

Penerapan *Artificial Neural Network* Algoritma Backpropagation Pada Prediksi Produksi Jagung

Clarisna Evita

Teknik Elektro, Universitas Trunojoyo Madura
180431100071@student.trunojoyo.ac.id

Abstract - Prediction of corn production is important to support the national development of the agricultural sector in a country or region. For planning effectiveness agricultural sector development, accuracy of production prediction rice is becoming increasingly crucial. Artificial Neural Network (ANN) is one of the best methods for making predictions. Artificial Neural Network (ANN) or Artificial Neural Network (ANN) is an information processing system with a characteristic resembling the nervous system in humans can solve SVM and KNN problems by doing large data training and ANN has the ability to Tolerating errors so that it can generate predictions The main problem is how to determine the optimal number of neurons and hidden layers so that the prediction accuracy is high. This article aims to design an ANN architecture to predict maize production using ANN with backpropagation algorithm. The stages of the research carried out were collecting corn production data, pre-processing data, processing predictions, and testing accuracy and error as well as implementation. The prediction process is carried out according to the prediction model design, namely the epoch, momentum, learning rate, hidden layer parameters to produce high accuracy. The findings obtained are in the form of an optimal design for making predictions by using multilayer.

Keywords - ANN, prediction, parameter epoch, momentum, learning rate.

Abstrak - Prediksi produksi jagung menjadi penting dilakukan untuk menunjang pembangunan nasional sektor pertanian pada suatu negara atau wilayah. Untuk efektifitas perencanaan pembangunan sektor pertanian, akurasi dari prediksi produksi jagung menjadi semakin krusial. Artificial Neural Network (ANN) termasuk metode yang terbaik dalam melakukan prediksi. Artificial Neural Network (ANN) atau Jaringan Syaraf Tiruan (JST) merupakan suatu sistem pemrosesan informasi dengan suatu karakteristik menyerupai sistem saraf pada manusia yang dapat memecahkan masalah SVM dan KNN dengan melakukan *training* data yang besar dan ANN memiliki kemampuan untuk mentoleransi kesalahan sehingga dapat menghasilkan prediksi yang baik Masalah utamanya adalah bagaimana menentukan jumlah neuron dan hidden layer yang optimal sehingga akurasi prediksinya tinggi. Artikel ini bertujuan untuk merancang arsitektu ANN untk melakukan prediksi terhadap produksi jagung menggunakan ANN dengan algortima backpropagation. Tahapan penelitian yang dilakukan adalah mengumpulkan data produksi jagung, melakukan pre-processing data, memproses prediksi, dan pengujian akurasi dan error serta implementasi. Dalam memproses prediksi dilakukan sesuai dengan rancangan model prediksi, yaitu parameter epoch, momentum, learning rate, hidden layer untuk menghasilkan keakuratan yang tinggi. Temuan yang diperoleh berupa

rancangan optimal untuk melakukan prediksi yaitu dengan menggunakan multilayer.

Kata Kunci - ANN, prediksi, parameter epoch, momentum, learning rate.


