



Analisis Penurunan Gradien dengan Kombinasi Fungsi Aktivasi pada Algoritma JST untuk Pencarian Akurasi Terbaik

Anjar Wanto^{1,*}, Jufriadif Na'am², Yuhandri², Agus Perdana Windarto³, Mesran⁴

¹ Program Studi Teknik Informatika, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

² Program Studi Teknik Informatika, Universitas Putra Indonesia YPTK Padang, Indonesia

³ Program Studi Sistem Informasi, STIKOM Tunas Bangsa, Pematangsiantar, Indonesia

⁴ Program Studi Teknik Informatika, Universitas Budi Darma, Medan, Indonesia

Email Penulis Korespondensi: *anjarwanto@amiktunasbangsa.ac.id

Abstrak—Banyak sekali metode fungsi training penurunan gradien (gradient descent) dan fungsi aktivasi (fungsi transfer) yang bisa digunakan pada algoritma JST khususnya algoritma backpropagation. Oleh karena itu tujuan dari makalah ini adalah untuk menganalisa gradient descent yang terbaik yang dapat dijadikan rujukan untuk digunakan pada algoritma JST, khususnya algoritma backpropagation dalam masalah prediksi data, klasifikasi maupun pengenola pola. Metode gradient descent yang akan dianalisa diantaranya: Gradient descent backpropagation (traingd), Gradient descent with momentum backpropagation (traingdm), Gradient descent with adaptive learning rate backpropagation (traingda), dan Gradient descent with momentum and adaptive learning rate backpropagation (traingdx). Fungsi training akan dikombinasikan dengan fungsi aktivasi (fungsi transfer) sigmoid bipolar (tansig), transfer linier (purelin) dan sigmoid biner (logsig). Data sampel yang digunakan untuk proses analisa adalah data times-series Indeks Pembangunan Manusia di Indonesia yang diperoleh dari Badan Pusat Statistik (BPS). Model arsitektur yang digunakan untuk analisa gradient descent diantaranya: 6-10-15-1, 6-15-20-1, 6-20-25-1 dan 6-25-30-1. Berdasarkan hasil analisa, fungsi training terbaik adalah traingda dengan model arsitektur 6-15-20-1 yang menghasilkan tingkat akurasi 91% dan MSE Testing 0,000731529 (lebih kecil dibandingkan metode lainnya).

Kata Kunci: Penurunan Gradien, Fungsi Aktivasi, JST, Backpropagation, Akurasi

Abstract—There are many training function methods for gradient descent (gradient descent) and activation functions (transfer functions) that can be used in the ANN algorithm, especially the backpropagation algorithm. Therefore the aim of this paper is to analyze the best gradient descent that can be used as a reference for use in the ANN algorithm, especially the backpropagation algorithm in data prediction, classification and pattern management problems. The gradient descent methods to be analyzed include; Gradient descent backpropagation (traingd), Gradient descent with momentum backpropagation (traingdm), Gradient descent with adaptive learning rate backpropagation (traingda), and Gradient descent with momentum and adaptive learning rate backpropagation (traingdx). The training function will be combined with the activation function (transfer function) of bipolar sigmoid (tansig), linear transfer (purelin) and binary sigmoid (logsig). The sample data used for the analysis process is the time-series data for the Human Development Index in Indonesia, which is obtained from the Central Bureau of Statistics (BPS). Architectural models used for gradient descent analysis include: 6-10-15-1, 6-15-20-1, 6-20-25-1 and 6-25-30-1. Based on the analysis results, the best training function is traingda with an architectural model of 6-15-20-1 which produces an accuracy rate of 91% and MSE testing is 0.000731529 (smaller than other methods).

Keywords: Gradient Descent, Activation Functions, ANN, Backpropagation, Accuracy

1. PENDAHULUAN

Jaringan Saraf Tiruan (JST) memiliki karakteristik yang hampir mirip dengan Jaringan Saraf Biologi yang ditentukan oleh 3 hal: arsitektur jaringan, metode penentu bobot penghubung (metode training/learning) dan fungsi aktivasi [1]. Terdapat banyak jenis-jenis algoritma JST, diantaranya: perceptron, backpropagation, Learning vector quantization (LVQ), probablistik neural network, hopfield, radial basis network, dan lain-lain [2], [3], [4], yang semuanya memiliki karakteristik masing-masing. Algoritma JST yang dibahas pada makalah ini adalah algoritma backpropagation yang merupakan salah satu metode JST yang mampu bekerja secara sistematis dengan melatih jaringan multiplayer menggunakan ilmu matematis berdasarkan model-model arsitektur jaringan yang dikembangkan [5], [6], [7]. Standar training algoritma backpropagation menggunakan penurunan gradien (gradient descent) dapat menggunakan metode optimisasi yang lain. Backpropagation yang sudah dilatih dengan baik memberikan *output* yang sesuai apabila diberi *input* yang berbeda dengan pola arsitektur yang digunakan dalam training. Sifat generalisasi ini membuat training lebih efisien karena tidak memerlukan keseluruhan data training.

Gradient descent merupakan cara pengoptimalan urutan iteratif pertama untuk menemukan fungsi minimum, untuk menemukan lokal minimum dari gradient descent, harus mengambil langkah-langkah yang seimbang dengan fungsi gradien negatif (perkiraan gradien) pada titik saat ini [8]. Sebagaimana telah dijelaskan sebelumnya bahwa metode gradient descent berfungsi untuk merubah bobot pada training arsitektur jaringan yang digunakan. Bobot dan bias diubah pada arah dimana unjuk kerja fungsi menurun paling cepat, yaitu dalam arah negatif gradiennya.

