

Penerapan Jaringan Syaraf Tiruan Backpropagation Dalam Memprediksi Jumlah Pertumbuhan Kendaraan Di Provinsi Sumatera Utara

Bagus Supranda*, Solikhun, Zulia Almaida Siregar

STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

Jalan Jendral Sudirman Blok A, No.1,2 & 3, Pematangsiantar, Sumatera Utara, Indonesia

Email: bagussupranda@gmail.com,

Email Penulis Korespondensi: bagussupranda@gmail.com

Abstrak—Kendaraan bermotor menjadi bagian dari kebutuhan terhadap transportasi atau kendaraan yang merupakan turunan akibat aktifitas ekonomi, sosial dan aktivitas lainnya. Pertumbuhan kendaraan tidak sebanding dengan populasi penduduk di provinsi Sumatera Utara. Hal ini menyebabkan berbagai dampak negatif, salah satunya yaitu terjadinya peningkatan kemacetan lalu lintas, pencemaran udara dari kendaraan bermotor yang menimbulkan meningkatnya emisi gas rumah kaca. Berdasarkan masalah tersebut perlu adanya prediksi terhadap jumlah kendaraan yang ada di Provinsi Sumatera Utara dengan menggunakan jaringan saraf tiruan algoritma backpropagation. Hasil uji coba yang dilakukan dengan software MATLAB R2011b model arsitektur terbaiknya adalah model 2-2-1 dengan tingkat akurasi 94% dengan jumlah MSE 0.000208514, nilai epoch 789. Dapat disimpulkan bahwa metode Backpropagation dapat di jadikan salah satu metode prediksi yang memudahkan dalam mencari prediksi apapun

Kata Kunci: Backpropagation; JST; Kendaraan; Matlab; BPS

Abstract—Motorized vehicles are part of the need for transportation or vehicles that are derivatives due to economic, social and other activities. The growth of vehicles is not proportional to the population in the province of North Sumatra. This causes various negative impacts, one of which is an increase in traffic congestion, air pollution from motorized vehicles which causes an increase in greenhouse gas emissions. Based on this problem, it is necessary to predict the number of vehicles in North Sumatra Province using the backpropagation algorithm artificial neural network. The results of trials carried out with MATLAB R2011b software, the best architectural model is the 2-2-1 model with an accuracy rate of 94% with MSE number 0.000208514, epoch value 789. It can be concluded that the Backpropagation method can be used as one of the predictive methods that makes it easier to find predictions. whatever

Keywords: Back-propagation; Vehicle ANN; Matlab; BPS

1. PENDAHULUAN

Pesatnya kemajuan global kebutuhan terhadap kendaraan bermotor semakin tinggi, maka dapat mengakibatkan tidak seimbang terhadap populasi penduduk yang ada[1]. Pada saat ini, kendaraan bermotor menjadi bagian dari kebutuhan terhadap transportasi atau kendaraan yang merupakan turunan akibat aktifitas ekonomi, sosial dan aktivitas lainnya[2]. Provinsi Sumatera Utara merupakan salah satu provinsi yang ada di Indonesia. Banyak aktivitas kegiatan masyarakat baik dalam bidang pemerintahan, pendidikan, perdagangan, industri maupun transportasi. Provinsi Sumatera Utara mengalami pertumbuhan penduduk yang cukup tinggi dari tahun-ketahun, dikarenakan banyaknya penduduk yang bermigrasi dari daerah lain. Perkembangan jumlah penduduk juga mempengaruhi bertambahnya jumlah kendaraan yang ada. Berdasarkan data dari Badan Pusat Statistik (BPS), bahwa jumlah kendaraan di provinsi Sumatera Utara pada Tahun 2017 (305.983), Tahun 2018 (363.362) dan Tahun 2019 (518.798) dengan jumlah keseluruhan (1.188.143). Pertumbuhan kendaraan tidak sebanding dengan populasi penduduk di provinsi Sumatera Utara. Hal ini menyebabkan berbagai dampak negatif, salah satunya yaitu terjadinya peningkatan kemacetan lalu lintas, pencemaran udara dari kendaraan bermotor yang menimbulkan meningkatnya emisi gas rumah kaca. Berdasarkan masalah tersebut perlu adanya prediksi terhadap jumlah kendaraan yang ada di Provinsi Sumatera Utara. Oleh karena itu, dibutuhkan prediksi yang akurat untuk mengetahui jumlah kendaraan tiap tahun. Untuk itu dapat dilakukan tindakan preventif untuk menyesuaikan antara kebutuhan masyarakat atas kendaraan dengan kendaraan umum yang ada. Selain itu, dapat dilakukan juga pembatasan pada kepemilikan kendaraan. Prediksi dilakukan dengan memanfaatkan sistem kecerdasan buatan yang salah satunya adalah Jaringan Syaraf Tiruan dengan menggunakan metode Algoritma *Backpropagation* dalam memprediksi jumlah pertumbuhan kendaraan di Provinsi Sumatera Utara. Jaringan Syaraf Tiruan merupakan salah satu representasi buatan dari otak manusia yang diimplementasikan pada program komputer yang mampu menyelesaikan sejumlah perhitungan dalam menarik suatu kesimpulan [3]. *Backpropagation* merupakan bagian dari Jaringan Syaraf Tiruan yang menggunakan beberapa pola dalam mencapai jumlah kesalahan yang minimum dalam memprediksi suatu kebenaran [3]. Diharapkan dengan sistem ini dapat membantu kepada pihak terkait dalam menghitung dan memprediksi jumlah pertumbuhan kendaraan di Provinsi Sumatera Utara.

