



Analisis Optimasi Fungsi Pelatihan Machine Learning Neural Network dalam Peramalan Kemiskinan

Sahat Sonang S^{*1}, Sarjon Defit^{#2}, Mukhlis Ramadhan^{#3}

**Politeknik Bisnis Indonesia Pematangsiantar, Indonesia*

Jl. Sriwijaya, Melayu, Kec. Siantar Utara, Kota Pematang Siantar, Sumatera Utara 21146

¹sahatsonangstg@gmail.com

#Department of Informatics Engineering, Universitas Putra Indonesia YPTK Padang, Indonesia

STMIK TRIGUNA DHARMA Medan, Indonesia

²sarjond@yahoo.co.uk

³mukhlis.ramadhan99@gmail.com

Abstrak— Banyak metode fungsi pelatihan dalam Machine Learning Neural Network yang digunakan dalam menyelesaikan masalah komputasi yang berkaitan dengan prediksi. Fungsi pelatihan yang digunakan pada Machine Learning metoda algoritma backpropagation dapat menghasilkan prediksi yang berbeda, yang dipengaruhi oleh parameter dan data yang digunakan. Tujuan dari penelitian dilakukan untuk menganalisa performance dan keakuratan algoritma backpropagation standard serta mengoptimalkan fungsi pelatihan dengan algoritma Bayesian Regulation, dan One Step Secant. Dalam proses analisis, penelitian ini menggunakan Dataset jumlah kemiskinan di Indonesia dalam jangka waktu 12 tahun (tahun 2009 - 2020) yang terdiri dari 34 provinsi. Data diperoleh dari website Badan Pusat Statistik (BPS) Indonesia <https://www.bps.go.id/>. Berdasarkan pelatihan, pengujian, dan analisa yang dilakukan diperoleh hasil dari penelitian, bahwa model jaringan 5-9-1 menggunakan fungsi pelatihan Bayesian Regulation mampu melakukan optimasi yang lebih baik dengan percepatan waktu pelatihan, MSE Pengujian, *Performance* lebih rendah dibandingkan dengan 2 metode yang lain, dengan demikian disimpulkan bahwa model jaringan 5-9-1 menggunakan algoritma Bayesian Regulation dapat digunakan untuk prediksi kemiskinan di Indonesia.

Kata kunci— Optimasi, Machine Learning, Backpropagation, Bayesian Regulation, One Step Secant, Kemiskinan

Abstract— Many methods of training functions in Machine Learning Neural Networks are used in solving computational problems related to prediction. The training function used in Machine Learning backpropagation algorithm method can produce different predictions, which is influenced by the parameters and data used. The purpose of this research is to analyze the performance and accuracy of the standard backpropagation algorithm and optimize the training function with the Bayesian Regulation algorithm. and One Step Secant. In the analysis process, This study uses a dataset

on the number of poverty in Indonesia for a period of 12 years (2009 - 2020) consisting of 34 provinces. Data obtained from the website Indonesian Statistical Center (BPS) <https://www.bps.go.id/>. Based on the training, testing, and analysis carried out, the results obtained from the research, that the 5-9-1 network model using the Bayesian Regulation training function is able to perform better optimization by accelerating the training time, MSE Testing, Performance is lower than the other 2 methods, thus it is concluded that the 5-9-1 network model using the Bayesian Regulation algorithm can be used to predict poverty in Indonesia.

Keywords— Optimization, Machine Learning, Backpropagation, Bayesian Regulation, One Step Secant, Poverty

I. PENDAHULUAN

Saat ini Machine Learning sangat banyak diperbincangkan dalam perkembangan teknologi informasi secara khusus dalam bidang penelitian yang diterapkan di berbagai bidang seperti teknologi, perbankan, bisnis, kesehatan, dan lainnya [1]. Machine Learning mampu menyelesaikan masalah yang kompleks [2]–[4], seperti menganalisa gambar, menganalisa data times-series, dan melacak objek. [5] Teknik Machine Learning bertujuan agar komputer dapat belajar secara otomatis tanpa adanya campur tangan manusia, [6] serta menyesuaikan tindakan yang tepat. [7] Fokus penelitian Machine Learning tentang bagaimana meningkatkan kinerja sistem pembelajaran otomatis melalui pelatihan-pelatihan atau pengalaman. [8] permasalahan Machine Learning digunakan sebagai pilihan dalam mengoptimalkan cara kerja komputer sesuai dengan data lalu. [9] Penelitian ini membahas teknik Machine Learning dengan metode jaringan syaraf Backpropagation. Metode backpropagation pada Machine Learning banyak dipergunakan dalam pelatihan jaringan syaraf *feedforward*. [10]–[12]

Algoritma Backpropagation memiliki beberapa fungsi, yaitu: fungsi transfer dan fungsi pelatihan dimana setiap fungsi memiliki beberapa tehnik dan cara untuk menyelesaikan permasalahan yang kompleks. fungsi transfer banyak digunakan pada Machine Learning neural network secara khusus algoritma propagasi balik seperti fungsi sigmoid-tangen-hiperbolik (tansig), [13] log-sigmoid (logsig), [14] linear-purelin. [15] Metode Backpropagation standard umumnya menggunakan fungsi pelatihan *gradient descent* yaitu: *traingd*, *trainngdx*, *traingda*, dan *traingdm*. [16] selain itu masih banyak fungsi pelatihan yang digunakan untuk optimasi yang dapat mempengaruhi hasil komputasi, seperti halnya *gradien* konjugasi berskala (*trainscg*), [17] pelatihan urutan acak dengan fungsi pembelajaran (*trainr*), [18] regulasi bayesian (*trainbr*), [19] pelatihan bobot atau bias perintah acak tidak terawasi (*trainru*), [20] Levenberg-Marguardt (*trainlm*), [21], [22] OSS (*trainoss*), [23] pelatihan inkremental berurutan fungsi pembelajaran (*trains*), [24] pelatihan batch bobot atau bias tanpa pengawasan (*trainbu*), [25] pelatihan batch menggunakan aturan pembelajaran bobot dan bias (*trainb*), [26] pelatihan konjugasi gradien (*traingcgp*, *traingcb*, *traingcf*), [27] resilient (*trainrp*), [28] BFGS quasi-newton (*trainbfg*), [29] urutan siklus bobot atau bias (*trainc*), [30] dan BFGS quasi-newton referensi adaptif kontrol (*trainbfgc*). [31] Pemanfaatan fungsi transfer maupun fungsi pelatihan menghasilkan peramalan yang tingkat keakuratan berbeda-beda, yang dipengaruhi oleh parameter atau metode yang diberikan serta data yang akan di uji. [32]–[36] Sesuai dengan hal tersebut, penelitian ini fokus membahas pada penggunaan fungsi pelatihan dalam mengoptimalkan kemampuan algoritma backpropagation standard.

Dalam penyelesaian masalah yang banyak dan kompleks dilakukan pelatihan-pelatihan untuk meningkatkan kinerja yang lebih optimal. S Leloho, et al (2019) dalam penelitian perbandingan kinerja empat fungsi pelatihan: Resilient Backpropagation, Scale Conjugate Gradient, Quasi-Newton, dan Levenberg-Marguardt diterapkan pada pelatihan Jaringan Syaraf Tiruan dalam prediksi rata-rata radiasi matahari. proses perbandingan dilaksanakan dengan mengamati nilai Root Mean Square Error (RMSE), model Koefisien Korelasi (R), dan Mean Absolute Percentage Error (MAPE). Hasil dari penelitian ini diperoleh TRAIN-LM bekerja lebih baik dibandingkan model lainnya dan nilai koefisien korelasi 99,742% MAPE 2,394%. Pengujian, pelatihan, dan validasi yang dilakukan dengan menggunakan data aktual dari database NASA dengan enam lokasi yang berbeda di kota-kota Barat Laut. Hasil dari penelitian ini bermanfaat untuk optimalisasi kinerja jaringan mikro. [37] D. Uwanuakwa and P Akpınar (2020) dalam penelitiannya membahas mengoptimalkan peramalan dalamnya karbon tembok menggunakan algoritma OSS. Pelatihan jaringan yang dibangun dalam makalah ini menggabungkan 10 *hidden layer* yang tidak sama dengan 11 rasio distribusi data. Dimana nilai (R) 0,99 dan persentasi hasil variasi 30-50% yang berarti nilai R meningkat signifikan dari yang diamati 60-80%. [38]

