

ANALISIS TINGKAT AKURASI ALGORITMA BACKPROPAGATION DALAM PREDIKSI PRODUKSI UBI KAYU DI PROVINSI INDONESIA

Nuraysah Zamil Purba¹, Deviana Sitompul²

Program Studi Teknik Informatika, STIKOM Tunas Bangsa Pematangsiantar.
Jln. Sudirman Blok A No 1,2 dan 3 Pematangsiantar 21111 - Indonesia
nuraysah7388@gmail.com, devianaitompul821@gmail.com

Abstract

Cassava is one type of food that is widely consumed by the people of Indonesia. In addition to the typical taste, cassava is often processed by the community into a cake or snacks that diverse. According to the statistical report of cassava agriculture in Indonesia from 2005-2015 experience up and down. In order to improve the cassava in Indonesia, it is necessary to make a prediction for the coming year so that the government will have a reference to immediately make the right policy to increase the production of cassava in Indonesia to prevent the increase of cassava import quantity. This study aims to determine the development of cassava production in Indonesia, in the hope that it can be used as a reference to increase the production and productivity of cassava. Data used in this research is data of cassava production in province of Indonesia year 2005-2015, algorithm used is Artificial Neural Network Backpropagation. Data analysis was done using Matlab 2011b. This research uses 5 architecture that is 5-8-1, 5-10-1, 5-15-1, 5-18-1, 5-20-1 but the best architecture is 5-18-1 with percentage accuracy 94% and MSE value of 0.007227812. This model is well used to predict cassava in the province of Indonesia.

Keywords: Analysis, Accuracy, Backpropagation, Prediction, Cassava

Abstrak

Ubi kayu merupakan salah satu jenis bahan pangan yang banyak dikonsumsi oleh penduduk Indonesia. Selain rasanya yang khas, ubi kayu sering diolah oleh masyarakat menjadi kue atau jajanan yang beraneka ragam. Menurut laporan statistik pertanian ubi kayu di Indonesia dari tahun 2005-2015 mengalami naik turun. Untuk mengupayakan peningkatan ubi kayu di Indonesia, perlu dilakukan yang namanya prediksi untuk tahun yang akan datang sehingga nantinya pemerintah memiliki acuan untuk segera membuat kebijakan yang tepat dalam upaya peningkatan produksi ubi kayu di Indonesia untuk mencegah peningkatan jumlah import ubi kayu. Penelitian ini bertujuan untuk mengetahui perkembangan produksi ubi kayu di Indonesia, dengan harapan dapat dijadikan referensi untuk turut meningkatkan produksi dan produktivitas ubi kayu. Data yang digunakan pada penelitian ini adalah data produksi ubi kayu di provinsi Indonesia tahun 2005-2015, algoritma yang digunakan adalah Jaringan Saraf Tiruan *Backpropagation*. Analisa data dilakukan dengan menggunakan Matlab 2011b. Penelitian ini menggunakan 5 arsitektur yaitu 5-8-1, 5-10-1, 5-15-1, 5-18-1, 5-20-1 tapi arsitektur yang terbaik adalah 5-18-1 dengan persentase akurasi 94% dan nilai MSE sebesar 0,007227812. Model ini baik digunakan untuk memprediksi ubi kayu di provinsi Indonesia.

Kata Kunci : Analisis, Akurasi, *Backpropagation*, Prediksi, Ubi Kayu

1. PENDAHULUAN

Ubi kayu merupakan salah satu tanaman utama penghasil pati, selain jagung, sorghum, gandum, beras, sugu, dan kentang, dengan karakteristik masing-masing pati berbeda [1]. Ubi kayu juga merupakan salah satu komoditas tanaman pangan yang menjadi unggulan dan mempunyai potensi dalam pertumbuhan ekonomi Indonesia [2]. Di Indonesia sendiri, ubi kayu termasuk bahan makanan penting setelah padi dan jagung [3]. Pentingnya ubikayu dalam mewujudkan kedaulatan

pangan di Indonesia adalah karena ubikayu selain berperan dalam pemenuhan kebutuhan sumber karbohidrat untuk substitusi beras, juga untuk diversifikasi pangan. Ubikayu juga dapat dimanfaatkan sebagai sumber pakan, bahan baku industri dan bahan baku bioethanol. Karena begitu pentingnya ubi kayu sebagai salah satu sumber bahan makanan di Indonesia, maka perlu dilakukan tindakan dan langkah yang tepat dari Pemerintah Indonesia, agar produksi ubi kayu tetap stabil dari tahun ketahun.

Pada tabel 1 dapat dilihat data produksi ubi kayu pada tiap provinsi di Indonesia. Berdasarkan tabel 1 bahwa produksi ubi kayu dari tahun 2005 sampai dengan tahun 2015 tidak stabil, kadang produksinya naik bahkan kadang menurun. Pada daerah-daerah seperti pada provinsi Aceh, Jawa Tengah, Yogyakarta, Bali, Jawa Timur, Nusa Tenggara Timur, Kalimantan Barat, Kalimantan Tengah, Kalimantan Selatan, Kalimantan Timur, Sulawesi Tengah, Sulawesi Utara, Gorontalo, Sulawesi Barat, dan Papua Barat secara umum produksi ubi kayu mengalami penurunan. Sedangkan di provinsi-provinsi lainnya relatif menaik.

