

Implementasi Metode Backpropagation Neural Network Dalam Memprediksi Hasil Produksi Kedelai

Barorotus Sulusayil Laili*
Program Studi Teknik Informatika Jurusan
Teknologi Informasi Politeknik Negeri
Jember, Indonesia
Email: barorotus.sl@gmail.com

Denny Trias Utomo
Program Studi Teknik Informatika Jurusan
Teknologi Informasi Politeknik Negeri
Jember, Indonesia
Email: denny_trias@polije.ac.id

Denny Wijanarko
Program Studi Teknik Komputer Jurusan
Teknologi Informasi Politeknik Negeri
Jember, Indonesia
Email: denny_wijanarko@polije.ac.id

Abstract— The necessary of soybean in Indonesia tends to increase annually. However, soybean production tends to decrease so that soybean needs does not fulfilled. One of the environmental factors that influence soybean production is climate such as temperature, humidity, sunlight, rainfall, and wind velocity. This study aims to predict soybean production results based on the influence of climate by using an Artificial Neural Network (ANN) method. The algorithm used is Backpropagation with climate and soybean production results in the previous period parameters as input in the prediction process. The results of this study get a training accuracy of 96.6% and testing accuracy of 96.5%.

Keywords— ANN; Backpropagation; Soybean

Abstrak— Kebutuhan kedelai di Indonesia cenderung meningkat setiap tahunnya, namun produksi kedelai cenderung menurun sehingga belum memenuhi kebutuhan kedelai. Salah satu faktor lingkungan yang mempengaruhi hasil produksi kedelai adalah komponen iklim seperti suhu, kelembapan, lama penyinaran sinar matahari, curah hujan dan kecepatan angin. Penelitian ini bertujuan untuk melakukan prediksi terhadap hasil produksi kedelai berdasarkan pengaruh iklim dengan menggunakan metode Artificial Neural Network (ANN). Algoritma yang digunakan adalah Backpropagation dengan parameter iklim dan hasil produksi kedelai pada periode sebelumnya sebagai masukan dalam proses prediksi. Hasil penelitian ini mendapatkan akurasi pelatihan sebesar 96,6 % dan akurasi pengujian sebesar 96,5%.

Keywords—ANN; Backpropagation; Kedelai

PENDAHULUAN

Sektor pertanian merupakan sektor yang penting dalam pembangunan ekonomi nasional. Tanaman pangan merupakan salah satu komoditas tanaman dari sektor pertanian yang diolah untuk memenuhi kebutuhan utama akan makanan dan dimanfaatkan untuk pengadaan serta ketahanan pangan bagi masyarakat. Salah satu komoditas tanaman pangan yang utama adalah kedelai setelah padi dan jagung [1]. Namun disisi lain produksi nasional kedelai mengalami

penurunan sehingga belum mencukupi kebutuhan kedelai, untuk mengatasi kekurangan produksi kedelai dalam negeri pemerintah terpaksa melakukan kebijakan impor [2].

Salah satu faktor lingkungan yang menjadi penentu keberhasilan usaha produksi kedelai adalah komponen iklim seperti suhu, kelembapan, sinar matahari, curah hujan, dan angin [3]. Curah hujan sangat berpengaruh pada besar kecilnya nilai produksi pada kedelai, jika semakin tinggi nilai curah hujan maka produksi kedelai semakin tinggi, begitupula sebaliknya [4]. Sebuah sistem prediksi atau peramalan produksi tanaman kedelai sangat dibutuhkan karena dapat membantu pihak terkait dalam menentukan kebijakan ketahanan pangan dan untuk mengetahui seberapa besar perkembangan tingkat produksi kedelai di Indonesia dimasa yang akan datang.

