

Peramalan Pelayanan Service Mobil (After-Sale) Menggunakan Backpropagation Neural Network (BPNN)

Novianti Puspitasari ^{(1)*}, Haviluddin ⁽²⁾, Arinda Mulawardani Kustiawan ⁽³⁾, Hario Jati Setyadi ⁽⁴⁾, Gubtha Mahendra Putra ⁽⁵⁾

^{1,2,3,5} Informatika, Fakultas Teknik, Universitas Mulawarman, Samarinda

⁴ Sistem Informasi, Fakultas Teknik, Universitas Mulawarman, Samarinda

e-mail : {novia.ftik.unmul,arinda.mulawardani}@gmail.com, haviluddin@unmul.ac.id, {hario.setyadi,gubthamp}@fkti.unmul.ac.id.

* Penulis korespondensi.

Artikel ini diajukan 4 Juni 2021, direvisi 20 Juni 2021, diterima 28 Juni 2021, dan dipublikasikan 22 September 2021.

Abstract

The automotive industry in Indonesia, primarily cars, is getting more and more varied. Along with increasing the number of vehicles, Brand Holder Sole Agents (ATPM) compete to provide after-sale services (mobile service). However, the company has difficulty knowing the rate of growth in the number of mobile services handled, thus causing losses that impact sources of income. Therefore, we need a standard method in determining the forecasting of the number of car services in the following year. This study implements the Backpropagation Neural Network (BPNN) method in forecasting car service services (after-sale) and Mean Square Error (MSE) for the process of testing the accuracy of the forecasting results formed. The data used in this study is car service data (after-sale) for the last five years. The results show that the best architecture for forecasting after-sales 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

Abstrak

Industri otomotif di Indonesia terutama mobil semakin banyak dan bervariasi. Seiring dengan meningkatkan jumlah mobil maka Agen Tunggal Pemegang Merk (ATPM) berlomba-lomba untuk memberikan pelayanan *after-sale* (*service* mobil). Namun, pihak perusahaan mengalami kesulitan dalam mengetahui laju pertumbuhan jumlah *service* mobil 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

1. PENDAHULUAN

Industri otomotif di Indonesia terutama jumlah pertumbuhan mobil semakin meningkat dan bervariasi dipasaran. Menurut laporan Gabungan Industri Kendaraan Bermotor Indonesia (Gaikindo) jumlah penjualan mobil sebanyak 1.151.413 unit di akhir tahun 2018 (GAIKINDO, 2018). 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 (Untari et al., 2018). 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 (Solihat, 2019).

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 di masa 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. Di antaranya adalah 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 namun perlu menambah atribut dan menggunakan *dataset* yang lebih banyak terutama data aktual (Mahanggara & Laksito, 2019). Prediksi peramalan kedatangan turis menggunakan metode *Average Based Fuzzy Time Series* yang memiliki nilai *Mean Absolute Percentage Error* (MAPE) sebesar 0,77375% (Widians et al., 2019), metode *Adaptive Neural Network Backpropagation* (ANNBP) untuk memprediksi tinggi muka air dengan hasil akurasi MSE dan MAPE sebesar 9,7% (Mislani et al., 2018), serta masih banyak lagi penelitian tentang peramalan menggunakan berbagai metode kecerdasan buatan (Alfajriani et al., 2020; Ardianto et al., 2018; Bisht & Kumar, 2016; Gadaleta et al., 2016; Minarni & Aldyanto, 2016; Puspitasari et al., 2019). Namun dari beberapa metode tersebut masih memiliki akurasi yang lebih kecil dibandingkan metode Jaringan Syaraf Tiruan (JST).

Metode JST merupakan metode yang sangat baik untuk mendapatkan hasil peramalan yang lebih baik (Aini et al., 2019; Haviluddin & Dengen, 2016; Ma et al., 2016; Majhi et al., 2014; Purnawansyah & Haviluddin, 2014; Sakinah et al., 2018; Simanungkalit et al., 2020; Syafiq et al., 2020). Model akurasi peramalan terbaik yang digunakan dalam JST adalah MSE (Haviluddin et al., 2016; Simanungkalit et al., 2020). 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.

2. METODE PENELITIAN

Pada bab ini akan dijelaskan tentang metode yang digunakan untuk peramalan menggunakan pelatihan yang terdapat pada metode BPNN, metode evaluasi terhadap akurasi dari hasil peramalan yang telah dilakukan, dan data peramalan yang digunakan.