2. METODOLOGI PENELITIAN

2.1. Teknik Pengumpulan Data

Sumber data diperoleh dari Badan Pusat Statistik Indonesia melalui *website* www.bps.go.id. Data penelitian yang digunakan adalah data pertumbuhan kendaraan Provinsi Sumatera Utara pada tahun 2017 sampai 2019.

2.2. Analisis Data

Data yang digunakan dalam penelitian ini dapat dilihat pada Tabel 3.1. merupakan data mentah dari *Microsoft Excel* Jumlah Kendaraan Menurut Unit Pelaksana Teknis (UPT) 2017-2019 dengan nama *datasheet* Data Jumlah Kendaraan.

Tabel 1. Data Sheet Jumlah Kendaraan

No	Unit Pelaksana Teknis (UPT)	Tahun		
		2017	2018	2019
1	Medan Utara	96584	163352	223135
2	Medan Selatan	29884	30652	52240
3	Lubuk Pakam	13904	12304	19694
4	Tebing Tinggi	8486	7678	11028
5	Pematang Siantar	14987	15988	25407
6	Binjai	12029	11658	17669
7	Stabat	8792	7464	11760
8	Tanjung Balai	3542	2950	4575
9	Kisaran	18037	17012	22750
10	Rantau Prapat	11701	9500	13796
11	Lima Puluh	4594	2696	4718
12	Perdagangan	7812	6040	7621
13	Sei Rampah	8674	7396	10732
14	Aek Kanopan	5535	4088	5770
15	Kota Pinang	6936	4596	6801
16	Kabanjahe	4613	4719	7512
17	Pangkalan Brandan	6372	5127	6522
18	Sibolga	5796	4759	5813
19	Sidikalang	2687	2949	4121
20	Tarutung	2818	3466	4812
21	Padang Sidempuan	4878	5353	7012
22	Panyabungan	3922	5107	6621
23	Sibuhuan	818	749	655
24	Gunung Sitoli	5561	5802	7905
25	Gunung Tua	476	549	548
26	Natal	919	995	978
27	Pandan	1544	3935	5890
28	Balige	2254	2473	3849
29	Teluk Dalam	1333	1463	2134
30	Pangururan	1172	1355	2311
31	Dolok Sanggul	1669	1971	2622
32	Salak	264	339	429
33	Sipirok	7390	8877	11368
Jumlah		308000	365380	520817

3. HASIL DAN PEMBAHASAN

Selanjutnya data dibagi menjadi menjadi 2, yaitu data pelatihan dan data pengujian. Data pelatihan dan data pengujian diambil dari data yang sama yaitu 2 kolom awal yaitu tahun 2017 (X1), tahun 2018 (X2) dan data kolom akhir tahun 2019 (Target).

