

PENERAPAN ALGORITMA BACKPROPAGATION DALAM MEMPREDIKSI PRODUKSI TANAMAN PADI SAWAH MENURUT KABUPATEN/KOTA DI SUMATERA UTARA

Meychael Adi Putra Hutabarat^{*1}, Muhammad Julham², Anjar Wanto³

^{*1,2,3} Program Studi Teknik Informatika, STIKOM Tunas Bangsa Pematangsiantar

e-mail:^{*1}meychaelhutabarat@gmail.com,

²mhdjulham@gmail.com, ³anjarwanto@amiktunasbangsa.ac.id

Abstrak

Provinsi Sumatera Utara merupakan provinsi yang cukup terkenal produksi tanaman padi sawahnya. Tetapi dari Semua Kabupaten dan Kota yang ada di Sumatera Utara produksi padi nya tidak lah merata dan tidak stabil, kadang produksinya naik, kadang turun. Oleh karena itu dibutuhkan sebuah penelitian berupa prediksi untuk Produksi Tanaman Padi Sawah ini, agar pemerintah daerah Sumatera Utara dapat membuat kebijakan sedini mungkin, agar produksi tanaman padi sawah dapat terus naik demi mendukung tercapainya swasembada pangan. Pada penelitian ini data yang akandiprediksi bersumberdari Badan Pusat Statistik Provinsi Sumatera Utara tahun 2012 sampaidengan 2016. Algoritma yangdigunakan untukmelakukan prediksi ini adalah algoritma *Backpropagation* .Algoritma ini memiliki kemampuan untuk mengingat dan membuat generalisasi dari apayang sudah ada sebelumnya. Ada5 model arsitektur yang digunakan pada penelitian ini, antara lain 3-5-1 yang nanti nya akan menghasilkan prediksi dengantingkat akurasi 78%, 3-7-1=70%, 3-10-1=82%, 3-15-1=82% dan 3-9-1=91%.Arsitektur terbaik dari ke 5 model ini adalah 3-9-1 dengan tingkat keakurasianmencapai 91% dan tingkat error yang digunakan 0,001-0,05. Diharapkan dari hasil penelitian ini dapat memberikan kontribusi terhadap pemerintah dalam menentukan kebijakan pertanian di masa yang akan datang.

Kata kunci—Aplikasi, *Backpropagation* , Prediksi, Produksi, Beras

Abstract

North Sumatra Province is a province well known for its rice field production. But from all regencies and cities in North Sumatra, its rice production is uneven and unstable, sometimes its production goes up, sometimes down. Therefore, it is needed a research in the form of prediction for Production of Rice Field Crops, so that local government of North Sumatra can make policy as early as possible, so that production of paddy rice field can continue to rise in order to support the achievement of food self-sufficiency. In this study data that will be predicted sourced from the Central Bureau of Statistics of North Sumatra Province from 2012 until 2016. The algorithm used to make this prediction is the *Backpropagation* algorithm. This algorithm has the ability to remember and make generalizations of what has been there before. There are 5 architectural models used in this research, among others 3-5-1 which later will produce predictions with 78% accuracy rate, 3-7-1 = 70%, 3-10-1 = 82%, 3-15 -1 = 82% and 3-9-1 = 91%. The best architecture of the 5 models is 3-9-1 with 91% accuracy and error rate of 0.001-0.05. It is expected that the results of this study can contribute to the government in determining agricultural policy in the future.

Keywords—Application, *Backpropagation*, Prediction, Production, Rice

1. PENDAHULUAN

Padi merupakan tanaman pangan yang memiliki peran dan manfaat penting bagi kelangsungan hidup. Tanaman padi banyak ditemukan di lingkungan sekitar khususnya yang bertempat tinggal di daerah pedesaan [1]. Tanaman padi merupakan tanaman yang menghasilkan beras. Sedangkan beras sangatlah penting sebagai sumber bahan pangan masyarakat Indonesia yang juga turut andil dalam memelihara stabilitas ekonomi, sosial, politik dan keamanan nasional [2]. Kita ketahui bersama bahwa beras sumber makanan pokok hampir 90 % manusia dan setiap tahunnya terus mengalami peningkatan permintaan akan kebutuhan beras yang diakibatkan oleh terus meningkatnya jumlah penduduk [3]. Oleh karena itu lah perlu dilakukan prediksi (peramalan) [4][5], terhadap produksi tanaman padi sawah di Indonesiakhhusus nya di Sumatera Utara untuk tahun-tahun selanjutnya agar produksi tanaman padi sawah 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 [6][7]. Salah satu teknik yang baik digunakan untuk prediksi adalah jaringan saraf tiruan *backpropagation* karena algoritma *backpropagation* memungkinkan untuk menghindari kesulitan yang dijelaskan menggunakan aturan belajar[8].

Pada Tabel 1 dijabarkan produksi padi sawah menurut kabupaten/kota di Sumatera Utara tahun 2012-2016. Pada tabel 1 secara garis besar terlihat bahwa data tidak stabil, kadang naik dan kadang turun pada tiap tahunnya.