I. PENDAHULUAN

Jagung merupakan salah satu tanaman pangan dunia yang terpenting, selain gandum dan padi. Prediksi produksi jagung merupakan suatu yang vital bagi Indonesia khususnya di sektor pertanian. Dengan jumlah masyarakat yang mencapai 267 juta orang serta tingkat konsumsi mencapai 124,89 kg/kapita/tahun, perencanaan pembangunan produksi jagung menjadi semakin strategis [1]. Untuk efektifitas perencanaan pembangunan sektor pertanian, akurasi dari prediksi produksi jagung menjadi semakin krusial. Untuk memperoleh akurasi yang baik, beragam metode sudah dikembangkan. Metode dan teknik prediksi yang berkembang sudah direview pada penelitian sebelumnya [2]. Support Vector Machines (SVM) memiliki kelebihan dalam menginterpretasi hasil, tingkat error yang rendah, dan juga dapat menghasilkan prediksi yang baik, tapi memiliki kelemahan pada saat *training* dengan kumpulan data besar sehingga *training* jadi lambat [3]. K-Nearest Neighbor (KNN) memiliki kelebihan efektif terhadap data yang berukuran besar, dan handal terhadap data yang memiliki banyak noise, namun juga memiliki kekurangan yaitu perlunya menghitung satu persatu data *testing* terhadap semua data *training*, dan sensitive terhadap data *pre processing* [4]. Artificial Neural Network (ANN) atau Jaringan Syaraf Tiruan (JST) merupakan suatu sistem pemrosesan informasi dengan suatu karakteristik menyerupai sistem saraf pada manusia yang dapat memecahkan masalah SVM dan KNN dengan melakukan *training* data yang besar dan ANN memiliki kemampuan untuk mentoleransi kesalahan sehingga dapat menghasilkan prediksi yang baik [5]. Selain itu metode ini juga dapat digunakan untuk memodelkan hubungan yang kompleks antara masukan (*input*) dan keluaran (*output*) dalam menemukan polapola pada data. Namun masalahnya adalah ANN memiliki kelemahan yaitu sulit untuk mengetahui berapa banyak neuron dan lapisan yang diperlukan, dan mengalami perlambatan saat *learning*. Dalam metode ANN, terdapat beberapa algoritma yang telah digunakan salah satunya adalah *backpropagation* [6]. Algoritma *Backpropagation* merupakan salah satu prosedur yang paling populer, efektif, dan mudah dipelajari pada jaringan multilayer

yang kompleks untuk mengoptimalkan pelatihan jaringan saraf tiruan. *Backpropagation* melakukan pembelajaran terbimbing (*supervised learning*) yang digunakan pada jaringan *multi-layer* yang terdiri dari beberapa *hidden-layer* yang bertujuan untuk meminimalkan *error* terhadap jaringan yang menghasilkan keluaran (*output*) [7]. Menggunakan fungsi pelatihan (*training functions*) variabel laju pemahaman (*traingdx*) untuk mempercepat pelatihan *backpropagation*, yang merupakan kombinasi dari parameter laju pemahaman (*learning rate*) dan momentum sehingga mendapatkan hasil yang relatif lebih akurat [8]. Makalah ini membahas bagaimana menentukan banyak neuron dan jumlah layer yang diperlukan untuk prediksi hasil produksi jagung.

II. METODE PENELITIAN

Dalam pelaksanaan penelitian ini, ada beberapa tahapan yang dilaksanakan yaitu mengumpulkan data, melakukan pemrosesan awal, memprediksi produksi jagung, melakukan pengujian akurasi dan implementasi seperti pada gambar 1.



Gambar 1. Tahapan Penelitian

2.1. Pengumpulan Data

Data yang dikumpulkan merupakan data produksi jagung selama 5 (lima) tahun, yang berasal dari 19 Kota/Kabupaten di Jawa Timur. Data yang dikumpulkan untuk masing-masing kota/kabupaten adalah; (1) data target luas tanam jagung (Ha), (2) data target luas panen jagung (Ha), (3) data target produktifitas jagung (ton/Ha), (4) data target produksi jagung (ton).

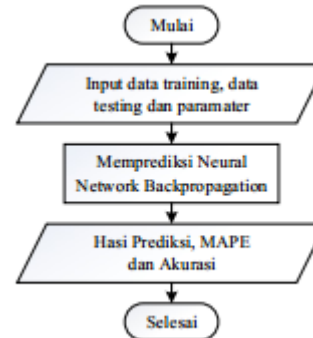
2.2. Pre-Processing Data

Pada tahap ini, target luas tanam jagung, target luas panen jagung dan target produktifitas jagung dari tahun 2016-2020 dan target produksi jagung dari tahun 2016-2020 tersebut dikelompokkan menjadi 2 jenis data, yaitu data latih (*training*) dan data uji (*testing*) sebagai data input. Tahap ini bertujuan juga untuk mempersiapkan data agar dapat digunakan dalam prediksi. Selanjutnya melakukan normalisasi atau transformasi data, karena lapisan tersembunyi (*hidden layer*) menggunakan fungsi aktivasi *sigmoid biner* atau *logsig* untuk lapisan tersembunyi dan *purelin* untuk lapisan keluaran. Proses

normalisasi atau transformasi memiliki tujuan untuk mempermudah perhitungan dan mendapatkan hasil akurat.

