



METODE JARINGAN SARAF TIRUAN DALAM MEMPREDIKSI JUMLAH POPULASI ITIK MANILA BERDASARKAN PROVINSI DI INDONESIA

Della Puspita^a, Agus Perdana Windarto^b, Hendry Qurniawan^c

^a Program Studi Sistem Informasi, dellapuspita0058@gmail.com, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

^b Program Studi Sistem Informasi, agus.perdana@amiktunasbangsa.ac.id, STIKOM Tunas Bangsa, Pematangsiantar

^c Program Studi Sistem Informasi, hendryqurniawan@gmail.com, STIKOM Tunas Bangsa, Pematangsiantar

ABSTRACT

Livestock is one of the agricultural sub-sectors that is needed to meet the food needs of the community, especially the nutritional needs of animal protein. The biggest commodity in livestock currently comes from the poultry sector, nearly 70% in the livestock sector and is dominated by poultry. Based on population data of manila ducks in Indonesia from several provinces, the number of populations per year has an unstable value. The data sample used in this study was taken based on the last five years, namely 2017 – 2021. It can be seen that in 2017 – 2020 the population has decreased, but in 2020 – 2021 the population has increased. In this study using the back-propagation method. This research contributes to the understanding of forecasting or prediction of the number of manila duck populations in the future and also this study introduces the implementation of the back-propagation algorithm to predict the number of manila duck populations. The results of the research using the best architecture experiment were 3 – 15 – 1 to predict the number of manila duck populations in 2022 by showing an accuracy of 85.3%. Mse Testing of 0.0010. From this model, predictions for the number of manila duck populations can be generated based on the province of each province in Indonesia.

Keywords: *Indonesia, Manila Duck, ANN, Prediction, Province.*

ABSTRAK

Peternakan merupakan salah satu subsektor pertanian yang sangat diperlukan untuk dapat memenuhi kebutuhan pangan masyarakat, terutama kebutuhan gizi protein hewani. Komoditas terbesar di peternakan saat ini berasal pada sektor per-unggas-an, hampir 70% di Sektor peternakan dan didominasi per-unggas-an. Berdasarkan data populasi itik manila di Indonesia dari beberapa provinsi menampilkan jumlah populasi pertahun nya yang memiliki nilai yang tidak stabil. Pada sampel data yang digunakan dalam penelitian ini diambil berdasarkan lima tahun terakhir yaitu 2017 – 2021, dilihat bahwa pada tahun 2017 – 2020 jumlah populasi mengalami penurunan namun pada tahun 2020 – 2021 jumlah populasi mengalami kenaikan. Pada penelitian ini menggunakan metode back-propagation. Penelitian ini memberikan kontribusi dalam pemahaman peramalan atau prediksi pada jumlah populasi itik manila di masa yang akan datang dan juga penelitian ini memperkenalkan implementasi algoritma back-propagation untuk memprediksi jumlah populasi itik manila. Hasil penelitian dengan percobaan yang dilakukan arsitektur terbaik yaitu 3 – 15 – 1 untuk memprediksi jumlah populasi itik manila pada tahun 2022 dengan menunjukkan hasil akurasi sebesar 85,3%. Mse Testing sebesar 0,0010. Dari model ini maka dapat dihasilkan prediksi jumlah populasi itik manila berdasarkan provinsi dari masing – masing provinsi yang ada di Indonesia.

Kata Kunci: *Indonesia, Itik Manila, JST, Prediksi, Provinsi Indonesia.*

1. PENDAHULUAN

Peternakan merupakan salah satu subsektor pertanian yang sangat diperlukan untuk dapat memenuhi kebutuhan pangan masyarakat, terutama kebutuhan gizi protein hewani. Komoditas terbesar di peternakan saat ini berasal pada sektor perunggasan, hampir 70% di Sektor peternakan dan didominasi perunggasan [1]. Unggas merupakan ternak yang dapat dimanfaatkan sebagai sumber protein hewani, karena mampu menghasilkan pangan dalam waktu singkat dan harganya relatif murah [2]. Faktor yang mempengaruhi fluktuasi populasi itik manila yaitu persaingan dengan itik jenis lain yang lebih cepat per kembang biak nya dan tidak memerlukan biaya yang mahal. Itik manila atau entog merupakan salah satu jenis unggas air yang memiliki beberapa nama, berdasarkan nama daerahnya. Entog di ambil dari bahasa Sunda, sedangkan bahasa Jawa nya adalah Mentok. Entog dalam bahasa Indonesia dikenal dengan nama itik manila, sedangkan dalam bahasa inggris disebut *Muscovy duck*. Entog merupakan unggas yang masih kerabat dengan itik, masih dalam satu sub famili yaitu *Anatidae* [3].

Berdasarkan data Badan Pusat Statistik (BPS) di Indonesia dalam lima tahun terakhir yaitu dari tahun 2017-2021, populasi itik manila mengalami peningkatan dan penurunan. Pada tahun 2017, populasi itik manila tercatat sebesar 57.557.451 ekor kemudian naik menjadi 59.551.713 ekor, pada tahun 2019 terjadi penurunan menjadi 57.229.088 ekor, pada tahun 2020 turun menjadi 56.569.977 ekor, pada tahun 2021 terjadi peningkatan menjadi 58.651.838 ekor. Sehingga dalam lima tahun terjadi peningkatan dan penurunan jumlah populasi. Sebab itu, diperlukan suatu analisis untuk meramalkan peningkatan dan penurunan jumlah populasi itik di masa yang akan datang. Salah satu cara yang dapat dilakukan untuk memprediksi adalah dengan menggunakan jaringan syaraf tiruan dengan metode back-propagation. Metode back-propagation ini telah banyak digunakan dalam proses prediksi dan memberikan hasil yang akurat dengan error yang rendah [4] seperti pada perbandingan beberapa penelitian berikut “ Perbandingan Metode Back-propagation dan Learning vector quantization (LVQ) Dalam Menggali Potensi Mahasiswa Baru di STMIK Palcomtech” dalam penelitian ini didapat tingkat akurasi pengenalan pola pada metode back-propagation sebesar 99,17% dengan variasi learning rate 0,1 dan jumlah epoch 100, metode learning vector quantization didapat tingkat akurasi sebesar 96,67% dengan variasi learning rate 1 dan jumlah epoch 20, dari hasil perbandingan metode back-propagation lebih unggul dari segi akurasi [5]. Dan pada penelitian “ Perbandingan Jaringan Saraf Tiruan LVQ Dengan Back-propagation Dalam Deteksi Dini Penyakit Jantung Coroner “ dalam penelitian ini didapat hasil bahwa metode back-propagation lebih baik daripada metode LVQ dengan perbandingan nilai akurasi pelatihan sebesar 95,99097% untuk back-propagation banding 66,89659% untuk LVQ dan nilai akurasi pengujian sebesar 68,76034% untuk back-propagation banding 54,30313% untuk LVQ [6].

Beberapa penelitian sebelumnya yang menjadi rujukan penelitian ini diantaranya : "Model Jaringan Saraf Tiruan Dalam Memprediksi Jumlah Produksi Daging Sapi Berdasarkan Provinsi Di Indonesia", dalam penelitian tersebut dapat diperoleh tingkat akurasi 100% [7]. Penelitian lain mengenai jaringan saraf tiruan back-propagation yaitu "Model Jaringan Syaraf Tiruan Dalam Memprediksi Jumlah Produksi Telur Ayam Petelur Berdasarkan Provinsi Di Indonesia", dalam penelitian tersebut dapat diperoleh tingkat akurasi 96,88% [8], dan masih banyak lagi penelitian-penelitian lain nya [9]–[16].

Berdasarkan latar belakang tersebut, diharapkan dapat melakukan peramalan populasi itik manila berdasarkan model peramalan terbaik melalui serangkaian uji coba menggunakan metode back-propagation dan hasil penelitian ini dapat dijadikan sebagai acuan pembandingan untuk penelitian lain dengan topik yang sama.

2. TINJAUAN PUSTAKA

2.1. Jaringan Saraf Tiruan

Jaringan saraf tiruan bisa dibayangkan seperti otak buatan di dalam cerita fiksi ilmiah. Otak buatan ini dapat berpikir seperti manusia, dan juga se-pandai manusia dalam menyimpulkan sesuatu dari potongan-potongan informasi yang diterimanya. Khayalan manusia tersebut mendorong para peneliti untuk mewujudkannya. Komputer diusahakan agar bisa berpikir sama seperti cara berpikir manusia. Caranya adalah dengan melakukan peniruan terhadap aktivitas yang terjadi di dalam sebuah jaringan saraf biologis [17]–[19]. Jaringan saraf tiruan (artificial neural network) adalah model komputasi yang terinspirasi secara biologis, jaringan saraf tiruan terdiri dari beberapa elemen pengolahan (neuron) dan ada hubungan antara neuron. Neuron – neuron tersebut akan mentransformasikan informasi yang diterima oleh neuron satu menuju neuron lain nya, hubungan ini disebut dengan bobot [20]–[22].