2.1. *Backpropagation Neural Network* (BPNN)

Backpropagation Neural Network (BPNN) merupakan salah satu metode pelatihan dari JST yang banyak digunakan untuk memecahkan berbagai persoalan simulasi termasuk peramalan (Aini et al., 2019). 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 persamaan (1).

$$z_{net_j} = v_{j0} + \sum_{i=1}^n x_i v_{kj} \quad (1)$$

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 persamaan (2).

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

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

$$y_{net_k} = w_{k0} + \sum_{j=1}^p z_j w_{kj} \quad (3)$$

Hitung fungsi aktivasi untuk menghitung *signal* keluaran dan dikirimkan ke semua unit keluaran dengan persamaan (4).

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

Fase 2 : **Backpropagation**

Tahap 6 : Hitung faktor δ unit keluaran *error* $y_k, (k = 1, 2, \dots, m)$.

$$\delta_k = (t_k - y_k) f'(y_{net_k}) = (t_k - y_k) y_k (1 - y_k) \quad (5)$$

Di mana: t_k = target keluaran, δ = unit keluaran yang digunakan untuk memperbarui bobot. Hitung perubahan bobot baru dan bias w_{kj} , dengan nilai laju pembelajaran α .

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

Tahap 7 : Hitung faktor δ dalam unit lapisan tersembunyi berdasarkan nilai *error* $Z_j, (j = 1, 2, \dots, p)$.

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

Hitung faktor δ dalam unit lapisan tersembunyi.

$$\delta_j = \delta_{net_j} f'(z_{net_j}) = \delta_{net_j} \cdot z_j (1 - z_j) \quad (8)$$

Hitung nilai perubahan bobot dan bias v_{ji} .

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

Fase 3 : **Perubahan bobot**

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

$$w_{kj}(new) = w_{kj}(old) + \delta w_{ji}; \quad (k = 1, 2, \dots, p; j = 0, 1, \dots, n) \quad (10)$$



Hitung perubahan bobot dan bias di dalam lapisan tersembunyi dengan persamaan (11).

$$v_{kj}(new) = v_{kj}(old) + \delta v_{ji}; \quad (j = 1,2, \dots, p; w = 0,1, \dots, n) \quad (11)$$

2.2. Metode Evaluasi Model

Pengukuran suatu model peramalan dapat menggunakan beberapa metode statistik di antaranya *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 (Haviluddin et al., 2015; Huang et al., 2015). Metode untuk mengukur akurasi peramalan yang digunakan dalam penelitian ini adalah MSE (Haviluddin et al., 2016; Simanungkalit et al., 2020). Rumus MSE terlihat pada persamaan (12).

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

Di mana, x_t adalah nilai observasi data; $x_t - \hat{x}_t$ adalah nilai hasil prediksi; M adalah nilai dari deret waktu.

2.3. 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 1.

Tabel 1. 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

Software yang digunakan untuk melakukan analisis 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).

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

Di mana, \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 2.



Tabel 2. 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

3. HASIL DAN PEMBAHASAN

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 adalah MSE yang 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 diuji terlihat pada Tabel 3.

Tabel 3. Model Arsitektur BPNN.

Variabel	Nilai
Arsitektur Hidden Layer	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

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 mendapatkan model arsitektur yang baik untuk prediksi. Hasil pengujian model arsitektur BPNN dapat dilihat pada Tabel 4.

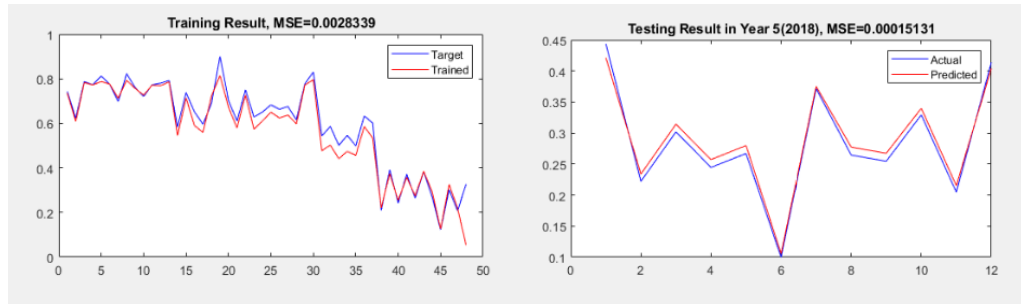


Tabel 4. Hasil Pengujian Model Arsitektur BPNN.