2.3. Proses Prediksi Produksi Jagung

Proses prediksi produksi jagung menggunakan metode Artificial Neural Network (ANN) *Backpropagation* dapat ditunjukkan seperti pada gambar 2 berikut;



Gambar 2. Flowchart Prediksi Produksi Jagung dengan Jaringan Saraf Tiruan *Backpropagation*

Pada rancangan prediksi produksi jagung menggunakan ANN *Backpropagation* ini, dimulai dengan melakukan penginputan data uji dan data latih. Data uji dan data latih dapat dikatakan sebagai variabel input dan data target. variabel input terdiri dari data target luas tanam jagung, target luas panen jagung dan target produktivitas jagung tahun 2016-2020. Dan variabel target yaitu data target produksi jagung tahun 2016-2020. Output merupakan hasil prediksi produksi jagung tahun 2021. Untuk merancang arsitektur metode ANN *Backpropagation* yang menghasilkan prediksi yang optimal, maka dilakukan penentuan atau penginputan jumlah nilai parameter-parameter yang digunakan, seperti jumlah *hidden layer*, laju pemahaman (*learningrate*), maksimum iterasi (*epoch*), dan momentum dengan menggunakan proses *trial and error*. Setelah menentukan jenis data dan parameter, prediksi dilakukan dengan metode ANN *Backpropagation* berdasarkan langkah-langkah arahan Laurene Fausett [9]. Selanjutnya, hasil prediksi yang diperoleh dievaluasi nilai *error*nya dengan menggunakan MAPE untuk memperoleh tingkat akurasi pada prediksi.

2.4. Pengujian akurasi dan error

Pada tahapan ini dilakukan pengujian hasil prediksi yang sudah diperoleh dengan cara melihat tingkat keakuratan dan *error* pada sistem. Pengujian dilakukan kepada masing-masing data *training* dan data *testing*. Pengujian bertujuan untuk mengetahui sistem kerja *input*, proses dan *output* apakah sesuai dengan tujuan yang diharapkan. Cara menghitung nilai *error* digunakan MAPE (*Meanverage Percentage Error*). Nilai MAPE menunjukkan seberapa banyak kesalahan dalam hasil prediksi dibandingkan dengan nilai aktual. *Mean Absolute Percentage Error* (MAPE) dihitung menggunakan kesalahan mutlak dalam setiap periode dibagi dengan nilai-nilai yang diamati yang jelas untuk periode tersebut. Semakin kecil nilai MAPE maka semakin baik kinerja prediksi. Untuk

menghitung akurasi terhadap prediksi yang dilakukan, maka sebuah akurasi 100% dikurangi dengan nilai MAPE [10].

$$MAPE = \frac{\sum_{t=1}^n \frac{|x_t - y_t|}{x_t}}{n} \times 100\% \dots \dots \dots (1)$$

$$Akurasi = 100\% - MAPE \dots \dots \dots (2)$$

Dimana x_t adalah nilai target data asli pada periode t , sedangkan y_t merupakan nilai prediksi pada periode t dan n adalah banyaknya data prediksi pada periode t . MAPE digunakan dalam penelitian ini untuk mengevaluasi kinerja berbagai jenis model prediksi. Semakin kecil MAPE maka semakin baik model prediksinya [11] seperti pada tabel 1.

Tabel 1. Kriteria Skala MAPE

Skala MAPE	Kriteria
<10%	Sangat Baik
10%-20%	Baik
20%-50%	Cukup
>50%	Buruk

2.5. Implementasi

Pada tahapan ini, hasil penelitian prediksi jaringan saraf tiruan *backpropagation* diterapkan pada GUI MATLAB agar mempermudah *user* dalam pengoperasian model yang telah dibangun[12].