2.2. Metode Back-propagation

Back-propagation merupakan salah satu algoritma yang sering digunakan dalam menyelesaikan masalah yang rumit. Metode ini merupakan metode yang sangat baik dalam menangani masalah pengenalan pola kompleks [23]–[25]. Ciri khas back-propagation melibatkan tiga lapisan: lapisan input, dimana data diperkenalkan ke jaringan; hidden layer, dimana data diproses dan lapisan output, di mana hasil dari masukan yang diberikan oleh lapisan input [26]–[28].

3. METODOLOGI PENELITIAN

3.1. Lokasi dan Waktu Penelitian

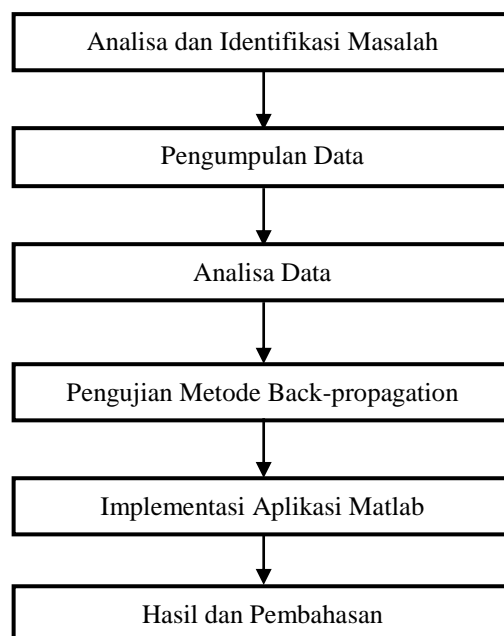
Penelitian ini dilakukan dengan mengambil data populasi itik manila berdasarkan provinsi di Indonesia dari Badan Pusat Statistik (BPS) yang memiliki alamat link atau URL yaitu: <https://www.bps.go.id/indicator/24/479/1/populasi-itik-itik-manila-menurut-provinsi.html>. Data yang di ambil

yaitu data dari tahun 2019 sampai dengan Tahun 2021, banyaknya data yang digunakan adalah 34 Provinsi yang terdiri atas Aceh, Sumatera Utara, Sumatera Barat, Riau, Jambi, Sumatera Selatan, Bengkulu, Lampung, Kep. Bangka Belitung, Kep. Riau, DKI Jakarta, Jawa Barat, Jawa Tengah, Yogyakarta, Jawa Timur, Banten, Bali, Nusa Tenggara Barat, Nusa Tenggara Timur, Kalimantan Barat, Kalimantan Timur, Kalimantan Utara, Sulawesi Utara, Sulawesi Tengah, Sulawesi Selatan, Sulawesi Tenggara, Gorontalo, Sulawesi Barat, Maluku, Maluku, Utara, Papua Barat, Papua. Data set dapat dilihat pada Tabel 3.1 berikut:

Tabel 1. Populasi Itik Manila di Indonesia

Provinsi	Populasi Itik/Itik Manila menurut Provinsi (Ekor)				
	2017	2018	2019	2020	2021
Aceh	3.311.189	2.746.254	2.534.628	2.335.820	2.346.387
Sumatera Utara	3.402.459	3.664.181	3.180.488	3.192.720	3.294.597
Sumatera Barat	1.127.066	1.101.263	1.143.702	1.169.392	1.185.955
Riau	281.224	309.360	293.152	282.920	288.578
Jambi	1.162.800	959.694	864.368	751.439	757.594
Sumatera Selatan	1.652.145	1.770.131	2.016.950	2.090.997	2.822.086
Bengkulu	218.884	238.321	235.031	231.494	323.269
Lampung	840.873	1.068.059	1.087.055	919.118	924.458
Kep. Bangka Belitung	92.049	99.728	95.153	96.545	99.511
Kep. Riau	49.759	20.355	32.976	36.451	38.358
DKI Jakarta	125	19.978	8.693	10.184	11.186
Jawa Barat	11.649.227	11.795.350	11.630.399	11.533.729	11.600.450
Jawa Tengah	6.614.681	6.705.767	6.873.101	6.739.383	7.017.519
DI Yogyakarta	524.747	485.803	479.886	522.838	528.424
Jawa Timur	7.095.144	7.339.606	7.673.683	7.918.845	8.226.867
Banten	1.908.145	1.911.082	2.075.112	2.091.645	2.139.200
Bali	580.518	522.312	555.279	499.374	508.370
Nusa Tenggara Barat	960.857	1.110.870	1.176.647	737.703	791.226
Nusa Tenggara Timur	345.750	320.254	259.540	283.209	299.515
Kalimantan Barat	591.482	592.151	580.057	577.388	564.595
Kalimantan Tengah	328.888	345.517	350.524	353.565	370.561
Kalimantan Selatan	4.144.792	4.284.438	4.846.849	4.376.689	4.472.410
Kalimantan Timur	255.083	291.829	297.573	307.572	294.436
Kalimantan Utara	46.688	32.098	36.023	33.779	35.888
Sulawesi Utara	194.555	213.331	217.130	222.803	231.658
Sulawesi Tengah	792.469	919.726	1.241.336	1.318.186	1.340.939
Sulawesi Selatan	7.630.298	8.861.142	5.778.627	6.193.104	6.316.964
Sulawesi Tenggara	483.486	558.585	587.482	620.641	659.953
Gorontalo	77.179	81.634	84.450	80.020	80.405
Sulawesi Barat	387.777	390.025	350.269	361.543	391.201
Maluku	467.743	458.613	274.227	275.554	275.594
Maluku Utara	93.224	95.376	117.985	130.573	129.946
Papua Barat	94.595	97.592	92.546	94.323	95.076
Papua	151.550	141.288	158.167	180.431	188.662

3.2. Rancangan Penelitian



Gambar 1. Rancangan Penelitian

Berdasarkan Rancangan penelitian pada gambar 1, maka dapat diuraikan langkah – langkahnya sebagai berikut:

1. Analisa dan identifikasi masalah
Permasalahan – permasalahan yang ada akan dianalisa dan diidentifikasi. Dengan menganalisa masalah – masalah yang ada, diharapkan dapat menjelaskan bagaimana cara mengatasi masalah tersebut dengan baik. Dalam menganalisa dan mengidentifikasi masalah diperlukannya data yang berhubungan dengan masalah yang berkaitan dengan penelitian.
2. Pengumpulan Data
Tahap ini merupakan tahap yang dilakukan setelah tahap analisa dan identifikasi masalah. Selanjutnya data – data dikumpulkan berdasarkan pengelompokan yang telah ditentukan. Dalam memperoleh data bisa dilakukan dengan cara mendapatkan informasi dari situs web yang berkenaan dengan masalah yang diteliti. Tahap selanjutnya akan dibandingkan dengan kenyataan yang terjadi dan yang di peroleh penulis.
3. Analisa Data
Data yang telah didapat dari proses yang didapatkan kemudian dikumpulkan dan dianalisa. Kemudian data yang telah dianalisa dikelompokkan agar nantinya penulis mudah dalam menganalisa data selanjutnya. Pada penelitian ini, data yang dipergunakan adalah data populasi itik manila berdasarkan provinsi di Indonesia. Data yang telah didapatkan nantinya akan diuji menggunakan metode back-propagation.
4. Pengujian metode back-propagation.
Data yang telah dikelompokkan kemudian dianalisa permasalahannya kemudian dilakukan tahap pengujian. Dalam melakukan pengujian dilakukan menggunakan metode back-propagation. Fungsi aktivasi dalam metode back-propagation digunakan dalam mencari ataupun melakukan proses pengujian.
5. Implementasi aplikasi Matlab
Pada tahap ini setelah dilakukan perhitungan secara manual menggunakan metode back-propagation kemudian dilakukan pengujian menggunakan aplikasi Matlab. Aplikasi matlab yang digunakan penulis pada penelitian ini menggunakan aplikasi Matlab 2011a.
6. Hasil dan Pembahasan
Setelah hasil yang didapatkan menggunakan aplikasi Matlab maka selanjutnya akan diketahui hasil dari pengujian tersebut dan selanjutnya membandingkan hasil prediksi JST dengan data sebenarnya yang dilakukan menggunakan aplikasi. Dari hasil tersebut nantinya diambil suatu kesimpulan dan saran dalam memprediksi populasi itik manila berdasarkan provinsi di Indonesia

4. HASIL DAN PEMBAHASAN

4.1. Normalisasi Data

Pada penelitian ini salah satu langkah simulasi jaringan saraf tiruan adalah dengan membagi data menjadi dua bagian yaitu: data pelatihan (training), dan data untuk pengujian (testing) yang diambil berdasarkan tabel 1, menggunakan rumus normalisasi [25], [29]–[35].