No.	Parameter		MSE		
	Model Arsitektur	Fungsi Pembelajaran	LR	Pelatihan	Pengujian
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	5-5-5-1	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		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	5-5-6-6-1	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		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	5-5-10-10-1	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		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	5-10-5-1	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		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	5-10-7-1	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		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	5-10-9-1	TRAINGD	0,3	0,0068869	0,007943
51		TRAINGD	0,3	0,0088565	0,0012978
52		TRAINLM	0,9	0,006209	0,0024579
53		TRAINGD	0,9	-	-
54		TRAINGD	0,9	0,013497	0,0042891


Plot grafik hasil pelatihan dan pengujian dapat dilihat pada Gambar 1. Dari Gambar 1 terlihat bahwa nilai MSE hasil pelatihan yang didapatkan sebesar 0,0028339. Hal ini menunjukkan bahwa hasil pelatihan hampir mendekati dengan target yang diinginkan.






Gambar 1. Plot Grafik Hasil Pelatihan dan Pengujian Model Arsitektur.

Lebih lanjut, plot grafik hasil pengujian menghasilkan nilai MSE sebesar 0,00015131. Hal ini menunjukkan bahwa hasil pengujian hampir mendekati dengan target yang diinginkan. 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, *epoch* berhenti pada iterasi ke lima puluh dengan waktu eksekusi selama kurang dari satu detik didapatkan analisis pasca pelatihan (*post-training analysis*) seperti pada Gambar 2. 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.



Gambar 2. Post Training Analysis Jaringan BPNN (*learning rate* 0,3).


Dari Gambar 2 terdapat garis putus-putus yang merupakan target dan garis merah yang merupakan hasil prediksi dengan sedikit kesamaan dikarenakan koefisien relasinya kurang mendekati angka 1 yang berarti hasil prediksi kurang mendekati target. Plot grafik hasil pelatihan dan pengujian jaringan menggunakan arsitektur terbaik pada pengujian jaringan BPNN dengan LR 0,3 ditunjukkan oleh Gambar 3. dengan nilai MSE sebesar 0,0094242 untuk hasil pelatihan dan 0,0084325 untuk hasil pengujian.



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




Uji coba berikutnya menggunakan LR 0,9 dengan 5 inputan, 3 *hidden layer* dengan masing-masing *neuron* yaitu 5-5-5 dan 1 *output*, serta *epoch* maksimal sebesar 1000, membuat *epoch* berhenti pada iterasi ke satu 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 4. 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 4 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.



Gambar 4. 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 5. Plot grafik hasil pelatihan dan pengujian menggunakan arsitektur terbaik didapatkan nilai MSE pelatihan sebesar 0,0074305 dan nilai MSE pengujian sebesar 0,00077034.



Gambar 5. Plot Grafik Hasil Pelatihan dan Pengujian Jaringan BPNN (learning rate 0,9).


Lebih lanjut, 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 membuat *epoch* berhenti pada iterasi ke dua 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 6. Intersep kesesuaian dari nilai aktual dan nilai prediksi didapatkan sebesar 0,025. Koefisien korelasi antara nilai aktual dan nilai prediksi sebesar 0,97796.





Gambar 6. Post Training Analysis Jaringan BPNN (*learning rate* 0,2).

Dilihat dari Gambar 6, 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. Plot grafik hasil pelatihan jaringan menggunakan arsitektur terbaik pada pengujian jaringan BPNN dengan LR 0,2 ditunjukkan oleh Gambar 7. Pada Gambar 7, plot grafik hasil pelatihan menggunakan arsitektur terbaik mendapatkan nilai MSE sebesar 0,0051096 dan 0,00045581 untuk hasil pengujian.



Gambar 7. Plot Grafik Hasil Pelatihan dan Pengujian Jaringan BPNN (*learning rate* 0,2).

Dari hasil pelatihan model pada data *after-sale* yang ditunjukkan oleh Tabel 5, 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 5. 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

Selanjutnya, Tabel 6 menampilkan hasil prediksi pelayanan *service* mobil (*after-sale*) pada tahun 2018. Lebih lanjut dilakukan perbandingan antara data aktual dan data hasil prediksi. Dari hasil perbandingan data aktual diperoleh total *error* sebesar 0,005469693 dan rata-rata *error* yang diperoleh adalah 0,000455808.



Tabel 6. Hasil Prediksi Berdasarkan Data Aktual.