III. HASIL DAN PEMBAHASAN

3.1 Pengumpulan Data

Hasil dari pengumpulan data adalah berupa data target luas tanam jagung, target luas panen jagung, dan target produktifitas jagung dari tahun 2016-2020 serta target produksi jagung dari tahun 2016-2021. Pada tabel 2 berikut ini akan menunjukkan data yang digunakan[13].

3.2. Pre-Processing

Data produksi jagung dan variabel lainnya dibagi atas dua kelompok yaitu sebagai data latih (training) dan data uji (testing). Maka proporsi pembagian data training dan data testing yang digunakan dalam penelitian ini yaitu 70% data training berjumlah 66 data setiap variabel dan 30% data testing berjumlah 29 data setiap variable[14]. Setelah data terbagi menjadi dua bagian, selanjutnya dilakukan pemeriksaan agar data tersebut *valid* dan siap digunakan untuk melakukan prediksi produksi jagung. Setiap data *input* dilakukan normalisasi[15]. Setelah data terbagi menjadi dua bagian, selanjutnya akan dilakukan pemeriksaan agar tidak ada yang *missing* hingga data tersebut *valid* dan dapat digunakan dalam melakukan prediksi produksi jagung. Karena pada penelitian ini menggunakan fungsi aktivasi *sigmoid biner* yang mempunyai rentang nilai 0 hingga 1, maka setiap data *input* melakukan normalisasi atau transformasi. Normalisasi data dilakukan dengan menggunakan persamaan (3) berikut :

$$X' = \frac{0.8(K - K_{min})}{K_{max} - K_{min}} + 0.1 \dots \dots \dots (3)$$

Data primer yang digunakan merupakan data dari Dinas Tanaman Pangan, Hortikultura, dan Perkebunan Provinsi Jawa Timur diproses terlebih dahulu sebelum diolah pada MATLAB[16]. Data tersebut dimasukkan ke dalam *Microsoft Excel*, data di kelompokkan berdasarkan data *input* dan data target. Lalu dilakukan proses normalisasi. Setelah itu data siap untuk di *input* pada MATLAB. Pada tabel 3 berikut ini akan menunjukkan hasil data setelah melakukan proses normalisasi pada data tahun 2016.

3.3. Proses Prediksi


3.3.1. Perancangan Arsitektur Model ANN

Rincian rancangan model prediksi produksi jagung seperti yang ditunjukkan pada Tabel 4

Tabel 2. Rancangan Model ANN Multilayer Prediksi

Parameter	Jumlah	Keterangan
<i>Input Layer</i>	3 neuron	Target Luas Tanam Jagung; Target Luas Panen Jagung; Target Produktifitas Jagung
<i>Hidden Layer</i>	trial and error	3 neuron
<i>Output Layer</i>	1 neuron	Produksi jagung
Bobot Awal	trial and error	BB : 0.05 BA : 0.08 Bilangan acak antara 0.05-0.08
<i>Learning Rate</i>	Trial and error	0.1-0.5
<i>Momentum</i>	Trial and error	0.5-0.9
<i>Epoch</i>	Trial and error	100-200 (dengan interval 50)
Fungsi Aktivasi	2	Logsig dan Purelin

Dari tabel 2 dapat digambarkan arsitekturnya seperti gambar 3 berikut;



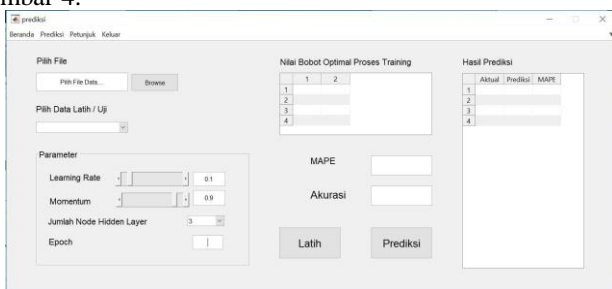
Gambar 3. Arsitektur ANN Prediksi Produksi Jagung

Arsitektur ANN yang dirancang menggunakan tiga neuron pada input layer yaitu target luas tanam jagung, target luas panen jagung dan target produktifitas jagung. Hidden layer terdiri dari tiga neuron diperoleh dari proses trial dan error. Bobot yang digunakan adalah rentang 0.05 sampai dengan 0.08. Output layer berupa prediksi produksi jagung dengan 1 neuron[17].