Pada penelitian prediksi hasil produksi kedelai ini menggunakan teknik kecerdasan buatan dengan metode *Artificial Neural Network (ANN)*. Algoritma yang digunakan adalah *Backpropagation* dengan parameter iklim dan hasil produksi kedelai pada periode sebelumnya sebagai masukan pada proses prediksi. Penelitian terkait telah dilakukan yaitu Prediksi IHSG dengan *Backpropagation Neural Network* [5], pada penelitian tersebut dilakukan prediksi Indeks Harga Saham Gabungan (IHSG) dengan mempelajari data 5 hari sebelumnya untuk digunakan prediksi periode selanjutnya dan dilakukan uji variasi *learning rate* serta *epoch*. Hasil MSE terbaik yang didapatkan pada pengujian adalah 320,49865083640924 dengan menggunakan *learning rate* 0,3 dan 3.000 *epoch*. Penelitian selanjutnya yaitu Prediksi Volume Penggunaan Air PDAM Menggunakan Metode Jaringan Saraf Tiruan *Backpropagation* [6], pada penelitian tersebut dilakukan prediksi volume penggunaan air PDAM dengan variabel data diambil dari data pelanggan yaitu sosial umum, sosial khusus, rumah tangga 1, rumah tangga 2, rumah tangga 3, niaga 1, niaga 2 dan niaga 3 sebagai masukan serta uji coba jumlah neuron pada *hidden layer* sebagai pola pada proses prediksi. Hasil terbaik didapatkan dengan pola 8-9-1 dengan MSE sebesar 0,001. Penelitian selanjutnya adalah *Analysis of Backpropagation Algorithm in Predicting the Most Number of Internet Users in the World* [7], pada penelitian tersebut dilakukan prediksi pengguna internet

terbanyak di dunia dengan data jumlah pengguna internet di 25 negara sebagai masukan serta uji coba jumlah neuron pada *hidden layer* sebagai pola arsitektur pada proses prediksi. Hasil terbaik yang didapatkan pada penelitian tersebut dengan pola 3-50-1 dan tingkat akurasi sebesar 92 %.

Berdasarkan pada uraian penelitian sebelumnya menjadi rujukan bagi penulis untuk melakukan pengembangan penelitian prediksi kedelai dengan algoritma *backpropagation*, dimana pada penelitian ini dilakukan variasi uji coba penentuan arsitektur terbaik dengan tujuan mendapatkan hasil akurasi yang bagus. Variasi uji coba penentuan arsitektur terbaik yang digunakan pada beberapa penelitian diatas adalah *learning rate*, jumlah epoch, jumlah neuron, serta *hidden layer*. Sedangkan pada penelitian ini lebih dikembangkan dengan variasi uji coba algoritma fungsi pelatihan (*training*, *trainingd*, *trainingdm*), *learning rate*, *momentum*, jumlah neuron pada *hidden layer*, serta rasio dataset pelatihan : pengujian (80%:20%, 70%:30%, 75%:25%, 60%:40%).

METODE PENELITIAN

Pada penelitian ini data yang digunakan adalah data sekunder sebanyak 216 data berupa data iklim bulanan seperti curah hujan, suhu, kelembaban, larna penyinaran dan kecepatan angin yang didapat dari *website* resmi BMKG stasiun meteorologi Banyuwangi tahun 2008 - 2018 dan hasil produksi kedelai bulanan yang didapat dari BPS Kabupaten Banyuwangi tahun 2008 - 2018. Data iklim dan hasil produksi kedelai pada periode sebelumnya sebagai *input* dan hasil produksi kedelai sebagai *output*. Data akan dibagi menjadi dua set yaitu data pelatihan dan data pengujian.

A. Normalisasi Data

Normalisasi berguna untuk menyesuaikan nilai data yang berbeda dengan range fungsi aktivasi yang digunakan dalam jaringan. Fungsi aktivasi yang digunakan adalah sigmoid binner dengan rentang [0,1] maka data disesuaikan dengan persamaan berikut [8]:

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

Dimana :

- x : Data yang akan dinormalisasi
- a : Nilai minimum
- b : Nilai Maksimum

B. Arsitektur Artificial Neural Network (ANN)

ANN merupakan salah satu dari teknik pengolahan informasi yang terinspirasi dari sistem saraf sel otak manusia yang bekerja dalam memproses suatu informasi. Jaringan ini terdiri dari neuron yaitu dihubungkan oleh jaringan komunikasi atau konektor untuk melakukan fungsi spesifik berdasarkan pembobotan antar elemen, jaringan ini juga dikenal sebagai *multilayer perceptron* [9].