Banyak penelitian terkait yang membahas tentang training menggunakan gradient descent, diantaranya penelitian Ruslan, et al (2018) [9] tentang perbandingan fungsi training traingd dan trainoss pada model prediksi banjir. Makalah ini mengusulkan model blackbox Neural Network Autoregressive with Exogenous Inputs (NNARX) dengan fungsi training traingd dan trainoss. Hasil menyebutkan performa model NNARX dengan trainoss tidak sebaik traingd. Model NNARX bekerja lebih baik traingd sebagai fungsi training. Berikut



penelitian Haryati et al (2019) tentang model backpropagation pada prediksi Indeks Pembangunan Manusia di NTB dengan fungsi traingd, traingdx, dan trainrp. Hasil menyebutkan fungsi traingd menjadi fungsi terbaik dengan akurasi sebesar 99,76% [10]. Selanjutnya Pamungkas (2020) mengusulkan makalah tentang fungsi training trainlm, traingdx, traingd, trainrp dan traingda pada produksi udang *Litopenaeus vannamei* dan *Penaeus Monodon* di Kabupaten Indramayu. Hasil menyebutkan traingd menjadi fungsi training terbaik dengan MSE 0,0174 dan MAPE 19,28%, trainrp menjadi fungsi Testing terbaik dengan MSE 0,0200 dan MAPE 22,99% [11]. Secara garis besar dari ke tiga penelitian tersebut, metode traingd merupakan gradient descent yang terbaik, tetapi relatif lama dalam waktu training. Sehingga makalah ini mengusulkan fungsi training penurunan gradien dengan beberapa fungsi seperti traingd, traingdm, traingda, dan traingdx yang dikombinasikan dengan fungsi aktivasi sigmoid bipolar (tansig), fungsi linier (purelin) dan sigmoid biner (logsig). Empat jenis metode gradient descent dianalisa dengan melatih dan menguji pada data times-series, untuk mencari akurasi terbaik dengan mengkombinasi fungsi aktivasi yang berbeda sehingga memperoleh hasil penurunan gradien yang lebih baik dan lebih cepat dari segi waktu.

2. METODOLOGI PENELITIAN

2.1 Data Penelitian

Pengumpulan data menggunakan metode kuantitatif, yakni mengambil data times-series Indeks Pembangunan Manusia di Indonesia yang bersumber dari Badan Pusat Statistik Indonesia dengan sampel data IPM tahun 2010-2017 [12].

Tabel 1. Indeks Pembangunan Manusia (IPM) tahun 2010-2017

No	Provinsi / Kabupaten / Kota	Indeks Pembangunan Manusia							
		2010	2011	2012	2013	2014	2015	2016	2017
1	Aceh	67,09	67,45	67,81	68,30	68,81	69,45	70,00	70,60
2	North Sumatra	67,09	67,34	67,74	68,36	68,87	69,51	70,00	70,57
3	West Sumatra	67,25	67,81	68,36	68,91	69,36	69,98	70,73	71,24
4	Riau	68,65	68,90	69,15	69,91	70,33	70,84	71,20	71,79
5	Jambi	65,39	66,14	66,94	67,76	68,24	68,89	69,62	69,99
6	South Sumatra	64,44	65,12	65,79	66,16	66,75	67,46	68,24	68,86
7	Bengkulu	65,35	65,96	66,61	67,50	68,06	68,59	69,33	69,95
8	Lampung	63,71	64,20	64,87	65,73	66,42	66,95	67,65	68,25
9	Bangka Belitung Islands	66,02	66,59	67,21	67,92	68,27	69,05	69,55	69,99
10	Riau islands	71,13	71,61	72,36	73,02	73,40	73,75	73,99	74,45
11	DKI Jakarta	76,31	76,98	77,53	78,08	78,39	78,99	79,60	80,06
12	West Java	66,15	66,67	67,32	68,25	68,80	69,50	70,05	70,69
13	Central Java	66,08	66,64	67,21	68,02	68,78	69,49	69,98	70,52
14	DI Yogyakarta	75,37	75,93	76,15	76,44	76,81	77,59	78,38	78,89
15	East Java	65,36	66,06	66,74	67,55	68,14	68,95	69,74	70,27
16	Banten	67,54	68,22	68,92	69,47	69,89	70,27	70,96	71,42
17	Bali	70,10	70,87	71,62	72,09	72,48	73,27	73,65	74,30
18	West Nusa Tenggara	61,16	62,14	62,98	63,76	64,31	65,19	65,81	66,58
19	East Nusa Tenggara	59,21	60,24	60,81	61,68	62,26	62,67	63,13	63,73
20	West Kalimantan	61,97	62,35	63,41	64,30	64,89	65,59	65,88	66,26
21	Central Kalimantan	65,96	66,38	66,66	67,41	67,77	68,53	69,13	69,79
22	South Kalimantan	65,20	65,89	66,68	67,17	67,63	68,38	69,05	69,65
23	East Kalimantan	71,31	72,02	72,62	73,21	73,82	74,17	74,59	75,12
24	North Kalimantan	67,99	67,99	67,99	67,99	68,64	68,76	69,20	69,84
25	North Sulawesi	67,83	68,31	69,04	69,49	69,96	70,39	71,05	71,66
26	Central Sulawesi	63,29	64,27	65,00	65,79	66,43	66,76	67,47	68,11
27	South Sulawesi	66,00	66,65	67,26	67,92	68,49	69,15	69,76	70,34
28	Southeast Sulawesi	65,99	66,52	67,07	67,55	68,07	68,75	69,31	69,86
29	Gorontalo	62,65	63,48	64,16	64,70	65,17	65,86	66,29	67,01
30	West Sulawesi	59,74	60,63	61,01	61,53	62,24	62,96	63,60	64,30
31	Maluku	64,27	64,75	65,43	66,09	66,74	67,05	67,60	68,19
32	North Maluku	62,79	63,19	63,93	64,78	65,18	65,91	66,63	67,20
33	West Papua	59,60	59,90	60,30	60,91	61,28	61,73	62,21	62,99
34	Papua	54,45	55,01	55,55	56,25	56,75	57,25	58,05	59,09