Tabel 1 Produksi Padi Sawah Menurut Kabupaten/Kota (Ton) 2012 - 2016 Sumatera Utara

No.	Kab/Kota	2012	...	2015	2016
1	Nias	30645,0	...	32874,0	47795,4

No.	Kab/Kota	2012	...	2015	2016
2	Mandailing Natal	163410,0	...	199428,0	248360,3
3	Tapael	147787,0	...	161999,0	173444,1
4	Tapteng	118887,0	...	132979,0	156779,4
5	Taput	107101,0	...	120893,0	124580,1
6	Toba Samosir	120701,0	...	116320,0	150729,9
7	Labuhanbatu	98055,0	...	116320,0	159790,1
8	Asahan	93173,0	...	100349,0	108876,2
9	Simalungun	440992,0	...	535805,0	634555,8
10	Dairi	71124,0	...	91861,0	109935,6
11	Karo	95477,0	...	104668,0	123025,6
12	Deli Serdang	446055,0	...	423083,0	489725,2
13	Langkat	410448,0	...	440952,0	409954,4
14	Nias Selatan	57712,0	...	116475,0	111684,0
15	Humhas	86190,0	...	82833,0	97880,0
16	Pakpak Barat	14226,0	...	10587,0	9527,3
17	Samosir	44558,0	...	43336,0	38913,1
18	Serdang Bedagai	373761,0	...	406947,0	425946,2
19	Batu Bara	176642,0	...	188729,0	159357,3
20	Pad. Lawas Utara	81235,0	...	110387,0	168338,9
21	Padang Lawas	65043,0	...	59562,0	58799,2
22	Labusel	2828,0	...	3987,0	5423,5
23	Lab. Utara	156403,0	...	102586,0	198344,7
24	Nias Utara	10433,0	...	12044,0	24263,5
25	Nias Barat	10106,0	...	10629,0	16878,0
26	Sibolga	0,0	...	0,0	0,0
27	Tanjungbalai	1040,0	...	1045,0	794,4
28	Pematangsiantar	22037,0	...	26778,0	23584,3
29	Tebing Tinggi	3888,0	...	3350,0	3575,8
30	Medan	16199,0	...	14233,0	11443,4
31	Binjai	20588,0	...	14445,0	15653,4
32	Padangsidempuan	56771,0	...	53689,0	59055,7
33	Gunungsitoli	8431,0	...	11330,0	20021,2

Penelitian ini akan membahas bagaimana memprediksi produksi tanaman padi sawah di kabupaten/kota di Sumatera Utara. Oleh karena itu peneliti melakukan prediksi atau peramalan pada tiap kabupaten/kota di provinsi Sumatera Utara untuk tahun-tahun yang akan datang. Dengan demikian pihak Pemerintah Daerah akan mampu menentukan kebijakan sedini mungkin, dengan menerapkan langkah-langkah yang dianggap tepat dalam mengatasi produksi tanaman padi sawah. Akan tetapi proses prediksi tidak lah mudah, dibutuhkan model dasar dan data rangkaian waktu dari masalah-masalah tersebut, yang umumnya rumit dengan cara estimasi keakuratan yang tidak mudah dicapai, sehingga membutuhkan teknik yang lebih maju [9].

Pada penelitian sebelumnya oleh [10] telah dilakukan penelitian menggunakan algoritma *backpropagation* untuk memprediksi Indeks Harga Konsumen berdasarkan kelompok kesehatan. Penelitian ini menghasilkan tingkat akurasi sebesar 92% dengan model arsitektur terbaik 12-70-1. Selanjutnya oleh [11], dilakukan penelitian menggunakan algoritma yang sama untuk memprediksi Indeks Pembangunan Manusia.

Hasil akurasi penelitian ini mencapai 100% dengan tingkat eror yang digunakan 0,001-0,05. Berdasarkan penelitian sebelumnya maka Penulis tertarik melakukan penelitian untuk memprediksi produksi tanaman padi sawah menggunakan algoritma jaringan saraf tiruan *backpropagation* dengan menggunakan learning rate 0,01 dengan 3 *input* layer, N *hidden* layer serta 1 *output* layer.

2. METODE PENELITIAN

2.1 Penerapan

Penerapan merupakan perencanaan sebuah aktivitas untuk mencapai suatu kegiatan yang terencana dan terstruktur dilakukan secara benar berdasarkan landasan norma tertentu untuk mencapai tujuan yang diinginkan [12].

2.2 Jaringan Saraf Tiruan *Backpropagation*

Jaringan Saraf Tiruan (JST) adalah salah satu buatan otak manusia yang selalu dicoba untuk mensimulasikan proses pembelajaran pada otak manusia [13]. Istilah buatan digunakan karena jaringan syaraf ini diimplementasikan dengan menggunakan program komputer yang mampu menyelesaikan sejumlah proses perhitungan selama proses pembelajaran [14]. Algoritma *backpropagation* adalah algoritma iteratif yang mudah dan sederhana yang biasanya berkinerja baik, bahkan dengan data yang kompleks. Bahkan *backpropagation* memiliki sifat komputasi yang baik apalagi bila data yang tersaji berskala besar [15].