Penelitian selanjutnya dilakukan untuk meramalkan radiasi gelombang panjang teluk benggala menggunakan lima fungsi pelatihan yang berbeda, yaitu: kuasi-Newton Broyden Fletcher Goldfarb Shanno (BFGS), garis potong satu langkah, gradien konjugasi dengan Beale-Powell restart, Levenberg-Marquardt, dan penurunan *gradien*. dalam penelitian menggunakan analisa *performance* (*Root mean square error*, korelasi koefisien, akurasi prediksi) dan analisa parameter untuk mengetahui performansi fungsi pelatihan. berdasarkan hasil penelitian ditemukan bahwa kelima fungsi pelatihan yang dilakukan Levenberg-Marquardt menghasilkan nilai akurasi 99,81% lebih tinggi dari fungsi pelatihan lainnya. [39]

Berdasarkan dari penelitian-penelitian yang dipaparkan, maka penelitian yang diusulkan dalam penelitian ini adalah analisa pemanfaatan fungsi pelatihan Machine Learning neural network backpropagation standard dalam peramalan kemiskinan di Indonesia. Penelitian ini membahas tehnik dan metode fungsi pelatihan yang digunakan dalam menyelesaikan masalah, dataset jumlah kemiskinan yang digunakan hanya membantu pembuktian dan pengujian. Dalam penerapannya Machine Learning dengan metode backpropagation standard pada proses pelatihan sering menghasilkan kecepatan konvergensi yang tidak baik, untuk itu perlu dilakukan kombinasi fungsi pelatihan dalam mempercepat konvergensi pelatihan jaringan, dengan menggunakan metode Bayesian Regulation, dan *One Step Secant* (OSS). Kinerja *Backpropagation standard* dilakukan analisis dan dibandingkan dengan metode *Bayesian Regulation*, dan *One Step Secant*. Hasil dari penelitian ini diharapkan dapat digunakan ataupun rujukan dalam menyelesaikan kasus peramalan kemiskinan di Indonesia, serta dapat membantu pihak akademisi dalam pengembangan studi selanjutnya.

II. METODE

A. Dataset Penelitian

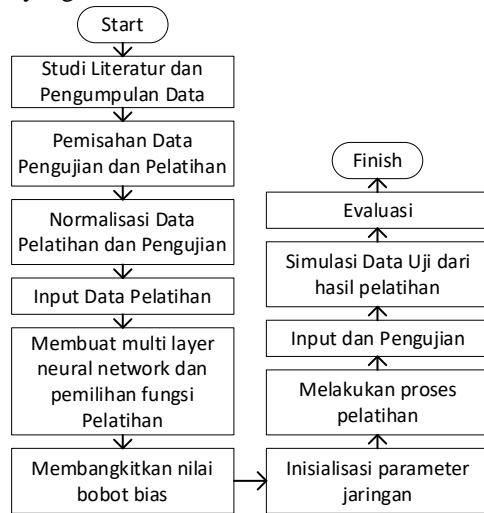
Dalam proses analisis, penelitian ini menggunakan dataset jumlah kemiskinan di Indonesia dalam jangka waktu 12 tahun (tahun 2009 - 2020) yang terdiri dari 34 Provinsi, yaitu: Propinsi Aceh, Provinsi Sumatera Utara, Provinsi Sumatera Barat, Provinsi Riau, Provinsi Jambi, Provinsi Sumatera Selatan, Provinsi Bengkulu, Provinsi Lampung, Provinsi Kepulauan Bangka Belitung, Provinsi Kepulauan Riau, Provinsi DKI Jakarta, Provinsi Jawa Barat, Provinsi Jawa Tengah, Provinsi Di Yogyakarta, Provinsi Jawa Timur, Provinsi Banten, Provinsi Bali, Provinsi Nusa Tenggara Barat, Provinsi Nusa Tenggara Timur, Provinsi Kalimantan Barat, Provinsi Kalimantan Tengah, Provinsi Kalimantan Selatan, Provinsi Kalimantan Timur, Provinsi Kalimantan Utara, Propinsi Sulawesi Utara, Provinsi Sulawesi Tengah, Provinsi Sulawesi Tenggara, Provinsi Gorontalo, Provinsi Sulawesi Barat, Provinsi Maluku, Provinsi Maluku Utara, Provinsi Papua Barat, Provinsi Papua. Data diperoleh dari website Badan Pusat Statistik (BPS) Indonesia <https://www.bps.go.id/>.

TABEL I
JUMLAH PENDUDUK MISKIN DI INDONESIA (TAHUN 2009-2020)

No	Provinsi	Tahun			
		2009	2010	2020
1	Aceh	892,86	861,85	833,91
2	Sumatera Utara	1499,68	1490,89	1356,72
3	Sumatera Barat	429,25	430,02	364,79
4	Riau	527,49	500,26	491,22
5	Jambi	249,69	241,61	288,1
6	Sumatera Selatan	1167,87	1125,73	1119,65
7	Bengkulu	324,13	324,93	306
8	Lampung	1558,28	1479,93	1091,14
9	Kep. Bangka Belitung	76,63	67,75	72,05
10	Kep. Riau	128,21	129,66	142,61
11	Dki Jakarta	323,17	312,18	496,84
12	Jawa Barat	4983,57	4773,72	4188,52
13	Jawa Tengah	5725,69	5369,16	4119,93
14	Di Yogyakarta	585,78	577,3	503,14
...
34	Papua	760,35	761,62	912,23
Jumlah		32571,31	31064,43	27549,7

B. Tahapan Riset

Dalam menyelesaikan riset pada Gambar 1 ditampilkan alur riset yang akan dilakukan.



Gambar. 1 Tahapan penyelesaian penelitian

Sesuai dengan Gambar. 1 di atas bahwa langkah pertama yang dilakukan pada penelitian ini adalah melaksanakan studi literatur dari Jurnal, Proceeding, dan buku-buku yang selanjutnya mengumpulkan dataset penelitian (Tabel 1). tahapan berikutnya melakukan pemisahan dataset menjadi 2 bagian, yaitu: data pelatihan, dan data pengujian. Data pelatihan yang digunakan data jumlah kemiskinan tahun 2009-2013 (X1-X5) dengan target tahun 2014 (Y1). Data pengujian tahun 2015-2019 (X6-X10) dengan target Y2 (tahun 2020). langkah berikutnya melaksanakan proses menormalkan dataset pelatihan dan data pengujian menggunakan rumus (1) [40].

$$x' = \frac{0.8(x-a)}{b-a} + 0.1 \tag{1}$$

Dimana: x' merupakan hasil data yang sudah dinormalisasi, 0.8 dan 0.1 nilai ketetapan. x = data yang akan dinormalkan, a = nilai terkecil dari dataset, b = nilai terbesar dari dataset. Data pelatihan yang sudah dinormalkan di input kedalam software Matlab R2021a untuk diolah dengan membangun jaringan syaraf multi layer. Arsitektur yang akan digunakan dalam pelatihan dan pengujian pada riset ini 5-8-1 (input 5, hidden layer 8, output 1), 5-9-1 (input 5, hidden layer 9, output 1), dan 5-11-1 (input 5, hidden layer 11, output 1). Dalam membangun arsitektur jaringan syaraf, hidden layer menggunakan fungsi transfer_logsig (sigmoid_biner), output_layer menggunakan fungsi_linear (purelin). Pada tahap ini akan dipilih fungsi pelatihan dari data yang dilatih bergantian menggunakan fungsi pelatihan traingd pada propogasi balik standar selanjutnya dilakukan optimasi dengan OSS (trainoss) dan Baysian Regulations (trainbr). Berikutnya membangkitkan nilai bobot (IW, LW) dan bias (b). Tahap berikutnya melakukan inisialisasi nilai parameter jaringan sesuai dengan fungsi pelatihan yang dipakai. Selanjutnya memasukkan script dalam melaksanakan proses pelatihan serta melihat nilai performances. Setelah pelatihan selesai dilaksanakan, selanjutnya memasukkan data pengujian yang dinormalisasi untuk melakukan proses simulasi data uji sesuai dengan hasil pelatihan. Jika semua tahapan sudah dilaksanakan, maka dilanjutkan dengan proses evaluasi untuk melihat kinerja dan kemampuan metode fungsi pelatihan yang terbaik.