Tabel 2. Normalisasi Data

Provinsi	Training				Testing			
	2017	2018	2019	Target	2019	2020	2021	Target
Aceh	0,3246	0,2863	0,2719	0,2719	0,2739	0,2602	0,2609	0,2609
Sumatera Utara	0,3308	0,3485	0,3157	0,3157	0,3183	0,3192	0,3262	0,3262
Sumatera Barat	0,1764	0,1747	0,1776	0,1776	0,1781	0,1799	0,1810	0,1810
Riau	0,1191	0,1210	0,1199	0,1199	0,1196	0,1189	0,1193	0,1193
Jambi	0,1789	0,1651	0,1586	0,1586	0,1589	0,1511	0,1516	0,1516
Sumatera Selatan	0,2120	0,2200	0,2368	0,2368	0,2382	0,2433	0,2937	0,2937
Bengkulu	0,1148	0,1162	0,1159	0,1159	0,1156	0,1153	0,1217	0,1217
Lampung	0,1570	0,1724	0,1737	0,1737	0,1742	0,1627	0,1630	0,1630
Kep. Bangka Belitung	0,1062	0,1068	0,1064	0,1064	0,1060	0,1060	0,1063	0,1063
Kep. Riau	0,1034	0,1014	0,1022	0,1022	0,1017	0,1019	0,1020	0,1020
Dki Jakarta	0,1000	0,1013	0,1006	0,1006	0,1000	0,1001	0,1002	0,1002
Jawa Barat	0,8901	0,9000	0,8888	0,8888	0,9000	0,8933	0,8979	0,8979
Jawa Tengah	0,5486	0,5548	0,5662	0,5662	0,5725	0,5633	0,5825	0,5825
Di Yogyakarta	0,1356	0,1329	0,1325	0,1325	0,1324	0,1354	0,1358	0,1358
Jawa Timur	0,5812	0,5978	0,6205	0,6205	0,6276	0,6445	0,6657	0,6657
Banten	0,2294	0,2296	0,2407	0,2407	0,2422	0,2434	0,2467	0,2467
Bali	0,1394	0,1354	0,1377	0,1377	0,1376	0,1338	0,1344	0,1344
Nusa Tenggara Barat	0,1652	0,1753	0,1798	0,1798	0,1804	0,1502	0,1539	0,1539
Nusa Tenggara Timur	0,1234	0,1217	0,1176	0,1176	0,1173	0,1189	0,1200	0,1200
Kalimantan Barat	0,1401	0,1402	0,1393	0,1393	0,1393	0,1391	0,1383	0,1383
Kalimantan Tengah	0,1223	0,1234	0,1238	0,1238	0,1235	0,1237	0,1249	0,1249
Kalimantan Selatan	0,3811	0,3906	0,4287	0,4287	0,4330	0,4007	0,4073	0,4073
Kalimantan Timur	0,1173	0,1198	0,1202	0,1202	0,1199	0,1206	0,1197	0,1197
Kalimantan Utara	0,1032	0,1022	0,1024	0,1024	0,1019	0,1017	0,1019	0,1019
Sulawesi Utara	0,1132	0,1145	0,1147	0,1147	0,1143	0,1147	0,1153	0,1153
Sulawesi Tengah	0,1537	0,1624	0,1842	0,1842	0,1849	0,1901	0,1917	0,1917
Sulawesi Selatan	0,6175	0,7010	0,4919	0,4919	0,4972	0,5257	0,5342	0,5342
Sulawesi Tenggara	0,1328	0,1379	0,1398	0,1398	0,1398	0,1421	0,1448	0,1448
Gorontalo	0,1052	0,1055	0,1057	0,1057	0,1052	0,1049	0,1049	0,1049
Sulawesi Barat	0,1263	0,1264	0,1237	0,1237	0,1235	0,1243	0,1263	0,1263
Maluku	0,1317	0,1311	0,1186	0,1186	0,1183	0,1184	0,1184	0,1184
Maluku Utara	0,1063	0,1065	0,1080	0,1080	0,1075	0,1084	0,1083	0,1083
Papua Barat	0,1064	0,1066	0,1063	0,1063	0,1058	0,1059	0,1059	0,1059
Papua	0,1103	0,1096	0,1107	0,1107	0,1103	0,1118	0,1124	0,1124

Dalam percobaan ini, data yang digunakan sebagai sampel adalah data populasi itik manila dari tahun 2017 sampai dengan tahun 2021 dengan input dataset sebanyak 3. Pada penelitian ini, terdapat lima model arsitektur yang akan digunakan untuk pelatihan dan pengujian data yaitu model 3-1-1, 3-4-1, 3-8-1, 3-11-1, dan 3-15-1.

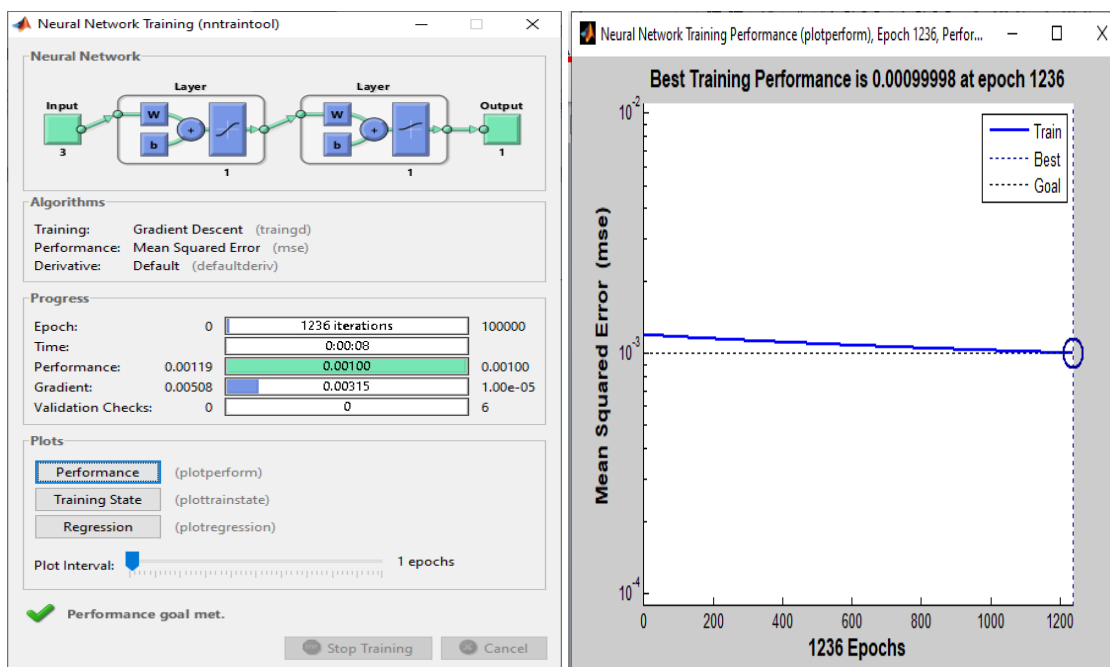
4.2. Pelatihan dan Pengujian Data

4.2.1. Model 3-1-1

Model ini menggunakan 3 *neuron* input, layer tersembunyi 1 *neuron*, serta 1 *neuron* keluaran. *Source Code* pelatihan *Backpropagation* yang digunakan dengan aplikasi *Matlab R2011a* sebagai berikut :

```
>>net=newff(minmax(p),[1,1],{'tansig','logsig'},'traingd');
>>net.IW{1,1};
>>net.b{1};
>>net.LW{2,1};
>>net.b{2};
>>net.trainParam.epochs=100000;
>>net.trainParam.goal = 0.001;
>>net.trainParam.Lr = 0.01;
>>net.trainParam.show = 1000;
```

```
>>net=train(net,p,t)
>>[a,Pf,Af,e,Perf]=sim(net,p,[],[],t)
```



Gambar 2. Pelatihan Menggunakan Arsitektur 3-1-1

Hasil pelatihan pada model 3-1-1 menghasilkan epoch 1236 iterasi, dengan waktu 00:08 detik. Best training performance sebesar 0,00099998.

Tabel 3. Hasil Pelatihan dan Pengujian dengan Model 3-1-1

No	Data Pelatihan				Data Pengujian				Hasil
	Target	Output	Error	SSE	Target	Output	Error	SSE	
1	0,2719	0,2722	-0,0003	0,0000	0,2609	0,2408	0,0201	0,0004	0
2	0,3157	0,2695	0,0462	0,0021	0,3262	0,2779	0,0483	0,0023	0
3	0,1776	0,1639	0,0137	0,0002	0,1810	0,1739	0,0071	0,0001	1
4	0,1199	0,1276	-0,0077	0,0001	0,1193	0,1451	-0,0258	0,0007	1
5	0,1586	0,1558	0,0028	0,0000	0,1516	0,1632	-0,0116	0,0001	1
6	0,2368	0,2077	0,0291	0,0008	0,2937	0,1797	0,1140	0,0130	0
7	0,1159	0,1259	-0,0100	0,0001	0,1217	0,1409	-0,0192	0,0004	1
8	0,1737	0,1526	0,0211	0,0004	0,1630	0,1712	-0,0082	0,0001	1
9	0,1064	0,1216	-0,0152	0,0002	0,1063	0,1395	-0,0332	0,0011	1
10	0,1022	0,1207	-0,0185	0,0003	0,1020	0,1379	-0,0359	0,0013	1
11	0,1006	0,1187	-0,0181	0,0003	0,1002	0,1373	-0,0371	0,0014	1
12	0,8888	0,8670	0,0218	0,0005	0,8979	0,8684	0,0295	0,0009	0
13	0,5662	0,6457	-0,0795	0,0063	0,5825	0,5892	-0,0067	0,0000	1
14	0,1325	0,1361	-0,0036	0,0000	0,1358	0,1510	-0,0152	0,0002	1
15	0,6205	0,7023	-0,0818	0,0067	0,6657	0,6605	0,0052	0,0000	1
16	0,2407	0,2155	0,0252	0,0006	0,2467	0,2145	0,0322	0,0010	0
17	0,1377	0,1399	-0,0022	0,0000	0,1344	0,1529	-0,0185	0,0003	1
18	0,1798	0,1596	0,0202	0,0004	0,1539	0,1715	-0,0176	0,0003	1
19	0,1176	0,1275	-0,0099	0,0001	0,1200	0,1439	-0,0239	0,0006	1
20	0,1393	0,1386	0,0007	0,0000	0,1383	0,1546	-0,0163	0,0003	1
21	0,1238	0,1301	-0,0063	0,0000	0,1249	0,1465	-0,0216	0,0005	1
22	0,4287	0,4554	-0,0267	0,0007	0,4073	0,4100	-0,0027	0,0000	1
23	0,1202	0,1277	-0,0075	0,0001	0,1197	0,1459	-0,0262	0,0007	1
24	0,1024	0,1204	-0,0180	0,0003	0,1019	0,1379	-0,0360	0,0013	1
25	0,1147	0,1254	-0,0107	0,0001	0,1153	0,1428	-0,0275	0,0008	1
26	0,1842	0,1661	0,0181	0,0003	0,1917	0,1777	0,0140	0,0002	0
27	0,4919	0,3819	0,1100	0,0121	0,5342	0,5064	0,0278	0,0008	0