3.1 Normalisasi

Data *Training* dan data *Testing* yang sudah ditentukan akan di normalisalkan menggunakan fungsi *sigmoid* (tidak pernah mencapai nilai 0 ataupun 1). Adapun rumus normalisasi dapat dilihat pada persamaan (1).

a) Perhitungan untuk normalisasi data *Training* dan data *Testing* dengan ketentuan nilai maksimum sebesar 223135 dan nilai minimum sebesar 264. Berikut merupakan contoh perhitungannya :

$$x' = \frac{0.8(96584-264)}{223135-264} + 0.1 = 0,4457$$

$$x' = \frac{0.8(163352-264)}{223135-264} + 0.1 = 0,6854$$

$$x' = \frac{0.8(223135-264)}{223135-264} + 0.1 = 0,9000$$

$$x' = \frac{0.8(29884-264)}{223135-264} + 0.1 = 0,2063$$

Hasil normalisasi data *Training* dan data *Testing* dapat dilihat pada tabel 2 dibawah sebagai berikut.

Tabel 2. Normalisasi Data *Training* dan Data *Testing*

Unit Pelaksana Teknis (UPT)	2017 (X1)	2018 (X2)	X3 (Target)
Medan Utara	0,4457	0,6854	0,9000
Medan Selatan	0,2063	0,2091	0,2866
Lubuk Pakam	0,1490	0,1432	0,1697
Tebing Tinggi	0,1295	0,1266	0,1386
Pematang Sianta	0,1528	0,1564	0,1903
Binjai	0,1422	0,1409	0,1625
Stabat	0,1306	0,1258	0,1413
Tanjung Balai	0,1118	0,1096	0,1155
Kisaran	0,1638	0,1601	0,1807
Rantau Prapat	0,1411	0,1332	0,1486
Lima Puluh	0,1155	0,1087	0,1160
Perdagangan	0,1271	0,1207	0,1264
Sei Rampah	0,1302	0,1256	0,1376
Aek Kanopan	0,1189	0,1137	0,1198
Kota Pinang	0,1239	0,1155	0,1235
Kabanjahe	0,1156	0,1160	0,1260
Pangkalan Brandan	0,1219	0,1175	0,1225
Sibolga	0,1199	0,1161	0,1199
Sidikalang	0,1087	0,1096	0,1138
Tarutung	0,1092	0,1115	0,1163
Padang Sidempuan	0,1166	0,1183	0,1242
Panyabungan	0,1131	0,1174	0,1228
Sibuhuan	0,1020	0,1017	0,1014
Gunung Sitoli	0,1190	0,1199	0,1274
Gunung Tua	0,1008	0,1010	0,1010
Natal	0,1024	0,1026	0,1026
Pandan	0,1046	0,1132	0,1202
Balige	0,1071	0,1079	0,1129
Teluk Dalam	0,1038	0,1043	0,1067
Pangururan	0,1033	0,1039	0,1073
Dolok Sanggul	0,1050	0,1061	0,1085
Salak	0,1000	0,1003	0,1006
Sipirok	0,1256	0,1309	0,1399

Maksud dari tabel 2. dapat dilihat pada kriteria *input* data *Training* dan *input* data *Testing* pada table 3. terdapat dua *input* data dengan satu target.

Tabel 3. Kriteria *Input* data *Training* dan *Input* data *Testing*

Input Data <i>Training</i>			Input Data <i>Testing</i>		
No.	Variabel	Nama Kriteria	No.	Variabel	Nama Kriteria
1	X1	Data tahun 2017	1	X2	Data tahun 2017
2	X2	Data tahun 2018	2	X2	Data tahun 2018
3	X3 (Target)	Data tahun 2019	3	X2 (Target)	Data tahun 2019

Pada penelitian ini menggunakan sebanyak 5 arsitektur pelatihan dan pengujian dengan algoritma *backpropagation* yaitu : 2-2-1, 2-3-1, 2-4-1, 2-5-1 dan 2-7-1.