C. Parameter Fungsi Pelatihan

Parameter fungsi pelatihan yang digunakan dalam penelitian ini akan diolah dan diproses dengan menggunakan aplikasi Matlab R2021a.

III. HASIL DAN PEMBAHASAN

A. Normalisasi Data

Data jumlah kemiskinan di negara Indonesia (Tabel 1), dinormalkan menggunakan rumus (1) dan selanjutnya dibuat 2 kelompok, yakni dataset pelatihan, dan dataset pengujian. Dataset pelatihan diambil dari dataset jumlah kemiskinan di Indonesia dari tahun 2009-2013 (X1-X5) dan target tahun 2014 (Y1) (lihat Tabel 2).

TABEL II
NORMALISASI DATA PELATIHAN

No	X1	X2	X3	X4	X5	Y1
1	0,1072	0,1070	0,1072	0,1071	0,1069	0,1068
2	0,1124	0,1123	0,1122	0,1113	0,1114	0,1112
3	0,1033	0,1033	0,1034	0,1030	0,1029	0,1027
4	0,1041	0,1039	0,1037	0,1037	0,1041	0,1039
5	0,1018	0,1017	0,1020	0,1019	0,1020	0,1020
6	0,1096	0,1092	0,1088	0,1085	0,1090	0,1089
7	0,1024	0,1024	0,1022	0,1023	0,1024	0,1023
8	0,1129	0,1122	0,1107	0,1100	0,1093	0,1093
9	0,1003	0,1002	0,1003	0,1003	0,1003	0,1002

No	X1	X2	X3	X4	X5	Y1
10	0,1007	0,1008	0,1008	0,1008	0,1007	0,1007
11	0,1024	0,1023	0,1027	0,1028	0,1028	0,1032
12	0,1419	0,1401	0,1390	0,1371	0,1368	0,1356
13	0,1482	0,1451	0,1429	0,1409	0,1395	0,1383
14	0,1046	0,1045	0,1044	0,1044	0,1042	0,1042
15	0,1507	0,1465	0,1450	0,1417	0,1409	0,1399
16	0,1063	0,1061	0,1055	0,1051	0,1054	0,1052
17	0,1012	0,1011	0,1011	0,1010	0,1012	0,1013
18	0,1086	0,1082	0,1072	0,1067	0,1065	0,1066
19	0,1082	0,1082	0,1082	0,1081	0,1082	0,1081
20	0,1033	0,1033	0,1029	0,1027	0,1030	0,1029
...
34	0,1061	0,1061	0,9000	0,1079	0,1086	0,1070

Data pengujian diambil dari dataset jumlah kemiskinan di Indonesia dari tahun 2015-2019 (X6-X10) dan target tahun 2020 (Y2).

TABEL III
NORMALISASI DATA PENGUJIAN

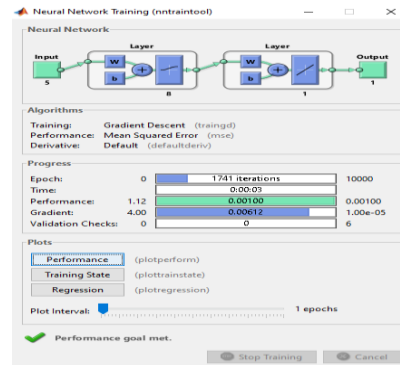
No	X6	X7	X8	X9	X10	Y2
1	0,1069	0,1068	0,1067	0,1067	0,1065	0,1067
2	0,1124	0,1120	0,1109	0,1106	0,1103	0,1112
3	0,1026	0,1028	0,1027	0,1026	0,1026	0,1027
4	0,1044	0,1039	0,1039	0,1038	0,1038	0,1038
5	0,1023	0,1021	0,1020	0,1020	0,1020	0,1021
6	0,1091	0,1089	0,1089	0,1088	0,1087	0,1091
7	0,1024	0,1024	0,1022	0,1022	0,1022	0,1022
8	0,1090	0,1093	0,1088	0,1089	0,1085	0,1089
9	0,1002	0,1003	0,1003	0,1002	0,1002	0,1003
10	0,1006	0,1007	0,1007	0,1007	0,1007	0,1009
11	0,1028	0,1029	0,1030	0,1028	0,1027	0,1039
12	0,1377	0,1350	0,1316	0,1296	0,1283	0,1351
13	0,1378	0,1377	0,1352	0,1324	0,1308	0,1346
14	0,1038	0,1038	0,1036	0,1035	0,1034	0,1039
15	0,1401	0,1390	0,1370	0,1360	0,1340	0,1385
16	0,1055	0,1052	0,1056	0,1053	0,1051	0,1069
17	0,1015	0,1011	0,1012	0,1011	0,1010	0,1013
18	0,1065	0,1063	0,1060	0,1059	0,1056	0,1060
19	0,1095	0,1094	0,1093	0,1093	0,1092	0,1096
20	0,1031	0,1030	0,1030	0,1028	0,1028	0,1028
...
34	0,1073	0,1074	0,1074	0,1074	0,1073	0,1074

B. Hasil Pelatihan dan Pengujian

Simalasi dan testing dilaksanakan dengan Aplikasi Matlab R2021a dengan 3 model jaringan, yaitu: 5-8-1 (input 5, hidden layer 8, output 1), 5-9-1 (input 5, hidden layer 9, output 1), dan 5-11-1 (input 5, hidden layer 11, output 1).

1. Pelatihan dan pengujian dengan Metode Backpropagation Standard.

Model Arsitektur Jaringan 5-8-1



Gambar. 2 Pelatihan model 5-8-1 (traingd)
Hasil dari pelatihan dengan fungsi training model 5-8-1, epoch = 1741 iterasi, waktu latih = 3 detik.

TABEL IV
HASIL PELATIHAN MODEL 5-8-1

Target (Y2)	Epoch 1741			Performance
	Actual	Error	SSE	
0,1067	0,097795	-0,00893	7,97E-05	0,002287423
0,1112	0,088621	-0,02253	0,000508	
0,1027	0,100149	-0,0026	6,76E-06	
0,1038	0,099622	-0,0042	1,76E-05	
0,1021	0,100342	-0,00176	3,08E-06	
0,1091	0,09511	-0,01403	0,000197	
0,1022	0,100266	-0,00198	3,93E-06	
0,1089	0,094975	-0,01393	0,000194	
0,1003	0,100818	0,00055	3,02E-07	
0,1009	0,100726	-0,00014	1,95E-08	
0,1039	0,100111	-0,00376	1,41E-05	
0,1351	-0,07752	-0,21265	0,045222	
0,1346	-0,01687	-0,15143	2,29E-02	
0,1039	0,099752	-0,00417	1,74E-05	
0,1385	0,048973	-0,08953	8,02E-03	
0,1069	0,098972	-0,00795	6,32E-05	
0,1013	0,100601	-0,00072	5,25E-07	
0,106	0,098261	-0,00772	5,95E-05	
0,1096	0,094316	-0,01528	0,000234	
0,1028	0,100051	-0,00275	7,54E-06	
....	
0,1074	0,097204	-0,01018	0,000104	
		Total SSE	0,077772	
		MSE	0,002287	

TABEL V
HASIL PENGUJIAN MODEL 5-8-1

Target (Y2)	Epoch 1			Performance
	Actual	Error	SSE	
0,1067	0,124409	0,017687	0,000313	0,001574989
0,1112	0,125456	0,014306	0,000205	
0,1027	0,126966	0,024218	0,000587	
0,1038	0,126576	0,022757	0,000518	
0,1021	0,126952	0,024854	0,000618	
0,1091	0,126793	0,01765	0,000312	
0,1022	0,123906	0,021656	0,000469	
0,1089	0,12666	0,017759	0,000315	
0,1003	0,070645	-0,02962	0,000877	
0,1009	-0,06862	-0,16948	0,028724	
0,1039	0,018405	-0,08546	0,007304	
0,1351	0,097492	-0,03765	0,001417	

Target (Y2)	Epoch 1			
	Actual	Error	SSE	Performance
0,1346	0,126965	-0,00759	5,77E+09	
0,1039	0,126623	0,022704	0,000515	
0,1385	0,129349	-0,00916	8,39E+09	
0,1069	0,126539	0,019616	0,000385	
0,1013	0,126568	0,025242	0,000637	
0,106	0,126602	0,020624	0,000425	
0,1096	0,126361	0,016762	0,000281	
0,1028	0,126621	0,023823	0,000568	
....	
0,1074	0,127993	0,020608	0,000425	
		Total SSE	0,05355	
		MSE	0,001575	