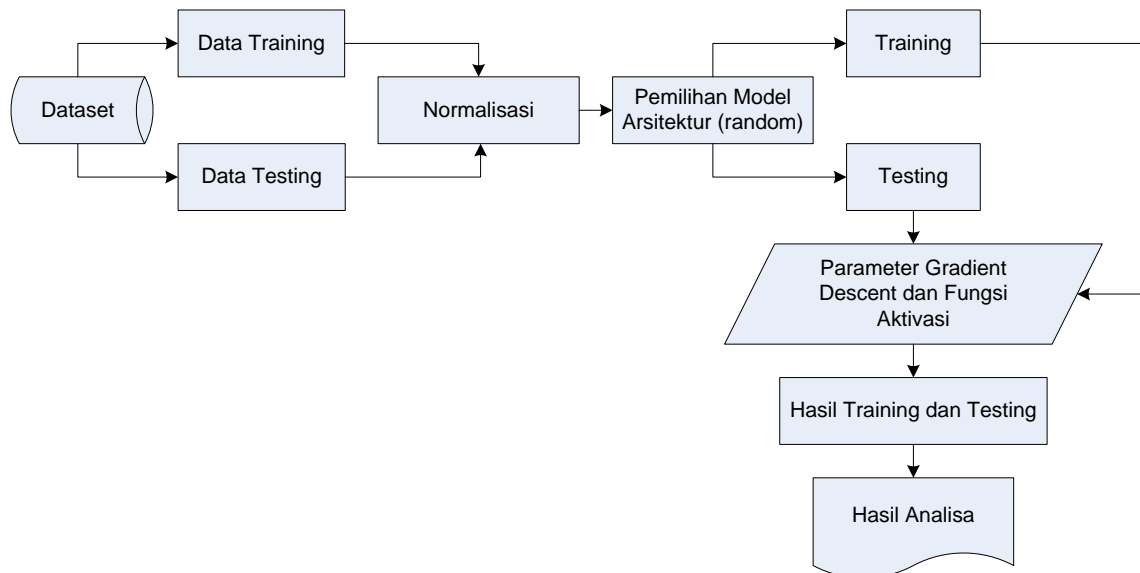
2.2 Algoritma Penelitian



Algoritma yang digunakan dan akan dijabarkan pada makalah ini adalah algoritma backpropagation dengan fungsi training Gradient descent backpropagation (traingd), Gradient descent with momentum backpropagation (traingdm), Gradient descent with adaptive learning rate backpropagation (traingda), dan Gradient descent with momentum and adaptive learning rate backpropagation (traingdx). Fungsi training akan dikombinasikan dengan fungsi aktivasi (fungsi transfer) sigmoid bipolar (tansig), transfer linier (purelin) dan sigmoid biner (logsig).

2.3 Diagram Alir

Diagram alir yang diusulkan pada makalah ini disajikan pada gambar 1.



Gambar 1. Diagram alir yang diusulkan

Pada gambar 1 dapat dijelaskan bahwa hal pertama yang dilakukan pada pengusulan makalah ini adalah menyiapkan dataset, yakni data Indeks Pembangunan Manusia di Indonesia. Selanjutnya dataset tersebut dibagi menjadi 2 bagian, untuk data training (training) dan data testing (Testing). Langkah berikutnya melakukan normalisasi terhadap data training dan data testing. Setelah data dinormalisasi, selanjutnya memilih atau menentukan model arsitektur jaringan yang akan digunakan untuk proses training dan Testing dengan menggunakan aplikasi Matlab 2011b dan Microsoft Excel. Proses training dan Testing dilakukan dengan menggunakan parameter gradient descent (traingd, traingdm, traingda, dan traingdx) dan fungsi aktivasi/fungsi transfer (tansig, purelin, logsig). Matlab akan memberikan hasil perhitungan (output) dari data yang sudah di masukkan dan diproses pada training dan testing dengan menggunakan model arsitektur yang sudah ditentukan secara random. Hasil output dari Matlab ini nantinya akan dimasukkan kedalam Microsoft Excel untuk diolah dan dihitung kembali serta dianalisa sampai memperoleh model arsitektur yang terbaik. Model arsitektur yang terbaik ditentukan berdasarkan perbandingan beberapa model arsitektur yang sudah ditentukan secara random.

3. HASIL DAN PEMBAHASAN

3.1 Menentukan Data Training dan Data Testing

Berdasarkan data penelitian yang tersaji pada tabel 1, maka data tersebut akan dibagi menjadi dua bagian, yakni data training dan data testing. Tidak ada aturan yang baku untuk menentukan data training dan data testing, dengan catatan data training dan target training tidak boleh sama dengan data testing dan target testing. Pada makalah ini data training yang digunakan data tahun 2010-2015 dengan target training tahun 2016. Sedangkan data testing yang digunakan data tahun 2011-2016 dengan target testing tahun 2017.

3.2 Normalisasi

Data training dan data testing yang sudah ditentukan selanjutnya akan dinormalisasi menggunakan rumus normalisasi sesuai persamaan (1) berikut [13], [14], [15] :

$$x' = \frac{0,8 (x-a)}{(b-a)} + 0,1 \quad (1)$$

Keterangan:

- x' = Hasil normalisasi
- x = Data yang akan dinormalisasi
- a = Data terkecil dari dataset



b = Data terbesar dari dataset

Hasil Normalisasi data training dan data testing dapat dilihat pada tabel 2 dan tabel 3 berikut.