3.3.2. Aplikasi Pengujian Prediksi

Pada halaman prediksi terdapat *pop up menu* untuk memilih untuk memprediksi data latih atau data uji yang telah di *input*-kan sebelumnya pada *Microsoft Excel*[18]. Setelah data uji atau

data input dipilih, lalu *input* nilai-nilai pada setiap parameter yaitu, *Epoch*, *Learning Rate*, *Momentum*, dan *Hidden Layer*. Saat semua nilai telah terisi, maka pengguna menekan *button* prediksi untuk melakukan proses prediksi dengan metode *ANN Backpropagation*. Lalu sistem akan menampilkan hasil prediksi pada tabel hasil prediksi jagung, yang dibedakan atas dua kolom, yaitu kolom aktual (target produksi) yang berasal dari variabel (data) target produksi jagung, dan kolom prediksi jagung yang merupakan hasil prediksi sistem. Setelah hasil prediksi ditampilkan, maka dilakukan perhitungan *error* dan akurasi. Perhitungan *error* dilakukan dengan rumus MAPE[19]. Sistem akan menghasilkan akurasi 100% jika nilai *error* bernilai 0, atau dapat dikatakan hasil prediksi sistem mirip atau sama dengan nilai aktual. Antarmuka aplikasi pengujian prediksi produksi jagung seperti ditunjukkan pada gambar 4.



Gambar 4. Antarmuka Halaman Prediksi

3.3.3. Pengujian Aplikasi

Setelah sistem selesai dibangun, maka dilakukan pengujian untuk menghitung akurasi dan nilai *error* pada prediksi produksi jagung menggunakan jaringan saraf tiruan *backpropagation*. Ada dua jenis pengujian, yaitu pengujian fungsionalitas sistem dan pengujian aplikasi. Pengujian sistem ini dilakukan dengan fungsionalitas dari sudut pandang *user* (pengguna)[20]. Format dan pengujian yang dilakukan terhadap sistem ditunjukkan pada table 3 berikut ini

Tabel 5. Pengujian Fungsionalis Sistem

No.	Komponen Pengujian	Input	Output	Status
1.	Halaman Beranda	User memilih menu beranda	Menampilkan halaman beranda	OK
2.	Halaman Prediksi	User memilih menu prediksi	Menampilkan halaman prediksi	OK
3.	Halaman Petunjuk	User memilih menu petunjuk	Menampilkan halaman petunjuk	OK

Dari tabel 3 berdasarkan pengujian *input* dan *output* pada setiap komponen pengujian yaitu halaman beranda, halaman prediksi, dan halaman petunjuk dapat dikatakan bahwa fungsionalitas sistem berhasil. Hasil pengujian parameter prediksi produksi jagung menggunakan jaringan saraf tiruan *backpropagation* seperti yang ditunjukkan pada tabel 4.

Tabel 4. Hasil Prediksi dengan Pengujian Parameter

Epoch	Momen tum	Learning Rate	MAPE (%)	Akurasi (%)
-------	-----------	---------------	----------	-------------