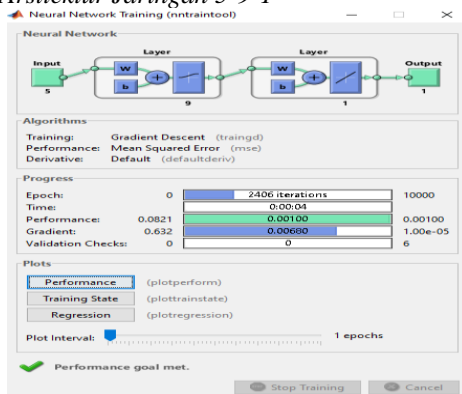
Target (Y1)	Epoch 2406			
	Actual	Error	SSE	Performance
0,1002	0,122885	0,022658	5,13E-04	
0,1007	0,119506	1,88E-02	3,53E-04	
0,1032	0,10376	0,000606	3,67E-07	
0,1356	0,18019	0,044624	0,001991	
0,1383	0,177354	0,039053	1,53E-03	
0,1042	0,090616	-0,01355	1,84E-04	
0,1399	0,183445	0,043563	1,90E-03	
0,1052	0,097172	-0,00798	6,38E-05	
0,1013	0,123248	0,021931	4,81E-04	
0,1066	0,081615	-0,02496	0,000623	
0,1081	0,054485	-0,05358	0,00287	
0,1029	0,118188	0,015295	2,34E-04	
....	
0,107	0,02815	-0,07883	0,006214	
		Total SSE	0,033989	
		MSE	0,001	

Gambar 2, Tabel 4, dan Tabel 5 merupakan hasil pelatihan dan pengujian parameter backpropagation standar yang dilakukan dengan Matlab, selanjutnya membandingkan hasil pelatihan dan pengujian dengan menggunakan Ms. Excel. Nilai Actual dihasilkan dari output hasil pelatihan dan pengujian. Value Errors dihasilkan berdasarkan kalkulasi targer (Y) Actual. value SSE dihasilkan dari perkiraan Errors kuadrat. Value total SSE dihasilkan berdasarkan pertambahan value SSE. Value MSE/Performances (Pref) dihasilkan dari jumlah SSE/34 dimana 34 merupakan jumlah baris data. Berdasarkan dari hasil pelatihan dan pengujian Matlab dan Ms. Excel hasilnya sesuai (valid).

TABEL VII
HASIL PENGUJIAN MODEL 5-9-1

Target (Y2)	Epoch 1				Performance
	Actual	Error	SSE	Performance	
0,1067	0,066788	-0,03993	1,59E-03	0,000922011	
0,1112	0,045302	-0,06585	0,004336		
0,1027	0,108341	0,005593	3,13E-05		
0,1038	0,098064	-0,00575	3,31E-05		
0,1021	0,112937	0,010839	1,17E-04		
0,1091	0,04702	-0,06212	0,003859		
0,1022	0,112449	0,010199	1,04E-04		
0,1089	0,044187	-0,06471	0,004188		
0,1003	0,122517	0,022249	4,95E-04		
0,1009	0,120228	0,019362	3,75E-04		
0,1039	0,106477	0,00261	6,81E-06		
0,1351	0,168881	0,033742	0,001139		
0,1346	0,172644	0,038086	1,45E-03		
0,1039	0,103181	-0,00074	5,45E-07		
0,1385	0,162449	0,023943	5,73E-04		
0,1069	0,079613	-0,02731	7,46E-04		
0,1013	0,119067	0,017742	3,15E-04		
0,106	0,078015	-0,02796	7,82E-04		
0,1096	0,042301	-0,0673	0,004529		
0,1028	0,108999	0,006201	3,85E-05		
....		
0,1074	0,058753	-0,04863	0,002365		
		Total SSE	0,031348		
		MSE	0,000922		

Model Arsitektur Jaringan 5-9-1



Gambar. 3 Pelatihan model 5-9-1 (traingd)

Hasil dari pelatihan dengan fungsi traingd model 5-9-1, epoch = 2406 iterasi, waktu latih = 4 detik.

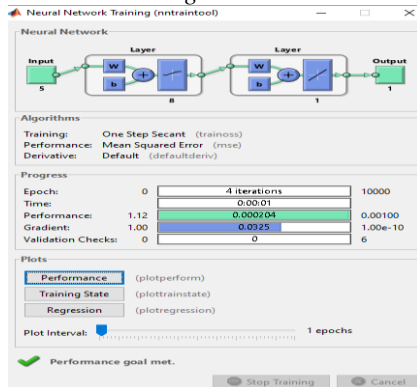
TABEL VI
HASIL PELATIHAN MODEL 5-9-1

Target (Y1)	Epoch 2406			
	Actual	Error	SSE	Performance
0,1068	0,06095	-0,0458	2,10E-03	0,000999688
0,1112	0,037115	-0,07407	0,005486	
0,1027	0,1058	0,003138	9,84E-06	
0,1039	0,104913	0,001035	1,07E-06	
0,102	0,112256	0,010212	1,04E-04	
0,1089	0,061878	-0,04698	0,002207	
0,1023	0,113065	0,010726	1,15E-04	
0,1093	0,058526	-0,05082	0,002583	

Gambar 3, Tabel 6, dan Tabel 7 merupakan hasil pelatihan dan pengujian parameter backpropagation standar yang dilakukan dengan Matlab, selanjutnya membandingkan hasil pelatihan dan pengujian dengan menggunakan Ms. Excel. Nilai Actual dihasilkan dari output hasil pelatihan dan pengujian. Value Errors dihasilkan berdasarkan kalkulasi targer (Y) Actual. value SSE dihasilkan dari perkiraan Errors kuadrat. Value total SSE dihasilkan berdasarkan pertambahan value SSE. Value MSE/Performances (Pref) dihasilkan dari jumlah SSE/34 dimana 34 merupakan jumlah baris data. Berdasarkan dari hasil pelatihan dan pengujian Matlab dan Ms. Excel hasilnya sesuai (valid).

2. Pelatihan dan pengujian dengan Metode One Step Secant (OSS).

Model Arsitektur Jaringan 5-8-1



Gambar. 4 Pelatihan model 5-8-1 (trainoss)

Hasil dari pelatihan dengan fungsi trainoss model 5-8-1, epoch= 4 iterasi, waktu latih = 1 detik.

TABEL VIII
HASIL PELATIHAN MODEL 5-8-1

Target (Y1)	Epoch 4			
	Actual	Error	SSE	Performance
0,1068	0,110138	0,003387	1,15E-05	0,000204221
0,1112	0,100029	-0,01115	1,24E-04	
0,1027	0,112413	0,009751	9,51E-05	
0,1039	0,112073	0,008194	6,71E-05	
0,102	0,112816	0,010772	1,16E-04	
0,1089	0,10723	-0,00163	2,64E-06	
0,1023	0,112656	0,010318	1,06E-04	
0,1093	0,102127	-0,00722	5,21E-05	
0,1002	0,113138	0,012911	1,67E-04	
0,1007	0,113052	1,23E-02	1,52E-04	
0,1032	0,11264	0,009486	9,00E-05	
0,1356	0,10321	-0,03236	1,05E-03	
0,1383	0,154814	0,016513	2,73E-04	
0,1042	0,111885	7,72E-03	5,95E-05	
0,1399	0,158936	0,019054	3,63E-04	
0,1052	0,110968	0,005811	3,38E-05	
0,1013	0,112956	0,011638	1,35E-04	
0,1066	0,109319	0,002744	7,53E-06	
0,1081	0,108752	0,000692	4,79E-07	
0,1029	0,112379	0,009486	9,00E-05	
....	
0,107	0,155583	0,048606	2,36E-03	
		Total SSE	0,006944	
		MSE	2,04E-04	

