H. Haryanto, and E. Mulyanto, "Prediksi Tingkat Kerawanan Kebakaran di Daerah Kudus Menggunakan Fuzzy Tsukamoto," *Creat. Inf. Technol. J.*, vol. 4, pp. 186–194, 2018, [Online]. Available: internal-pdf://167.117.96.251/109-220-1-SM.pdf.
- [7] N. Puspitasari, A. Tejawati, and F. Prakoso, "Estimasi Stok Penerimaan Bahan Bakar Minyak Menggunakan Metode Fuzzy Tsukamoto," *JRST (Jurnal Ris. Sains dan Teknol.*, vol. 3, no. 1, pp. 9–18, 2019, doi: 10.30595/jrst.v3i1.3112.
- [8] D. Gadaleta, S. Manganelli, A. Manganaro, N. Porta, and E. Benfenati, "A knowledge-based expert rule system for predicting mutagenicity (Ames test) of aromatic amines and azo compounds," *Toxicology*, vol. 370, pp. 20–30, 2016.
- [9] K. Bisht and S. Kumar, "Fuzzy time series forecasting method based on hesitant fuzzy sets," *Expert Syst. Appl.*, vol. 64, pp. 557–568, 2016.
- [10] I. P. A. A. Pramana, "Peramalan Jumlah Kasus Demam Berdarah di Kabupaten Malang Menggunakan Metode Fuzzy Inference System," *J. Tek. ITS*, vol. 5, 2016, [Online]. Available: internal-pdf://138.58.218.49/14114-34666-1-PB.pdf.
- [11] R. S. Kalaksita and I. Irhamah, "Peramalan Curah Hujan Harian di Stasiun Ahmad Yani Kota Semarang Menggunakan Adaptive Neuro Fuzzy Inference System (ANFIS)," *J. Sains dan Seni ITS*, vol. 5, 2016.
- [12] N. P. Sakinah, I. Cholissodin, and A. W. Widodo, "Prediksi Jumlah Permintaan Koran Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, 2018.
- [13] B. Majhi, M. Rout, and V. Baghel, "On the development and performance evaluation of a multiobjective GA-based RBF adaptive model for the prediction of stock indices," *J. King Saud Univ. - Comput. Inf. Sci.*, 2014, doi: 10.1016/j.jksuci.2013.12.005.
- [14] Purnawansyah and Havaluddin, "Comparing performance of Backpropagation and RBF neural network models for predicting daily network traffic," in *Proceeding - 2014 Makassar International Conference on Electrical Engineering and Informatics, MICEEI 2014*, 2014, pp. 166–169, doi: 10.1109/MICEEI.2014.7067332.
- [15] E. Ma, Y. Liu, J. Li, and S. Chen, "Anticipating Chinese tourists arrivals in Australia: A time series analysis," *Tour. Manag. Perspect.*, vol. 17, pp. 50–58, 2016, doi: 10.1016/j.tmp.2015.12.004.
- [16] M. Syafiq, D. Hartama, I. O. Kirana, I. Gunawan, and A. Wanto, "Prediksi Jumlah Penjualan Produk di PT Ramayana Pematangsiantar Menggunakan Metode JST Backpropagation," *JURIKOM (Jurnal Ris. Komputer)*, vol. 7, no. 1, pp. 175–181, 2020, doi: 10.30865/jurikom.v7i1.1963.
- [17] H. Aini, H. Havaluddin, E. Budiman, M. Wati, and N. Puspitasari, "Prediksi Produksi Minyak Kelapa Sawit Menggunakan Metode Backpropagation Neural Network," *Sains, Apl. Komputasi dan Teknol. Inf.*, vol. 1, no. 1, pp. 24–33, 2019, doi: 10.30872/jsakti.v1i1.2261.
- [18] Havaluddin and N. Dengen, "Comparison of SARIMA, NARX and BPNN models in forecasting time series data of network traffic," in *Proceeding - 2016 2nd International Conference on Science in Information Technology, ICSITech 2016: Information Science for Green Society and Environment*, 2017, pp. 264–269, doi: 10.1109/ICSITech.2016.7852645.
- [19] J. R. Simanungkalit, H. Havaluddin, H. S. Pakpahan, N. Puspitasari, and M. Wati, "Algoritma Backpropagation Neural Network dalam Memprediksi Harga Komoditi Tanaman Karet," *Ilk. J. Ilm.*, vol. 12, no. 1, pp. 32–38, 2020, doi: 10.33096/ilkom.v12i1.521.32-38.
- [20] H. Havaluddin, Z. Arifin, A. H. Kridalaksana, and D. Cahyadi, "Prediksi Kedatangan Turis Asing ke Indonesia Menggunakan Backpropagation Neural Networks," *J. Teknol. dan Sist. Komput.*, vol. 4, no. 4, pp. 485–490, 2016, doi: 10.14710/jtsiskom.4.4.2016.485-490.
- [21] H. X. Huang, J. C. Li, and C. L. Xiao, "A proposed iteration optimization approach integrating backpropagation neural network with genetic algorithm," *Expert Syst. Appl.*, 2015, doi: 10.1016/j.eswa.2014.07.039.
- [22] Havaluddin, R. Alfred, J. H. Obit, M. H. A. Hijazi, and A. A. A. Ibrahim, "A performance comparison of statistical and machine learning techniques in learning time series data," *Adv. Sci. Lett.*, 2015, doi: 10.1166/asl.2015.6490.