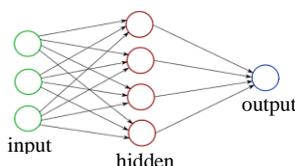


Fig. 1. Model Artificial Neural Network

ANN memiliki model matematika seperti pada gambar Fig. 1 yang terdiri dari satu set fungsi sederhana yaitu input *x*, unit output *y*, dan unit *z* tersembunyi yang terhubung ke output [10]. Pada penelitian ini data iklim dan hasil produksi kedelai periode sebelumnya digunakan sebagai *input* sebanyak 6 neuron, jumlah *hidden layer* adalah satu dengan uji coba neuron antara 2-12, dan hasil produksi kedelai saat ini sebagai *output*.

C. Algoritma Backpropagation

Backpropagation merupakan metode sistematis jaringan ANN dengan menggunakan algoritma pembelajaran terawasi dan biasanya digunakan oleh perceptron dengan banyak lapisan layar untuk mengubah bobot di lapisan tersembunyi. *Backpropagation* adalah jenis pelatihan terkontrol yang menggunakan pola penyesuaian berat untuk mencapai nilai kesalahan minimum antara output yang diprediksi dan output aktual [11].

1. Tahap Pelatihan (Training)

Tahap pelatihann pada *backpropagation* terdiri dari tiga langkah utama [12] yaitu :

- a) Perambatan maju (*feedforward*). Pola masukan dihitung maju mulai dari layar masukan hingga layar keluaran menggunakan fungsi aktivasi yang ditentukan
- b) Perambatan balik (*backpropagation*). Selisih antara keluaran jaringan dengan target yang diinginkan tersebut dipropagasikan mundur
- c) Pembaharuan nilai bobot dan bias

Backpropagation terkadang terlalu lambat untuk keperluan praktis. Beberapa modifikasi dilakukan terhadap standart *backpropagation* dengan cara memodifikasi algoritma fungsi pelatihannya [13].

- a) Metode Penurunan Gradien dengan Mornentum (*trainingdm*). Modifikasi metode penurunan tercepat dilakukan dengan menarnbahkan *momentum*. Momentum digunakan untuk mernpercepat proses pembelajaran pada saat training dilakukan, sehingga jaringan dapat mencapai konvergensi dengan waktu yang cepat
- b) Variabel Laju Pemahaman (*trainingd*, *trainingda*, *trainingdx*). Modifikasi metode penurunan tercepat dilakukan dengan menambahkan *trial&error* pada *learning rate*. *Learning rate* atau laju pembelajaran untuk menghitung besarnya penyesuaian pada bobot ketika dilakukan proses pelatihan.

2. Tahap Pengujian (Testing)

Testing dilakukan dengan menggunakan nilai hasil pembaharuan bobot dan bias terbaik serta parameter terbaik yang didapatkan pada proses *training*.

D. Perhitungan Error dan Akurasi

Untuk mengukur suatu metode permalan, hal yang diperhitungkan adalah tingkat kesalahan (*error*) yang terjadi. Perhitungan *error* bertujuan untuk pengukuran akurasi jaringan dalam mengenali pola yang diberikan. Semakin kecil tingkat kesalahan, maka semakin baik hasil peramalan tersebut.

1. MSE (Mean square Error)

Nilai MSE mewakili kesalahan absolut rata - rata antara hasil perkiraan dan nilai actual [14]. Berikut adalah persamaan MSE:

$$MSE = \sum_{i=1}^n \frac{(y_i - y'_i)^2}{n} \quad (2)$$

Dimana :

- y_i = Data awal
- y'_i = Data akhir
- n = Jumlah data

2. MAPE (Mean Absolute Percentage Error)

MAPE dihitung dengan melakukan perbandingan presentase perbedaan nilai rata-rata absolut antara nilai peramalan dengan nilai yang sebenarnya terjadi. MAPE dirumuskan sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - Y'_t|}{Y_t} \times 100 \quad (3)$$

Dimana:

- Y_t = Hasil Aktual
- Y'_t = Hasil Peramalan
- n = Jumlah Data

Adapun perhitungan akurasi dirumuskan sebagai berikut :

$$100\% - MAPE \quad (4)$$

HASIL DAN PEMBAHASAN

Berikut ini adalah data asli yang digunakan dalam sistem prediksi menggunakan *backpropagation neural network*:

Tabel 1. Data Asli

Tanggal	Y	X1	X2	X3	X4	X5	X6
Jan-01	4609.51	27.0	80.9	133.	2.4	4609.51	4
Feb-01	4541.05	27.4	78.6	104.	2.7	4609.51	4
Mar-01	4473.83	27.4	80.1	192	129	4541.05	8
.....
Des-18	1762.81	29.1	75.2	65.	134.	1970.27	6