Tabel 1. Data Produksi Ubi Kayu Di Provinsi Indonesia

Provinsi	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
Aceh	53424	46504	41558	38403	49839	43810	39384	38257	34738	31621	29131
Sumatera Utara	509796	452450	438573	736771	1007284	905571	1091711	1171520	1518221	1383346	1619495
Sumatera Barat	114199	133095	114551	102285	115492	193188	191946	213647	218830	217962	208386
Riau	41668	47586	51784	50772	68046	75904	79480	88577	103070	117287	103599
Jambi	39780	40779	44794	36905	39355	39564	40462	38978	33291	35550	43433
Sumatera Selatan	179952	228321	150133	197150	166890	159929	159346	143565	165250	220014	217807
Bengkulu	79934	113488	76924	49478	37311	43847	47735	57618	62193	78853	80309
Lampung	4806254	5499403	6394906	7721882	7569178	8637594	9193676	8387351	8329201	8034016	7387084
Kep. Bangka Belitung	19234	17264	18666	19722	23332	21427	13276	13469	14203	19759	35024
Kep. Riau	3526	6899	7077	9364	9180	8397	7805	7666	8530	8979	9157
Jawa Barat	2068981	2044674	1922840	2034854	2086187	2014402	2058785	2131123	2138532	2250024	2000224
Jawa Tengah	3478970	3553820	3410469	3325099	3676809	3876242	3501458	3848462	4089635	3977810	3571594
Di Yogyakarta	920909	1016270	976610	892907	1047684	1114665	867596	866357	1013565	884931	873362
Jawa Timur	4023614	3680567	3423630	3533772	3222637	3667058	4032081	4246028	3601074	3635454	3161573
Banten	144110	143561	117550	115591	105621	118979	107052	82796	97847	85943	74163
Bali	155808	159058	174189	169761	171456	163746	166291	147201	156953	131887	86070
Nusa Tenggara Barat	92991	87041	88527	68386	85062	70606	75367	79472	59085	92643	107254
Nusa Tenggara Timur	891783	938010	794121	928974	913053	1032538	962128	892145	811166	677577	637315
Kalimantan Barat	243251	250173	221630	193804	166584	177807	141550	153564	168521	192967	173449
Kalimantan Tengah	73866	65661	67617	73344	74670	76669	49475	46630	40762	43342	45712
Kalimantan Selatan	80377	82389	117322	119085	121656	76202	86504	90043	87323	92272	71751
Kalimantan Timur	93885	101249	105395	116218	125714	110061	91858	82786	55519	60941	53966
Sulawesi Utara	68463	82416	74406	83656	77206	84084	70147	63187	55207	46553	44123
Sulawesi Tengah	48256	52791	70858	70181	82294	74128	83139	93642	100950	84688	47295
Sulawesi Selatan	464435	567749	514277	504198	434862	601437	370125	682995	433399	478486	565958
Sulawesi Tenggara	256467	238039	239271	217727	226927	163350	164850	175719	180680	175086	175095
Gorontalo	12211	9410	7432	9215	7117	6171	5910	3776	4537	3987	2653
Sulawesi Barat	56717	40413	45921	54809	47781	46368	47670	48265	52972	29902	24984
Maluku	94995	103260	105761	107214	124442	144407	125763	119545	97813	97959	134661
Maluku Utara	142680	123833	118354	116838	106443	109033	115940	116515	119799	147917	120283
Papua Barat	25897	21838	17834	23072	12228	25113	20440	9747	12219	11169	11181
Papua	33959	37825	34450	35100	36500	35531	34899	36679	38901	45512	46388

Oleh karena itu perlu dilakukan prediksi (peramalan) [4][5][6], terhadap produksi ubi kayu di Indonesia untuk tahun-tahun selanjutnya agar produksi ubi kayu tetap stabil. Salah satu cara yang sering digunakan untuk melakukan prediksi adalah dengan menggunakan jaringan saraf tiruan. Jaringan saraf tiruan (JST) adalah representasi buatan dari otak manusia yang selalu mencoba untuk mensimulasikan proses pembelajaran pada otak manusia. Istilah buatan digunakan karena jaringan saraf ini diimplementasikan dengan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran [7][8][9]. Salah satu penggunaan teknik yang baik untuk prediksi adalah penerapan jaringan saraf tiruan *Backpropagation*, hal ini karena algoritma *Backpropagation* mampu menghindari kesulitan yang dijelaskan dengan menggunakan aturan belajar yang mirip dengan plastisitas lonjakan waktu yang tergantung pada sinapsis [10][11][12]. Maksudnya bahwa algoritma *Backpropagation* ini mampu mengatasi ketidakmampuan otak biasa dalam mengingat hal-hal yang sudah pernah terjadi di masa lampau dengan melakukan proses pembelajaran memori.