Tabel 2. Normalisasi Data Training

Data	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	Target
1	0,502068	0,513519	0,524970	0,540557	0,556779	0,577137	0,594632
2	0,502068	0,510020	0,522744	0,542465	0,558688	0,579046	0,594632
3	0,507157	0,524970	0,542465	0,559960	0,574274	0,593996	0,617853
4	0,551690	0,559642	0,567594	0,591769	0,605129	0,621352	0,632803
5	0,447992	0,471849	0,497296	0,523380	0,538648	0,559324	0,582545
6	0,417773	0,439404	0,460716	0,472485	0,491252	0,513837	0,538648
7	0,446720	0,466123	0,486799	0,515109	0,532922	0,549781	0,573320
8	0,394553	0,410139	0,431451	0,458807	0,480755	0,497614	0,519881
9	0,468032	0,486163	0,505885	0,528469	0,539602	0,564414	0,580318
10	0,630577	0,645845	0,669702	0,690696	0,702783	0,713917	0,721551
11	0,795348	0,816660	0,834155	0,851650	0,861511	0,880596	0,900000
12	0,472167	0,488708	0,509384	0,538966	0,556461	0,578728	0,596223
13	0,469940	0,487753	0,505885	0,531650	0,555825	0,578410	0,593996
14	0,765447	0,783260	0,790258	0,799483	0,811252	0,836064	0,861193
15	0,447038	0,469304	0,490934	0,516700	0,535467	0,561233	0,586362
16	0,516382	0,538012	0,560278	0,577773	0,591133	0,603221	0,625169
17	0,597813	0,622306	0,646163	0,661113	0,673519	0,698648	0,710736
18	0,313439	0,344612	0,371332	0,396143	0,413638	0,441630	0,461352
19	0,251412	0,284175	0,302306	0,329980	0,348429	0,361471	0,376103
20	0,339205	0,351292	0,385010	0,413320	0,432087	0,454354	0,463579
21	0,466123	0,479483	0,488390	0,512247	0,523698	0,547873	0,566958
22	0,441948	0,463897	0,489026	0,504612	0,519245	0,543101	0,564414
23	0,636302	0,658887	0,677972	0,696740	0,716143	0,727276	0,740636
24	0,530696	0,530696	0,530696	0,530696	0,551372	0,555189	0,569185
25	0,525606	0,540875	0,564095	0,578410	0,593360	0,607038	0,628032
26	0,381193	0,412366	0,435586	0,460716	0,481074	0,491571	0,514155
27	0,467396	0,488072	0,507475	0,528469	0,546600	0,567594	0,586998
28	0,467078	0,483936	0,501431	0,516700	0,533241	0,554871	0,572684
29	0,360835	0,387237	0,408867	0,426044	0,440994	0,462942	0,476620
30	0,268270	0,296581	0,308668	0,325209	0,347793	0,370696	0,391054
31	0,412366	0,427634	0,449264	0,470258	0,490934	0,500795	0,518290
32	0,365288	0,378012	0,401551	0,428588	0,441312	0,464533	0,487435
33	0,263817	0,273360	0,286083	0,305487	0,317256	0,331571	0,346839
34	0,100000	0,117813	0,134990	0,157256	0,173161	0,189066	0,214513

Tabel 3. Normalisasi Data Testing

Data	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	Target
1	0,497285	0,508782	0,524431	0,540719	0,561158	0,578723	0,597884
2	0,493772	0,506547	0,526347	0,542635	0,563074	0,578723	0,596926
3	0,508782	0,526347	0,543912	0,558283	0,578084	0,602036	0,618323
4	0,543593	0,551577	0,575848	0,589261	0,605549	0,617046	0,635888
5	0,455449	0,480998	0,507186	0,522515	0,543273	0,566587	0,578403
6	0,422874	0,444271	0,456088	0,474930	0,497605	0,522515	0,542315
7	0,449701	0,470459	0,498882	0,516766	0,533693	0,557325	0,577126
8	0,393493	0,414890	0,442355	0,464391	0,481317	0,503673	0,522834
9	0,469820	0,489621	0,512295	0,523473	0,548383	0,564351	0,578403
10	0,630140	0,654092	0,675170	0,687305	0,698483	0,706148	0,720838
11	0,801637	0,819202	0,836766	0,846667	0,865828	0,885309	0,900000
12	0,472375	0,493134	0,522834	0,540399	0,562754	0,580319	0,600758
13	0,471417	0,489621	0,515489	0,539760	0,562435	0,578084	0,595329
14	0,768104	0,775130	0,784391	0,796208	0,821118	0,846347	0,862635
15	0,452894	0,474611	0,500479	0,519321	0,545190	0,570419	0,587345
16	0,521876	0,544232	0,561796	0,575210	0,587345	0,609381	0,624072
17	0,606507	0,630459	0,645469	0,657924	0,683154	0,695289	0,716048
18	0,327705	0,354531	0,379441	0,397006	0,425110	0,444910	0,469501
19	0,267026	0,285230	0,313014	0,331537	0,344631	0,359321	0,378483



Data	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆	Target
20	0,334411	0,368263	0,396687	0,415529	0,437884	0,447146	0,459281
21	0,463114	0,472056	0,496008	0,507505	0,531776	0,550938	0,572016
22	0,447465	0,472695	0,488343	0,503034	0,526986	0,548383	0,567545
23	0,643234	0,662395	0,681238	0,700719	0,711896	0,725309	0,742236
24	0,514531	0,514531	0,514531	0,535289	0,539122	0,553174	0,573613
25	0,524750	0,548064	0,562435	0,577445	0,591178	0,612255	0,631737
26	0,395729	0,419042	0,444271	0,464711	0,475250	0,497924	0,518363
27	0,471737	0,491218	0,512295	0,530499	0,551577	0,571058	0,589581
28	0,467585	0,485150	0,500479	0,517086	0,538802	0,556687	0,574251
29	0,370499	0,392216	0,409461	0,424471	0,446507	0,460240	0,483234
30	0,279481	0,291617	0,308224	0,330898	0,353892	0,374331	0,396687
31	0,411058	0,432774	0,453852	0,474611	0,484511	0,502076	0,520918
32	0,361238	0,384870	0,412016	0,424790	0,448104	0,471098	0,489301
33	0,256168	0,268942	0,288423	0,300240	0,314611	0,329940	0,354850
34	0,100000	0,117246	0,139601	0,155569	0,171537	0,197086	0,230299

Maksud dari tabel 2 dan tabel 3 dapat dilihat pada kriteria input data training dan input data testing pada tabel 4. Pada tabel 4 terdapat enam input data training dengan satu target dan enam input data testing dengan 1 target.