2.3 Prediksi

Prediksi adalah usaha menduga atau memperkirakan sesuatu yang akan terjadi di waktu mendatang dengan memanfaatkan berbagai informasi yang relevan pada waktu-waktu sebelumnya (historis) melalui suatu metode ilmiah. Prediksi juga memperkirakan besar atau jumlah sesuatu pada waktu yang akan datang berdasarkan data pada masa lampau yang dianalisis secara ilmiah khususnya menggunakan metode statistika [16].

2.4 Tahapan Penelitian

Ada beberapa tahapan penelitian yang digunakan untuk menyelesaikan masalah

dalam penelitian ini, untuk lebih jelasnya dapat dilihat pada Gambar 1.




Gambar 1 Tahapan Penelitian

Dari Gambar 1 dapat dijelaskan bahwa tahapan penelitian yang pertama sekali dilakukan ialah pemilihan dataset, dimana dataset yang digunakan adalah data produksi padi sawah menurut kabupaten/kota di Sumatera Utara tahun 2012 sampai tahun 2016. 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 Arsitektur Jaringan

Gambar 2 adalah contoh arsitektur jaringan yang digunakan.



Gambar 2 Arsitektur Jaringan *Backpropagation* yang Digunakan

Keterangan :

X1 – X14 : Data masukan (*input layer*)

b (warna merah) : Bias

W_{ij} : Bobot ke simpul *hidden*

W_{jk} : Bobot ke simpul *output*

Z1 – Z10 (Hijau) : *Hidden Layer*

Y : Hasil Keluaran (*output*)

Dari keterangan tersebut, contoh Pola arsitektur jaringan yang digunakan untuk peramalan atau prediksi Jumlah produksi tanaman padi sawah di kabupaten/kota di Provinsi Sumatera Utara yaitu 3-N-1. Dimana 3 adalah node data *input*. Sedangkan jumlah *hidden* node N menggunakan aturan '*rule of thumb*'. Pada penelitian ini akan menghasilkan masing-masing 1 keluaran pada masing-masing data.

2.6 Tahapan Dalam Backpropagation

Secara garis besar tahapan dalam teknik *backpropagation* dibagi menjadi dua yaitu Tahap pengupdatean bobot dan propagasi (perambatan).

Tahap 1:

Pengupdatean Bobot Untuk setiap bobot-sinaps: Masukan aktivasi dan delta *output* untuk mendapatkan nilai bobot. Bawa bobot ke arah gradien dengan menambahkan perbandingannya dari berat nya.

Tahap 2:

Propagasi atau Perambatan melibatkan beberapa langkah-langkah sebagai berikut:

- Teruskan propagasi masukan pola pelatihan yang diberikan melalui JST untuk menghasilkan aktivasi *output* propagasi.
- Propagasi balik dari propagasi aktivasi keluaran, melalui JST menggunakan target pola pelatihan untuk menghasilkan delta semua keluaran dan neuron yang tersembunyi.

2.7 Data yang Digunakan

Dalam penelitian ini data yang digunakan adalah data Produksi Tanaman Padi Sawah Di Kabupaten/Kota di provinsi Sumatera Utara Tahun 2012-2016 (Tabel 1), yang berasal dari Badan Pusat Statistik (BPS) Sumatera Utara. Data kemudian dibagi menjadi dua bagian, yakni data *training* dan

data *testing*. Data *training* yang akan digunakan adalah data tahun 2012-2014 dengan target tahun 2015. Sedangkan data *testing* yang akan digunakan adalah data tahun 2013-2015 dengan target tahun 2016.

2.8 Normalisasi Data

Sebelum di proses, terlebih dahulu data di normalisasi dengan menggunakan fungsi sigmoid (tidak mencapai 0 atau 1), maka transformasi data dilakukan pada interval yang lebih kecil yaitu (0.1;0.9), ditunjukkan oleh Persamaan (1).

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

Keterangan : (x') = Normalisasi data, x = Data yang akan dinormalisasi, a = Data terendah, b = Data tertinggi).

Tabel 2 adalah data *training* awal, data ini telah dibagi menjadi 2 bagian berdasarkan pada tabel 1, yakni tahun 2012-2014 dengan target tahun 2015.