2. METODE PENELITIAN

2.1. Analisis

Analisis adalah sebuah kemampuan untuk memecahkan suatu masalah subjek kedalam elemen-elemen konstituen, mencari hubungan-hubungan internal, serta mengatur format-format pemecahan masalah secara keseluruhan yang ada. Analisis data bertujuan untuk membuktikan hipotesis, dan atau menjelaskan fenomena yang menjadi latar belakang penelitian [13][14].

2.2. Jaringan Saraf Tiruan *Backpropagation*

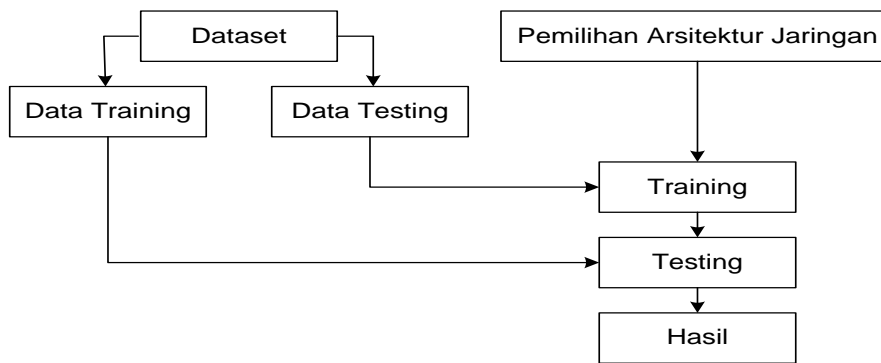
Backpropagation merupakan sebuah metode sistematis untuk pelatihan multiplayer jaringan saraf tiruan. Metode ini memiliki dasar matematis yang kuat, obyektif dan algoritma ini mendapatkan bentuk persamaan dan nilai koefisien dalam formula dengan meminimalkan jumlah kuadrat galat error melalui model yang dikembangkan [15][16]. *Backpropagation* merupakan algoritma pembelajaran yang terawasi dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot yang terhubung dengan neuron yang ada pada lapisan tersembunyinya [17][18].

2.3. Prediksi

Prediksi adalah memperkirakan suatu hal yang akan terjadi di waktu yang akan datang berdasarkan data-data dimasa yang lampau dianalisis secara ilmiah. Prediksi dapat diartikan sebagai penggunaan teknik-teknik statistik dalam bentuk gambaran masa depan berdasarkan pengolahan angka-angka historis [19]. Definisi lain dari prediksi ialah suatu usaha untuk meramalkan suatu keadaan dimasa mendatang melalui pengujian data-data di masa lalu [20].

2.4. Tahapan Penelitian

Adapun tahapan penelitian dalam tulisan ini dalapat dilihat pada gambar 1 berikut.



Gambar 1. Tahapan Penelitian

Pada gambar 1 diatas, pertama sekali yang dilakukan ialah pemilihan dataset, dimana dataset yang digunakan adalah data Produksi Ubi Kayu Di Provinsi Indonesia tahun 2005 hingga tahun 2015. Pada dataset ini akan dilakukan praprocessing data untuk membagi data menjadi dua bagian yaitu dataset untuk training dan dataset untuk testing. Tahapan selanjutnya adalah pemilihan arsitektur jaringan untuk memproses data training dan data testing, sehingga akan diperoleh hasil yang terbaik.

2.5. Data Yang Digunakan

Data yang digunakan untuk penelitian ini adalah data produksi ubi kayu menurut Provinsi di Indonesia (Dapat dilihat di Tabel 1 pada pembahasan sebelumnya) yang diperoleh dari Badan Pusat Statistik (BPS) Indonesia. Data pada tabel 1 nanti nya akan dibagi menjadi 2 bagian, yaitu data training dan data testing. Data training yang digunakan yakni data tahun 2005-2009 dengan target tahun 2010, sedangkan untuk data testing yang digunakan yakni data tahun 2010-2014 dengan target tahun 2015

2.6. Normalisasi Data

Data mentah (data awal) yang telah dikumpulkan harus terlebih dahulu dinormalisasi dengan menggunakan fungsi Sigmoid. Artinya data yang dinormalisasi nanti nya akan menghasilkan nilai antara 0 dan 1 (Tidak boleh 0 dan 1, apalagi lebih dari itu), karena hal itu sudah merupakan ketentuan dari normalisasi. Normalisasi data dilakukan dengan menggunakan persamaan :

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

Keterangan :

x' = Normalisasi data

x = Data yang akan dinormalisasi

a = Data terendah

b = Data tertinggi

Pada tabel 2 dapat dilihat hasil normalisasi data training. Data ini telah dinormalisasi menggunakan fungsi sigmoid (persamaan 1) berdasarkan pada tabel 1, yakni tahun 2005-2009 dengan target tahun 2010.