3.2. Pelatihan dan Pengujian Data Dengan Model Arsitektur 2-2-1

Arsitektur pertama yang digunakan yaitu arsitektur 2-2-1, maksudnya pelatihan dan pengujian data menggunakan *layer* masukan sebanyak 2, *neuron Input 2layer* tersembunyi dan 1 *Output* keluaran. *Source Code* pelatihan dan pengujian yang digunakan pada *Software Matlab R2011b* sebagai berikut :

- `>>net=newff(minmax(P),[2,1],{'tansig','purelin'},'traingd');`
Perintah ini digunakan untuk membentuk jaringan *back-propagation* standard yang mempunyai 2 neuron hidden dan 1 neuron target.
- `>> net.IW{1,1};`
Net.LW{1,1} bobot pertama digunakan untuk bobot *hidden*
- `>> net.b{1};`
Net.b{1} bias yang digunakan untuk bias *hidden*.
- `>> net.LW{2,1};`
Net.LW{2,1} bobot kedua untuk bobot output.

e. `>> net.b{2};`

Bias yang digunakan untuk bias output.

f. `>> net.trainParam.epochs=15000;`

Perintah untuk menentukan jumlah iterasi (*epochs*) maksimum saat pelatihan

g. `>> net.trainParam.goal = 0.01;`

Perintah untuk menentukan batas MSE agar iterasi dihentikan.

h. `>> net.trainParam.Lr = 0.01;`

Perintah untuk menentukan laju pembelajaran (*learning rate*).

i. `>> net.trainParam.show = 100;`

Perintah untuk menampilkan frekuensi perubahan MSE

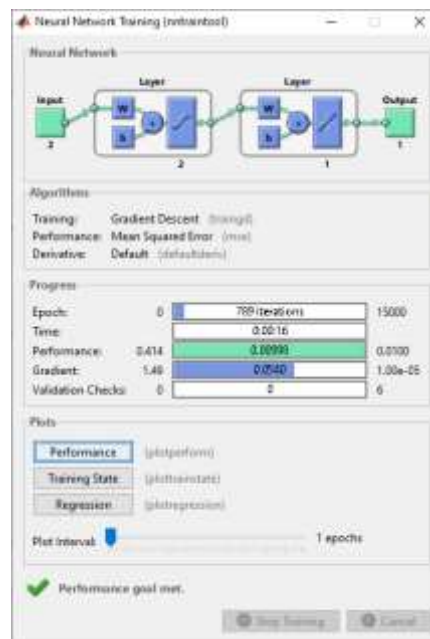
j. `>> net=train(net,P,T)`

Perintah untuk menampilkan jaringan hasil pelatihan.

k. `>> [a,Pf,Af,e,Perf]=sim(net,P,[],[],T)`

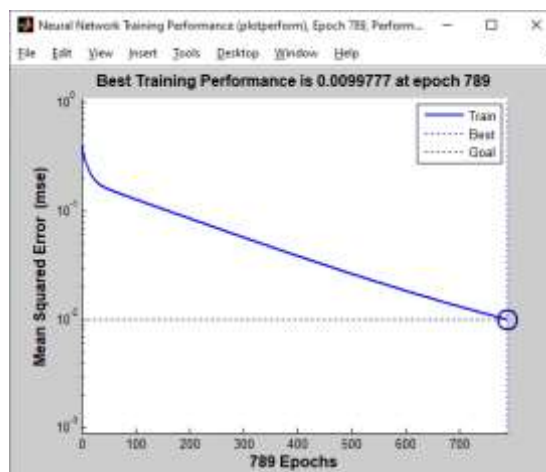
Perintah untuk melihat hasil output oleh jaringan

Pelatihan dan pengujian Jaringan Saraf Tiruan dengan arsitektur 2-2-1 dapat dilihat pada Gambar 1, dan 2. berikut :



Gambar 1. Pelatihan Model Arsitektur 2-2-1 *Backpropagation*

Berdasarkan Gambar 1 dapat dilihat bahwa model jaringan arsitektur 2-2-1 menghasilkan *epoch* sebesar 789 iterasi dalam waktu 00:16 detik.