Tabel 2 Data *Training* (Tahun 2012-2014) dengan Target Tahun 2015

No.	Kabupaten/Kota	2012	...	2014	Target
1	Nias	30645,0	...	12422,0	32874,0
2	Mandailing Natal	163410,0	...	181013,0	199428,0
3	Tapanuli Selatan	147787,0	...	153734,0	161999,0
4	Tapanuli Tengah	118887,0	...	107586,0	132979,0
5	Tapanuli Utara	107101,0	...	112292,0	120893,0
6	Toba Samosir	120701,0	...	127366,0	116320,0
7	Labuhanbatu	98055,0	...	112510,0	116320,0
8	Asahan	93173,0	...	104646,0	100349,0
9	Simalungun	440992,0	...	526330,0	535805,0
10	Dairi	71124,0	...	81980,0	91861,0
11	Karo	95477,0	...	88831,0	104668,0
12	Deli Serdang	446055,0	...	423060,0	423083,0
13	Langkat	410448,0	...	345073,0	440952,0
14	Nias Selatan	57712,0	...	83739,0	116475,0
15	Hum. Hasundutan	86190,0	...	8327,0	82833,0
16	Pakpak Bharat	14226,0	...	10729,0	10587,0
17	Samosir	44558,0	...	40814,0	43336,0
18	Serdang Bedagai	373761,0	...	372310,0	406947,0
19	Batu Bara	176642,0	...	173840,0	188729,0
20	Padang L. Utara	81235,0	...	84070,0	110387,0
21	Padang Lawas	65043,0	...	53131,0	59562,0
22	Lab. Selatan	2828,0	...	2958,0	3987,0
23	Lab. Utara	156403,0	...	86595,0	102586,0
24	Nias Utara	10433,0	...	8061,0	12044,0
25	Nias Barat	10106,0	...	5643,0	10629,0
26	Sibolga	0,0	...	0,0	0,0
27	Tanjungbalai	1040,0	...	659,0	1045,0
28	Pematangsiantar	22037,0	...	16736,0	26778,0
29	Tebing Tinggi	3888,0	...	3774,0	3350,0
30	Medan	16199,0	...	14771,0	14233,0
31	Binjai	20588,0	...	12926,0	14445,0
32	Padangsidempuan	56771,0	...	46637,0	53689,0
33	Gunungsitoli	8431,0	...	12953,0	11330,0

Hasil normalisasi data *training* dapat dilihat pada Tabel 3. Data ini telah dinormalisasi menggunakan fungsi sigmoid (Persamaan (1)), yakni tahun 2012-2014 dengan target tahun 2015.

Tabel 3 Data *Training* setelah Normalisasi (tahun 2012-2014) / target 2015

No.	Kabupaten/Kota	2012	2013	2014	Target
1	Nias	0,14658	0,13067	0,11888	0,14997
2	Mandailing Natal	0,34838	0,37483	0,37513	0,40312
3	Tapanuli Selatan	0,32463	0,31967	0,33367	0,34623
4	Tapanuli Tengah	0,28070	0,28422	0,26353	0,30212
5	Tapanuli Utara	0,26279	0,27313	0,27068	0,28375
6	Toba Samosir	0,28346	0,30774	0,29359	0,27680
7	Labuhanbatu	0,24904	0,28500	0,27101	0,27680
8	Asahan	0,24162	0,25572	0,25906	0,25253
9	Simalungun	0,77029	0,76373	0,90000	0,91440
10	Dairi	0,20811	0,22305	0,22461	0,23962
11	Karo	0,24512	0,23242	0,23502	0,25909
12	Deli Serdang	0,77799	0,78167	0,74303	0,74307
13	Langkat	0,72386	0,71704	0,62450	0,77023
14	Nias Selatan	0,18772	0,23443	0,22728	0,27704
15	Hum. Hasundutan	0,23101	0,23063	0,11266	0,22590
16	Pakpak Bharat	0,12162	0,11601	0,11631	0,11609
17	Samosir	0,16773	0,16572	0,16204	0,16587
18	Serdang Bedagai	0,66810	0,70035	0,66590	0,71854
19	Batu Bara	0,36849	0,37601	0,36423	0,38686
20	Padang L. Utara	0,22347	0,21093	0,22778	0,26778
21	Padang Lawas	0,19886	0,18755	0,18076	0,19053
22	Lab. Selatan	0,10430	0,10453	0,10450	0,10606
23	Lab. Utara	0,33773	0,24059	0,23162	0,25593
24	Nias Utara	0,11586	0,10869	0,11225	0,11831
25	Nias Barat	0,11536	0,10931	0,10858	0,11616
26	Sibolga	0,10000	0,10000	0,10000	0,10000
27	Tanjungbalai	0,10158	0,10186	0,10100	0,10159
28	Pematangsiantar	0,13350	0,12985	0,12544	0,14070
29	Tebing Tinggi	0,10591	0,10560	0,10574	0,10509
30	Medan	0,12462	0,12599	0,12245	0,12163
31	Binjai	0,13129	0,12995	0,11965	0,12196
32	Padangsidempuan	0,18629	0,18061	0,17089	0,18161
33	Gunungsitoli	0,11281	0,12166	0,11969	0,11722

Tabel 4 adalah data *Testing*, data ini telah dibagi menjadi 2 bagian berdasarkan pada tabel 1, yakni tahun 2013-2015 dengan target tahun 2016.

Tabel 4 Data *Testing* (Tahun 2013-2015) / target Tahun 2016

No.	Kabupaten/Kota	2013	...	2015	Target
1	Nias	20177,0	...	32874,0	47795,4
2	Mandailing Natal	180813,0	...	199428,0	248360,3
3	Tapanuli Selatan	144524,0	...	161999,0	173444,1
4	Tapanuli Tengah	121199,0	...	132979,0	156779,4
5	Tapanuli Utara	113903,0	...	120893,0	124580,1
6	Toba Samosir	136678,0	...	116320,0	150729,9
7	Labuhanbatu	121715,0	...	116320,0	159790,1
8	Asahan	102448,0	...	100349,0	108876,2
9	Simalungun	436678,0	...	535805,0	634555,8
10	Dairi	80953,0	...	91861,0	109935,6
11	Karo	87118,0	...	104668,0	123025,6
12	Deli Serdang	448479,0	...	423083,0	489725,2