Tabel 2. Normalisasi Data Training Tahun 2005-2009 / Target Tahun 2010

Provinsi	2005	2006	2007	2008	2009	Target
Aceh	0,10462	0,10398	0,10352	0,10323	0,10429	0,10373
Sumatera Utara	0,14691	0,14160	0,14031	0,16794	0,19300	0,18358
Sumatera Barat	0,11025	0,11201	0,11029	0,10915	0,11037	0,11757
Riau	0,10353	0,10408	0,10447	0,10438	0,10598	0,10671
Jambi	0,10336	0,10345	0,10382	0,10309	0,10332	0,10334
Sumatera Selatan	0,11635	0,12083	0,11358	0,11794	0,11514	0,11449
Bengkulu	0,10708	0,11019	0,10680	0,10426	0,10313	0,10374
Lampung	0,54500	0,60923	0,69220	0,81515	0,80100	0,90000
Kep. Bangka Belitung	0,10146	0,10127	0,10140	0,10150	0,10184	0,10166
Kep. Riau	0,10000	0,10031	0,10033	0,10054	0,10052	0,10045
Jawa Barat	0,29138	0,28913	0,27784	0,28822	0,29297	0,28632
Jawa Tengah	0,42202	0,42896	0,41567	0,40776	0,44035	0,45883
Di yogyakarta	0,18500	0,19384	0,19016	0,18241	0,19675	0,20295
Jawa Timur	0,47249	0,44070	0,41689	0,42710	0,39827	0,43945
Banten	0,11303	0,11298	0,11057	0,11038	0,10946	0,11070
Bali	0,11411	0,11441	0,11581	0,11540	0,11556	0,11485
Nusa Tenggara Barat	0,10829	0,10774	0,10788	0,10601	0,10755	0,10622
Nusa Tenggara Timur	0,18230	0,18659	0,17325	0,18575	0,18427	0,19534
Kalimantan Barat	0,12221	0,12285	0,12021	0,11763	0,11511	0,11615
Kalimantan Tengah	0,10652	0,10576	0,10594	0,10647	0,10659	0,10678
Kalimantan Selatan	0,10712	0,10731	0,11054	0,11071	0,11095	0,10673
Kalimantan Timur	0,10837	0,10905	0,10944	0,11044	0,11132	0,10987
Sulawesi Utara	0,10602	0,10731	0,10657	0,10742	0,10683	0,10746
Sulawesi Tengah	0,10414	0,10456	0,10624	0,10618	0,10730	0,10654
Sulawesi Selatan	0,14271	0,15228	0,14732	0,14639	0,13997	0,15540
Sulawesi Tenggara	0,12344	0,12173	0,12184	0,11985	0,12070	0,11481
Gorontalo	0,10080	0,10055	0,10036	0,10053	0,10033	0,10025
Sulawesi Barat	0,10493	0,10342	0,10393	0,10475	0,10410	0,10397
Maluku	0,10848	0,10924	0,10947	0,10961	0,11120	0,11305
Maluku Utara	0,11289	0,11115	0,11064	0,11050	0,10954	0,10978
Papua Barat	0,10207	0,10170	0,10133	0,10181	0,10081	0,10200
Papua	0,10282	0,10318	0,10287	0,10293	0,10306	0,10297

Pada tabel 3 dapat dilihat hasil normalisasi data testing. Data ini telah dinormalisasi menggunakan fungsi sigmoid (persamaan 1) berdasarkan pada tabel 1, yakni tahun 2010-2014 dengan target tahun 2015.

Tabel 3. Normalisasi Data Testing Tahun 2010-2014 / Target Tahun 2015

Provinsi	2010	2011	2012	2013	2014	Target
Aceh	0,10358	0,10320	0,10310	0,10279	0,10252	0,10230
Sumatera Utara	0,17859	0,19479	0,20174	0,23192	0,22018	0,24073
Sumatera Barat	0,11658	0,11648	0,11837	0,11882	0,11874	0,11791
Riau	0,10638	0,10669	0,10748	0,10874	0,10998	0,10879

Provinsi	2010	2011	2012	2013	2014	Target
Jambi	0,10321	0,10329	0,10316	0,10267	0,10286	0,10355
Sumatera Selatan	0,11369	0,11364	0,11227	0,11415	0,11892	0,11873
Bengkulu	0,10359	0,10392	0,10478	0,10518	0,10663	0,10676
Lampung	0,85160	0,90000	0,82982	0,82475	0,79906	0,74275
Kep. Bangka Belitung	0,10163	0,10092	0,10094	0,10101	0,10149	0,10282
Kep. Riau	0,10050	0,10045	0,10044	0,10051	0,10055	0,10057
Jawa Barat	0,27511	0,27897	0,28527	0,28591	0,29561	0,27387
Jawa Tengah	0,43716	0,40454	0,43474	0,45574	0,44600	0,41065
Di yogyakarta	0,19679	0,17529	0,17518	0,18799	0,17679	0,17579
Jawa Timur	0,41896	0,45073	0,46935	0,41321	0,41620	0,37496
Banten	0,11013	0,10909	0,10698	0,10829	0,10725	0,10622
Bali	0,11402	0,11424	0,11258	0,11343	0,11125	0,10726
Nusa Tenggara Barat	0,10591	0,10633	0,10669	0,10491	0,10783	0,10910
Nusa Tenggara Timur	0,18964	0,18351	0,17742	0,17037	0,15875	0,15524
Kalimantan Barat	0,11525	0,11209	0,11314	0,11444	0,11657	0,11487
Kalimantan Tengah	0,10644	0,10408	0,10383	0,10332	0,10354	0,10375
Kalimantan Selatan	0,10640	0,10730	0,10761	0,10737	0,10780	0,10601
Kalimantan Timur	0,10935	0,10776	0,10697	0,10460	0,10507	0,10447
Sulawesi Utara	0,10709	0,10587	0,10527	0,10457	0,10382	0,10361
Sulawesi Tengah	0,10622	0,10701	0,10792	0,10856	0,10714	0,10389
Sulawesi Selatan	0,15212	0,13199	0,15922	0,13749	0,14142	0,14903
Sulawesi Tenggara	0,11399	0,11412	0,11506	0,11550	0,11501	0,11501
Gorontalo	0,10031	0,10028	0,10010	0,10016	0,10012	0,10000
Sulawesi Barat	0,10381	0,10392	0,10397	0,10438	0,10237	0,10194
Maluku	0,11234	0,11072	0,11017	0,10828	0,10830	0,11149
Maluku Utara	0,10926	0,10986	0,10991	0,11020	0,11264	0,11024
Papua Barat	0,10195	0,10155	0,10062	0,10083	0,10074	0,10074
Papua	0,10286	0,10281	0,10296	0,10316	0,10373	0,10381