Gambar 2. Best Training Performance Model Arsitektur 2-2-1

Pada Gambar 2. menunjukkan *error goal (MSE)* pada pelatihan ini sebesar 0.0099777 dicapai pada *epoch* yang 789. Semua data yang selesai diolah dapat disimpulkan kembali agar mendapat model arsitektur terbaik. Pada penelitian ini terdapat tiga model arsitektur yaitu 2-2-1, 2-3-1, 2-4-1, 2-5-1, 2-7-1 dapat dilihat pada table berikut :

Tabel 4. Model Arsitektur *Backpropagation*

No	Arsitektur	Traning			Testing	
		Epoch	Waktu	MSE	MSE	Akurasi
1	02/02/2001	789	00:16	0,0002085	0,0002085	94
2	02/03/2001	460	00:09	0,0050641	0,0050641	85
3	02/04/2001	544	00:14	0,0071905	0,0071905	61
4	02/05/2001	734	00:13	0,0048128	0,0048128	85
5	02/07/2001	459	00:10	0,0029904	0,0008466	88

Pada tahapan ini akan dilakukan pengamatan terhadap laju pembelajaran kinerja jaringan dengan parameter tingkat akurasi, waktu pembelajaran, MSE selama proses pelatihan dan lamanya waktu iterasi (*Epoch*). Dengan memakai arsitektur jaringan terbaik pada pelatihan, maka akan diamati laju pembelajaran terhadap kinerja jaringan. Berdasarkan Tabel 4.10. diatas dapat disimpulkan bahwa dalam melakukan proses prediksi jumlah pertumbuhan kendaraan dengan menerapkan algoritma *backpropagation* yang menggunakan lima (5) model arsitektur. Dari kelima model arsitektur tersebut diperoleh satu (1) model terbaik yaitu 2-2-1 dengan tingkat keakurasian 94 % dengan epoch 789 iterasi dalam waktu 00.16 detik. Berikut ini adalah hasil dari arsitektur terbaik :

Tabel 5. Hasil Arsitektur *Backpropagation* Terbaik

Data Training-Testing					
Pola	Target	Output JST	Error	SSE	Hasil
1	0,9000	0,3329	0,5671	0,3216	0
2	0,2491	0,2508	-0,0017	0,0000	1
3	0,1591	0,1671	-0,0080	0,0001	1
4	0,1364	0,1462	-0,0098	0,0001	1
5	0,1771	0,1783	-0,0011	0,0000	1
6	0,1559	0,1615	-0,0056	0,0000	1
7	0,1353	0,1463	-0,0110	0,0001	1
8	0,1132	0,1304	-0,0173	0,0003	1
9	0,1822	0,1884	-0,0063	0,0000	1
10	0,1453	0,1561	-0,0108	0,0001	1
11	0,1119	0,1313	-0,0194	0,0004	1
12	0,1283	0,1419	-0,0136	0,0002	1
13	0,1350	0,1460	-0,0110	0,0001	1
14	0,1188	0,1349	-0,0162	0,0003	1
15	0,1212	0,1378	-0,0166	0,0003	1
16	0,1219	0,1347	-0,0129	0,0002	1
17	0,1239	0,1380	-0,0141	0,0002	1
18	0,1220	0,1365	-0,0144	0,0002	1
19	0,1132	0,1294	-0,0162	0,0003	1
20	0,1157	0,1303	-0,0146	0,0002	1
21	0,1250	0,1362	-0,0112	0,0001	1
22	0,1238	0,1344	-0,0106	0,0001	1
23	0,1024	0,1241	-0,0217	0,0005	1
24	0,1272	0,1379	-0,0108	0,0001	1
25	0,1014	0,1235	-0,0221	0,0005	1
26	0,1036	0,1246	-0,0210	0,0004	1
27	0,1180	0,1295	-0,0115	0,0001	1
28	0,1108	0,1281	-0,0173	0,0003	1
29	0,1059	0,1256	-0,0198	0,0004	1
30	0,1054	0,1253	-0,0200	0,0004	1
31	0,1084	0,1267	-0,0184	0,0003	1
32	0,100368	0,1230	-0,0227	0,0005	1
33	0,14225	0,1466	-0,0043	0,0000	1
Total				0,0069	94
MSE				0,0002085	

Dalam melakukan proses prediksi terhadap jumlah pertumbuhan kendaraan ditahun yang akan datang maka akan dilakukan pengolahan data dengan melakukan pengujian data secara komputerisasi. Proses yang dilakukan sama dengan melakukan pelatihan terhadap data awal, namun dalam proses prediksi pengujian data yang dilakukan pada *software Matlab R2011b* menggunakan model arsitektur terbaik untuk mengetahui seberapa besar keakuratan suatu model

arsitektur terbaik yang diperoleh. Adapun langkah-langkah yang dilakukan dalam melakukan proses prediksi, yaitu sebagai berikut :