Keterangan:

- Y : Hasil Produksi Kedelai (*Output*)
- X1 : Suhu (*Input 1*)
- X2 : Kelembapan (*Input 2*)
- X3 : Curah Hujan (*Input 3*)
- X4 : Lama Penyinaran (*Input 4*)
- X5 : Kecepatan Angin (*Input 5*)
- X6 : Hasil Produksi Kedelai Sebelumnya (*Input 6*)

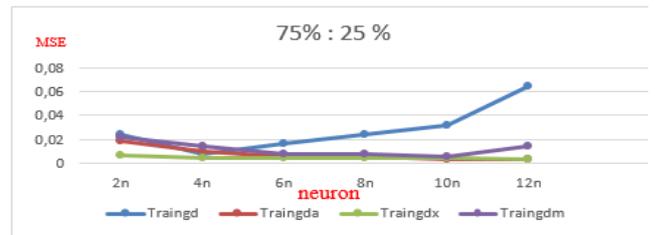
Berikut ini adalah data hasil normalisasi menggunakan rumus pada persamaan (1) dengan rentang [0,1]:

Tabel 2. Data Normalisasi

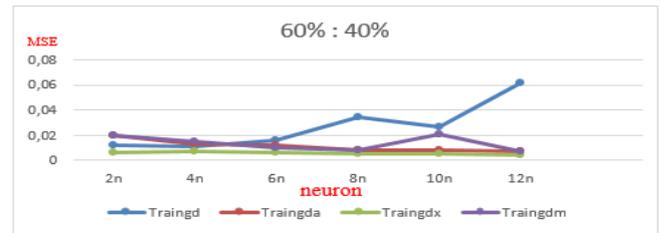
Tanggal	Y	X1	X2	X3	X4	X5	X6
Jan-01	0.675	0.47	0.62	0.48	0.45	0.41	0.662
Feb-01	0.661	0.53	0.51	0.26	0.37	0.48	0.662
Mar-01	0.647	0.53	0.58	0.39	0.44	0.25	0.648
.....

Des-18	0.100	0.82	0.35	0.19	0.45	0.67	0.100
		6	1	9	8	6	

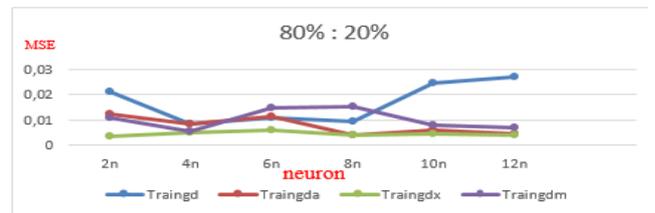
Data pada Tabel 2 digunakan sebagai pelatihan dan pengujian dengan variasi rasio dataset 75%:25%, 60%:40%, 80%:20%, dan 70%:30%. Selanjutnya dilakukan proses pelatihan dengan beberapa variasi parameter untuk menentukan pola jaringan terbaik berdasarkan jumlah neuron pada *hidden layer* dengan beberapa metode pelatihan (*traingd*, *traingda*, *traingdx*, *traingdm*) serta nilai bobot dan bias acak pada masing-masing dataset. Nilai default awal *learning rate* adalah 0,5, *momentum* adalah 0,9, *goal error* adalah 0,001 dan nilai maksimum epoch yang digunakan adalah 1000. Berikut adalah hasil pada masing – masing dataset:



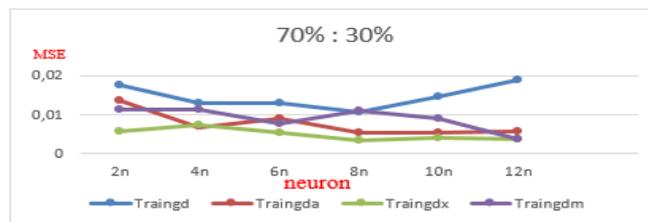
(a)



(b)



(c)



(d)

Fig. 2. (a) Dataset 1, (b) Dataset 2, (c) Dataset 3, (d) Dataset 4

Metode algoritma pelatihan terbaik adalah metode yang memiliki nilai MSE terkecil. Berdasarkan gambar grafik pada Fig. 2 diatas diperoleh algoritma pelatihan dengan nilai MSE terkecil pada tiap neuron adalah metode *traingdx*. Untuk mencari metode pelatihan *traingdx* yang terbaik pada masing-masing dataset maka dilakukan perbandingan metode pelatihan *traingdx* pada setiap variasi dataset untuk mendapatkan parameter dataset terbaik.