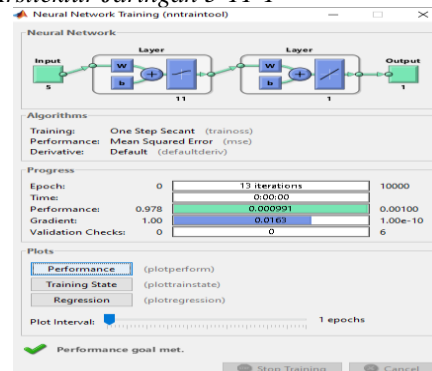
TABEL IX
HASIL PENGUJIAN MODEL 5-8-1

Target (Y2)	Epoch 1			
	Actual	Error	SSE	Performance
0,1067	0,110375	0,003653	1,33E-05	0,002448018
0,1112	0,101697	-0,00945	8,94E-05	
0,1027	0,112569	0,009821	9,65E-05	
0,1038	0,112091	0,008272	6,84E-05	
0,1021	0,112734	0,010636	1,13E-04	
0,1091	0,107795	-0,00135	1,82E-06	

Target (Y2)	Epoch 1			
	Actual	Error	SSE	Performance
0,1022	0,112674	0,010425	1,09E-04	0,000990799
0,1089	0,107665	-0,00124	1,53E-05	
0,1003	0,113142	0,012874	1,66E-04	
0,1009	0,113064	0,012198	1,49E-04	
0,1039	0,112531	0,008664	7,51E-05	
0,1351	-0,08646	-0,22159	4,91E-02	
0,1346	-0,01861	-0,15317	2,35E-02	
0,1039	0,112225	0,008305	6,90E-05	
0,1385	0,050025	-0,08848	7,83E-03	
0,1069	0,111461	0,004538	2,06E-05	
0,1013	0,112957	0,011631	1,35E-04	
0,106	0,110853	0,004876	2,38E-05	
0,1096	0,107013	-0,00259	6,69E-06	
0,1028	0,112486	0,009689	9,39E-05	
....	
0,1074	0,109805	0,00242	5,86E-06	
		Total SSE	0,083233	
		MSE	2,45E-03	

Gambar 4, Tabel 8, dan Tabel 9 merupakan hasil pelatihan dan pengujian parameter One Step Secant (OSS) yang dilakukan dengan Matlab, selanjutnya membandingkan hasil pelatihan dan pengujian dengan menggunakan Ms. Excel. Nilai actual dihasilkan dari output hasil pelatihan dan pengujian. Value Errors dihasilkan berdasarkan kalkulasi targer (Y) actual. value SSE dihasilkan dari perkiraan Errors kuadrat. Value total SSE dihasilkan berdasarkan penambahan value SSE. Value MSE/Performances (Pref) dihasilkan dari jumlah SSE/34 dimana 34 merupakan jumlah baris data. Berdasarkan dari hasil pelatihan dan pengujian Matlab dan Ms. Excel hasilnya sesuai (valid).

Model Arsitektur Jaringan 5-11-1



Gambar. 5 Pelatihan model 5-11-1 (trainoss)

Hasil dari pelatihan dengan fungsi trainoss model 5-11-1, epoch = 13 iterasi, waktu latih = 0 detik.

TABEL X
HASIL PELATIHAN MODEL 5-11-1

Target (Y1)	Epoch 13			
	Actual	Error	SSE	Performance
0,1068	0,099995	-0,00676	4,56E-05	0,000990799
0,1112	0,083937	-0,02725	7,42E-04	
0,1027	0,107748	0,005085	2,59E-05	

Target (Y1)	Epoch 13			Performance
	Actual	Error	SSE	
0,1039	0,104827	0,000948	8,99E-07	
0,102	0,127967	0,025923	6,72E-04	
0,1089	0,074417	-0,03444	1,19E-03	
0,1023	0,116065	0,013727	1,88E-04	
0,1093	0,04345	-0,0659	4,34E-03	
0,1002	0,132824	0,032597	1,06E-03	
0,1007	0,12975	2,90E-02	8,43E-04	
0,1032	0,12964	0,026485	7,01E-04	
0,1356	0,163991	0,028425	8,08E-04	
0,1383	0,159951	0,02165	4,69E-04	
0,1042	0,104187	1,79E+09	3,21E-10	
0,1399	0,171153	0,031271	9,78E-04	
0,1052	0,074833	-0,03032	9,20E-04	
0,1013	0,123478	0,02216	4,91E-04	
0,1066	0,052131	-0,05444	2,96E-03	
0,1081	0,092868	-0,01519	2,31E-04	
0,1029	0,098613	-0,00428	1,83E-05	
....	
0,107	0,007344	-0,09963	9,93E-03	
		Total SSE	0,033687	
		MSE	9,91E-04	

TABEL XI
HASIL PENGUJIAN MODEL 5-11-1

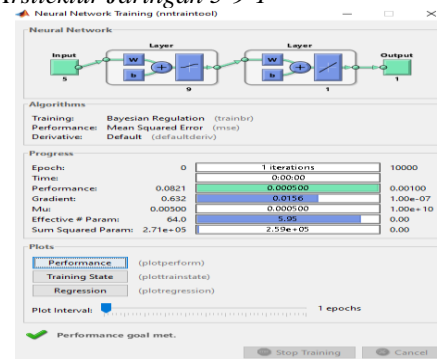
Target (Y2)	Epoch 1			Performance
	Actual	Error	SSE	
0,1067	0,095744	-0,01098	1,21E-04	0,000825011
0,1112	0,067356	-0,04379	1,92E-03	
0,1027	0,113552	0,010804	1,17E-04	
0,1038	0,105735	0,001916	3,67E-06	
0,1021	0,117861	0,015763	2,48E-04	
0,1091	0,090146	-0,019	3,61E-04	
0,1022	0,114912	0,012662	1,60E-04	
0,1089	0,086659	-0,02224	4,95E-04	
0,1003	0,132752	0,032484	1,06E-03	
0,1009	0,131154	0,030288	9,17E-04	
0,1039	0,114433	0,010567	1,12E-04	
0,1351	0,22641	0,091271	8,33E-03	
0,1346	0,201794	0,067236	4,52E-03	
0,1039	0,103716	-0,0002	4,17E-08	
0,1385	0,17403	0,035524	1,26E-03	
0,1069	0,105179	-0,00174	3,04E-06	
0,1013	0,123532	0,022206	4,93E-04	
0,106	0,088219	-0,01776	3,15E-04	
0,1096	0,091796	-0,0178	3,17E-04	
0,1028	0,110827	0,008029	6,45E-05	
....	
0,1074	0,098572	-0,00881	7,77E-05	
		Total SSE	0,02805	
		MSE	8,25E-04	

Gambar 5, Tabel 10, dan Tabel 11 merupakan hasil pelatihan dan pengujian parameter One Step Secant (OSS) yang dilakukan dengan Matlab, selanjutnya membandingkan hasil pelatihan dan pengujian dengan menggunakan Ms. Excel. Nilai Actual dihasilkan dari output hasil pelatihan dan pengujian. Value Errors dihasilkan berdasarkan kalkulasi targer (Y) Actual. value SSE dihasilkan dari perkiraan Errors kuadrat. Value total

SSE dihasilkan berdasarkan pertambahan value SSE. Value MSE/Performances (Pref) dihasilkan dari jumlah SSE/34 dimana 34 merupakan jumlah baris data. Berdasarkan dari hasil pelatihan dan pengujian Matlab dan Ms. Excel hasilnya sesuai (valid).

3. Pelatihan dan pengujian dengan Metode Bayesian Regulation.

Model Arsitektur Jaringan 5-9-1



Gambar. 6 Pelatihan model 5-9-1 (trainbr)

Hasil dari pelatihan dengan fungsi trainbr model 5-9-1, epoch = 1 iterasi, waktu latih = 0 detik.