Tabel 4. Kriteria Input Data Training dan Input Data Testing

Input Data Training			Input Data Testing		
No	Kriteria	Keterangan	No	Kriteria	Keterangan
1	X1	Data Tahun 2010	1	X1	Data Tahun 2011
2	X2	Data Tahun 2011	2	X2	Data Tahun 2012
3	X3	Data Tahun 2012	3	X3	Data Tahun 2013
4	X4	Data Tahun 2013	4	X4	Data Tahun 2014
5	X5	Data Tahun 2014	5	X5	Data Tahun 2015
6	X6	Data Tahun 2015	6	X6	Data Tahun 2016
7	Target	Data Tahun 2016	7	Target	Data Tahun 2017

3.3 Pemilihan Model Arsitektur

Pada algoritma Backpropagation tidak ada aturan yang mengharuskan menggunakan model arsitektur tertentu, penggunaan dan penentuan model arsitektur dilakukan secara random dengan melakukan training jaringan secara terus menerus hingga diperoleh model terbaik yang memiliki akurasi yang tinggi. Pada penelitian ini telah dilakukan proses training dan Testing dengan menggunakan bantuan aplikasi matlab dan Excel pada 50 model, tetapi dari 50 model yang dilatih dan diuji dipilih empat model arsitektur saja yang memiliki tingkat akurasi terbaik. Model arsitektur yang digunakan untuk analisa data diantaranya: 6-10-15-1, 6-15-20-1, 6-20-25-1 dan 6-25-30-1. Berdasarkan empat model arsitektur ini akan dianalisa metode mana yang terbaik diantara metode gradient descent (traingd, traingdm, traingda, dan traingdx).

3.4 Hasil Analisa

Secara garis besar Hasil analisa dan Proses training dan testing menggunakan empat model arsitektur dengan Parameter Gradient Descent (traingd, traingdm, traingda, dan traingdx) dan Fungsi Aktivasi (tansig, purelin, logsig) dapat dilihat pada tabel 5, tabel 6, tabel 7 dan tabel 8 berikut.

Tabel 5. Hasil Training dan Testing Gradient descent backpropagation (traingd)

No	Model	Training			Testing		
		Epoch	Waktu	Nilai MSE	Fungsi Aktivasi	Nilai MSE	Akurasi
1	6-10-15-1	3965	00:28	0,000999534	tansig, purelin, logsig	0,000896563	79%
2	6-15-20-1	3813	00:28	0,000999388	tansig, purelin, logsig	0,000740382	85%
3	6-20-25-1	4502	00:33	0,000999425	tansig, purelin, logsig	0,000899537	88%
4	6-25-30-1	1275	00:11	0,000998332	tansig, purelin, logsig	0,000965694	79%

Tabel 6. Hasil Training dan Testing Gradient descent with momentum (traingdm)

No	Model	Training			Testing		
		Epoch	Waktu	Nilai MSE	Fungsi Aktivasi	Nilai MSE	Akurasi
1	6-10-15-1	3946	00:29	0,000999854	tansig, purelin, logsig	0,000895571	79%
2	6-15-20-1	3759	00:28	0,001000313	tansig, purelin, logsig	0,000741574	85%
3	6-20-25-1	4489	00:37	0,000999645	tansig, purelin, logsig	0,000899667	88%
4	6-25-30-1	1264	00:14	0,000998855	tansig, purelin, logsig	0,000966053	79%



Tabel 7 Hasil Training dan Testing Gradient descent with adaptive learning rate backpropagation (traingda)

No	Model	Training			Testing		
		Epoch	Waktu	Nilai MSE	Fungsi Aktivasi	Nilai MSE	Akurasi
1	6-10-15-1	190	00:02	0,001000214	tansig, purelin, logsig	0,000889723	79%
2	6-15-20-1	359	00:03	0,000992385	tansig, purelin, logsig	0,000731529	91%
3	6-20-25-1	546	00:04	0,000999453	tansig, purelin, logsig	0,000893522	88%
4	6-25-30-1	177	00:03	0,000996743	tansig, purelin, logsig	0,000994578	76%

Tabel 8. Hasil Training & Testing GD with momentum and adaptive learning rate backpropagation (traingdx)