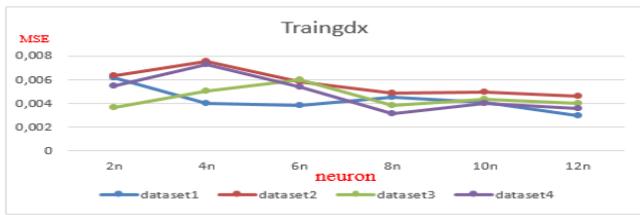


Fig. 3 Grafik Perbandingan Traingdx

Berdasarkan grafik pada Fig. 3 diperoleh hasil dataset terbaik menggunakan perbandingan rasio 75% untuk pelatihan dan 25% untuk pengujian. Namun hasil rata-rata *error* pada pengujian ini kurang memenuhi target untuk mendapatkan akurasi yang baik. Maka dilakukan pengujian bobot berdasarkan perbandingan bobot&bias secara acak dan menggunakan metode Nguyen Widrow.



Fig. 4. Grafik Perbandingan Metode Penentu Nilai Bobot

Pemilihan metode bobot awal terbaik adalah metode yang memiliki nilai *error* (MAPE) terkecil. Berdasarkan grafik pada Fig. 4 diperoleh hasil nilai rata-rata MAPE terkecil menggunakan pemilihan bobot awal dengan metode Nguyen Widrow. Selanjutnya dilakukan uji variasi *learning rate* pada setiap neuron. Berikut hasil *trial* dan *error* penentuan jumlah neuron terbaik berdasarkan hasil MAPE terkecil:

Tabel 3. Hasil Penentuan Jumlah Neuron

Jumlah Neuron	Learning Rate	MAPE Pelatihan	MAPE Pengujian
2	0.1	3.42054	3.50966
	0.2	3.43455	3.60636
	0.3	3.44538	3.67165
	0.4	3.43896	3.59961
	0.5	3.45372	3.84214
	0.6	3.45401	3.87532
	0.7	3.45067	3.80435
	0.8	3.45779	3.81816
	0.9	3.44022	3.55598
4	0.1	3.52155	4.45142
	0.2	3.50526	4.23663
	0.3	3.51832	4.47026
	0.4	3.52222	4.47867
	0.5	3.52171	4.40474
	0.6	3.51531	4.35818
	0.7	3.51088	4.319
	0.8	3.51825	4.47136
	0.9	3.52555	4.48224
6	0.1	3.53161	4.29634
	0.2	3.52933	4.33093

	0.3	3.53279	4.34004	
	0.4	3.52781	4.32004	
	0.5	3.53602	4.32911	
	0.6	3.53223	4.33334	
	0.7	3.5351	4.32723	
	0.8	3.52846	4.32711	
	0.9	3.52823	4.32592	
	8	0.1	3.54821	4.05112
		0.2	3.54388	4.04484
0.3		3.54723	4.06023	
0.4		3.54305	4.05206	
0.5		3.54524	4.05424	
0.6		3.54606	4.0431	
0.7		3.54433	4.04627	
0.8		3.54527	4.05407	
0.9		3.54074	4.03931	
10	0.1	3.54049	4.46418	
	0.2	3.53848	4.43607	
	0.3	3.5363	4.41003	
	0.4	3.53536	4.38589	
	0.5	3.53571	4.41995	
	0.6	3.53489	4.39597	
	0.7	3.53706	4.43472	
	0.8	3.53662	4.41278	
	0.9	3.53895	4.45051	
12	0.1	3.53789	4.52267	
	0.2	3.54132	4.55036	
	0.3	3.53743	4.53366	
	0.4	3.53674	4.47877	
	0.5	3.54175	4.54041	
	0.6	3.53996	4.54451	
	0.7	3.54106	4.53022	
	0.8	3.53877	4.53905	
	0.9	3.53766	4.53758	