- Melakukan perhitungan secara komputerisasi terhadap data *input* (data awal) dengan variabel yang berbeda dengan pelatihan sebelumnya.
- Melihat hasil keluaran data target prediksi dengan menggunakan *software Matlab R2011b* dengan menentukan parameter-parameter yang sudah ditentukan.
- Setelah hasil keluaran data target prediksi diperoleh, langkah selanjutnya yaitu mencari hasil dari hasil prediksi sebagai hasil jumlah pertumbuhan kendaraan ditahun yang akan datang dengan menggunakan persamaan sebagai berikut.

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

Keterangan : a : data minimum

b : data maksimum

Adapun hasil prediksi terhadap jumlah pertumbuhan kendaraan untuk tahun 2020 dapat dilihat pada table 6. berikut :

Tabel 6. Prediksi Jumlah Pertumbuhan Kendaraan 2020

No	Data Real (2019)	Target	Target Prediksi	Prediksi
1	223135	0,9000	0,3329	287966
2	52240	0,2864	0,2508	265103
3	19694	0,1695	0,1671	241808
4	11028	0,1384	0,1462	235995
5	25407	0,1900	0,1783	244923
6	17669	0,1622	0,1615	240244
7	11760	0,1410	0,1463	236024
8	4575	0,1152	0,1304	231605
9	22750	0,1805	0,1884	247751
10	13796	0,1483	0,1561	238753
11	4718	0,1157	0,1313	231855
12	7621	0,1261	0,1419	234800
13	10732	0,1373	0,1460	235939
14	5770	0,1195	0,1349	232857
15	6801	0,1232	0,1378	233665
16	7512	0,1258	0,1347	232798
17	6522	0,1222	0,1380	233711
18	5813	0,1197	0,1365	233290
19	4121	0,1136	0,1294	231309
20	4812	0,1161	0,1303	231582
21	7012	0,1240	0,1362	233208
22	6621	0,1226	0,1344	232704
23	655	0,1011	0,1241	229848
24	7905	0,1272	0,1379	233698
25	548	0,1008	0,1235	229682
26	978	0,1023	0,1246	229976
27	5890	0,1199	0,1295	231336
28	3849	0,1126	0,1281	230964
29	2134	0,1064	0,1256	230274
30	2311	0,1071	0,1253	230189
31	2622	0,1082	0,1267	230575
32	429	0,1003	0,1230	229549
33	11368	0,1396	0,1466	236095

Adapun penjelasan dari tabel diatas yaitu :

- Data Real diperoleh dari data asli tahun terakhir
- Data Target diperoleh dari data *testing* yang sudah di normalisasi
- Data Target Prediksi diperoleh dari hasil pengujian menggunakan *Software Matlab R201b*, adapun parameter pencarian data target prediksi sebagai berikut :

1) `>>net=newff(minmax(PP),[2,1],{'tansig','logsig'},'traingd');`

2) `>> net=IW{1,1};`

3) `>> net.b{1};`

4) `>> net.LW{2,1};`

- 5) `>> net.b{2};`
- 6) `>> net.trainParam.epochs=100000;`
- 7) `>> net.trainParam.goal=0.001;`
- 8) `>> net.trainParam.Lr=0.01;`
- 9) `>> net.trainParam.show=1000;`
- 10) `>> net=train(net,PP,TT)`

Setelah proses pengujian selesai, selanjutnya untuk mendapatkan hasil target prediksi digunakan rumus :

$$[a,Pf,Af,e,Perf]=sim(net,PP,[],[],TT)$$

3.3. Prediksi Tahun 2021 Menggunakan Arsitektur 2-2-1

Dalam melakukan pengujian data untuk memperoleh hasil prediksi yang diinginkan menggunakan model arsitektur 2-2-1 terbaik yang diperoleh melalui langkah yang sudah dilakukan penulis menggunakan *software Matlab R2011b*. Adapun hasil prediksi terhadap jumlah pertumbuhan kendaraan untuk tahun 2021 dapat dilihat pada Tabel 7. berikut.

