

# Implementasi Algoritma *Backpropagation Neural Network* dengan Algoritma Genetika untuk Memprediksi Harga Bahan Pangan

Heliawati Hamrul\*<sup>1</sup>, Nurhikma Arifin<sup>2</sup>, Muh. Rifki Anhar<sup>3</sup>

<sup>1,2,3</sup>Program Studi Informatika, Universitas Sulawesi Barat

E-mail: \*[heliawatyhamrul@unsulbar.ac.id](mailto:heliawatyhamrul@unsulbar.ac.id), <sup>2</sup>[nurhikmarifin@unsulbar.ac.id](mailto:nurhikmarifin@unsulbar.ac.id)

## **Abstrak**

Penelitian ini bertujuan untuk mengembangkan model prediksi harga bahanpangan di Pasar Sentral Majene dengan memanfaatkan algoritma backpropagation neural network dan algoritma genetika. Selanjutnya, model dibentuk dengan menggunakan algoritma backpropagation neural network dan dioptimasi dengan algoritma genetika. Data harga bahan pangan yang digunakan dalam penelitian ini berasal dari catatan mingguan di Pasar Sentral Majene yang bersumber dari Dinas Perdagangan Kabupaten Majene pada periode 2017-2022. Hasil dari penelitian ini menunjukkan bahwa model prediksi yang dikembangkan dengan menggunakan algoritma backpropagation neural network dan dioptimasi dengan algoritma genetika mampu memberikan hasil prediksi harga bahan pangan di Pasar Sentral Majene yang akurat dan dapat diandalkan. Dalam hal ini, pengujian menggunakanBPNN menghasilkan akurasi tertinggi sebesar 95,84% dan MAPE 4,15 dengan *learning rate* 0,09 dan epoch 400. Sedangkan pengujian menggunakan BPNN-GAhasil akurasi tertinggi mencapai 99,33% dan MAPE 0,66 dengan pc dan pm 1.0 pada generasi 100 dan epoch 400. Kesimpulannya, algoritma backpropagation neural network dan algoritma genetika dapat mengoptimasi BPNN dan dapatdigunakan sebagai alternatif untuk memprediksi harga bahan pangan di Pasar Sentral Majene

**Kata kunci**— *Algoritma Genetika, Backpropagation Neural Network, Harga pangan, Prediksi, Optimasi*

## **Abstract**

*This research aims to develop a food price prediction model using the backpropagation neural network algorithm and genetic algorithm. Food price data used in this research comes from the Majene Regency Trade Office for the 2017-2022 period. The results of the research show that the prediction model developed using the backpropagation neural network algorithm and optimized with a genetic algorithm is able to provide accurate and reliable food price predictions at the Majene Central Market. Testing using BPNN produces the highest accuracy of 95.84% and MAPE 4.15 with a learning rate of 0.09 and epoch 400. Meanwhile testing using BPNN-GA results in the highest accuracy reaching 99.33% and MAPE 0.66 with PC and PM 1.0 at generation 100 and epoch 400. The conclusion is that the backpropagation neural network algorithm and genetic algorithm can optimize BPNN and can be used as an alternative to predict food prices at Majene Central Market*

**Keywords**— *Backpropagation Neural Network, Genetic Algorithm, Prediction, Price, Optimization*

## 1. PENDAHULUAN

Makanan adalah salah satu kebutuhan utama setiap manusia. Setiap hari manusia selalu berusaha untuk dapat memenuhi kebutuhan mereka untuk mendapatkan makanan. Makanan dapat diperoleh dengan membeli bahan makanan dan kemudian diproses atau juga dapat secara langsung membeli makanan yang siap untuk dikonsumsi. Makanan yang diolah maupun yang tidak diolah dipasaran terkadang memiliki harga yang relatif tinggi dan kestabilan harga juga dapat berdampak terhadap pengusaha dan masyarakat dalam memenuhi kebutuhan sehari-hari. Karena alasan ini harga makanan sangat berpengaruh dalam kehidupan manusia. Perubahan harga bahan pangan biasanya mengalami perubahan sesuai dengan faktor-faktor yang mempengaruhinya, seperti musim, hari perayaan tertentu, dan kebutuhan manusia akan makanan itu sendiri [1]. Dengan mengetahui perkembangan harga pangan dan prediksi harga untuk setiap bahan pangan baik harga bahan pokok ataupun pendamping, kita dapat mengambil langkah-langkah pencegahan untuk mengurangi lonjakan harga pangan di masa depan. Selain itu manajemen keuangan juga dapat direncanakan dengan lebih baik dan juga dapat melakukan strategi lain seperti menyimpan bahan makanan ketika harga mengalami penurunan dan menggunakannya saat mengalami kenaikan harga [2]

Persiapan akan tidak stabilnya harga yang diperlukan dapat diperoleh dari adanya prediksi sebagai strategi untuk pemecahan masalah dan sebagai langkah awal kedepannya. Untuk pemecahan masalahnya tidak hanya menduga hasil yang akan terjadi tetapi menggunakan data dari periode sebelumnya untuk dijadikan acuan dan bahan analisis kedepannya. Oleh karena itu perlu adanya peramalan atau prediksi yang tepat dan akurat dalam membantu pemerintah mengambil langkah awal dalam menstabilkan harga pangan.[3], [4]

Untuk mengatasi masalah tersebut, peneliti mengusulkan metode Backpropagation yang dioptimasi menggunakan Algoritma Genetika. Backpropagation memiliki kemampuan untuk mengatasi permasalahan training klasifikasi dengan skala data yang luas,[5] namun memiliki dua kelemahan utama yaitu kecepatan convergence yang buruk dan tidak stabil hal ini dikarenakan resiko terjebak pada lokal minimum. Kelemahan itu dipengaruhi oleh parameter bobot awal yang dipilih secara random. Kecepatan pembelajaran juga dipengaruhi oleh penentuan learning rate. Jika learning rate terlalu kecil maka akan membutuhkan waktu yang lama untuk mendapatkan error minimum namun learning rate yang terlalu besar update bobot akan melampaui error minimal dan bobot akan beresilasi.(Hrasko et al., 2015).