TABEL XII
HASIL PELATIHAN MODEL 5-9-1

Target (Y1)	Epoch 1			Performance
	Actual	Error	SSE	
0,1068	0,067443	-0,03931	1,55E-03	0,000499547
0,1112	0,050655	-0,06053	0,003664	
0,1027	0,102469	-0,00019	3,75E-08	
0,1039	0,103122	-0,00076	5,72E-07	
0,102	0,106676	0,004632	2,15E-05	
0,1089	0,071575	-0,03728	1,39E-03	
0,1023	0,108111	0,005773	3,33E-05	
0,1093	0,067879	-0,04147	0,00172	
0,1002	0,114449	0,014222	2,02E-04	
0,1007	0,111861	1,12E-02	1,24E-04	
0,1032	0,099822	-0,00333	1,11E-05	
0,1356	0,151987	0,016421	0,00027	
0,1383	0,139302	0,001001	1,00E-06	
0,1042	0,090511	-1,37E-02	1,87E-04	
0,1399	0,142003	0,002121	4,50E-06	
0,1052	0,098917	-0,00624	3,89E-05	
0,1013	0,11593	0,014613	2,14E-04	
0,1066	0,08689	-0,01969	3,88E-04	
0,1081	0,063343	-0,04472	2,00E-03	
0,1029	0,113981	0,011088	1,23E-04	
....	
0,107	0,050993	-0,05598	0,003134	
		Total SSE	0,016985	
		MSE	0,0005	

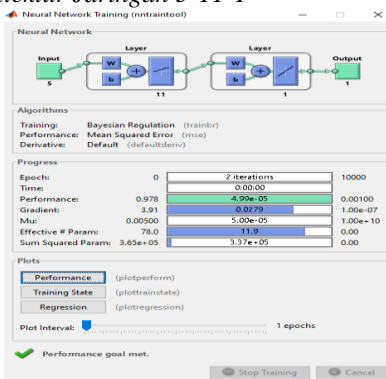
TABEL XIII
HASIL PENGUJIAN MODEL 5-9-1

Target (Y2)	Epoch 1			Performance
	Actual	Error	SSE	
0,1067	0,072309	-0,03441	1,18E-03	0,000549791
0,1112	0,057067	-0,05408	0,002925	

Target (Y2)	Epoch 1			Performance
	Actual	Error	SSE	
0,1027	0,104122	0,001374	1,89E-06	
0,1038	0,096709	-0,00711	5,05E-05	
0,1021	0,107576	0,005478	3,00E-05	
0,1091	0,057249	-0,05189	2,69E-03	
0,1022	0,107404	0,005154	2,66E-05	
0,1089	0,054355	-0,05455	2,98E-03	
0,1003	0,114067	0,013799	1,90E-04	
0,1009	0,112493	0,011628	1,35E-04	
0,1039	0,102622	-0,00124	1,55E-06	
0,1351	0,146018	0,010879	0,000118	
0,1346	0,147244	0,012686	1,61E-04	
0,1039	0,100814	-0,00311	9,65E-06	
0,1385	0,134892	-0,00361	1,31E-05	
0,1069	0,08178	-0,02514	6,32E-04	
0,1013	0,11199	0,010665	1,14E-04	
0,106	0,081555	-0,02442	5,96E-04	
0,1096	0,053503	-0,0561	0,003147	
0,1028	0,105145	0,002347	5,51E-06	
....	
0,1074	0,065878	-0,04151	1,72E-03	
		Total SSE	0,018693	
		MSE	0,00055	

Gambar 6, Tabel 12, dan Tabel 13 merupakan hasil pelatihan dan pengujian parameter Bayesian Regulation yang dilakukan dengan Matlab, selanjutnya membandingkan hasil pelatihan dan pengujian dengan menggunakan Ms. Excel. Nilai actual dihasilkan dari output hasil pelatihan dan pengujian. Value Errors dihasilkan berdasarkan kalkulasi targer (Y) Actual. value SSE dihasilkan dari perkiraan Errors kuadrat. Value total SSE dihasilkan berdasarkan pertambahan value SSE. Value MSE/Performances (Pref) dihasilkan dari jumlah SSE/34 dimana 34 merupakan jumlah baris data. Berdasarkan dari hasil pelatihan dan pengujian Matlab dan Ms. Excel hasilnya sesuai (valid).

Model Arsitektur Jaringan 5-11-1



Gambar. 7 Pelatihan model 5-11-1 (trainbr)

Hasil dari pelatihan dengan fungsi trainbr model 5-11-1, epoch= 2 iterasi, waktu latih = 0 detik

TABEL XIV
HASIL PELATIHAN MODEL 5-11-1

Target (Y1)	Epoch 2				Performance
	Actual	Error	SSE	Performance	
0,1068	0,098905	-0,00785	6,16E-05	4,99135E-05	
0,1112	0,105022	-0,00616	3,80E-05		
0,1027	0,095152	-0,00751	5,64E-05		
0,1039	0,096105	-0,00777	6,04E-05		
0,102	0,094841	-0,0072	5,19E-05		
0,1089	0,100866	-0,00799	6,38E-05		
0,1023	0,094853	-0,00749	5,60E-05		
0,1093	0,101892	-0,00746	5,56E-05		
0,1002	0,093413	-0,00681	4,64E-05		
0,1007	0,093738	-6,97E-03	4,86E-05		
0,1032	0,095569	-0,00759	5,75E-05		
0,1356	0,134683	-0,00088	7,79E-07		
0,1383	0,138787	0,000486	2,36E-07		
0,1042	0,096269	-7,90E-03	6,24E-05		
0,1399	0,14101	0,001128	1,27E-06		
0,1052	0,096823	-0,00833	6,95E-05		
0,1013	0,094027	-0,00729	5,32E-05		
0,1066	0,097681	-0,00889	7,91E-05		
0,1081	0,100278	-0,00778	6,06E-05		
0,1029	0,094993	-0,0079	6,24E-05		
....		
0,107	0,105305	-0,00167	2,80E-06		
		Total SSE	0,001697		
		MSE	4,99E-05		

TABEL XV
HASIL PENGUJIAN MODEL 5-11-1

Target (Y2)	Epoch 1				Performance
	Actual	Error	SSE	Performance	
0,1067	0,098433	-0,00829	6,87E-05	5,68557E-05	
0,1112	0,103327	-0,00782	6,12E-05		
0,1027	0,095003	-0,00774	6,00E-05		
0,1038	0,09581	-0,00801	6,41E-05		
0,1021	0,094534	-0,00756	5,72E-05		
0,1091	0,100892	-0,00825	6,81E-05		
0,1022	0,094667	-0,00758	5,75E-05		
0,1089	0,100839	-0,00806	6,50E-05		
0,1003	0,093388	-0,00688	4,73E-05		
0,1009	0,093792	-0,00707	5,00E-05		
0,1039	0,095165	-0,0087	7,57E-05		
0,1351	0,127927	-0,00721	5,20E-05		
0,1346	0,133252	-0,00131	1,71E-05		
0,1039	0,095518	-0,0084	7,06E-05		
0,1385	0,134923	-0,00358	1,28E-05		
0,1069	0,097133	-0,00979	9,58E-05		
0,1013	0,0938	-0,00753	5,66E-05		
0,106	0,097401	-0,00858	7,36E-05		
0,1096	0,101582	-0,00802	6,43E-05		
0,1028	0,095108	-0,00769	5,91E-05		
....		
0,1074	0,09936	-0,00802	6,44E-05		
		Total SSE	0,001933		
		MSE	5,69E-05		

Gambar 7, Tabel 14, dan Tabel 15 merupakan hasil pelatihan dan pengujian parameter Bayesian Regulation yang dilakukan dengan Matlab, selanjutnya

membandingkan hasil pelatihan dan pengujian dengan menggunakan Ms. Excel. Nilai Actual dihasilkan dari output hasil pelatihan dan pengujian. Value Errors dihasilkan berdasarkan kalkulasi target (Y) Actual. value SSE dihasilkan dari perkiraan Errors kuadrat. Value total SSE dihasilkan berdasarkan pertambahan value SSE. Value *MSE/Performances* (Pref) dihasilkan dari jumlah SSE/34 dimana 34 merupakan jumlah baris data. Berdasarkan dari hasil pelatihan dan pengujian Matlab dan Ms. Excel hasilnya sesuai (valid).

C. Analisis Hasil dan Evaluasi

Berdasarkan hasil pelatihan dan pengujian yang dilakukan dengan menggunakan aplikasi Matlab R2021a dan Ms. Excel, dilanjutkan dengan analisis dan evaluasi hasil dalam menghasilkan model arsitektur jaringan serta fungsi pelatihan yang baik.