3. HASIL DAN PEMBAHASAN

3.1. Analisis

Sebelum training dilakukan, terlebih dahulu menentukan nilai parameter yang diinginkan untuk memperoleh hasil yang optimal. Parameter yang digunakan secara umum pada aplikasi Matlab untuk training dan testing dapat dilihat pada kode berikut :

```
>> net=newff(minmax(P),[ Hidden,Target],{'transig','purelin'},'traingd');
//Perintah ini digunakan untuk membentuk jaringan pada Backpropagation dengan hidden layer 19
dan output 1, dengan menggunakan fungsi aktivasi tansig dan purelin serta fungsi pelatihan traingd.
>> net.IW{1,1};
// Perintah ini digunakan untuk melihat nilai bobot awal pada lapisan masukan dan lapisan
tersembunyi (bilangan diambil secara acak dari komputer)
>> net.b{1};
// Perintah ini digunakan untuk melihat nilai bias awal pada lapisan tersembunyi (bilangan diambil
secara acak dari komputer)
>> net.LW{2,1};
```

// Perintah ini digunakan untuk melihat nilai bobot awal pada lapisan tersembunyi dan lapisan keluaran (bilangan diambil secara acak dari komputer)

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

// Perintah ini digunakan untuk melihat nilai bias awal pada lapisan keluaran (bilangan diambil secara acak dari komputer)

```
>> net.trainParam.epochs=10000;
```

// Perintah yang dipakai untuk menentukan jumlah epochs maksimum pelatihan

```
>> net.trainParam.goal=0.001;
```

//Perintah untuk menentukan batas MSE agar iterasi dihentikan. Iterasi akan berhenti jika MSE < dari batas yang ditentukan atau jumlah epoch telah mencapai maksimum sesuai nilai yang diberikan pada perintah net.trainParam.epochs

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

//Perintah yang digunakan untuk menentukan laju pembelajaran (learning rate). Default-nya adalah 0,01. Semakin besar nilai laju pembelajaran, semakin cepat pula proses pelatihan. Akan tetapi jika nilainya terlalu besar, algoritma menjadi tidak stabil dan mencapai titik minimum lokal

```
>> net.trainParam.show=1000;
```

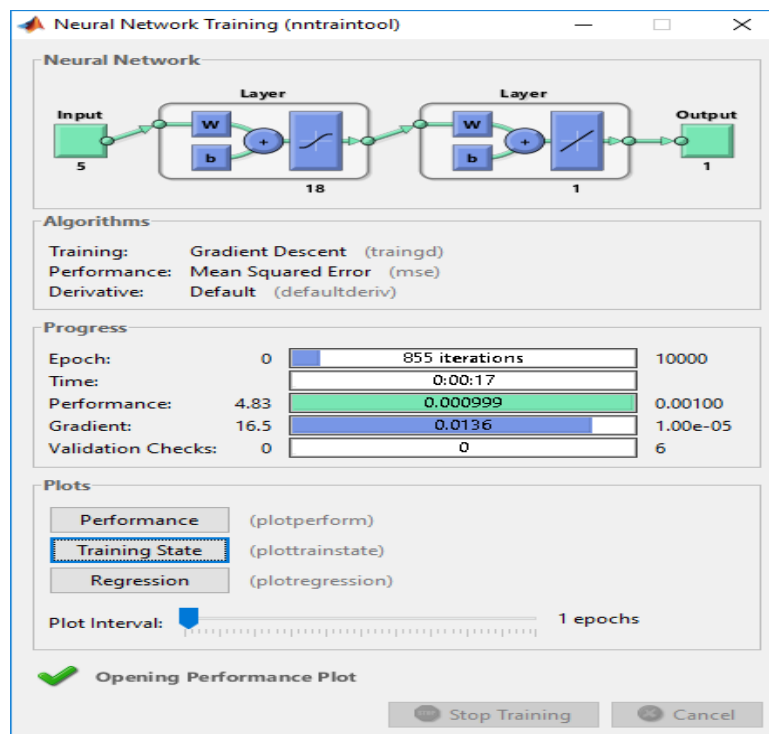
// Perintah yang digunakan untuk menampilkan frekuensi perubahan MSE

```
>> net=train(net,P,T);
```