Tabel 7. Prediksi Jumlah Pertumbuhan Kendaraan 2021

No	Data Real (2020)	Target	Target Prediksi	Prediksi
1	287966	0,9000	0,3329	246554
2	265103	0,8364	0,2508	240557
3	241808	0,7717	0,1671	234447
4	235995	0,7555	0,1462	232922
5	244923	0,7803	0,1783	235264
6	240244	0,7673	0,1615	234036
7	236024	0,7556	0,1463	232929
8	231605	0,7433	0,1304	231770
9	247751	0,7882	0,1884	236005
10	238753	0,7632	0,1561	233645
11	231855	0,7440	0,1313	231836
12	234800	0,7522	0,1419	232608
13	235939	0,7553	0,1460	232907
14	232857	0,7468	0,1349	232099
15	233665	0,7490	0,1378	232311
16	232798	0,7466	0,1347	232083
17	233711	0,7491	0,1380	232323
18	233290	0,7480	0,1365	232212
19	231309	0,7425	0,1294	231693
20	231582	0,7432	0,1303	231764
21	233208	0,7477	0,1362	232191
22	232704	0,7463	0,1344	232059
23	229848	0,7384	0,1241	231310
24	233698	0,7491	0,1379	232319
25	229682	0,7379	0,1235	231266
26	229976	0,7388	0,1246	231343
27	231336	0,7425	0,1295	231700
28	230964	0,7415	0,1281	231602
29	230274	0,7396	0,1256	231421
30	230189	0,7393	0,1253	231399
31	230575	0,7404	0,1267	231500
32	229549	0,7376	0,1230	231231
33	236095	0,7558	0,1466	232948

Adapun penjelasan dari tabel diatas yaitu :

- 1) Data Real diperoleh dari data asli tahun terakhir
- 2) Data Target diperoleh dari data *testing* yang sudah di normalisasi
- 3) Target Prediksi diperoleh dari hasil pengujian menggunakan *Software Matlab R2011b*.

3.4. Perbandingan Data Awal dengan Hasil Prediksi

Berikut merupakan perbandingan jumlah pertumbuhan kendaraan tahun 2017-2019 dengan jumlah penjualan kelapa sawit hasil prediksi menggunakan jaringan saraf tiruan metode backpropagation untuk tahun 2020. Dari hasil rekap data dapat diketahui bahwa jumlah penjualan tahun 2020 dengan tahun 2021 ada yang akan mengalami peningkatan dan ada juga yang mengalami penurunan. Secara rinci dapat dilihat dari tabel 8. berikut.

Tabel 8. Data Jumlah Pertumbuhan Kendaraan (2017-2021)

No	UPT	Tahun				
		2017	2018	2019	2020	2021
1	Medan Utara	96584	163352	223135	287966	246554
2	Medan Selatan	29884	30652	52240	265103	240557
3	Lubuk Pakam	13904	12304	19694	241808	234447
4	Tebing Tinggi	8486	7678	11028	235995	232922
5	Pematang Sianta	14987	15988	25407	244923	235264
6	Binjai	12029	11658	17669	240244	234036
7	Stabat	8792	7464	11760	236024	232929
8	Tanjung Balai	3542	2950	4575	231605	231770
9	Kisaran	18037	17012	22750	247751	236005
10	Rantau Prapat	11701	9500	13796	238753	233645
11	Lima Puluh	4594	2696	4718	231855	231836
12	Perdagangan	7812	6040	7621	234800	232608
13	Sei Rampah	8674	7396	10732	235939	232907
14	Aek Kanopan	5535	4088	5770	232857	232099
15	Kota Pinang	6936	4596	6801	233665	232311
16	Kabanjahe	4613	4719	7512	232798	232083
17	Pangkalan Brandan	6372	5127	6522	233711	232323
18	Sibolga	5796	4759	5813	233290	232212
19	Sidikalang	2687	2949	4121	231309	231693
20	Tarutung	2818	3466	4812	231582	231764
21	Padang Sidempuan	4878	5353	7012	233208	232191
22	Panyabungan	3922	5107	6621	232704	232059
23	Sibuhuan	818	749	655	229848	231310
24	Gunung Sitoli	5561	5802	7905	233698	232319
25	Gunung Tua	476	549	548	229682	231266
26	Natal	919	995	978	229976	231343
27	Pandan	1544	3935	5890	231336	231700
28	Balige	2254	2473	3849	230964	231602
29	Teluk Dalam	1333	1463	2134	230274	231421
30	Pangururan	1172	1355	2311	230189	231399
31	Dolok Sanggul	1669	1971	2622	230575	231500
32	Salak	264	339	429	229549	231231
33	Sipirok	7390	8877	11368	236095	232948