No	Data Pelatihan				Data Pengujian				Hasil	
	Target	Output	Error	SSE	Target	Output	Error	SSE		
28	0,1398	0,1372	0,0026	0,0000	0,1448	0,1533	-0,0085	0,0001	1	
29	0,1057	0,1215	-0,0158	0,0002	0,1049	0,1393	-0,0344	0,0012	1	
30	0,1237	0,1300	-0,0063	0,0000	0,1263	0,1461	-0,0198	0,0004	1	
31	0,1186	0,1266	-0,0080	0,0001	0,1184	0,1448	-0,0264	0,0007	1	
32	0,1080	0,1227	-0,0147	0,0002	0,1083	0,1403	-0,0320	0,0010	1	
33	0,1063	0,1217	-0,0154	0,0002	0,1059	0,1396	-0,0337	0,0011	1	
34	0,1107	0,1243	-0,0136	0,0002	0,1124	0,1412	-0,0288	0,0008	1	
SSE				0,0340	SSE				0,0340	79,4 %
MSE				0,0010	MSE				0,0010	

Nilai target diperoleh dari tabel normalisasi data pelatihan dan pengujian. Nilai *Output* diperoleh dari rumus $[a, Pf, Af, e, Perf] = sim(net, p, [], [], t)$ yang dimasukkan pada aplikasi Matlab dari *input* dan data target. Nilai *error* diperoleh dari : $Target - Output$. SSE diperoleh dari $Error^2$ (^: Pangkat). Jumlah SSE adalah total dari keseluruhan SSE. MSE diperoleh dari : jumlah SSE / 34 (jumlah data). Hasil bernilai 1 (satu atau benar) apabila nilai SSE $\leq 0,01$, dan hasil bernilai 0 (nol atau salah) apabila nilai SSE $> 0,01$ adalah target *error* dari pelatihan *Backpropagation*. Akurasi (%) diperoleh dari : jumlah benar / 34 * 100.

4.2.2. Model 3-4-1

Model ini menggunakan 3 *neuron* input, layer tersembunyi 4 *neuron*, serta 1 *neuron* keluaran. *Source Code* pelatihan *Backpropagation* yang digunakan dengan aplikasi *Matlab R2011a* sebagai berikut :

```
>>net=newff(minmax(p),[4,1],{'tansig','logsig','traingd');
>>net.IW{1,1};
>>net.b{1};
>>net.LW{2,1};
>>net.b{2};
>>net.trainParam.epochs=100000;
>>net.trainParam.goal = 0.001;
>>net.trainParam.Lr = 0.01;
>>net.trainParam.show = 1000;
>>net=train(net,p,t)
>>[a,Pf,Af,e,Perf]=sim(net,p,[],[],t)
```



Gambar 3. Pelatihan Menggunakan Arsitektur 3-4-1

Hasil pelatihan pada model 3-4-1 menghasilkan *epoch* 54837 iterasi, dengan waktu 04:54 detik. Best training performance sebesar 0,00099999.

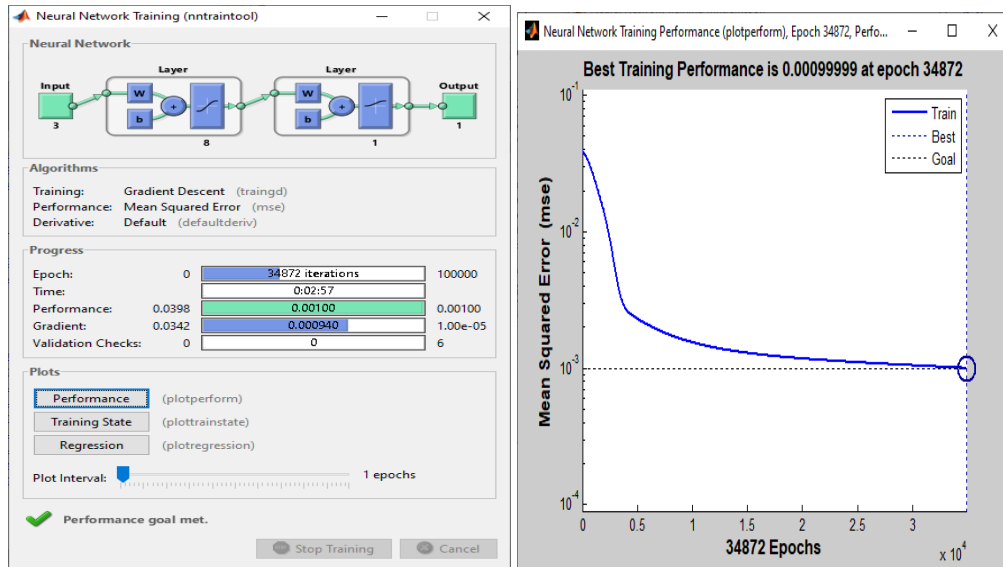
Tabel 4. Hasil Pelatihan dan Pengujian dengan Model 3-4-1

No	Data Pelatihan				Data Pengujian				Hasil
	Target	Output	Error	SSE	Target	Output	Error	SSE	
1	0,2719	0,2765	-0,0046	0,0000	0,2609	0,2470	0,0139	0,0002	0
2	0,3157	0,2888	0,0269	0,0007	0,3262	0,3090	0,0172	0,0003	0
3	0,1776	0,1701	0,0075	0,0001	0,1810	0,1723	0,0087	0,0001	1
4	0,1199	0,1335	-0,0136	0,0002	0,1193	0,1249	-0,0056	0,0000	1
5	0,1586	0,1629	-0,0043	0,0000	0,1516	0,1422	0,0094	0,0001	1
6	0,2368	0,2145	0,0223	0,0005	0,2937	0,2718	0,0219	0,0005	0
7	0,1159	0,1316	-0,0157	0,0002	0,1217	0,1273	-0,0056	0,0000	1
8	0,1737	0,1614	0,0123	0,0002	0,1630	0,1497	0,0133	0,0002	0
9	0,1064	0,1279	-0,0215	0,0005	0,1063	0,1193	-0,0130	0,0002	1
10	0,1022	0,1266	-0,0244	0,0006	0,1020	0,1178	-0,0158	0,0002	1
11	0,1006	0,1257	-0,0251	0,0006	0,1002	0,1171	-0,0169	0,0003	1
12	0,8888	0,9537	-0,0649	0,0042	0,8979	0,7561	0,1418	0,0201	0
13	0,5662	0,5082	0,0580	0,0034	0,5825	0,6515	-0,0690	0,0048	1
14	0,1325	0,1407	-0,0082	0,0001	0,1358	0,1364	-0,0006	0,0000	1
15	0,6205	0,6982	-0,0777	0,0060	0,6657	0,7267	-0,0610	0,0037	1
16	0,2407	0,2244	0,0163	0,0003	0,2467	0,2379	0,0088	0,0001	1
17	0,1377	0,1432	-0,0055	0,0000	0,1344	0,1321	0,0023	0,0000	1
18	0,1798	0,1669	0,0129	0,0002	0,1539	0,1333	0,0206	0,0004	0
19	0,1176	0,1338	-0,0162	0,0003	0,1200	0,1266	-0,0066	0,0000	1
20	0,1393	0,1439	-0,0046	0,0000	0,1383	0,1364	0,0019	0,0000	1
21	0,1238	0,1351	-0,0113	0,0001	0,1249	0,1285	-0,0036	0,0000	1
22	0,4287	0,3190	0,1097	0,0120	0,4073	0,3798	0,0275	0,0008	0
23	0,1202	0,1332	-0,0130	0,0002	0,1197	0,1257	-0,0060	0,0000	1
24	0,1024	0,1266	-0,0242	0,0006	0,1019	0,1175	-0,0156	0,0002	1
25	0,1147	0,1310	-0,0163	0,0003	0,1153	0,1235	-0,0082	0,0001	1
26	0,1842	0,1643	0,0199	0,0004	0,1917	0,1842	0,0075	0,0001	1
27	0,4919	0,5073	-0,0154	0,0002	0,5342	0,5649	-0,0307	0,0009	1
28	0,1398	0,1421	-0,0023	0,0000	0,1448	0,1423	0,0025	0,0000	1
29	0,1057	0,1276	-0,0219	0,0005	0,1049	0,1186	-0,0137	0,0002	1
30	0,1237	0,1328	-0,0091	0,0001	0,1263	0,1297	-0,0034	0,0000	1
31	0,1186	0,1333	-0,0147	0,0002	0,1184	0,1248	-0,0064	0,0000	1
32	0,1080	0,1309	-0,0229	0,0005	0,1083	0,1205	-0,0122	0,0001	1
33	0,1063	0,1309	-0,0246	0,0006	0,1059	0,1192	-0,0133	0,0002	1
34	0,1107	0,1312	-0,0205	0,0004	0,1124	0,1228	-0,0104	0,0001	1
			SSE	0,0342			SSE	0,0342	79,4 %
			MSE	0,0010			MSE	0,0010	