// Perintah untuk menampilkan hasil dari data training dan data testing yang telah di masukkan pada aplikasi matlab

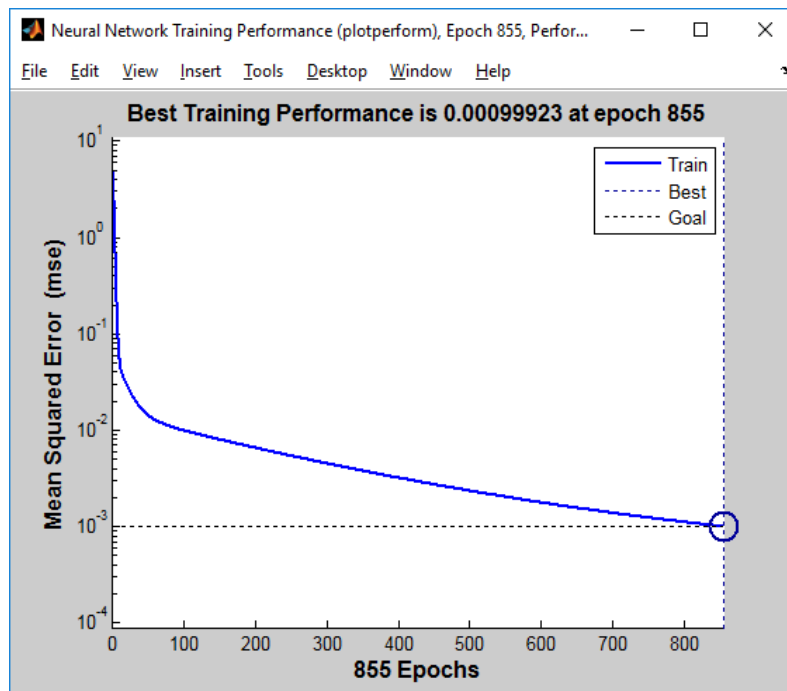
3.2. Hasil

Penelitian ini menggunakan 5 arsitektur, antara lain : 5-8-1, 5-10-1, 5-15-1, 5-18-1 dan 5-20-1. Dari kelima arsitektur tersebut, arsitektur yang terbaik ialah 5-18-1 dengan tingkat akurasi sebesar 94% serta epoch sebesar 885 iterasi.



Gambar 2. Data Training Dengan Model Arsitektur 5-18-1

Dari gambar 2 data training dengan model arsitektur 5-18-1 dapat dijelaskan bahwa epoch yang terjadi sebesar 855 iterations dengan waktu yang cukup cepat, yakni selama 17 detik.



Gambar 3. Best Training Performance Dengan Arsitektur 5-18-1

Berdasarkan gambar 3 dapat dijelaskan bahwa *performance* pelatihan terbaik adalah 0.00099923 pada epoch 855. Tabel 4 merupakan hasil akurasi dari model arsitektur terbaik dengan algoritma *Backpropagation*, yakni 5-18-1. Tabel 4 ini dibuat dan dihitung dengan menggunakan Microsoft Excel.

Tabel 4. Arsitektur Terbaik Algoritma *Backpropagation* dengan Model 5-18-1

No	Data Training				Data Testing				Hasil
	Target	Output	Error	SSE	Target	Output	Error	SSE	
1	0,10373	0,11990	0,06368	0,00405515	0,10230	0,12010	-0,01780	0,00031667	1
2	0,18358	0,16390	-0,04633	0,00214616	0,24073	0,24850	-0,00777	0,00006034	1
3	0,11757	0,11550	-0,00879	0,00007733	0,11791	0,11880	-0,00089	0,00000080	1
4	0,10671	0,12100	-0,01766	0,00031191	0,10879	0,12100	-0,01221	0,00014917	1
5	0,10334	0,12050	-0,00601	0,00003610	0,10355	0,12020	-0,01665	0,00027724	1
6	0,11449	0,10640	-0,00266	0,00000710	0,11873	0,11800	0,00073	0,00000053	1
7	0,10374	0,11320	0,78680	0,61905424	0,10676	0,12160	-0,01484	0,00022025	1
8	0,90000	0,89110	-0,78944	0,62321766	0,74275	0,75540	-0,01265	0,00015998	1
9	0,10166	0,12130	-0,02085	0,00043467	0,10282	0,12140	-0,01858	0,00034530	1
10	0,10045	0,12150	0,16482	0,02716568	0,10057	0,12140	-0,02083	0,00043405	1
11	0,28632	0,28860	0,17023	0,02897865	0,27387	0,40250	-0,12863	0,01654530	1
12	0,45883	0,43920	-0,23625	0,05581221	0,41065	0,71660	-0,30595	0,09360797	1
13	0,20295	0,11250	0,32695	0,10689564	0,17579	0,12040	0,05539	0,00306781	0
14	0,43945	0,50910	-0,39840	0,15872460	0,37496	0,69700	-0,32204	0,10371170	1
15	0,11070	0,11370	0,00115	0,00000131	0,10622	0,11600	-0,00978	0,00009556	1