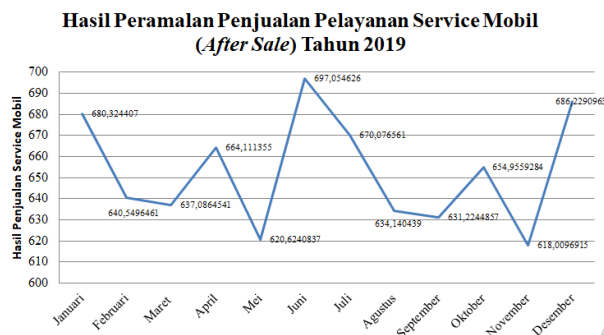
Bulan	Prediksi 2018 (Y')	Prediksi 2018 (Y)	Aktual 2018 (X')	Aktual 2018 (X)	Selisih (X' - Y')	Error ((X' - Y') ²)
Januari	0,416768303	709	0,443925234	720	0,02715693	0,000737499
Februari	0,210174189	626	0,22211838	631	0,011944191	0,000142664
Maret	0,27929194	653	0,301869159	663	0,022577219	0,000509731
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 7 dan plot hasil peramalan terlihat pada Gambar 8.

Tabel 7. 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 8 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, di bulan Agustus dan September akan mengalami penurunan, lalu dibulan Oktober akan mengalami kenaikan sedikit, dan kembali menurun di bulan November, lalu pada bulan Desember akan mengalami kenaikan kembali.

Gambar 8. Grafik Hasil Peramalan Data *After-Sale* tahun 2019

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.

4. KESIMPULAN

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*.

DAFTAR PUSTAKA

- Aini, H., Haviluddin, H., Budiman, E., Wati, M., & Puspitasari, N. (2019). Prediksi Produksi Minyak Kelapa Sawit Menggunakan Metode Backpropagation Neural Network. *Sains, Aplikasi, Komputasi Dan Teknologi Informasi*, 1(1), 24. <https://doi.org/10.30872/jsakti.v1i1.2261>
- Alfajriani, A., Wati, M., & Puspitasari, N. (2020). Penerapan Metode Fuzzy Time Series Chen dan Hsu dalam Memprediksi Kunjungan Wisatawan di Museum Mulawarman. *Jurnal Rekayasa Teknologi Informasi (JURTI)*, 4(2), 144–153. <https://doi.org/http://dx.doi.org/10.30872/jurti.v4i2.5802>
- Ardianto, C., Haryanto, H., & Mulyanto, E. (2018). Prediksi Tingkat Kerawanan Kebakaran di Daerah Kudus Menggunakan Fuzzy Tsukamoto. *Creative Information Technology Journal*, 4(3), 186. <https://doi.org/10.24076/citec.2017v4i3.109>
- Bisht, K., & Kumar, S. (2016). Fuzzy time series forecasting method based on hesitant fuzzy sets. *Expert Systems with Applications*, 64, 557–568. <https://doi.org/10.1016/j.eswa.2016.07.044>
- Gadaleta, D., Manganelli, S., Manganaro, A., Porta, N., & Benfenati, E. (2016). A knowledge-based expert rule system for predicting mutagenicity (Ames test) of aromatic amines and azo compounds. *Toxicology*, 370, 20–30. <https://doi.org/10.1016/j.tox.2016.09.008>
- GAIKINDO. (2018). *Domestic Auto Production By Category 2018*. Gabungan Industri Kendaraan Bermotor Indonesia (GAIKINDO). <https://www.gaikindo.or.id/indonesian-automobile-industry-data/>
- Haviluddin, ., Alfred, R., Obit, J. H., Ahmad Hijazi, M. H., & Ag Ibrahim, A. A. (2015). A Performance Comparison of Statistical and Machine Learning Techniques in Learning Time Series Data. *Advanced Science Letters*, 21(10), 3037–3041. <https://doi.org/10.1166/asl.2015.6490>
- Haviluddin, & Dengen, N. (2016). Comparison of SARIMA, NARX and BPNN models in forecasting time series data of network traffic. *2016 2nd International Conference on Science in Information Technology (ICSITech)*, 264–269. <https://doi.org/10.1109/ICSITech.2016.7852645>
- Haviluddin, H., Arifin, Z., Kridalaksana, A. H., & Cahyadi, D. (2016). Prediksi Kedatangan Turis Asing ke Indonesia Menggunakan Backpropagation Neural Networks. *Jurnal Teknologi Dan Sistem Komputer*, 4(4), 485. <https://doi.org/10.14710/jtsiskom.4.4.2016.485-490>
- Huang, H.-X., Li, J.-C., & Xiao, C.-L. (2015). A proposed iteration optimization approach integrating backpropagation neural network with genetic algorithm. *Expert Systems with Applications*, 42(1), 146–155. <https://doi.org/10.1016/j.eswa.2014.07.039>
- Ma, E., Liu, Y., Li, J., & Chen, S. (2016). Anticipating Chinese tourists arrivals in Australia: A time series analysis. *Tourism Management Perspectives*, 17, 50–58. <https://doi.org/10.1016/j.tmp.2015.12.004>
- Mahanggara, A., & Laksito, A. D. (2019). PREDIKSI PENGUNDURAN DIRI MAHASISWA UNIVERSITAS AMIKOM YOGYAKARTA MENGGUNAKAN METODE NAIVE BAYES. *Simetris: Jurnal Teknik Mesin, Elektro Dan Ilmu Komputer*, 10(1), 273–280.