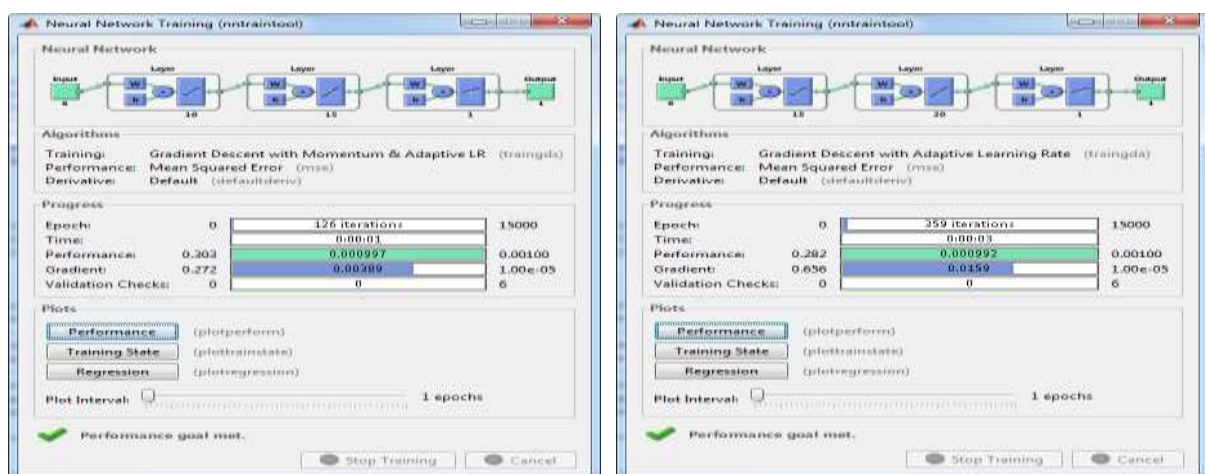
No	Model	Training			Testing		
		Epoch	Waktu	Nilai MSE	Fungsi Aktivasi	Nilai MSE	Akurasi
1	6-10-15-1	126	00:01	0,000996774	tansig, purelin, logsig	0,000881195	79%
2	6-15-20-1	142	00:01	0,000997322	tansig, purelin, logsig	0,000758693	82%
3	6-20-25-1	203	00:03	0,000997082	tansig, purelin, logsig	0,000907319	88%
4	6-25-30-1	97	00:01	0,000928816	tansig, purelin, logsig	0,000953942	74%

Berdasarkan hasil analisa yang disajikan pada tabel 5, tabel 6, tabel 7 dan tabel 8, dapat dilihat bahwa model arsitektur 6-10-15-1 dengan menggunakan fungsi traingd, traingdm, traingda, dan traingdx menghasilkan nilai akurasi yang sama sebesar 79%. Begitu pula dengan model arsitektur 6-20-25-1 yang menghasilkan akurasi sebesar 88%. Berbeda halnya dengan model arsitektur 6-15-20-1 dan model arsitektur 6-25-30-1 yang menghasilkan akurasi yang bervariasi. Setelah dilakukan perbandingan berdasarkan model-model arsitektur yang digunakan, nilai epoch, waktu training, nilai MSE training, fungsi aktivasi, fungsi train, nilai MSE testing dan tingkat akurasi, diperoleh hasil bahwa model arsitektur 6-15-20-1 merupakan model arsitektur terbaik dibandingkan 3 model yang lainnya dan fungsi traingda juga merupakan fungsi train terbaik dibandingkan traingd, traingdx dan traingdm dengan menghasilkan tingkat akurasi sebesar 91% dan nilai MSE testing yang lebih kecil. Bahkan untuk model arsitektur 6-20-25-1 fungsi traingda juga merupakan fungsi gradient descent yang terbaik, lebih baik dibandingkan traingd, traingdx dan traingdm.

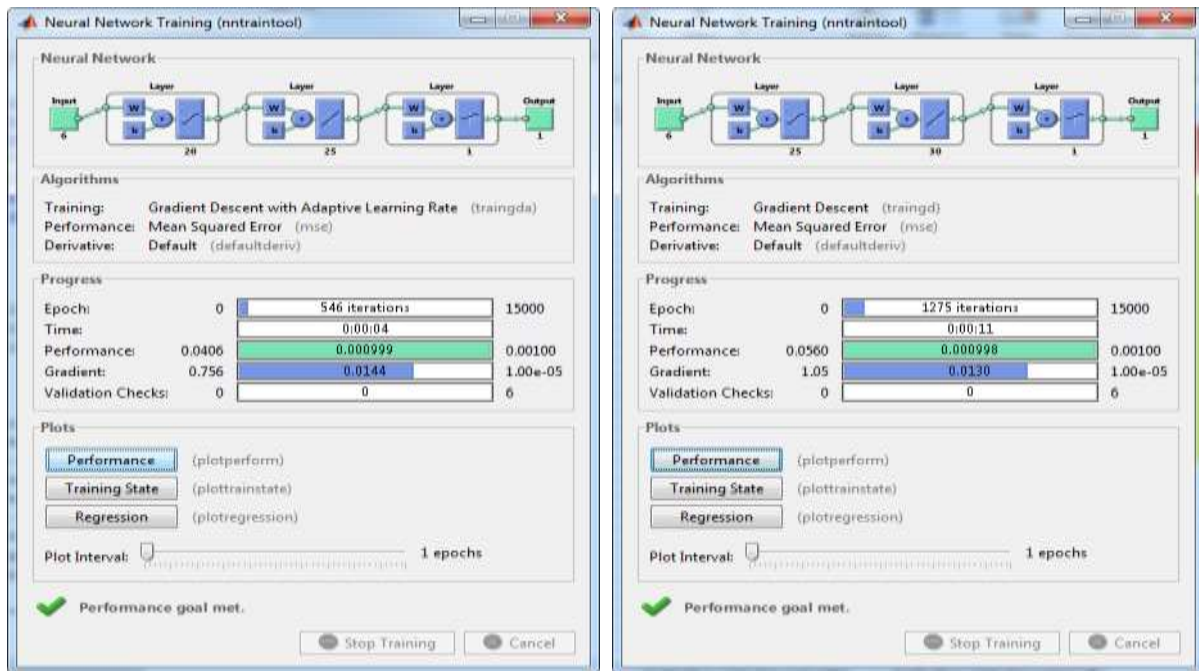
Tabel 9. Hasil Perbandingan dari masing-masing Model Arsitektur Terbaik

Model	Training				Testing		
	Epoch	Waktu	Nilai MSE	Fungsi Aktivasi	Fungsi Train	Nilai MSE	Akurasi
6-10-15-1	126	00:01	0,000996774	tansig, purelin, logsig	traingdx	0,000881195	79%
6-15-20-1	359	00:03	0,000992385	tansig, purelin, logsig	traingda	0,000731529	91%
6-20-25-1	546	00:04	0,000999453	tansig, purelin, logsig	traingda	0,000893522	88%
6-25-30-1	1275	00:11	0,000998332	tansig, purelin, logsig	traingd	0,000965694	79%

Berdasarkan tabel 9, proses training dan testing dari masing-masing model terbaik (6-10-15-1, 6-15-20-1, 6-20-25-1 dan 6-25-30-1) dapat dilihat pada gambar 2 berikut.