No.	Kabupaten/Kota	2013	...	2015	Target
13	Langkat	405957,0	...	440952,0	409954,4
14	Nias Selatan	88440,0	...	116475,0	111684,0
15	Hum. Hasundutan	85943,0	...	82833,0	97880,0
16	Pakpak Bharat	10536,0	...	10587,0	9527,3
17	Samosir	43239,0	...	43336,0	38913,1
18	Serdang Bedagai	394978,0	...	406947,0	425946,2
19	Batu Bara	181590,0	...	188729,0	159357,3
20	Padang L. Utara	72983,0	...	110387,0	168338,9
21	Padang Lawas	57602,0	...	59562,0	58799,2
22	Lab. Selatan	2982,0	...	3987,0	5423,5
23	Lab. Utara	92494,0	...	102586,0	198344,7
24	Nias Utara	5714,0	...	12044,0	24263,5
25	Nias Barat	6126,0	...	10629,0	16878,0
26	Sibolga	0,0	...	0,0	0,0
27	Tanjungbalai	1224,0	...	1045,0	794,4
28	Pematangsiantar	19638,0	...	26778,0	23584,3
29	Tebing Tinggi	3683,0	...	3350,0	3575,8
30	Medan	17098,0	...	14233,0	11443,4
31	Binjai	19707,0	...	14445,0	15653,4
32	Padangsidempuan	53034,0	...	53689,0	59055,7
33	Gunungsitoli	14253,0	...	11330,0	20021,2

Hasil normalisasi data *Testing* dapat dilihat pada Tabel 5, data ini telah dinormalisasi menggunakan fungsi sigmoid (Persamaan (1)), yakni tahun 2013-2015 dengan target tahun 2016.

Tabel 5 Data *Testing* setelah Normalisasi (tahun 2013-2015) target tahun 2016

No.	Kabupaten/Kota	2013	2014	2015	Target
1	Nias	0,13013	0,11855	0,14908	0,17136
2	Mandailing Natal	0,36997	0,37027	0,39776	0,47082
3	Tapanuli Selatan	0,31579	0,32954	0,34188	0,35897
4	Tapanuli Tengah	0,28096	0,26063	0,29855	0,33408
5	Tapanuli Utara	0,27007	0,26766	0,28050	0,28601
6	Toba Samosir	0,30407	0,29017	0,27368	0,32505
7	Labuhanbatu	0,28173	0,26799	0,27368	0,33858
8	Asahan	0,25296	0,25624	0,24983	0,26256
9	Simalungun	0,75200	0,88585	0,90000	1,04744
10	Dairi	0,22087	0,22240	0,23716	0,26414
11	Karo	0,23007	0,23263	0,25628	0,28369
12	Deli Serdang	0,76962	0,73166	0,73170	0,83120
13	Langkat	0,70613	0,61522	0,75838	0,71209
14	Nias Selatan	0,23205	0,22503	0,27391	0,26675
15	Hum. Hasundutan	0,22832	0,11243	0,22368	0,24614
16	Pakpak Bharat	0,11573	0,11602	0,11581	0,11423
17	Samosir	0,16456	0,16094	0,16470	0,15810
18	Serdang Bedagai	0,68973	0,65589	0,70760	0,73597
19	Batu Bara	0,37113	0,35956	0,38179	0,33793
20	Padang L. Utara	0,20897	0,22552	0,26482	0,35134
21	Padang Lawas	0,18600	0,17933	0,18893	0,18779
22	Lab. Selatan	0,10445	0,10442	0,10595	0,10810
23	Lab. Utara	0,23810	0,22929	0,25317	0,39614
24	Nias Utara	0,10853	0,11204	0,11798	0,13623
25	Nias Barat	0,10915	0,10843	0,11587	0,12520
26	Sibolga	0,10000	0,10000	0,10000	0,10000
27	Tanjungbalai	0,10183	0,10098	0,10156	0,10119
28	Pematangsiantar	0,12932	0,12499	0,13998	0,13521
29	Tebing Tinggi	0,10550	0,10563	0,10500	0,10534
30	Medan	0,12553	0,12205	0,12125	0,11709
31	Binjai	0,12942	0,11930	0,12157	0,12337
32	Padangsidempuan	0,17918	0,16963	0,18016	0,18817
33	Gunungsitoli	0,12128	0,11934	0,11692	0,12989

3. HASIL DAN PEMBAHASAN

3.1 Analisis


Sebelum *Training* dilakukan, terlebih dahulu ditentukan nilai parameter yang diinginkan guna memperoleh hasil yang optimal. Parameter-parameter yang digunakan secara umum pada aplikasi Matlab untuk *training* dan *testing* dapat dilihat pada Gambar 3.

```
>> net=newff(minmax(P),[Hiden,Hidden,
Target],{'tansig','purelin','tansig'},
'traind');
>> net.IW{1,1};
>> net.b{1};
>> net.LW{2,1};
>> net.b{2};
>> net.LW{3,2};
>> net.trainparam.epochs=100000;
>> net.trainparam.LR=0.01;
>> net.trainParam.goal = 0.001;
>> net.trainParam.show = 1000;
>> net.b{3};
>> net=train(net,P,T);
```