No	Data Training				Data Testing				Hasil
	Target	Output	Error	SSE	Target	Output	Error	SSE	
16	0,11485	0,11840	-0,01218	0,00014847	0,10726	0,11420	-0,00694	0,00004815	1
17	0,10622	0,11880	0,07654	0,00585904	0,10910	0,12010	-0,01100	0,00012090	1
18	0,19534	0,09490	0,02125	0,00045149	0,15524	0,05780	0,09744	0,00949492	0
19	0,11615	0,10730	-0,00052	0,00000027	0,11487	0,12000	-0,00513	0,00002635	1
20	0,10678	0,11990	-0,01317	0,00017335	0,10375	0,11960	-0,01585	0,00025129	1
21	0,10673	0,12260	-0,01273	0,00016202	0,10601	0,11940	-0,01339	0,00017917	1
22	0,10987	0,11960	-0,01214	0,00014728	0,10447	0,11710	-0,01263	0,00015961	1
23	0,10746	0,11840	-0,01186	0,00014062	0,10361	0,11830	-0,01469	0,00021581	1
24	0,10654	0,12200	0,03340	0,00111557	0,10389	0,11980	-0,01591	0,00025326	1
25	0,15540	0,09490	0,01991	0,00039636	0,14903	0,14730	0,00173	0,00000300	1
26	0,11481	0,11330	-0,01305	0,00017043	0,11501	0,11800	-0,00299	0,00000894	1
27	0,10025	0,12110	-0,01713	0,00029345	0,10000	0,12120	-0,02120	0,00044944	1
28	0,10397	0,12090	-0,00785	0,00006157	0,10194	0,11970	-0,01776	0,00031529	1
29	0,11305	0,11930	-0,00952	0,00009071	0,11149	0,11620	-0,00471	0,00002218	1
30	0,10978	0,11650	-0,01450	0,00021025	0,11024	0,11930	-0,00906	0,00008211	1
31	0,10200	0,12040	-0,01743	0,00030396	0,10074	0,12010	-0,01936	0,00037472	1
32	0,10297	0,12020	-0,12020	0,01444804	0,10381	0,12090	-0,01709	0,00029218	1
			SSE	1,65109127			SSE	0,23128999	94 %
			MSE	0,05159660			MSE	0,00722781	

Keterangan :

1=Benar 0=Salah

Pada tabel 5 dapat dilihat perbandingan dari 5 model arsitektur jaringan yang digunakan. Dari ke 5 model arsitektur ini, tingkat Epoch dan waktu diperoleh dengan menggunakan aplikasi Matlab, sedangkan MSE dan Akurasi dari masing-masing model arsitektur diperoleh dengan menggunakan perhitungan pada Microsoft Excel. Model arsitektur terbaik adalah 5-18-1 yang menghasilkan tingkat akurasi yang sama sebesar 94%.

Tabel 5. Perbandingan Akurasi Model Arsitektur *Backpropagation*

No	Arsitektur	Training			Testing	
		Epoch	Waktu	MSE	MSE	Akurasi
1	5-8-1	5978	1:33	0,000999858	0,002536222	84 %
2	5-10-1	6262	1:38	0,049458460	0,038720990	72 %
3	5-15-1	1285	0:28	0,000999007	0,007851080	47 %
4	5-18-1	855	0:17	0,051596602	0,007227812	94 %
5	5-20-1	2000	0:37	0,001000131	0,026721617	88 %

4. SIMPULAN

Berdasarkan uraian hasil pembahasan sebelumnya dapat disimpulkan bahwa dari 5 model arsitektur yang digunakan antara lain : 5-8-1, 5-10-1, 5-15-1, 5-18-1 dan 5-20-1, diperoleh model arsitektur terbaik, yakni model 5-18-1 yang dapat melakukan prediksi dengan akurasi 94%. Epoch serta waktu model arsitektur 5-18-1 juga lebih kecil (cepat) dibandingkan dengan 4 model arsitektur yang lain.