200	0,5	0,1	13,271129	86,728871
		0,2	12,005893	87,994107
		0,3	11,886828	88,113172
		0,4	11,865150	88,134850
		0,5	11,861308	88,138692
0,6	0,1	0,1	13,274849	86,725151
		0,2	12,006093	87,993907
		0,3	11,886851	88,113149
		0,4	11,865101	88,134899
		0,5	11,861311	88,138689
0,7	0,1	0,1	13,273208	86,726792
		0,2	12,005597	87,994403
		0,3	11,886781	88,113219
		0,4	11,902695	88,097305
		0,5	11,861312	88,138688
0,8	0,1	0,1	13,275736	86,724264
		0,2	12,006159	87,993841
		0,3	11,886636	88,113364
		0,4	11,865135	88,134865
		0,5	11,861316	88,138684
0,9	0,1	13,276099	86,723901	

Berdasarkan hasil pengujian sistem terhadap rancangan model parameter-parameter yang telah ditentukan, maka diperoleh parameter yang menghasilkan nilai MAPE terkecil dan akurasi terbesar, yaitu dengan *epoch* sebesar 200, *momentum* sebesar 0,5, dan *learning rate* sebesar 0,5. Nilai MAPE yang didapatkan yaitu 11,86 % dan nilai akurasi atau keakuratan prediksi sebesar 88,14%.

3.3.3. Post-Processing Data

Setelah proses prediksi, maka akan didapatkan nilai *output* atau hasil prediksi, dimana data awal sebagai data *input* telah dilakukan proses normalisasi atau transformasi. Jadi untuk data prediksi yang baru dihasilkan perlu dilakukan proses denormalisasi. Proses ini disebut dengan *post-processing*, yaitu proses dimana nilai *output* yang menghasilkan nilai dengan rata - rata sama dengan nol, maka dalam proses ini akan mengembalikan nilai tersebut sesuai dengan data awal atau data yang asli. Nilai *output* yang dihasilkan pada proses simulasi adalah nilai dari data yang telah dinormalisasi pada langkah awal. Denormalisasi data dilakukan dengan menggunakan persamaan berikut:

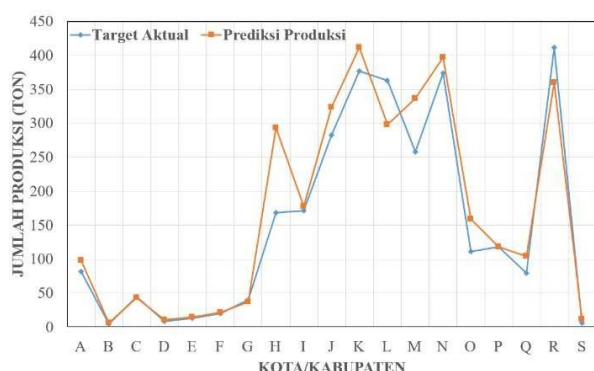
$$X = \frac{(x' - 0,1) \times X_{max} - X_{min}}{0,8} + X_{min} \dots \dots \dots (4)$$

Setelah seluruh proses prediksi dilakukan pada MATLAB, data hasil prediksi disalin, dipindahkan, dan diolah pada Microsoft Excel untuk melakukan proses denormalisasi. Prediksi produksi jagung yang dilakukan dengan menggunakan metode jaringan saraf tiruan *backpropagation* sehingga diperoleh model yang menghasilkan akurasi dan tingkat kesalahan (*error*) yang optimal. Hasil denormalisasi sekaligus hasil prediksi produksi jagung pada kabupaten/kota di provinsi Jawa Timur untuk tahun 2021 ditunjukkan pada tabel 5 berikut.

Tabel 5. Hasil Denormalisasi Prediksi Produksi

Kabupaten/Kota	Sebelum Denormalisasi	Setelah Denormalisasi
A	0,288718	97.808
B	0,110297	6.316
C	0,182405	43.292
D	0,119414	10.991
E	0,126920	14.84
F	0,139737	21.413
G	0,170091	36.977
H	0,670671	293.667
I	0,443951	177.408
J	0,728241	323.188
K	0,900000	411.263
L	0,679379	298.132
M	0,754264	336.532
N	0,872649	397.238
O	0,408359	159.157
P	0,328559	118.237
Q	0,301161	104.188
R	0,799787	359.876
S	0,121186	11.9

Untuk memprediksi target produksi jagung pada tahun tertentu, sudah berhasil di rancang suatu aplikasi menggunakan metode Artificial Neural Network algoritma Backpropagation. Aplikasi tersebut sudah dilakukan pengujian untuk memprediksi target produksi tahun berikutnya. Dari pengolahan data, diperoleh grafik perbandingan jumlah produksi jagung aktual yang dicapai pada tahun 2020 dengan prediksi target produksi jagung pada Kota/Kabupaten di Jawa Timur, Indonesia seperti yang ditunjukkan oleh gambar 5.