Gambar 3 Parameter *Training* dan *Testing*


3.2 Hasil

Penelitian ini menggunakan 5 arsitektur. Antara lain 3-5-1, 3-7-1, 3-9-1, 3-10-1, 3-15-1. Dari ke 5 arsitektur ini, arsitektur terbaiknya yaitu 3-9-1 dengan tingkat akurasi sebesar 91%. Gambar 4 menunjukkan Hasil Data *Training* dengan Model Arsitektur 3-9-1



Gambar 4 Hasil Data *Training* dengan Model Arsitektur 3-9-1

Berdasarkan Gambar 4 dapat dijelaskan bahwa dengan model arsitektur terbaik, yakni 3-9-1 akan menghasilkan Epoch 13453 iterations dengan lama waktu 2 menit 36 detik. Gambar 5 menunjukkan Best *Training* Performance dengan Arsitektur 3-9-1.



Gambar 5 Best *Training* Performance dengan Arsitektur 3-9-1

Dari Gambar 5 dapat dijelaskan bahwa performance *training* terbaik dengan menggunakan model Arsitektur 3-9-1 adalah 0,00099998 dengan epoch 13453

Tabel 6 ini merupakan hasil akurasi dan tingkat MSE dari model Arsitektur terbaik, yakni 3-9-1. Tabel 6 ini dibuat dan dihitung dengan menggunakan Microsoft Excel. Berdasarkan tabel 6, error = diperoleh dari Target-Output, SSE = diperoleh dari $E3^2$, Total = Jumlah SSE yang dihasilkan dari pola 1 ke pola33, Hasil = Jika nilai kesalahan dalam pengujian data ≤ 0.05 maka hasilnya benar (1). Jika tidak maka salah (0). Akurasi = diperoleh dari jumlah hasil yang benar pada $((\text{pola} / 33) * 100)$, menghasilkan 91%, MSE = Diperoleh dari Total SSE / 33 (jumlah pola), diperoleh keterangan prediksi (1 = Benar, 0 = Salah).

Tabel 6 Data *Training* Arsitektur Terbaik dengan Model 3-9-1

No	Data Traning			
	Target	Output	Error	SSE
1	0,14997	0,14180	0,00817	0,00007
2	0,40312	0,39730	0,00582	0,00003
3	0,34623	0,37230	-0,02607	0,00068
4	0,30212	0,29560	0,00652	0,00004
5	0,28375	0,28140	0,00235	0,00001
6	0,27680	0,30470	-0,02790	0,00078
7	0,27680	0,26530	0,01150	0,00013
8	0,25253	0,25740	-0,00487	0,00002
9	0,91440	0,89090	0,02350	0,00055

No	Data Traning			
	Target	Output	Error	SSE
10	0,23962	0,21720	0,02242	0,00050
11	0,25909	0,25450	0,00459	0,00002
12	0,74307	0,80830	-0,06523	0,00426
13	0,77023	0,66390	0,10633	0,01131
14	0,27704	0,20170	0,07534	0,00568
15	0,22590	0,23130	-0,00540	0,00003
16	0,11609	0,12230	-0,00621	0,00004
17	0,16587	0,16770	-0,00183	0,00000
18	0,71854	0,73150	-0,01296	0,00017
19	0,38686	0,41390	-0,02704	0,00073
20	0,26778	0,23070	0,03708	0,00138
21	0,19053	0,19740	-0,00687	0,00005
22	0,10606	0,11030	-0,00424	0,00002
23	0,25593	0,33430	-0,07837	0,00614
24	0,11831	0,11630	0,00201	0,00000
25	0,11616	0,11690	-0,00074	0,00000
26	0,10000	0,10670	-0,00670	0,00004
27	0,10159	0,10820	-0,00661	0,00004
28	0,14070	0,13420	0,00650	0,00004
29	0,10509	0,11130	-0,00621	0,00004
30	0,12163	0,12830	-0,00667	0,00004
31	0,12196	0,13390	-0,01194	0,00014
32	0,18161	0,18550	-0,00389	0,00002
33	0,11722	0,12110	-0,00388	0,00002
Total SEE				0,03302
MSE				0,0010006

Tabel 7 merupakan hasil data *Testing* terbaik dari model Arsitektur 3-9-1 yang diperoleh dengan menggunakan aplikasi Matlab yang menghasilkan akurasi sebesar 91% dan MSE 0,0025657.