Berdasarkan Tabel 3 diatas diperoleh hasil pengujian jumlah neuron terbaik dengan nilai MAPE terkecil berdasarkan percobaan *learning rate* adalah 2 neuron. Setelah mendapatkan nilai neuron terbaik pada *hidden layer* maka arsitektur jaringan yang terbentuk digambarkan sebagai berikut:

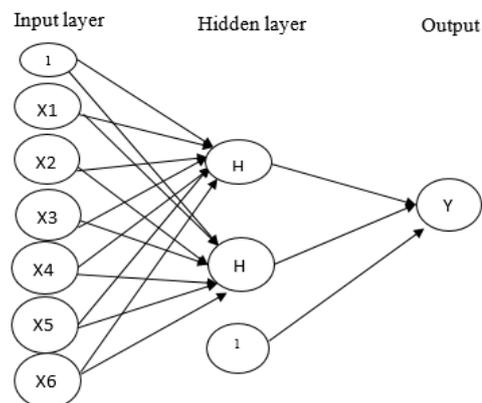


Fig. 5. Arsitektur jaringan

Pada Fig. 5 dapat dilihat bahwa pola arsitektur jaringan terbaik adalah 6-2-1 dimana jumlah neuron *input* sebanyak 6 neuron berdasarkan banyaknya jumlah parameter, jumlah neuron *hidden layer* sebanyak 2 neuron, dan jumlah neuron *output* sebanyak 1 neuron berdasarkan jumlah target. Selanjutnya dalam menentukan apakah nilai *learning rate*

tersebut merupakan yang terbaik maka dilakukan uji berdasarkan percobaan *momentum*. Berikut adalah tabel hasil uji percobaan:

Tabel 4. Hasil Percobaan Learning Rate Dan Momentum

Learning Rate	Momentum	Mape Training	Mape Testing
0.1	0.1	3.51748	5.05637
	0.3	3.51092	4.84737
	0.5	3.50092	4.77967
	0.7	3.49423	4.74805
	0.9	3.42054	3.50966
0.2	0.1	3.39703	4.34336
	0.3	3.50746	4.84198
	0.5	3.50644	4.82657
	0.7	3.49567	4.7223
	0.9	3.43455	3.60636
0.3	0.1	3.51213	5.04388
	0.3	3.5146	4.89075
	0.5	3.50351	4.81971
	0.7	3.47418	4.6443
	0.9	3.44538	3.67165
0.4	0.1	3.46222	4.63338
	0.3	3.51093	4.85141
	0.5	3.50128	4.78381
	0.7	3.49624	4.75642
	0.9	3.43896	3.59961
0.5	0.1	3.39204	4.33573
	0.3	3.50986	4.85276
	0.5	3.50938	4.85241
	0.7	3.50136	4.75657
	0.9	3.45372	3.84214
0.6	0.1	3.52641	5.02941
	0.3	3.50667	4.82553
	0.5	3.50303	4.83418
	0.7	3.49264	4.75043
	0.9	3.45401	3.87532
0.7	0.1	3.40985	4.36776
	0.3	3.50888	4.83543
	0.5	3.50607	4.82647
	0.7	3.47985	4.67987
	0.9	3.45067	3.80435
0.8	0.1	3.5073	5.05766
	0.3	3.50783	4.84477
	0.5	3.5071	4.83587
	0.7	3.49945	4.76338
	0.9	3.45779	3.81816
0.9	0.1	3.51892	5.05769
	0.3	3.50797	4.84361
	0.5	3.50484	4.80288
	0.7	3.50081	4.76379
	0.9	3.44022	3.55598

Pada Tabel 4 diperoleh bahwa semakin besar nilai momentum maka semakin baik atau semakin kecil nilai MAPE yang diperoleh dan semakin kecil nilai learning rate maka semakin baik atau semakin kecil nilai MAPE yang diperoleh. Berdasarkan tabel tersebut diperoleh nilai learning rate terbaik adalah 0.1 dan nilai momentum terbaik adalah 0,9. Berikut ini adalah *toolbox* proses pelatihan pada aplikasi matlab berdasarkan hasil penentuan parameter terbaik dengan jumlah data sebanyak 162:

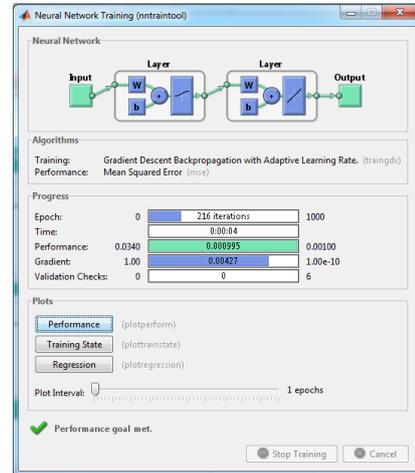


Fig. 6 Toolbox Proses Pelatihan

Pada Fig. 6 dapat dilihat bahwa *goal* 0.001 ditemukan hanya dalam 216 kali iterasi. Pada percobaan ini, jenis pelatihan yang digunakan adalah *Gradient Descent with Adaptive Learning Rate* yang merupakan fungsi pelatihan jaringan yang memperbarui nilai bobot dan bias berdasarkan momentum *gradient descent* dan tingkat pembelajaran adaptif. *Performance*, yang menyatakan metode untuk menghentikan proses jika sudah mencapai *goal* atau mencapai maksimum epoch, disini menggunakan *Mean Squared Error (MSE)*. *Epoch*, menyatakan jumlah perulangan pembelajaran. Pada pelatihan ini target *error* didapatkan setelah 216 iterasi. *Time*, menyatakan waktu yang ditempuh oleh sistem dalam melakukan pembelajaran.

Nilai pembaharuan bobot dan bias yang didapatkan pada proses pelatihan selanjutnya digunakan untuk simulasi pengujian. Simulasi bertujuan untuk menghasilkan output jaringan dari model jaringan dan input matriks. Berikut ini adalah plot hasil pengujian dengan data sebanyak 54:

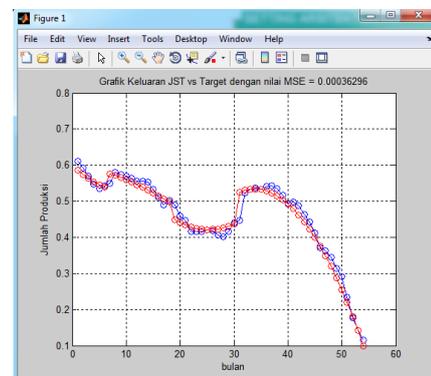


Fig. 7 Plot Hasil Simulasi Testing

Pada Fig. 7 dapat dilihat bahwa berdasarkan proses pelatihan dengan pola arsitektur terbaik, plot hasil pengujian menunjukkan performa yang bagus dengan hasil yang hampir sama dengan target prediksi dengan MSE sebesar

0,00036296. Kemudian untuk mengetahui nilai akurasi yang didapatkan maka dihitung nilai akurasi berdasarkan rumus akurasi yang telah dijelaskan pada persamaan (4).

a) *Akurasi Training*

Nilai MAPE pelatihan yang diperoleh adalah 3.42054, lalu dihitung akurasi menggunakan rumus akurasi :

$$\begin{aligned} \text{Akurasi Pelatihan} &= 100\% - \text{MAPE pelatihan} \\ &= 100\% - 3.42054 = 96,6\% \end{aligned}$$

b) *Akurasi Testing*

Nilai MAPE pengujian yang diperoleh adalah 3.50966, lalu dihitung akurasi menggunakan rumus akurasi :

$$\begin{aligned} \text{Akurasi Pelatihan} &= 100\% - \text{MAPE pelatihan} \\ &= 100\% - 3.50966 = 96,5\% \end{aligned}$$

KESIMPULAN

Berdasarkan hasil dan pembahasan dari bab sebelumnya maka penulis dapat mengambil kesimpulan bahwa arsitektur jaringan terbaik didapatkan dengan metode algoritma pelatihan Traingdx, bobot dan bias menggunakan metode Nguyen Widrow, jumlah neuron pada hidden layer sebanyak 2, momentum sebesar 0.9, learning rate sebesar 0.1, serta rasio training & testing adalah 75% : 25%.

Metode *Backpropagation Neural Network* dapat diimplementasikan dengan baik dalam memprediksi hasil produksi kedelai berdasarkan pengaruh iklim untuk periode selanjutnya dengan akurasi terbaik yang didapatkan pada penelitian ini untuk pelatihan sebesar 96,6% dan pengujian sebesar 96,5%. Untuk penelitian selanjutnya diharapkan dapat menggunakan algoritma ANN yang lain sebagai perbandingan dengan algoritma *backpropagation*.