Gambar 5. Perbandingan Aktual Produksi dengan Prediksi

Dari perbandingan target aktual produksi dengan prediksi target produksi, diperoleh tingkat akurasi hasil prediksi tersebut. Persentase keakuratan prediksi target produksi

jagung yang dihasilkan aplikasi dengan produksi jagung aktual dapat ditunjukkan pada Tabel 6.

Tabel 6. Persentase Akurasi Prediksi Produksi Jagung

Kota/ Kabupaten	Produksi Aktual (Ton)	Prediksi Produksi (Ton)	Akurasi Prediksi (%)
A	168.712	293.667	42,931
B	171.438	177.408	97,307
C	282.574	323.188	87,797
D	376.965	411.263	91,971
E	362.553	298.132	84,394
F	257.734	336.532	74,414
G	374.063	397.238	94,538
H	111.424	159.157	70,475
I	118.473	118.237	99,860
J	79.690	104.188	81,146
K	411.263	359.876	88,865
L	45.081	43.292	98,123
M	4.520	6.316	96,720
N	8.765	10.991	96,227
O	82.054	97.808	88,092
P	12.883	14.840	96,900
Q	19.987	21.413	97,971
R	6.505	11.900	90,493
S	40.224	36.977	96,411

IV. KESIMPULAN

Rancangan arsitektur Artificial Neural Network (ANN) sudah berhasil dibuat dan diterapkan untuk prediksi produksi jagung di Jawa Timur, Indonesia. Rancangan ANN yang menggunakan multilayer pada aplikasi sudah berhasil diujikan dengan memperoleh hasil prediksi produksi jagung untuk periode berikutnya. Dari implementasi sistem yang dirancang, diperoleh hasil prediksi dengan akurasi mencapai 88,14%. Patut dicatat bahwa proses trial dan error perlu mendapat perhatian untuk mendapatkan hasil yang maksimal dengan durasi waktu yang lebih baik. Aplikasi prediksi produksi jagung yang dibuat telah mampu melakukan prediksi produksi jagung untuk tahun 2021 dengan melakukan 75 kali pengujian terhadap parameter yang terdapat pada rancangan model prediksi sehingga didapatkan model dengan parameter yang optimal meliputi, *input layer* berjumlah 3, *hidden layer* berjumlah 3, dan *output layer* berjumlah 1 dengan *epoch* sebesar 200, *momentum* sebesar 0,5, dan *learning rate* sebesar 0,5.