4.2.3. Model 3-8-1

Model ini menggunakan 3 *neuron* input, layer tersembunyi 8 *neuron*, serta 1 *neuron* keluaran. *Source Code* pelatihan *Backpropagation* yang digunakan dengan aplikasi *Matlab R2011a* sebagai berikut :

```
>>net=newff(minmax(p),[8,1],{'tansig','logsig'},'traingd');
>>net.IW{1,1};
>>net.b{1};
>>net.LW{2,1};
>>net.b{2};
>>net.trainParam.epochs=100000;
>>net.trainParam.goal = 0.001;
>>net.trainParam.Lr = 0.01;
>>net.trainParam.show = 1000;
>>net=train(net,p,t)
>>[a,Pf,Af,e,Perf]=sim(net,p,[],[],t)
```

Gambar 4. Pelatihan Menggunakan Arsitektur 3-8-1

Hasil pelatihan pada model 3-8-1 menghasilkan *epoch* 34872 iterasi, dengan waktu 02:57 detik. Best training performance sebesar 0,00099999.

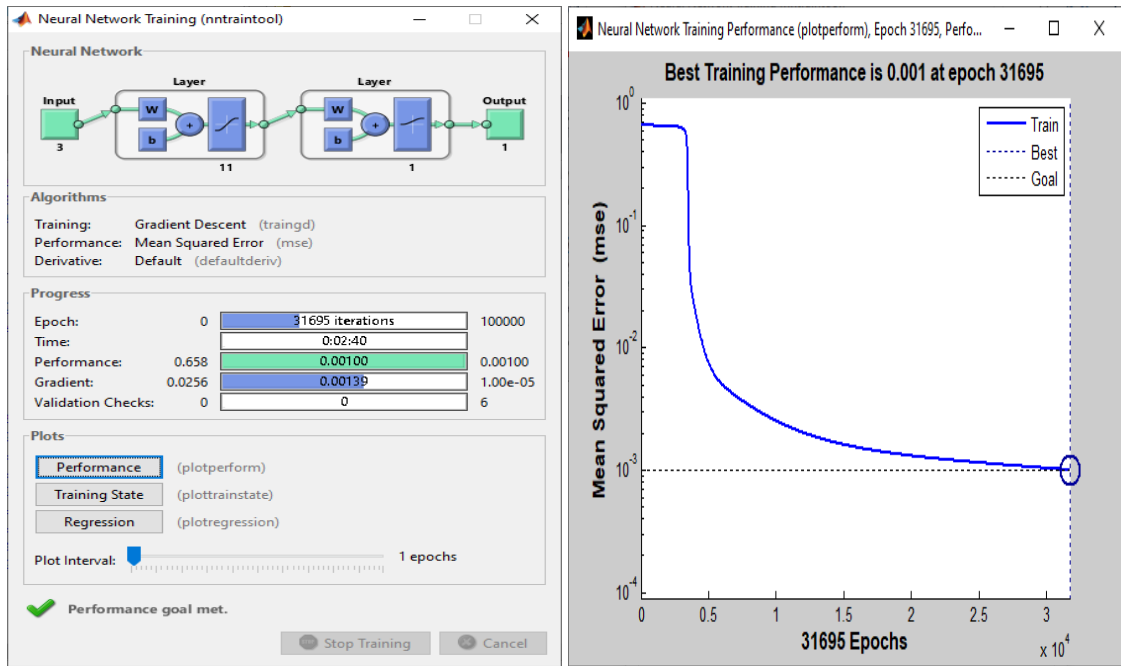
Tabel 5. Hasil Pelatihan dan Pengujian dengan Model 3-8-1

No	Data Pelatihan				Data Pengujian				Hasil
	Target	Output	Error	SSE	Target	Output	Error	SSE	
1	0,2719	0,2330	0,0389	0,0015	0,2609	0,2024	0,0585	0,0034	0
2	0,3157	0,2934	0,0223	0,0005	0,3262	0,2574	0,0688	0,0047	0
3	0,1776	0,1411	0,0365	0,0013	0,1810	0,1514	0,0296	0,0009	0
4	0,1199	0,1349	-0,0150	0,0002	0,1193	0,1359	-0,0166	0,0003	1
5	0,1586	0,1397	0,0189	0,0004	0,1516	0,1478	0,0038	0,0000	1
6	0,2368	0,1571	0,0797	0,0064	0,2937	0,2215	0,0722	0,0052	0
7	0,1159	0,1347	-0,0188	0,0004	0,1217	0,1382	-0,0165	0,0003	1
8	0,1737	0,1393	0,0344	0,0012	0,1630	0,1533	0,0097	0,0001	1
9	0,1064	0,1343	-0,0279	0,0008	0,1063	0,1328	-0,0265	0,0007	1
10	0,1022	0,1341	-0,0319	0,0010	0,1020	0,1318	-0,0298	0,0009	1
11	0,1006	0,1341	-0,0335	0,0011	0,1002	0,1315	-0,0313	0,0010	1
12	0,8888	0,8710	0,0178	0,0003	0,8979	0,9096	-0,0117	0,0001	1
13	0,5662	0,5675	-0,0013	0,0000	0,5825	0,6019	-0,0194	0,0004	1
14	0,1325	0,1358	-0,0033	0,0000	0,1358	0,1379	-0,0021	0,0000	1
15	0,6205	0,6005	0,0200	0,0004	0,6657	0,6371	0,0286	0,0008	0
16	0,2407	0,1631	0,0776	0,0060	0,2467	0,1812	0,0655	0,0043	0
17	0,1377	0,1360	0,0017	0,0000	0,1344	0,1411	-0,0067	0,0000	1
18	0,1798	0,1404	0,0394	0,0016	0,1539	0,1629	-0,0090	0,0001	1
19	0,1176	0,1350	-0,0174	0,0003	0,1200	0,1352	-0,0152	0,0002	1
20	0,1393	0,1362	0,0031	0,0000	0,1383	0,1397	-0,0014	0,0000	1
21	0,1238	0,1350	-0,0112	0,0001	0,1249	0,1370	-0,0121	0,0001	1
22	0,4287	0,4874	-0,0587	0,0034	0,4073	0,4740	-0,0667	0,0045	1
23	0,1202	0,1348	-0,0146	0,0002	0,1197	0,1349	-0,0152	0,0002	1
24	0,1024	0,1342	-0,0318	0,0010	0,1019	0,1320	-0,0301	0,0009	1
25	0,1147	0,1346	-0,0199	0,0004	0,1153	0,1346	-0,0193	0,0004	1
26	0,1842	0,1394	0,0448	0,0020	0,1917	0,1531	0,0386	0,0015	0
27	0,4919	0,5042	-0,0123	0,0002	0,5342	0,5333	0,0009	0,0000	1
28	0,1398	0,1359	0,0039	0,0000	0,1448	0,1412	0,0036	0,0000	1
29	0,1057	0,1343	-0,0286	0,0008	0,1049	0,1326	-0,0277	0,0008	1
30	0,1237	0,1352	-0,0115	0,0001	0,1263	0,1373	-0,0110	0,0001	1
31	0,1186	0,1355	-0,0169	0,0003	0,1184	0,1352	-0,0168	0,0003	1
32	0,1080	0,1343	-0,0263	0,0007	0,1083	0,1327	-0,0244	0,0006	1
33	0,1063	0,1343	-0,0280	0,0008	0,1059	0,1326	-0,0267	0,0007	1
34	0,1107	0,1344	-0,0237	0,0006	0,1124	0,1335	-0,0211	0,0004	1
			SSE	0,0340			SSE	0,0340	
			MSE	0,0010			MSE	0,0010	79,4 %

4.2.4. Model 3-11-1

Model ini menggunakan 3 neuron input, layer tersembunyi 11 neuron, serta 1 neuron keluaran. Source Code pelatihan Backpropagation yang digunakan dengan aplikasi Matlab R2011a sebagai berikut :

```
>>net=newff(minmax(p),[11,1],{'tansig','logsig'},'traingd');
>>net.IW{1,1};
>>net.b{1};
>>net.LW{2,1};
>>net.b{2};
>>net.trainParam.epochs=100000;
>>net.trainParam.goal = 0.001;
>>net.trainParam.Lr = 0.01;
>>net.trainParam.show = 1000;
>>net=train(net,p,t)
>>[a,Pf,Af,e,Perf]=sim(net,p,[],[],t)
```



Gambar 5. Pelatihan Menggunakan Arsitektur 3-11-1

Hasil pelatihan pada model 3-11-1 menghasilkan epoch 31695 iterasi, dengan waktu 02:40 detik. Best training performance sebesar 0,001.