- <https://doi.org/10.24176/simet.v10i1.2967>
- Majhi, B., Rout, M., & Baghel, V. (2014). On the development and performance evaluation of a multiobjective GA-based RBF adaptive model for the prediction of stock indices. *Journal of King Saud University - Computer and Information Sciences*, 26(3), 319–331. <https://doi.org/10.1016/j.jksuci.2013.12.005>
- Minarni, M., & Aldyanto, F. (2016). Prediksi Jumlah Produksi Roti Menggunakan Metode Logika Fuzzy (Studi Kasus: Roti Malabar Bakery). *Jurnal TEKNOIF*, 4(2), 59–65.
- Mislan, Gaffar, A. F. O., Haviluddin, & Puspitasari, N. (2018). Water Level Prediction of Lake Cascade Mahakam Using Adaptive Neural Network Backpropagation (ANNBP). *IOP Conference Series: Earth and Environmental Science*, 144(1), 012009. <https://doi.org/10.1088/1755-1315/144/1/012009>
- Purnawansyah, & Haviluddin. (2014). Comparing performance of Backpropagation and RBF neural network models for predicting daily network traffic. *2014 Makassar International Conference on Electrical Engineering and Informatics (MICEEI)*, 166–169. <https://doi.org/10.1109/MICEEI.2014.7067332>
- Puspitasari, N., Tejawati, A., & Prakoso, F. (2019). Estimasi Stok Penerimaan Bahan Bakar Minyak Menggunakan Metode Fuzzy Tsukamoto. *JRST (Jurnal Riset Sains Dan Teknologi)*, 3(1), 9. <https://doi.org/10.30595/jrst.v3i1.3112>
- Sakinah, N. P., Cholissodin, I., & Widodo, A. W. (2018). Prediksi Jumlah Permintaan Koran Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer (J-PTIIK)*, 2(7), 2612–2618.
- Simanungkalit, J. R., Haviluddin, H., Pakpahan, H. S., Puspitasari, N., & Wati, M. (2020). Algoritma Backpropagation Neural Network dalam Memprediksi Harga Komoditi Tanaman Karet. *ILKOM Jurnal Ilmiah*, 12(1), 32–38. <https://doi.org/10.33096/ilkom.v12i1.521.32-38>
- Solihat, A. (2019). Layanan Purna Jual pada Produk Otomotif. *Business Innovation and Entrepreneurship Journal*, 1(1), 6–10. <https://doi.org/10.35899/biej.v1i1.5>
- Syafiq, M., Hartama, D., Kirana, I. O., Gunawan, I., & Wanto, A. (2020). Prediksi Jumlah Penjualan Produk di PT Ramayana Pematangsiantar Menggunakan Metode JST Backpropagation. *JURIKOM (Jurnal Riset Komputer)*, 7(1), 175. <https://doi.org/10.30865/jurikom.v7i1.1963>
- Untari, S. N., Djaja, S., & Widodo, J. (2018). STRATEGI PEMASARAN MOBIL MEREK DAIHATSU PADA DEALER DAIHATSU JEMBER. *JURNAL PENDIDIKAN EKONOMI: Jurnal Ilmiah Ilmu Pendidikan, Ilmu Ekonomi Dan Ilmu Sosial*, 11(2), 82. <https://doi.org/10.19184/jpe.v11i2.6451>
- Widians, J. A., Puspitasari, N., & Sari, A. F. A. (2019). The Prediction Of Tourist Visiting With Average Based Fuzzy Time Series Method. *International Journal of Engineering and Advanced Technology*, 8(5C), 1467–1469. <https://doi.org/10.35940/ijeat.E1215.0585C19>