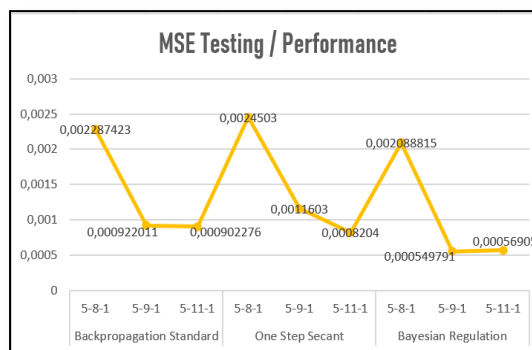
TABEL XVI
HASIL ANALISA FUNGSI PELATIHAN

Algoritma Machine Learning Neural Network						
Model	Algoritma	Fungsi Aktivas i	Fungsi Trainin g	Epoch (Iterasi)	MSE Training	MSE Testing / Performanc e
5-8-1	Backpropagation Standard	logsig', 'purelin'	traingd	1741	0,0009998	0,002287423
	One Step Secant (OSS)	logsig', 'purelin'	traingos	4	0,00020404	0,0024503
	Bayesian Regulation	logsig', 'purelin'	traingbr	1	0,0002766	0,002088815
5-9-1	Backpropagation Standard	logsig', 'purelin'	traingd	2406	0,0009997	0,000922011
	One Step Secant (OSS)	logsig', 'purelin'	traingos	7	0,0009,7704	0,0011603
	Bayesian Regulation	logsig', 'purelin'	traingbr	1	0,0004995	0,000549791
5-11-1	Backpropagation Standard	logsig', 'purelin'	traingd	3548	0,0009998	0,000902276
	One Step Secant (OSS)	logsig', 'purelin'	traingos	2	0,00099104	0,0008204
	Bayesian Regulation	logsig', 'purelin'	traingbr	13	0,0004990	0,00056905

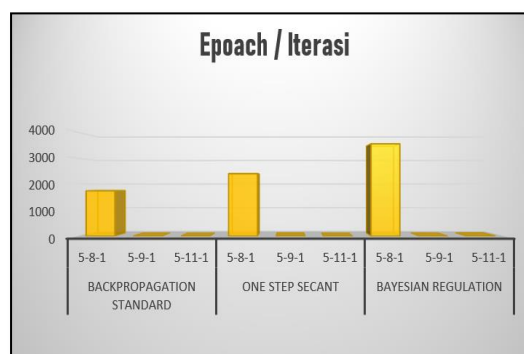
Dari Tabel 16 dapat dilihat perbandingan setiap metode fungsi pelatihan yang digunakan. Pada arsitektur jaringan 5-8-1 algoritma Bayesian Regulation memperoleh hasil yang terbaik dengan nilai epoch 1, nilai *MSE Training* 0,0002766, dan nilai *MSE Testing/Performance* 0,002088815. Pada arsitektur jaringan 5-9-1 algoritma Bayesian Regulation memperoleh hasil yang terbaik dengan nilai epoch 1, nilai *MSE Training* 0,0004995, dan nilai *MSE Testing/Performance* 0,000549791. Pada arsitektur jaringan 5-11-1 algoritma One Step Secant (OSS) memperoleh hasil yang terbaik dengan nilai epoch 2, nilai *MSE Training* 0,00099104, dan nilai *MSE Testing/Performance* 0,0008204.

Dari hasil analisa yang dilakukan pada 3 arsitektur jaringan dapat dilihat arsitektur jaringan 5-9-1 algoritma Bayesian Regulation yang memperoleh nilai epoch, nilai *MSE Training*, dan nilai *MSE Testing/Performance* yang paling rendah. Dengan demikian metode Bayesian Regulation terpilih menjadi fungsi pelatihan terbaik karena

jumlah epoch dan nilai *MSE Testing/Performance* lebih rendah dari fungsi pelatihan lainnya.



Gambar. 8 Perbandingan MSE testing / performance



Gambar. 9 Perbandingan epoch/iterasi

Gambar 8 dan 9 merupakan perbandingan setiap algoritma dan model arsitektur yang digunakan. Sesuai dengan gambar, fungsi pelatihan Bayesian Regulation merupakan hasil yang terbaik dengan model arsitektur jaringan 5-9-1.

IV. KESIMPULAN

Proses pelatihan dan pengujian dalam penelitian ditemukan bahwa metode dan fungsi pelatihan Bayesian Regulation merupakan fungsi pelatihan terbaik dari Backpropagation Standard dan One Step Secant (OSS), dengan demikian fungsi pelatihan Bayesian Regulation dapat digunakan dalam penyelesaian masalah peramalan kemiskinan di Indonesia. Fungsi pelatihan Bayesian Regulation (*trainbr*) dapat melatih jaringan lebih optimal, dan menghasilkan epoch/performance pelatihan lebih cepat, serta MSE pengujian lebih kecil dari fungsi pelatihan yang lain.

REFERENSI

- [1] I. Waspada, A. Wibowo, and N. S. Meraz, "Supervised Machine Learning Model For Microrna Expression Data In Cancer," Jurnal Ilmu Komputer dan Informatika, vol. 10, no. 2, p. 108, Jun. 2017, doi: 10.21609/jiki.v10i2.481.
- [2] I. Cong, S. Choi, and M. D. Lukin, "Quantum convolutional neural networks," Nature Physics, vol. 15, no. 12, pp. 1273–1278, Dec. 2019, doi: 10.1038/s41567-019-0648-8.
- [3] B. S. Rem et al., "Identifying quantum phase transitions using artificial neural networks on experimental data," Nature Physics,