Tabel 6. Hasil Pelatihan dan Pengujian dengan Model 3-11-1

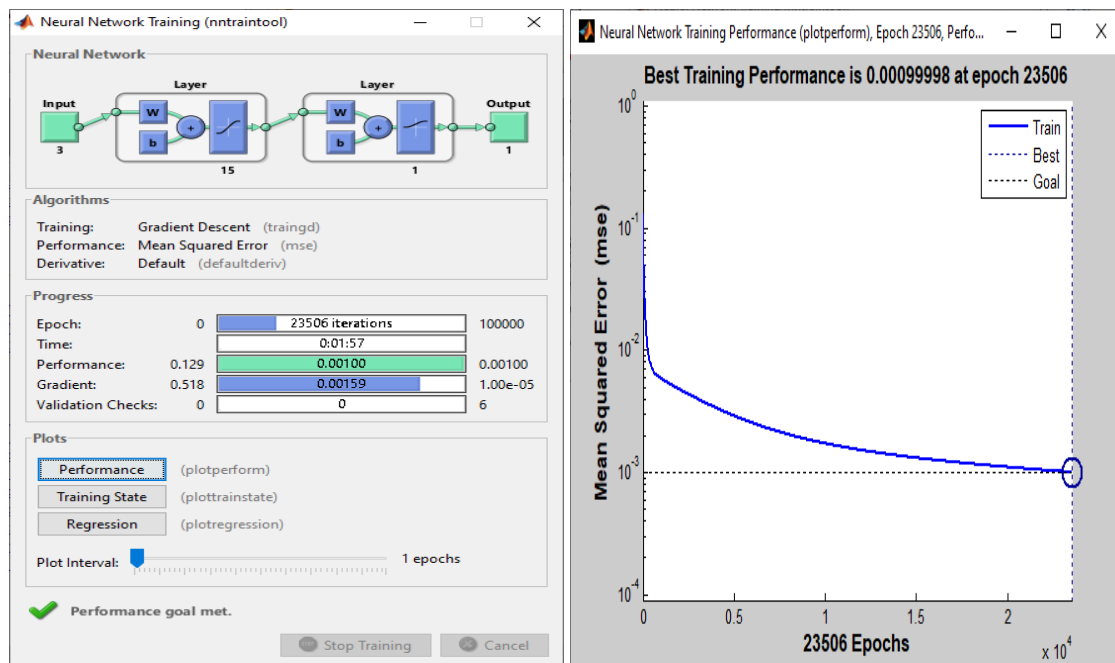
No	Data Pelatihan				Data Pengujian				
	Target	Output	Error	SSE	Target	Output	Error	SSE	Hasil
1	0,2719	0,2722	-0,0003	0,0000	0,2609	0,2153	0,0456	0,0021	0
2	0,3157	0,3410	-0,0253	0,0006	0,3262	0,2597	0,0665	0,0044	0
3	0,1776	0,1431	0,0345	0,0012	0,1810	0,1558	0,0252	0,0006	0
4	0,1199	0,1297	-0,0098	0,0001	0,1193	0,1367	-0,0174	0,0003	1
5	0,1586	0,1393	0,0193	0,0004	0,1516	0,1472	0,0044	0,0000	1
6	0,2368	0,1735	0,0633	0,0040	0,2937	0,2055	0,0882	0,0078	0
7	0,1159	0,1293	-0,0134	0,0002	0,1217	0,1363	-0,0146	0,0002	1
8	0,1737	0,1395	0,0342	0,0012	0,1630	0,1524	0,0106	0,0001	0
9	0,1064	0,1285	-0,0221	0,0005	0,1063	0,1338	-0,0275	0,0008	1
10	0,1022	0,1283	-0,0261	0,0007	0,1020	0,1330	-0,0310	0,0010	1
11	0,1006	0,1280	-0,0274	0,0008	0,1002	0,1326	-0,0324	0,0011	1
12	0,8888	0,8515	0,0373	0,0014	0,8979	0,8553	0,0426	0,0018	0
13	0,5662	0,4951	0,0711	0,0050	0,5825	0,6426	-0,0601	0,0036	1
14	0,1325	0,1317	0,0008	0,0000	0,1358	0,1404	-0,0046	0,0000	1

No	Data Pelatihan				Data Pengujian				Hasil
	Target	Output	Error	SSE	Target	Output	Error	SSE	
15	0,6205	0,5937	0,0268	0,0007	0,6657	0,6921	-0,0264	0,0007	1
16	0,2407	0,1833	0,0574	0,0033	0,2467	0,1922	0,0545	0,0030	0
17	0,1377	0,1326	0,0051	0,0000	0,1344	0,1411	-0,0067	0,0000	1
18	0,1798	0,1419	0,0379	0,0014	0,1539	0,1528	0,0011	0,0000	1
19	0,1176	0,1296	-0,0120	0,0001	0,1200	0,1365	-0,0165	0,0003	1
20	0,1393	0,1326	0,0067	0,0000	0,1383	0,1418	-0,0035	0,0000	1
21	0,1238	0,1302	-0,0064	0,0000	0,1249	0,1378	-0,0129	0,0002	1
22	0,4287	0,4677	-0,0390	0,0015	0,4073	0,4106	-0,0033	0,0000	1
23	0,1202	0,1298	-0,0096	0,0001	0,1197	0,1369	-0,0172	0,0003	1
24	0,1024	0,1282	-0,0258	0,0007	0,1019	0,1330	-0,0311	0,0010	1
25	0,1147	0,1292	-0,0145	0,0002	0,1153	0,1357	-0,0204	0,0004	1
26	0,1842	0,1414	0,0428	0,0018	0,1917	0,1591	0,0326	0,0011	0
27	0,4919	0,5691	-0,0772	0,0060	0,5342	0,5276	0,0066	0,0000	1
28	0,1398	0,1323	0,0075	0,0001	0,1448	0,1425	0,0023	0,0000	1
29	0,1057	0,1285	-0,0228	0,0005	0,1049	0,1336	-0,0287	0,0008	1
30	0,1237	0,1302	-0,0065	0,0000	0,1263	0,1380	-0,0117	0,0001	1
31	0,1186	0,1296	-0,0110	0,0001	0,1184	0,1365	-0,0181	0,0003	1
32	0,1080	0,1287	-0,0207	0,0004	0,1083	0,1342	-0,0259	0,0007	1
33	0,1063	0,1285	-0,0222	0,0005	0,1059	0,1338	-0,0279	0,0008	1
34	0,1107	0,1290	-0,0183	0,0003	0,1124	0,1349	-0,0225	0,0005	1
			SSE	0,0340			SSE	0,0340	
			MSE	0,0010			MSE	0,0010	76,5 %

4.2.5. Model 3-15-1

Model ini menggunakan 3 *neuron* input, layer tersembunyi 15 *neuron*, serta 1 *neuron* keluaran. *Source Code* pelatihan *Backpropagation* yang digunakan dengan aplikasi *Matlab R2011a* sebagai berikut :

```
>>net=newff(minmax(p),[15,1],{'tansig','logsig'},'traingd');
>>net.IW{1,1};
>>net.b{1};
>>net.LW{2,1};
>>net.b{2};
>>net.trainParam.epochs=100000;
>>net.trainParam.goal = 0.001;
>>net.trainParam.Lr = 0.01;
>>net.trainParam.show = 1000;
>>net=train(net,p,t)
>>[a,Pf,Af,e,Perf]=sim(net,p,[],[],t)
```



Gambar 6. Pelatihan Menggunakan Arsitektur 3-15-1

Hasil pelatihan pada model 3-15-1 menghasilkan *epoch* 31695 iterasi, dengan waktu 02:40 detik. Best training performance sebesar 0,001.