Gambar 2. (a) Proses Training dari masing-masing Model Arsitektur terbaik.



Gambar 2. (b) Proses Training dari masing-masing Model Arsitektur terbaik.

Hasil akurasi dari model arsitektur 6-15-20-1 dengan fungsi traingda yang sudah di proses dan dihitung dengan menggunakan aplikasi Matlab dan Excel, disajikan pada tabel 10 dan tabel 11 berikut.

Tabel 10. Data Pelatihan Model 6-15-20-1

Pola	Target	Output	Error	SSE
1	0,59463	0,59980	-0,00517	0,0000267061
2	0,59463	0,60390	-0,00927	0,0000858920
3	0,61785	0,59310	0,02475	0,0006127052
4	0,63280	0,65950	-0,02670	0,0007127201
5	0,58254	0,54770	0,03484	0,0012141553
6	0,53865	0,54710	-0,00845	0,0000714344
7	0,57332	0,55860	0,01472	0,0002166807
8	0,51988	0,54990	-0,03002	0,0009011574
9	0,58032	0,56220	0,01812	0,0003282652
10	0,72155	0,77520	-0,05365	0,0028782478
11	0,90000	0,84530	0,05470	0,0029920900
12	0,59622	0,56990	0,02632	0,0006928826
13	0,59400	0,57040	0,02360	0,0005567723
14	0,86119	0,86820	-0,00701	0,0000491003
15	0,58636	0,54870	0,03766	0,0014184134
16	0,62517	0,59950	0,02567	0,0006588968
17	0,71074	0,70700	0,00374	0,0000139546
18	0,46135	0,46030	0,00105	0,0000011065
19	0,37610	0,33370	0,04240	0,0017980466
20	0,46358	0,51580	-0,05222	0,0027270821
21	0,56696	0,57330	-0,00634	0,0000402178
22	0,56441	0,54800	0,01641	0,0002694036
23	0,74064	0,78460	-0,04396	0,0019328172
24	0,56918	0,65160	-0,08242	0,0067922502
25	0,62803	0,61430	0,01373	0,0001885626
26	0,51416	0,52620	-0,01204	0,0001450803
27	0,58700	0,56390	0,02310	0,0005335182
28	0,57268	0,56940	0,00328	0,0000107840
29	0,47662	0,51470	-0,03808	0,0014500652
30	0,39105	0,37030	0,02075	0,0004307151

Tabel 11. Data Pengujian Model 6-15-20-1

Pola	Target	Output	Error	SSE	Hasil
1	0,59788	0,59820	-0,00032	0,0000000997	1
2	0,59693	0,59350	0,00343	0,0000117385	1
3	0,61832	0,59430	0,02402	0,0005771215	1
4	0,63589	0,64300	-0,00711	0,0000505774	1
5	0,57840	0,54900	0,02940	0,0008645478	1
6	0,54232	0,55000	-0,00768	0,0000590535	1
7	0,57713	0,55110	0,02603	0,0006773396	1
8	0,52283	0,53570	-0,01287	0,0001655254	1
9	0,57840	0,57130	0,00710	0,0000504554	1
10	0,72084	0,76490	-0,04406	0,0019414313	1
11	0,90000	0,85200	0,04800	0,0023040000	0
12	0,60076	0,56570	0,03506	0,0012290972	0
13	0,59533	0,57140	0,02393	0,0005726134	1
14	0,86263	0,87810	-0,01547	0,0002391746	1
15	0,58735	0,55330	0,03405	0,0011590831	0
16	0,62407	0,59820	0,02587	0,0006693529	1
17	0,71605	0,73660	-0,02055	0,0004223886	1
18	0,46950	0,49490	-0,02540	0,0006451093	1
19	0,37848	0,37600	0,00248	0,0000061655	1
20	0,45928	0,49550	-0,03622	0,0013117843	1
21	0,57202	0,58070	-0,00868	0,0000754124	1
22	0,56754	0,55360	0,01394	0,0001944605	1
23	0,74224	0,79070	-0,04846	0,0023488050	1
24	0,57361	0,62710	-0,05349	0,0028608833	1
25	0,63174	0,60330	0,02844	0,0008086361	1
26	0,51836	0,53210	-0,01374	0,0001886977	1
27	0,58958	0,56910	0,02048	0,0004194647	1
28	0,57425	0,57390	0,00035	0,0000001236	1
29	0,48323	0,53660	-0,05337	0,0028479798	1
30	0,39669	0,41040	-0,01371	0,0001880566	1



Tabel 10. Data Pelatihan Model 6-15-20-1

Pola	Target	Output	Error	SSE
31	0,51829	0,56190	-0,04361	0,0019018096
32	0,48744	0,53140	-0,04396	0,0019328871
33	0,34684	0,35880	-0,01196	0,0001430663
34	0,21451	0,21820	-0,00369	0,0000135945
Jlh SSE				0,0337410814
MSE				0,0009923847

Tabel 11. Data Pengujian Model 6-15-20-1

Pola	Target	Output	Error	SSE	Hasil
31	0,52092	0,54350	-0,02258	0,0005099393	1
32	0,48930	0,52380	-0,03450	0,0011901536	1
33	0,35485	0,34810	0,00675	0,0000455665	1
34	0,23030	0,21490	0,01540	0,0002371416	1
Jlh SSE				0,0248719797	91%
MSE				0,0007315288	

Keterangan:

Target = Diperoleh dari target data pelatihan (tabel 4) dan target data pengujian (tabel 5)

Output = Diperoleh dari hasil perhitungan dengan matlab

Error = diperoleh dari Target-Output

SSE = diperoleh dari Error ²

Jlh SSE = Total SSE yang dihasilkan dari pola 1 – 34

MSE = Diperoleh dari Jumlah SSE / 34 (34 adalah jumlah pola)

Hasil = Jika nilai Error dalam data pengujian <= 0,03 maka hasilnya benar (1). Jika tidak maka salah (0).