- vol. 15, no. 9. Nature Publishing Group, pp. 917–920, Sep. 01, 2019. doi: 10.1038/s41567-019-0554-0.
- [4] R. Novickis, D. J. Justs, K. Ozols, and M. Greitāns, “An approach of feed-forward neural network throughput-optimized implementation in FPGA,” *Electronics* (Switzerland), vol. 9, no. 12, pp. 1–16, Dec. 2020. doi: 10.3390/electronics9122193.
- [5] L. Yang and A. Shami, “On hyperparameter optimization of machine learning algorithms: Theory and practice,” *Neurocomputing*, vol. 415, pp. 295–316, Nov. 2020. doi: 10.1016/j.neucom.2020.07.061.
- [6] C. T. Chen and G. X. Gu, “Generative Deep Neural Networks for Inverse Materials Design Using Backpropagation and Active Learning,” *Advanced Science*, vol. 7, no. 5, Mar. 2020. doi: 10.1002/advs.201902607.
- [7] S. Alsammarrāie and N. K. Hussein, “A New Hybrid Grasshopper Optimization-Backpropagation for Feedforward Neural Network Training,” *Tikrit Journal of Pure Science*, vol. 25, no. 1, p. 2020. doi: 10.25130/tjps.25.2020.018.
- [8] I. T. Sui Kim, V. Sethu, S. K. Arumugasamy, and A. Selvarajoo, “Fenugreek seeds and okra for the treatment of palm oil mill effluent (POME) – Characterization studies and modeling with backpropagation feedforward neural network (BFNN),” *Journal of Water Process Engineering*, vol. 37, Oct. 2020. doi: 10.1016/j.jwpe.2020.101500.
- [9] F. Cichos, K. Gustavsson, B. Mehlig, and G. Volpe, “Machine learning for active matter,” *Nature Machine Intelligence*, vol. 2, no. 2, pp. 94–103, Feb. 2020. doi: 10.1038/s42256-020-0146-9.
- [10] R. García-Ródenas, L. J. Linares, and J. A. López-Gómez, “Memetic algorithms for training feedforward neural networks: an approach based on gravitational search algorithm,” *Neural Computing and Applications*, vol. 33, no. 7, pp. 2561–2588, Apr. 2021. doi: 10.1007/s00521-020-05131-y.
- [11] E. Yan, J. Song, C. Liu, J. Luan, and W. Hong, “Comparison of support vector machine, back propagation neural network and extreme learning machine for syndrome element differentiation,” *Artificial Intelligence Review*, vol. 53, no. 4, pp. 2453–2481, Apr. 2020. doi: 10.1007/s10462-019-09738-z.
- [12] S. R. Salkuti, “A survey of big data and machine learning,” *International Journal of Electrical and Computer Engineering*, vol. 10, no. 1, pp. 575–580, 2020. doi: 10.11591/ijece.v10i1.pp575-580.
- [13] I. C. Afolabi, S. I. Popoola, and O. S. Bello, “Modeling pseudo-second-order kinetics of orange peel-paracetamol adsorption process using artificial neural network,” *Chemosometrics and Intelligent Laboratory Systems*, vol. 203, Aug. 2020. doi: 10.1016/j.chemolab.2020.104053.
- [14] A. Munther, R. Razif, M. AbuAlhaj, M. Anbar, and S. Nizam, “A preliminary performance evaluation of K-means, KNN and em unsupervised machine learning methods for network flow classification,” *International Journal of Electrical and Computer Engineering*, vol. 6, no. 2, pp. 778–784, Apr. 2016. doi: 10.11591/ijece.v6i1.8909.
- [15] A. Panyafong, N. Neamsorn, and C. Chaichana, “Heat load estimation using Artificial Neural Network,” in *Energy Reports*, Feb. 2020, vol. 6, pp. 742–747. doi: 10.1016/j.egy.2019.11.149.
- [16] E. W. Prasetyo, N. Hidetaka, D. A. Prasetya, W. Dirgantara, and H. F. Windi, “Spatial Based Deep Learning Autonomous Wheel Robot Using CNN,” *Lontar Komputer: Jurnal Ilmiah Teknologi Informasi*, vol. 11, no. 3, p. 167, Dec. 2020. doi: 10.24843/lkjiti.2020.v11.i03.p05.
- [17] C. K. Arthur, V. A. Temeng, and Y. Y. Ziggah, “Performance Evaluation of Training Algorithms in Backpropagation Neural Network Approach to Blast-Induced Ground Vibration Prediction,” *Ghana Mining Journal*, vol. 20, no. 1, pp. 20–33, Jul. 2020. doi: 10.4314/gm.v20i1.3.
- [18] “27 Application of Artificial Neural Networks for Airline Number of Passenger Estimation in time Series state”.
- [19] R. Kountchev, S. Patnaik, J. Shi, and M. N. Favorskaya Editors, “Smart Innovation, Systems and Technologies 179.” [Online]. Available: <http://www.springer.com/series/8767>
- [20] I. B. K. Sudiatik, F. Rahman, Trisno, and Suyoto, “Image forgery detection using error level analysis and deep learning,” *Telkomnika (Telecommunication Computing Electronics and Control)*, vol. 17, no. 2, pp. 653–659, Apr. 2019. doi: 10.12928/TELKOMNIKA.V17I2.8976.
- [21] M. Žic, V. Subotić, S. Pereverzyev, and I. Fajfar, “Solving CNLS problems using Levenberg-Marquardt algorithm: A new fitting strategy combining limits and a symbolic Jacobian matrix,” *Journal of Electroanalytical Chemistry*, vol. 866, Jun. 2020. doi: 10.1016/j.jelechem.2020.114171.
- [22] J. Bilski, B. Kowalczyk, A. Marchlewska, and J. M. Zurada, “Local Levenberg-Marquardt Algorithm for Learning Feedforward Neural Networks,” *Journal of Artificial Intelligence and Soft Computing Research*, vol. 10, no. 4, pp. 299–316, Oct. 2020. doi: 10.2478/jaiscr-2020-0020.
- [23] Q. H. Nguyen et al., “A novel hybrid model based on a feedforward neural network and one step secant algorithm for prediction of load-bearing capacity of rectangular concrete-filled steel tube columns,” *Molecules*, vol. 25, no. 15, Aug. 2020. doi: 10.3390/molecules25153486.
- [24] P. Parulian et al., “Analysis of Sequential Order Incremental Methods in Predicting the Number of Victims Affected by Disasters,” in *Journal of Physics: Conference Series*, Sep. 2019, vol. 1255, no. 1. doi: 10.1088/1742-6596/1255/1/012033.
- [25] M. Attamimi, R. Mardiyanto, and A. N. Irfansyah, “Inclined image recognition for aerial mapping using deep learning and tree based models,” *Telkomnika (Telecommunication Computing Electronics and Control)*, vol. 16, no. 6, pp. 3034–3044, Dec. 2018. doi: 10.12928/TELKOMNIKA.v16i6.10157.
- [26] N. L. W. S. R. Ginantra, M. A. Hanafiah, A. Wanto, R. Winanjaya, and H. Okprana, “Utilization of the Batch Training Method for Predicting Natural Disasters and Their Impacts,” *IOP Conference Series: Materials Science and Engineering*, vol. 1071, no. 1, p. 012022, Feb. 2021. doi: 10.1088/1757-899x/1071/1/012022.
- [27] IEEE Staff, 2019 Amity International Conference on Artificial Intelligence (AICAI). IEEE, 2019.
- [28] I. Fitriyaningsih and Y. Basani, “Flood Prediction with Ensemble Machine Learning using BP-NN and SVM,” *Jurnal Teknologi dan Sistem Komputer*, vol. 7, no. 3, pp. 93–97, Jul. 2019. doi: 10.14710/jtsiskom.7.3.2019.93-97.
- [29] R. Jayaseelan, G. Pandulu, and G. Ashwini, “Neural networks for the prediction of fresh properties and compressive strength of flowable concrete,” *Journal of Urban and Environmental Engineering*, vol. 13, no. 1, pp. 183–197, 2019. doi: 10.4090/juee.2019.v13n1.183197.
- [30] T. Afriliansyah and Z. Zulfahmi, “Prediction of Life Expectancy in Aceh Province by District City Using the Cyclical Order Algorithm,” *International Journal of Information System & Technology Akreditasi*, vol. 3, no. 36, pp. 268–275, 2020.
- [31] S. Murofin, M. Mughniy Machfud, D. H. Satyareni, R. Venantius, H. Ginardi, and C. Fatchah, “Komparasi Kinerja Algoritma C4.5, Gradient Boosting Trees, Random Forests, Dan Deep Learning Pada Kasus Educational Data Mining,” doi: 10.25126/jtiik.2020732665.
- [32] R. R. Pratama, “Analisis Model Machine Learning Terhadap Pengenalan Aktifitas Manusia,” *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 19, no. 2, pp. 302–311, May 2020. doi: 10.30812/matrik.v19i2.688.
- [33] M. Tyrtaiou, A. Papaleonidas, A. Elenas, and L. Iliadis, “Accomplished Reliability Level for Seismic Structural Damage Prediction Using Artificial Neural Networks,” 2020, pp. 85–98. doi: 10.1007/978-3-030-48791-1_6.
- [34] F. A. Bachtiar, I. K. Syahputra, and S. A. Wicaksono, “Perbandingan Algoritme Machine Learning Untuk Memprediksi Pengambil Mata Kuliah,” vol. 6, no. 5, pp. 543–548, 2019. doi: 10.25126/jtiik.2019611755.
- [35] I. Ferima Talia, I. Fitri Astuti, and P. Studi Ilmu Komputer Fakultas Ilmu Komputer dan Teknologi Informasi, “Peramalan Tingkat Kemiskinan Penduduk Provinsi Kalimantan Timur Menggunakan Metode Double Exponential Smoothing Zainal Arifin,” *Prosiding Seminar Nasional Ilmu Komputer dan Teknologi Informasi*, vol. 4, no. 2, 2019.
- [36] N. Choiriyati, Y. Arkeman, and W. A. Kusuma, “Deep learning model for metagenome fragment classification using spaced k-mers feature extraction,” *Jurnal Teknologi dan Sistem Komputer*, vol. 8, no. 3, pp. 234–238, Jul. 2020. doi: 10.14710/jtsiskom.2020.13407.

- [37] Sri Sivasubramaniya Nadar College of Engineering. Electronics and Communication Engineering Department and Institute of Electrical and Electronics Engineers, *WiSPNET 2019*: 2019 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET): 21-23, March 2019.
- [38] I. D. Uwanakwa and P. Akpınar, "Investigations on the influence of variations in hidden neurons and training data percentage on the efficiency of concrete carbonation depth prediction with ann," in *Advances in Intelligent Systems and Computing*, 2020, vol. 1095 AISC, pp. 958–965. doi: 10.1007/978-3-030-35249-3_128.
- [39] K. v. Shende, M. R. Ramesh Kumar, and K. v. Kale, "Comparison of Neural Network Training Functions for Prediction of Outgoing Longwave Radiation over the Bay of Bengal," in *Advances in Intelligent Systems and Computing*, 2020, vol. 1025, pp. 411–419. doi: 10.1007/978-981-32-9515-5_39.
- [40] S. Setti and A. Wanto, "Analysis of Backpropagation Algorithm in Predicting the Most Number of Internet Users in the World," *Jurnal Online Informatika*, vol. 3, no. 2, pp. 110–115, 2018, doi: 10.15575/join.