Tabel 7. Hasil Pelatihan dan Pengujian dengan Model 3-15-1

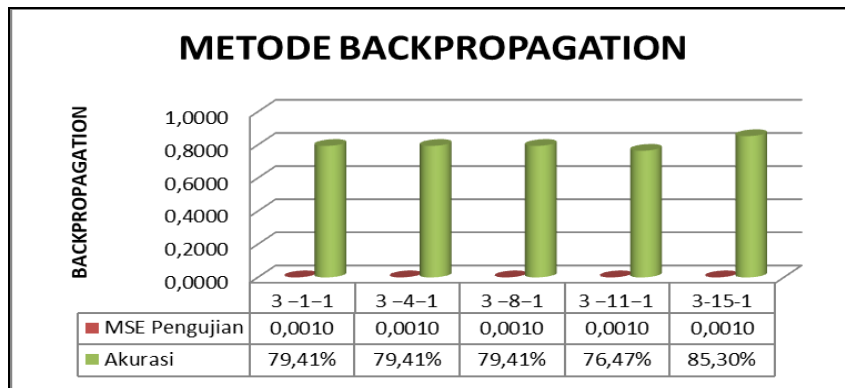
No	Data Pelatihan				Data Pengujian				Hasil
	Target	Output	Error	SSE	Target	Output	Error	SSE	
1	0,2719	0,2462	0,0257	0,0007	0,2609	0,2982	-0,0373	0,0014	1
2	0,3157	0,3334	-0,0177	0,0003	0,3262	0,3585	-0,0323	0,0010	1
3	0,1776	0,1378	0,0398	0,0016	0,1810	0,1553	0,0257	0,0007	0
4	0,1199	0,1327	-0,0128	0,0002	0,1193	0,1227	-0,0034	0,0000	1
5	0,1586	0,1296	0,0290	0,0008	0,1516	0,1455	0,0061	0,0000	1
6	0,2368	0,1558	0,0810	0,0066	0,2937	0,2107	0,0830	0,0069	0
7	0,1159	0,1330	-0,0171	0,0003	0,1217	0,1200	0,0017	0,0000	1
8	0,1737	0,1400	0,0337	0,0011	0,1630	0,1589	0,0041	0,0000	1
9	0,1064	0,1327	-0,0263	0,0007	0,1063	0,1183	-0,0120	0,0001	1
10	0,1022	0,1329	-0,0307	0,0009	0,1020	0,1171	-0,0151	0,0002	1
11	0,1006	0,1327	-0,0321	0,0010	0,1002	0,1167	-0,0165	0,0003	1
12	0,8888	0,8490	0,0398	0,0016	0,8979	0,9199	-0,0220	0,0005	1
13	0,5662	0,5725	-0,0063	0,0000	0,5825	0,5796	0,0029	0,0000	1
14	0,1325	0,1325	0,0000	0,0000	0,1358	0,1259	0,0099	0,0001	1
15	0,6205	0,5931	0,0274	0,0007	0,6657	0,7105	-0,0448	0,0020	1
16	0,2407	0,1564	0,0843	0,0071	0,2467	0,2374	0,0093	0,0001	1
17	0,1377	0,1338	0,0039	0,0000	0,1344	0,1315	0,0029	0,0000	1
18	0,1798	0,1411	0,0387	0,0015	0,1539	0,1728	-0,0189	0,0004	1
19	0,1176	0,1302	-0,0126	0,0002	0,1200	0,1207	-0,0007	0,0000	1
20	0,1393	0,1331	0,0062	0,0000	0,1383	0,1309	0,0074	0,0001	1
21	0,1238	0,1335	-0,0097	0,0001	0,1249	0,1235	0,0014	0,0000	1
22	0,4287	0,4718	-0,0431	0,0019	0,4073	0,4865	-0,0792	0,0063	1
23	0,1202	0,1337	-0,0135	0,0002	0,1197	0,1224	-0,0027	0,0000	1
24	0,1024	0,1327	-0,0303	0,0009	0,1019	0,1173	-0,0154	0,0002	1
25	0,1147	0,1333	-0,0186	0,0003	0,1153	0,1204	-0,0051	0,0000	1
26	0,1842	0,1494	0,0348	0,0012	0,1917	0,1597	0,0320	0,0010	0
27	0,4919	0,5270	-0,0351	0,0012	0,5342	0,4252	0,1090	0,0119	0
28	0,1398	0,1357	0,0041	0,0000	0,1448	0,1290	0,0158	0,0003	0
29	0,1057	0,1330	-0,0273	0,0007	0,1049	0,1182	-0,0133	0,0002	1
30	0,1237	0,1315	-0,0078	0,0001	0,1263	0,1230	0,0033	0,0000	1
31	0,1186	0,1260	-0,0074	0,0001	0,1184	0,1220	-0,0036	0,0000	1
32	0,1080	0,1338	-0,0258	0,0007	0,1083	0,1183	-0,0100	0,0001	1
33	0,1063	0,1327	-0,0264	0,0007	0,1059	0,1182	-0,0123	0,0002	1
34	0,1107	0,1333	-0,0226	0,0005	0,1124	0,1187	-0,0063	0,0000	1
			SSE	0,0340			SSE	0,0340	
			MSE	0,0010			MSE	0,0010	85,3 %

4.3. Kesimpulan Pelatihan dan Pengujian

Berikut kesimpulan dari pelatihan dan pengujian data set populasi itik manila menggunakan jaringan saraf tiruan Back-propagation

Tabel 8. Kesimpulan Pelatihan Dan Pengujian Jaringan

Model Arsitektur	Epoch	Waktu Pelatihan	MSE Pengujian	Akurasi
3-1-1	1236	00:08	0,0010	79,41%
3-4-1	54837	04:54	0,0010	79,41%
3-8-1	34872	02:57	0,0010	79,41%
3-11-1	31695	02:40	0,0010	76,47%
3-15-1	39106	03:19	0,0010	85,30%



Gambar 7. Grafik Kesimpulan Pelatihan Dan Pengujian Jaringan

Berdasarkan tabel 8 dan gambar 7 dapat dijelaskan bahwa hasil akurasi terbaik yaitu model 3-15-1 yang dihitung dengan menggunakan software Matlab dan Microsoft excel, menunjukkan dari data yang didapat bahwa performance perhitungan jaringan saraf tiruan dengan algoritma back-propagation adalah 85,3%.

4.4. Hasil Prediksi

Prediksi jumlah populasi itik manila di 34 provinsi yang ada di Indonesia, dicari menggunakan model arsitektur terbaik, yaitu model 3-15-1. Prediksi dilakukan menggunakan persamaan berikut :

$$\text{Prediksi} = \frac{(\text{Target Prediksi} - 0,1)(b - a)}{0,8} + a$$

Sehingga memperoleh hasil prediksi yang dapat dilihat pada tabel 9 berikut.

Tabel 9. Hasil Prediksi Jumlah Populasi Itik Manila di 34 Provinsi

No	Data Real 2021	Target 2021	Target Prediksi 2022	Prediksi 2022
1	2.346.387	0,2609	0,2436	2.091.459
2	3.294.597	0,3262	0,3593	3.767.556
3	1.185.955	0,1810	0,1429	632.660
4	288.578	0,1193	0,1281	418.259
5	757.594	0,1516	0,1331	490.692
6	2.822.086	0,2937	0,2007	1.469.985
7	323.269	0,1217	0,1305	453.027
8	924.458	0,1630	0,1371	548.638
9	99.511	0,1063	0,1273	406.670
10	38.358	0,1020	0,1271	403.772
11	11.186	0,1002	0,1271	403.772
12	11.600.450	0,8979	0,8964	11.548.298
13	7.017.519	0,5825	0,55	6.530.147
14	528.424	0,1358	0,1303	450.129
15	8.226.867	0,6657	0,6353	7.765.852
16	2.139.200	0,2467	0,1997	1.455.498
17	508.370	0,1344	0,1296	439.989
18	791.226	0,1539	0,1353	522.562
19	299.515	0,1200	0,1286	425.502
20	564.595	0,1383	0,1302	448.681
21	370.561	0,1249	0,1289	429.848
22	4.472.410	0,4073	0,5079	5.920.262
23	294.436	0,1197	0,1278	413.913
24	35.888	0,1019	0,1271	403.772
25	231.658	0,1153	0,128	416.810
26	1.340.939	0,1917	0,1476	700.747
27	6.316.964	0,5342	0,5419	6.412.806
28	659.953	0,1448	0,1322	477.654
29	80.405	0,1049	0,1271	403.772
30	391.201	0,1263	0,1294	437.091
31	275.594	0,1184	0,128	416.810
32	129.946	0,1083	0,1274	408.118
33	95.076	0,1059	0,1272	405.221
34	188.662	0,1124	0,1279	415.362

5. KESIMPULAN DAN SARAN

Berdasarkan hasil dan pembahasan yang telah dilakukan, maka dapat diambil beberapa kesimpulan bahwa Jaringan saraf tiruan dengan menggunakan algoritma back-propagation dapat diterapkan dalam menganalisa fluktuasi yang terjadi pada jumlah populasi itik manila berdasarkan provinsi di Indonesia. Diperoleh tingkat akurasi dari prediksi jumlah populasi itik manila dengan menggunakan back-propagation yaitu, didapat arsitektur terbaik yaitu 3-15-1 dengan jumlah MSE Training sebesar 0.0010, nilai epoch 39106, MSE Testing 0.0010 dan menghasilkan nilai akurasi sebesar 85,3%.

Saran yang dapat diberikan berdasarkan penelitian ini, bahwa dari model arsitektur yang didapat, bisa dijadikan masukan khusus bagi pemerintah ataupun masyarakat dalam memprediksi jumlah populasi itik manila di seluruh provinsi di Indonesia. Agar diadakan penelitian lebih lanjut mengenai populasi itik manila dengan menggunakan metode lain.