4. KESIMPULAN

Dari uraian pada bab sebelumnya, maka penulis mengambil beberapa kesimpulan yaitu, penggunaan metode *backpropagation* dapat digunakan dalam memprediksi jumlah pertumbuhan kendaraan di Sumatera Utara. Hasil uji coba yang dilakukan dengan *software MATLAB R2011b* model arsitektur terbaiknya adalah model 2-2-1 dengan tingkat akurasi 94% dengan jumlah MSE 0.000208514, nilai *epoch* 789. Dapat disimpulkan bahwa metode *Backpropagation* dapat di jadikan salah satu metode prediksi yang memudahkan dalam mencari prediksi apapun

REFERENCES

- [1] M. C. Amin, "Faktor- Faktor Yang Mempengaruhi Pertumbuhan Kendaraan Bermotor Roda Dua Di Kota Pekanbaru," pp. 1106–1120, 2017.
- [2] G. Guntoro, L. Costaner, and L. Lisnawita, "Prediksi Jumlah Kendaraan di Provinsi Riau Menggunakan Metode Backpropagation," *Inform. Mulawarman J. Ilm. Ilmu Komput.*, vol. 14, no. 1, p. 50, 2019.
- [3] M. Andrijasa *et al.*, "Penerapan Jaringan Syaraf Tiruan Untuk Memprediksi Jumlah Pengangguran di Provinsi Kalimantan Timur Dengan Menggunakan Algoritma Pembelajaran Backpropagation," *J. Inform. Mulawarman*, vol. 5, no. 1, 2010.
- [4] Husni, "Kecerdasan Buatan," 2012.
- [5] C. Oktaviani and Afdal, "Prediksi Curah Hujan Bulanan Menggunakan Jaringan Syaraf Tiruan Dengan Beberapa Fungsi Pelatihan Backpropagation," *J. Fis. Unand*, vol. 2, no. 4, pp. 228–237, 2013.
- [6] F. Tempola and S. Do Abdullah, "Case-Based Reasoning (CBR) untuk Penentuan Kelayakan Mahasiswa Penerima Beasiswa," vol. 5, no. 2, pp. 1–5, 2018.
- [7] C. Iswahyudi and E. Sutanta, "USE CASE DIAGRAM," 2018.
- [8] A. Paramitha, S. Kom, and M. Kom, "(Activity Diagram)," 2018.
- [9] B. Hardian, M. Sulistyani, and R. Rafian, "Diagram sequence uml," no. 51412367, pp. 1–11, 2014.
- [10] P. D. Liksha, "Aplikasi Akuntansi Pengolahan Data Jasa Service," vol. 1, no. 1, pp. 1–14, 2018.
- [11] R. Nurmalina, "Perencanaan dan Pengembangan Aplikasi Absensi Mahasiswa Menggunakan Smart Card Guna

- Pengembangan Kampus Cerdas (Studi Kasus Politeknik Negeri Tanah Laut),” vol. 9, no. 1, pp. 84–91, 2017.
- [12] A. MS and M. H. Baysha, “Pengaruh Media Pembelajaran Matrix Laboratory (Matlab) Terhadap Hasil Belajar Siswa,” vol. 3, pp. 10–20, 2018.
- [13] A. Fitriana, “Pengembangan Kapasitas (Capacity Building) Dosen Lektor Kepala Dalam Rangka Meningkatkan Kinerja Dosen Pada Fakultas Teknik Universitas Gadjah Mada Universitas Pendidikan Indonesia | repository.upi.edu | perpustakaan.upi.edu,” 2016.
- [14] Ismail, “Penyakit Anemia Dengan Metode Forward Chaining Berbasis Android,” *Repositori.Uin-alauddin.ac.id*, pp. 1–12, 2017.