Tabel 7 Data *Testing* Arsitektur Terbaik dengan Model 3-9-1

No.	Data Testing				
	Target	Output	Error	SSE	Hasil
1	0,17136	0,12630	0,04506	0,00203	1
2	0,47082	0,45220	0,01862	0,00035	1
3	0,35897	0,36080	-0,00183	0,00000	1
4	0,33408	0,31800	0,01608	0,00026	1
5	0,28601	0,29440	-0,00839	0,00007	1
6	0,32505	0,32310	0,00195	0,00000	1
7	0,33858	0,30430	0,03428	0,00118	1
8	0,26256	0,26620	-0,00364	0,00001	1
9	1,04744	0,96740	0,08004	0,00641	0
10	0,26414	0,23130	0,03284	0,00108	1
11	0,28369	0,24590	0,03779	0,00143	1
12	0,83120	0,83540	-0,00420	0,00002	1
13	0,71209	0,79240	-0,08031	0,00645	1
14	0,26675	0,25530	0,01145	0,00013	1
15	0,24614	0,24730	-0,00116	0,00000	1
16	0,11423	0,11980	-0,00557	0,00003	1
17	0,15810	0,16390	-0,00580	0,00003	1
18	0,73597	0,86350	-0,12753	0,01626	1
19	0,33793	0,44780	-0,10987	0,01207	1
20	0,35134	0,22720	0,12414	0,01541	0
21	0,18779	0,18620	0,00159	0,00000	1
22	0,10810	0,11000	-0,00190	0,00000	1
23	0,39614	0,25340	0,14274	0,02038	0
24	0,13623	0,11420	0,02203	0,00049	1
25	0,12520	0,11280	0,01240	0,00015	1
26	0,10000	0,10670	-0,00670	0,00004	1
27	0,10119	0,10770	-0,00651	0,00004	1
28	0,13521	0,12870	0,00651	0,00004	1

No.	Data Testing				
	Target	Output	Error	SSE	Hasil
29	0,10534	0,11130	-0,00596	0,00004	1
30	0,11709	0,12680	-0,00971	0,00009	1
31	0,12337	0,12720	-0,00383	0,00001	1
32	0,18817	0,17760	0,01057	0,00011	1
33	0,12989	0,12390	0,00599	0,00004	1
Total SEE				0,08467	91%
MSE				0,0025657	

Keterangan pada Hasil:

1 = Benar 0 = Salah

Pada Tabel 8 menunjukan hasil akhir *Backpropagation* dari beberapa arsitektur. Dan hasil ini diperoleh dari perhitungan dengan model arsitektur terbaik (3-9-1) menggunakan aplikasi Matlab dan Microsoft Excel.

Tabel 8 Perbandingan Akurasi dengan Algoritma *Backpropagation*

No	Arsitektur	Epoch	Waktu	MSE	Akurasi
1	3-5-1	9497	02:02	0,00321372	78%
2	3-7-1	8515	01:48	0,02711425	70%
3	3-9-1	13453	02:36	0,00256570	91%
4	3-10-1	4689	01:00	0,00626531	82%
5	3-15-1	10909	02:20	0,00481933	82%

Pada Tabel 9 dapat dilihat hasil prediksi produksi tanaman padi sawah untuk 3 tahun kedepan, yakni tahun 2017-2019. Adapun hasil ini diperoleh dari perhitungan dengan model Arsitektur terbaik (3-9-1) menggunakan aplikasi Matlab dan Microsoft Excel, sama seperti pembahasan sebelumnya.

Tabel 9 Hasil Prediksi 3 Tahun ke Depan dengan *Backpropagation* (Tahun 2017-2019)

No.	Kabupaten / Kota	Prediksi 2017	Prediksi 2018	Prediksi 2019
1	Nias	47671,00	53964,69	68935,93
2	Mandailing Natal	229867,84	263465,03	463113,74
3	Tapanuli Selatan	217573,32	288864,71	361296,16
4	Tapanuli Tengah	176803,11	212665,67	308458,57
5	Tapanuli Utara	173947,61	215770,07	308458,57
6	Toba Samosir	191715,17	214923,41	277948,36
7	Labuhanbatu	174344,21	196673,27	217044,85
8	Asahan	156021,41	184067,50	237618,78
9	Simalungun	753772,97	954900,83	216343,47
10	Dairi	140712,75	151518,28	1240597,91
11	Karo	153721,14	170897,30	192262,62
12	Deli Serdang	582363,59	630443,40	228033,20
13	Langkat	498760,86	610688,09	717833,03
14	Nias Selatan	161970,37	181433,46	853901,53
15	Hum. Hasundutan	124372,94	85667,25	285429,79
16	Pakpak Bharat	12849,75	30258,32	177416,66
17	Samosir	69563,18	69957,08	73728,72
18	Serdang Bedagai	488925,24	568543,44	126098,73
19	Batu Bara	236213,40	377011,02	691180,44

No.	Kabupaten / Kota	Prediksi 2017	Prediksi 2018	Prediksi 2019
20	Padang L. Utara	159035,55	161207,79	456918,18
21	Padang Lawas	96452,48	94039,74	228851,48
22	Lab.Selatan	1824,35	23955,43	145620,58
23	Lab. Utara	151658,84	144839,11	60168,63
24	Nias Utara	13960,23	35338,25	208277,55
25	Nias Barat	11659,96	31575,34	42166,44
26	Sibolga	0,00	0,00	0,00
27	Tanjungbalai	2538,22	20568,81	60285,53
28	Pematangsiantar	38311,31	45027,76	61922,09
29	Tebing Tinggi	1189,79	23202,85	100147,52
30	Medan	19433,27	33833,09	62740,37
31	Binjai	19750,55	34773,82	82262,23
32	Padangsidempuan	86854,83	85290,96	71858,36
33	Gunungsitoli	14753,42	34679,74	123293,19

4. KESIMPULAN

Kesimpulan yang dapat diambil dari penelitian ini antara lain :

1. Dengan model arsitektur 3-4-1, dapat melakukan prediksi Luas Panen Tanaman Biofarmaka di Indonesia dengan tingkat akurasi sebesar 87%.
2. Model Arsitektur jaringan serta parameter yang digunakan sangat mempengaruhi tingkat *training* dan *testing*.
3. Hasil dari penelitian ini, diharapkan mampu memberikan acuan dan masukan kepada para petani Biofarmaka maupun pemerintah untuk membuat kebijakan yang tepat agar Luas panen tanaman biofarmaka setiap tahunnya jangan sampai menurun.