DAFTAR PUSTAKA

- [1] J. Peternakan, F. Pertanian, U. Bengkulu, and K. Limun, "No Title," vol. 15, no. 1, pp. 98–109, 2020.
- [2] Y. Rahman and A. Ismanto, "Komposisi Kimia , Karakteristik Fisik dan Nilai Organoleptik Nugget Itik Manila (Cairinamoschata) yang diberi Pakan Limbah Pasar Samarinda Chemical Composition , Physical Characteristics , and Organoleptic Value of Nuggets from Manila Duck (Cairinamos," vol. 3, no. 2, pp. 94–101, 2020.
- [3] D. R. Susanti, "Kualitas Fisik Daging Itik Manila (Cairina Moschata) Berdasarkan Umur Potong Yang Berbeda." Universitas Mercu Buana Yogyakarta, 2021.
- [4] G. Z. Muflih, "Pengaruh Nilai Hidden layer dan Learning rate Terhadap Kecepatan Pelatihan Jaringan Saraf Tiruan Backpropagation," *Jurnal Riset Teknologi Informasi dan Komputer (JURISTIK)*, vol. 1, no. 2, pp. 12–17, 2021.
- [5] Y. Aprizal, R. I. Zainal, U. B. Darma, J. S. Tiruan, and L. V. Quantization, "PERBANDINGAN METODE BACKPROPAGATION DAN LEARNING VECTOR QUANTIZATION (LVQ) DALAM MENGGALI POTENSI MAHASISWA BARU DI," vol. 18, no. 2, pp. 294–301, 2019.
- [6] M. Setya, A. Fauzi, B. Rahayudi, and C. Dewi, "Perbandingan Jaringan Saraf Tiruan LVQ Dengan Backpropagation Dalam Deteksi Dini Penyakit Jantung Koroner," vol. 3, no. 2, pp. 1952–1960, 2019.
- [7] A. Revi, S. Solikhun, and M. Safii, "Jaringan Syaraf Tiruan Dalam Memprediksi Jumlah Produksi Daging Sapi Berdasarkan Provinsi," *KOMIK (Konferensi Nasional Teknologi Informasi dan Komputer)*, vol. 2, no. 1, 2018.
- [8] P. Mutiara Putri, D. Monika, L. Apriliani, P. Studi Manajemen Informatika, A. Tunas Bangsa Pematangsiantar, and J. A. Jenderal Sudirman Blok No, "Model Jaringan Syaraf Tiruan Dalam Memprediksi Jumlah Produksi Telur Ayam Petelur Berdasarkan Provinsi Di Indonesia," 2019.
- [9] Nurhayati, M. B. Sibuea, D. Kusbiantoro, M. Silaban, and A. Wanto, "Implementasi Algoritma Resilient untuk Prediksi Potensi Produksi Bawang Merah di Indonesia," *Building of Informatics, Technology and Science (BITS)*, vol. 4, no. 2, pp. 1051–1060, 2022.
- [10] I. M. Muhamad, S. A. Wardana, A. Wanto, and A. P. Windarto, "Algoritma Machine Learning untuk penentuan Model Prediksi Produksi Telur Ayam Petelur di Sumatera," *Journal of Informatics, Electrical and Electronics Engineering*, vol. 1, no. 4, pp. 126–134, 2022.
- [11] M. Mahendra, R. C. Telaumbanua, A. Wanto, and A. P. Windarto, "Akurasi Prediksi Ekspor Tanaman Obat , Aromatik dan Rempah-Rempah Menggunakan Machine Learning," *KLIK: Kajian Ilmiah Informatika dan Komputer*, vol. 2, no. 6, pp. 207–215, 2022.
- [12] R. Puspadini, A. Wanto, and N. Arminarahmah, "Penerapan ML dengan Teknik Bayesian Regulation untuk Peramalan," *Journal of Computer System and Informatics (JoSYC)*, vol. 3, no. 3, pp. 147–155, 2022.
- [13] N. L. W. S. R. Ginantra, A. D. GS, S. Andini, and A. Wanto, "Pemanfaatan Algoritma Fletcher-Reeves untuk Penentuan Model Prediksi Harga Nilai Ekspor Menurut Golongan SITC," *Building of Informatics, Technology and Science (BITS)*, vol. 3, no. 4, pp. 679–685, 2022.
- [14] N. Arminarahmah, S. D. Rizki, O. A. Putra, and A. Wanto, "Performance Analysis and Model Determination for Forecasting Aluminum Imports Using the Powell-Beale Algorithm," *IJISTECH (International Journal of Information System & Technology)*, vol. 5, no. 5, pp. 624–632, 2022.
- [15] A. Wanto, S. Defit, and A. P. Windarto, "Algoritma Fungsi Pelatihan pada Machine Learning berbasis

- ANN untuk Peramalan Fenomena Bencana,” *RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, pp. 254–264, 2021.
- [16] R. Sinaga, M. M. Situmorang, D. Setiawan, A. Wanto, and A. P. Windarto, “Akurasi Algoritma Fletcher-Reeves untuk Prediksi Ekspor Karet Remah Berdasarkan Negara Tujuan Utama,” *Journal of Informatics Management and Information Technology*, vol. 2, no. 3, pp. 91–99, 2022.
- [17] H. U. Sari, A. P. Windarto, and I. S. Damanik, “Analisis Jaringan Saraf Tiruan dengan Backpropagation pada korelasi Matakuliah Pratikum Terhadap Tugas Akhir,” vol. 9, no. 1, pp. 115–121, 2022.
- [18] N. Rahayu and H. Mustafidah, “Perbandingan Ketepatan Pola Data pada Jaringan Backpropagation Berdasarkan Metode Pembobotan Random dan Nguyen Widrow,” *Sainteks*, vol. 19, no. 1, p. 27, 2022.
- [19] P. Parulian *et al.*, “Analysis of Sequential Order Incremental Methods in Predicting the Number of Victims Affected by Disasters,” *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [20] A. Wanto *et al.*, “Forecasting the Export and Import Volume of Crude Oil, Oil Products and Gas Using ANN,” *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [21] E. Hartato, D. Sitorus, and A. Wanto, “Analisis Jaringan Saraf Tiruan Untuk Prediksi Luas Panen Biofarmaka di Indonesia,” *Jurnal semanTIK*, vol. 4, no. 1, pp. 49–56, 2018.
- [22] T. Afriliansyah *et al.*, “Implementation of Bayesian Regulation Algorithm for Estimation of Production Index Level Micro and Small Industry,” *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [23] B. W. N. Tanyo and D. Swanjaya, “Perbandingan antara Metode Holt-Winters dan Backpropagation pada Model Peramalan Penjualan,” *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, vol. 5, no. 3, pp. 174–181, 2021.
- [24] A. Wanto *et al.*, “Epoch Analysis and Accuracy 3 ANN Algorithm using Consumer Price Index Data in Indonesia,” in *Proceedings of the 3rd International Conference of Computer, Environment, Agriculture, Social Science, Health Science, Engineering and Technology (ICEST)*, 2021, no. 1, pp. 35–41.
- [25] N. L. W. S. R. Ginantra *et al.*, “Performance One-step secant Training Method for Forecasting Cases,” *Journal of Physics: Conference Series*, vol. 1933, no. 1, pp. 1–8, 2021.
- [26] A. Wanto and A. P. Windarto, “Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode Backpropagation,” *Jurnal & Penelitian Teknik Informatika Sinkron*, vol. 2, no. 2, pp. 37–44, 2017.
- [27] B. K. Sihotang and A. Wanto, “Analisis Jaringan Syaraf Tiruan Dalam Memprediksi Jumlah Tamu Pada Hotel Non Bintang,” *Jurnal Teknologi Informasi Techno*, vol. 17, no. 4, pp. 333–346, 2018.
- [28] J. Wahyuni, Y. W. Paranthi, and A. Wanto, “Analisis Jaringan Saraf Dalam Estimasi Tingkat Pengangguran Terbuka Penduduk Sumatera Utara,” *Jurnal Infomedia*, vol. 3, no. 1, pp. 18–24, 2018.
- [29] G. W. Bhawika *et al.*, “Implementation of ANN for Predicting the Percentage of Illiteracy in Indonesia by Age Group,” *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [30] A. Wanto *et al.*, “Analysis of the Backpropagation Algorithm in Viewing Import Value Development Levels Based on Main Country of Origin,” *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [31] E. Siregar, H. Mawengkang, E. B. Nababan, and A. Wanto, “Analysis of Backpropagation Method with Sigmoid Bipolar and Linear Function in Prediction of Population Growth,” *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [32] M. K. Z. Sormin, P. Sihombing, A. Amalia, A. Wanto, D. Hartama, and D. M. Chan, “Predictions of World Population Life Expectancy Using Cyclical Order Weight / Bias,” *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [33] A. Wanto *et al.*, “Analysis of the Accuracy Batch Training Method in Viewing Indonesian Fisheries Cultivation Company Development,” *Journal of Physics: Conference Series*, vol. 1255, no. 1, pp. 1–6, 2019.
- [34] Y. Andriani, H. Silitonga, and A. Wanto, “Analisis Jaringan Syaraf Tiruan untuk prediksi volume ekspor dan impor migas di Indonesia,” *Register: Jurnal Ilmiah Teknologi Sistem Informasi*, vol. 4, no. 1, pp. 30–40, 2018.
- [35] W. Saputra, J. T. Hardinata, and A. Wanto, “Implementation of Resilient Methods to Predict Open Unemployment in Indonesia According to Higher Education Completed,” *JITE (Journal of Informatics and Telecommunication Engineering)*, vol. 3, no. 1, pp. 163–174, 2019.