Akurasi = Diperoleh dari jumlah hasil yang benar ((Pola / 34) * 100), menghasilkan akurasi 91%.

4. KESIMPULAN

Berdasarkan permasalahan yang terdapat pada makalah ini, maka dapat diambil kesimpulan bahwa Gradient descent with adaptive learning rate backpropagation (traingda) dengan fungsi aktivasi sigmoid bipolar (tansig), fungsi linier (purelin) dan sigmoid biner (logsig) merupakan metode gradient descent yang terbaik apabila digunakan pada algoritma backpropagation untuk memprediksi data times series dengan model arsitektur 6-15-20-1, akan tetapi hal ini belum tentu sama hasilnya apabila parameter fungsi aktivasi yang digunakan berbeda. Hasil juga bisa berbeda apabila menggunakan model arsitektur yang berbeda, karena pada kasus ini model arsitektur yang digunakan menggunakan 2 hidden layer (lapisan tersembunyi).

REFERENCES

- [1] J. J. Siang, *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Penerbit Andi Yogyakarta, 2005.
- [2] M. Megawati and R. M. Candra, "Diagnosa Hama Dan Penyakit Pada Tanaman Jeruk Dengan Menerapkan Jaringan Syaraf Tiruan Learning Vector Quantization," *Jurnal CoreIT: Jurnal Hasil Penelitian Ilmu Komputer dan Teknologi Informasi*, vol. 3, no. 2, pp. 59–62, 2018.
- [3] Y. Ayyappa and A. Krishna, "Enhanced and Effective Computerized Multi Layered Perceptron based Back Propagation Brain Tumor Detection with Gaussian Filtering," in *Proceedings of the Second International Conference on Inventive Research in Computing Applications (ICIRCA-2020)*. IEEE Xplore Part Number: CFP20N67-ART; ISBN: 978-1-7281-5374-2, 2020, pp. 58–62.
- [4] B. T. Pham, M. D. Nguyen, K. T. T. Bui, I. Prakash, K. Chapi, and D. T. Bui, "A novel artificial intelligence approach based on Multi-layer Perceptron Neural Network and Biogeography-based Optimization for predicting coefficient of consolidation of soil," *Catena*, vol. 173, no. September 2018, pp. 302–311, 2019.
- [5] A. Wanto, "Prediksi Produktivitas Jagung Di Indonesia Sebagai Upaya Antisipasi Impor Menggunakan Jaringan Saraf Tiruan Backpropagation," *SINTECH (Science and Information Technology) Journal*, vol. 2, no. 1, pp. 53–62, 2019.
- [6] A. Wanto, "Optimasi Prediksi Dengan Algoritma Backpropagation Dan Conjugate Gradient Beale-Powell Restarts," *Jurnal Teknologi dan Sistem Informasi*, vol. 3, no. 3, pp. 370–380, Jan. 2017.
- [7] A. P. Windarto et al., *Jaringan Saraf Tiruan: Algoritma Prediksi dan Implementasi*. Yayasan Kita Menulis, 2020.
- [8] V. Ranganathan and S. Natarajan, "A New Backpropagation Algorithm without Gradient Descent," pp. 1–15, 2018.
- [9] F. A. Ruslan, A. M. Samad, and R. Adnan, "4 Hours NNARX flood prediction model using 'traingd' and 'trainoss' training function: A comparative study," *Proceedings - 2018 IEEE 14th International Colloquium on Signal Processing and its Application, CSPA 2018*, no. March, pp. 77–81, 2018.
- [10] M. Haryati and O. W. Arsani, "JurnalRiset Teknologi dan Inovasi Pendidikan Analisis Tingkat Akurasi Model Backpropagation Dalam Prediksi Indeks Pembangunan Manusia (IPM) di NTB Pendahuluan Peramalan (Forecasting) adalah kegiatan mengestimasi apa yang semakin berkembang dengan meman," (*JARTIKA) Jurnal Riset Teknologi dan Inovasi Pendidikan*, vol. 2, no. 2, pp. 94–102, 2019.
- [11] A. Pamungkas, R. Zulkarnain, K. Adiyana, Waryanto, H. Nugroho, and A. S. Saragih, "Application of Artificial Neural Networks to forecast Litopenaeus vannamei and Penaeus monodon harvests in Indramayu Regency, Indonesia," *IOP Conference Series: Earth and Environmental Science*, vol. 521, no. 1, pp. 1–9, 2020.
- [12] BPS, "[Metode Baru] Indeks Pembangunan Manusia menurut Provinsi," 2020. [Online]. Available: <https://www.bps.go.id/indicator/26/494/1/-metode-baru-indeks-pembangunan-manusia-menurut-provinsi.html>. [Accessed: 20-Sep-2020].
- [13] S. Setti and A. Wanto, "Analysis of Backpropagation Algorithm in Predicting the Most Number of Internet Users in the World," *JOIN (Jurnal Online Informatika)*, vol. 3, no. 2, pp. 110–115, 2018.



- [14] 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*, vol. 3, no. 2, pp. 268–275, 2020.
- [15] 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.