V. DAFTAR PUSTAKA

- [1] Badan Pusat Statistik, "Luas Panen dan Produksi Padi di

- Indonesia 2019 Hasil Survey Kerangka Sampel Area (KSA),” 2020. [Online]. Available: https://www.bps.go.id/website/materi_ind/materiBrsInd-20200204112508.pdf.
- [2] H. Putra, N. U. Walmi, and A. D. Kartika, “Data Mining Approach For Prediction Of Rice Production Using Backpropagation Artificial Neural Network Method,” in *The International Conference on ASEAN 2019*, 2019, pp. 321–326.
- [3] N. R. Dzakiyullah, B. Hussin, C. Saleh, and A. M. Handani, “Comparison neural network and support vector machine for production quantity prediction,” *Adv.Sci. Lett.*, vol. 20, no. 10–12, pp. 2129–2133, 2014.
- [4] G. F. Fan, Y. H. Guo, J. M. Zheng, and W. C. Hong, “Application of the weighted k-nearest neighbor algorithm for short-term load forecasting,” *Energies*, vol. 12, no. 5, 2019.
- [5] S. M. Gorade and P. A. Deo, “A Study Some Data Mining Classification Techniques,” *Int. J. Mod. Trends Eng. Res.*, vol. 4, no. 1, pp. 210–215, 2017.
- [6] L. Wang, Y. Zeng, and T. Chen, “Back propagation neural network with adaptive differential evolution algorithm for time series forecasting,” *Expert Syst. Appl.*, vol. 42, no. 2, pp. 855–863, 2015.
- [7] N. A. Hamid, N. M. Nawi, R. Ghazali, and M. N. M. Salleh, “Accelerating learning performance of back propagation algorithm by using adaptive gain together with adaptive momentum and adaptive learning rate on classification problems,” *Int. J. Softw. Eng. its Appl.*, vol. 5, no. 4, pp. 31–44, 2011.
- [8] G. Amaral *et al.*, *Modern Database Management*, vol. 369, no. 1. 2013.
- [9] Laurene V. Fausett, *Fundamentals Of Neural Networks: Architectures, Algorithms And Applications*, no. 888. 2007.
- [10] O. M. Rezapour, L. T. Shui, and A. A. Dehghani, “Review of genetic algorithm model for suspended sediment estimation,” *Aust. J. Basic Appl. Sci.*, vol. 4, no. 8, pp. 3354–3359, 2010.
- [11] P. C. Chang, Y. W. Wang, and C. H. Liu, “The development of a weighted evolving fuzzy neural network for PCB sales forecasting,” *Expert Syst. Appl.*, vol. 32, no. 1, pp. 86–96, 2007.
- [12] P. K. Sethy, N. K. Barpanda, A. K. Rath, and S. K. Behera, “Nitrogen Deficiency Prediction of Rice Crop Based on Convolutional Neural Network,” *J. Ambient Intell. Humaniz. Comput.*, no. 0123456789, 2020.
- [13] 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,” *IJISTECH (Internasional J. Inf. Syst. Technol.)*, vol. 1, no. 1, p. 43, 2017.
- [14] I. N. da Silva, D. H. Spatti, R. A. Flauzino, L. H. B. Liboni, and S. F. dos Reis Alves, “Artificial neural networks: A practical course,” *Artif. Neural Networks APract. Course*, pp. 1–307, 2016.
- [15] G. Deshpande, P. Wang, D. Rangaprakash, and B. Wilamowski, “Fully connected cascade artificial neural network architecture for attention deficit hyperactivity disorder classification from functional magnetic resonance imaging data,” *IEEE Trans. Cybern.*, vol. 45, no. 12, pp. 2668–2679, 2015.
- [16] R. B. Santos, M. Rupp, S. J. Bonzi, and A. M. F. Fileti, “Comparison between multilayer feedforward neural networks and a radial basis function network to detect and locate leaks in pipelines transporting gas,” *Chem. Eng. Trans.*, vol. 32, pp. 1375–1380, 2013.
- [17] A. A. Heidari, H. Faris, I. Aljarah, and S. Mirjalili, “An efficient hybrid multilayer perceptron neural network with grasshopper optimization,” *Soft Comput.*, vol. 23, no. 17, pp. 7941–7958, 2019.
- [18] E. Lee, Y. D. Seo, and Y. G. Kim, “Self-adaptive framework based on MAPE loop for internet of things,” *Sensors (Switzerland)*, vol. 19, no. 13, pp. 1–24, 2019.
- [19] Z. CÖMERT and A. KOCAMAZ, “A Study of Artificial Neural Network Training Algorithms for Classification of Cardiocography Signals,” *Bitlis Eren Univ. J. Sci. Technol.*, vol. 7, no. 2, pp. 93–103, 2017.
- [20] G. Ramadhona, B. D. Setiawan, and F. A. Bachtiar, “Prediksi Produktivitas Padi Menggunakan Jaringan Syaraf Tiruan Backpropagation,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 12, pp. 6048–6057, 2018.