5. SARAN

Berdasarkan hasil penelitian, ada saran-saran yang dapat penulis kemukakan demi pengembangan penelitian, antara lain:

1. Penggunaan model arsitektur jaringan hendaknya lebih dikembangkan lagi, selain dari yang sudah penulis lakukan. Misal nya dengan menggunakan 2 *hidden layer*.
2. Penggunaan learning rate dan tingkat error yang lebih kecil serta parameter train yang berbeda, agar menghasilkan tingkat akurasi yang lebih baik.
3. Penelitian ini hendaknya dikembangkan dengan menggunakan metode atau algoritma yang lain.

DAFTAR PUSTAKA

- [1] B. E. Cahyono, A. T. Nugroho, and J. Husen, "Karakteristik Time Series Reflektansi Tanaman Padi Varietas Ciherang dengan Analisis RGB Citra Fotografi," *Jurnal Fisika FLUX*, vol. 15, no. 1, pp. 59–65, 2018.
- [2] Rifiana, "Analisis Imbalan Faktor Produksi Usahatani Padi Sawah di Kabupaten Banjar," *Jurnal Agribisnis Pedesaan*, vol. 2, no. 1, pp. 24–34, 2012.
- [3] W. P. Tampoma, T. Nurmala, and M. Rachmadi, "Eksplorasi dan Karakterisasi Tanaman Padi Sawah (*Oryza sativa* L.) Kultivar Lokal di Kabupaten Poso," *Jurnal Agrotek Indonesia*, vol. 2, no. 2, pp. 88–92, 2017.
- [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, Jan. 2018.
- [5] A. Wanto *et al.*, "Levenberg-Marquardt Algorithm Combined With Bipolar Sigmoid Function To Measure Open Unemployment Rate In Indonesia," *International Conference of Computer, Environment, Agriculture, Social Science, Health Science, Engineering and Technology (3rd ICEST)*, pp. 1–7, 2018.
- [6] S. Kusmaryanto, "Jaringan Saraf Tiruan Backpropagation untuk Pengenalan Wajah Metode Ekstraksi Fitur Berbasis Histogram," *Jurnal EECCIS*, vol. 8, no. 2, pp. 193–198, 2014.
- [7] M. Fauzan *et al.*, "Epoch Analysis and Accuracy 3 ANN Algorithm Using Consumer Price Index Data in Indonesia," *3rd International Conference of Computer, Environment, Agriculture, Social Science, Health Science, Engineering and Technology*, pp. 1–7, 2018.
- [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] R. Hrasco, A. G. C. Pacheco, and R. A. Krohling, “Time Series Prediction Using Restricted Boltzmann Machines and Backpropagation,” *Procedia Computer Science*, vol. 55, no. Itqm, pp. 990–999, 2015.
- [10] 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, 2017.
- [11] S. P. Siregar and A. Wanto, “Analysis of Artificial Neural Network Accuracy Using Backpropagation Algorithm In Predicting Process (Forecasting),” *International Journal Of Information System & Technology*, vol. 1, no. 1, pp. 34–42, 2017.
- [12] S. E. Rahayu and H. Febriaty, “Penerapan Model Pembelajaran Contextual Teaching And Learning (CTL) Untuk Meningkatkan Pemahaman Materi Pasar Valuta Asing Pada Mata Kuliah Ekonomi Internasional 2 (Studi Mahasiswa Semester 5 Jurusan Ekonomi Pembangunan Fakultas Ekonomi UMSU),” *Jurnal Ilmiah Manajemen dan Bisnis*, vol. 17, no. 2, pp. 94–106, 2016.
- [13] A. P. Windarto, D. Hartama, and N. Dalimunthe, “Model Arsitektur Backpropagation Dalam Memprediksi Faktor Tunggakan Uang Kuliah (Studi Kasus AMIK Tunas Bangsa),” *Seminar Nasional Multidisiplin*, pp. 1–9, 2017.
- [14] A. Wanto, M. Zarlis, S. Nasution, and D. Hartama, “Analysis of Artificial Neural Network Backpropagation Using Conjugate Gradient Fletcher Reeves In The Predicting Process Analysis of Artificial Neural Network Backpropagation Using Conjugate Gradient Fletcher Reeves In The Predicting Process,” *Journal of Physics: Conference Series*, pp. 1–7, 2017.
- [15] 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.
- [16] A. Wanto *et al.*, “Analysis Of Standard Gradient Descent With GD Momentum And Adaptive LR For SPR Prediction,” *International Conference of Computer, Environment, Agriculture, Social Science, Health Science, Engineering and Technology (3rd ICEST)*, pp. 1–9, 2018.
-