DAFTAR PUSTAKA

- [1] I. Subekti, N. Khumaida, S. W. Ardie, and M. Syukur, "Evaluasi Hasil dan Kandungan Pati Mutan Ubi Kayu Hasil Iradiasi Sinar Gamma Generasi M 1 V 4," *Jurnal Agron Indonesia*, vol. 46, no. April, pp. 64–70, 2018.
- [2] F. S. Pramesti, E. S. Rahayu, and Agustono, "Analisis Daya Saing Ubi Kayu Indonesia Di Pasar Internasional," *Jurnal SEPA*, vol. 14, no. 1, pp. 1–7, 2017.
- [3] N. Zuraida, "Karakterisasi Beberapa Sifat Kualitatif dan Kuantitatif Plasma Nutfah Ubi Kayu (*Manihot esculenta* Crantz .)," *Buletin Plasma Nutfah*, vol. 16, no. 1, pp. 49–56, 2010.
- [4] 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, 2018.
- [5] A. Wanto *et al.*, "Levenberg-Marquardt Algorithm Combined with Bipolar Sigmoid Function to Measure Open Unemployment Rate in Indonesia," *3rd International Conference of Computer, Environment, Agriculture, Social Science, Health Science, Engineering and Technology*, pp. 1–7, 2018.
- [6] M. A. P. Hutabarat, M. Julham, and A. Wanto, "Penerapan Algoritma *Backpropagation* Dalam Memprediksi Produksi Tanaman Padi Sawah Menurut Kabupaten/Kota di Sumatera Utara," *Jurnal semanTIK*, vol. 4, no. 1, pp. 77–86, 2018.
- [7] M. Fauzan *et al.*, "Epoch Analysis and Accuracy 3 ANN Algorithm Using Consumer Price Index Data in Indonesia," in *3rd International Conference of Computer, Environment, Agriculture, Social Science, Health Science, Engineering and Technology*, 2018, pp. 1–7.
- [8] A. Wanto, "Penerapan Jaringan Saraf Tiruan Dalam Memprediksi Jumlah Kemiskinan Pada Kabupaten/Kota Di Provinsi Riau," *Kumpulan jurnal Ilmu Komputer (KLIK)*, vol. 5, no. 1, pp. 61–74, 2018.
- [9] A. P. Windarto, L. S. Dewi, and D. Hartama, "Implementation of Artificial Intelligence in Predicting the Value of Indonesian Oil and Gas Exports With BP Algorithm," *International Journal of Recent Trends in Engineering & Research (IJRTER)*, vol. 3, no. 10, pp. 1–12, 2017.
- [10] S. Putra Siregar and A. Wanto, "Analysis Accuracy of Artificial Neural Network Using *Backpropagation* Algorithm In Predicting Process (Forecasting)," *International Journal Of Information System & Technology*, vol. 1, no. 1, pp. 34–42, 2017.
- [11] A. P. Windarto, D. Hartama, and N. Dalimunthe, "Model Arsitektur *Backpropagation* Dalam Memprediksi Faktor Tunggakan Uang Kuliah (Studi Kasus AMIK Tunas Bangsa)," in *Seminar Nasional Multidisiplin*, 2017, pp. 1–9.
- [12] A. Wanto, M. Zarlis, Sawaluddin, D. Hartama, J. T. Hardinata, and H. F. Silaban, "Analysis of Artificial Neural Network *Backpropagation* Using Conjugate Gradient Fletcher Reeves In The Predicting Process," *Journal of Physics: Conference Series*, vol. 930, no. 1, pp. 1–7, 2017.
- [13] A. Wanto *et al.*, "Analysis Of Standard Gradient Descent With GD Momentum And Adaptive LR For SPR Prediction," in *International Conference of Computer, Environment, Agriculture, Social Science, Health Science, Engineering and Technology (3rd ICEST)*, 2018, pp. 1–9.
- [14] A. Wanto and A. P. Windarto, "Analisis Prediksi Indeks Harga Konsumen Berdasarkan Kelompok Kesehatan Dengan Menggunakan Metode *Backpropagation*," *Jurnal & Penelitian Teknik Informatika Sinkron*, vol. 2, no. 2, pp. 37–43, Oct. 2017.
- [15] Solikhun, A. P. Windarto, Handrizal, and M.Fauzan, "Jaringan Saraf Tiruan Dalam Memprediksi Suku Negara Ritel Berdasarkan Kelompok Profesi Dengan *Backpropagation* Dalam Mendorong Laju Pertumbuhan Ekonomi," *Kumpulan jurnal Ilmu Komputer (KLIK)*, vol. 4, no. 2, pp. 184–197, 2017.
- [16] A. P. Windarto, "Implementasi JST Dalam Menentukan Kelayakan Nasabah Pinjaman Kur Pada Bank Mandiri Mikro Serbelawan Dengan Metode *Backpropagation*," *Jurnal Sains*

- Komputer & Informatika (J-SAKTI)*, vol. 1, no. 1, pp. 12–23, 2017.
- [17] Sumijan, A. P. Windarto, A. Muhammad, and Budiharjo, “Implementation of Neural Networks in Predicting the Understanding Level of Students Subject,” *International Journal of Software Engineering and Its Applications*, vol. 10, no. 10, pp. 189–204, 2016.
- [18] A. Wanto, A. P. Windarto, D. Hartama, and I. Parlina, “Use of Binary Sigmoid Function And Linear Identity In Artificial Neural Networks For Forecasting Population Density,” *International Journal Of Information System & Technology*, vol. 1, no. 1, pp. 43–54, 2017.
- [19] E. Hartato, D. Sitorus, and A. Wanto, “Analisis Jaringan Saraf Tiruan Untuk Prediksi Luas Panen Biofarmaka di Indonesia,” *Jurnal semanTIK*, vol. 4, no. 1, pp. 49–56, 2018.
- [20] R. E. Pranata, S. P. Sinaga, and A. Wanto, “Estimasi Wisatawan Mancanegara Yang Datang ke Sumatera Utara Menggunakan Jaringan Saraf,” *Jurnal semanTIK*, vol. 4, no. 1, pp. 97–102, 2018.