RUJUKAN

[1] R. A. Carolina, S. Mulatsih, and L. Anggraeni, "ANALISIS VOLATILITAS HARGA DAN INTEGRASI PASAR KEDELAI INDONESIA DENGAN PASAR KEDELAI DUNIA Analysis of Price Volatility and Market Integration between World and Indonesia ' s Soybean Markets," *J. Agro Ekon.*, vol. 34, no. 1, pp. 47–66, 2016.

[2] D. Nugraha, M. O. Adnyana, and I. P. Wardana, "Pendugaan Produksi dan Tantangan Usahatani Kedelai di Indonesia Menggunakan Metode ARIMA," *Pendugaan Produksi Kedelai di Indone*, vol. 2, no. 3, pp. 155–163, 2018.

[3] N. Herlina, S. Fajriani, and F. A. Rahman, "Evaluasi Perubahan Iklim dan Pengaruhnya terhadap Pola Tanam, Waktu Tanam serta Produktivitas Kedelai (*Glycine max L. Merrill*) Di Kabupaten Malang Jawa Timur," *J. Lahan Suboptimal*, vol. 7, no. 2, pp. 106–120, 2019, doi: 10.33230/jlso.7.2.2018.351.

[4] F. Rizqiyah, "The Impact of Global Climate Change on The Production of Soybean (*Glicine max L Merrill*) at Malang District," *J. Chem. Inf. Model.*, vol. 53, no. 9, pp. 1689–1699, 2019.

[5] A. Santoso and S. Hansun, "Prediksi IHSG dengan Backpropagation Neural Network," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 3, no. 2, pp. 313–318, 2019, doi: 10.29207/resti.v3i2.887.

[6] B. Satria, "Prediksi Volume Penggunaan Air PDAM Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 2, no. 3, pp. 674–684, 2018, doi: 10.29207/resti.v2i3.575.

[7] S. Setti and A. Wanto, "Analysis of Backpropagation Algorithm in Predicting the Most Number of Internet Users in the World," *J. Online Inform.*, vol. 3, no. 2, p. 110, 2019, doi: 10.15575/join.v3i2.205.

[8] E. Siregar, H. Mawengkang, E. B. Nababan, and A. Wanto, "Analysis of Backpropagation Method with Sigmoid Bipolar and Linear Function in Prediction of Population Growth," *J. Phys. Conf. Ser.*, vol. 1255, no. 1, 2019, doi: 10.1088/1742-6596/1255/1/012023.

[9] S. R. Diana and G. Dharma, "Estimation the Amount of Oil Palm Production Using Artificial Neural Network and NDVI SPOT-6 Imagery," vol. 4, no. 11, pp. 548–554, 2019.

[10] A. Eskandarin, H. Nazarpour, M. Teimouri, and M. Z. Ahmadi, "Comparison of Neural Network and K-Nearest Neighbor Methods in Daily Flow Forecasting," *J. Appl. Sci.*, vol. 10, no. 11, pp. 1006–1010, 2010, doi: 10.3923/jas.2010.1006.1010.

[11] I. Prihandi, I. Ranggadara, S. Dwiasnati, Y. S. Sari, and Suhendra, "Implementation of Backpropagation Method for Identified Javanese Scripts," *J. Phys. Conf. Ser.*, vol. 1477, no. 3, 2020, doi: 10.1088/1742-6596/1477/3/032020.

[12] D. Kartini, "Penerapan Data Mining dengan Algoritma Neural Network (Backpropagation) Untuk Prediksi Lama Studi Mahasiswa," *Pros. Semin. Nas. Sisfotek*, vol. 3584, pp. 235–241, 2017, [Online]. Available: www.seminar.iaii.or.id %7C ISSN 2597-3584 (media online).

[13] M. S. Drs. Jong Jek Siang, "Jaringan Syaraf Tiruan dan Pemogramannya Menggunakan Matlab." p. 328, 2005.

[14] A. Holik, R. R. Bachtiar, and S. Setiadevi, "Forecasting Analysis of Organic Red Rice's Demand Using Artificial Neural Networks," *J. Manaj. dan Agribisnis*, no. July 2019, 2019, doi: 10.17358/jma.16.2.123.