Oleh karena itu, maka dilakukanlah sebuah penelitian untuk mengoptimasi *Backpropagation Neural Network* dengan menggunakan salah satu algoritma optimasi. Prediksi yang dihasilkan dari model *neural network* akan lebih akurat jika parameter-parameter yang digunakan dapat dioptimalkan secara tepat dan benar dan pemilihan *learning rate* yang sesuai dengan data yang dilatih juga menentukan dalam menghindari osilasi. [6]. Untuk mengoptimalkan parameter yang digunakan pada *Backpropagation Neural Network* penelitian ini menggunakan metode optimasi Algoritma Genetika[7]. Algoritma Genetika ini akan digunakan untuk menentukan parameter *learning rate* dengan tujuan untuk meminimalkan *error* sehingga bisa mendapatkan kemampuan *learning* yang baik serta menentukan perubahan parameter *learning rate* secara dinamis ketika *learning* mengalami osilasi dan terjebak pada lokal minimum sehingga proses *learning* dapat dilanjutkan tanpa harus mengulang *learning* dari awal pembelajaran *neural network*. [8]

## 2. METODE

Tahapan penelitian yang dilakukan dalam penelitian ini terdiri atas:

1. Perancangan konsep dan gagasan: pada tahap ini dilakukan analisis model BPNN dan algoritma genetika serta model optimasinya dalam memprediksi harga

2. Tahap analisis kebutuhan: pada tahap ini dilakukan identifikasi jenis dan bentuk data, *software* dan *hardware* yang akan digunakan.
3. Pengumpulan data set harga bahan pokok: pada tahap ini dicari data primer dan sekunder yang dibutuhkan, kemudian dintegrasikan dalam data set.
4. Desain model: Data dianalisis dan dikumpulkan untuk menjadi data yang saling berhubungan satu sama lainnya. Setelah analisis data diterapkan, selanjutnya menerapkan model- model yang sesuai dengan jenis datanya. Pembagian data dalam data testing (data uji) dan data training (data latihan) yang digunakan untuk pembuatan model.
5. Pembuatan program: pada tahap ini dilakukan Implementasi model BPNN dan optimasi Algoritma genetika ke dalam *source code* program dan menginput data training.
6. Pengujian program: model yang diusulkan akan diuji untuk melihat hasil berupa aturan yang akan dimanfaatkan dalam pengambilan keputusan.
7. Evaluasi data terhadap model yang akan ditetapkan untuk mengetahui tingkat akurasi model.

### 3. HASIL DAN PEMBAHASAN

Adapun penjelasan terkait data penelitian yang digunakan untuk mengoptimasi *Backpropagation Neural Network* menggunakan Algoritma Genetika adalah sebagai berikut:

#### 3.1 Variabel Input

Data yang digunakan pada penelitian ini menggunakan data yang diperoleh dari Dinas Koperasi, UKM, Perdagangan dan Perindustrian Kab. Majene yang terdiri dari 10 bahan pangan yaitu beras, daging ayam, daging sapi, telur ayam, bawang merah, bawang putih, cabai merah, cabai rawit, minyak goreng, dan gula pasir. Variabel *input* yang akan digunakan pada penelitian ini yakni data deret waktu (*time series*). Minggu pada data asli akan diubah menjadi variabel *input* yaitu  $x_1$ ,  $x_2$ ,  $x_3$  dan  $x_4$  serta yang menjadi nilai target adalah minggu pada bulan selanjutnya. Pada setiap data harga pangan dari 10 komoditi bahan pangan yang digunakan untuk membuat model pelatihan jaringan adalah data harga pangan daritahun 2017-2020 sebagai data *training* dengan data *testing* tahun 2021 dan untuk melakukan prediksi menggunakan data harga pangan tahun 2018-2021 sebagai *datatraining* dengan data *testing* tahun 2022. Total data yang digunakan adalah sebanyak 260 data. Sebelum data diolah menggunakan Algoritma data asli perlu diubah kedalam bentuk data *time series univariat*. Berikut contoh perubahan data set asli sebelum dan sesudah dilakukan pengolahan data:

Tabel 1 Data *training* sebelum diolah (Data Harga Beras)

Minggu	Tahun 2017	Tahun 2018	Tahun 2019	Tahun 2020	Tahun 2021
Minggu 1	Rp. 10.550	Rp. 10.600	Rp. 10.600	Rp. 10.600	Rp. 10.750
Minggu 2	Rp. 10.550	Rp. 10.600	Rp. 10.600	Rp. 10.600	Rp. 10.750
Minggu 3	Rp. 10.550	Rp. 10.600	Rp. 10.600	Rp. 10.600	Rp. 10.750
Minggu 4	Rp. 10.600	Rp. 11.400	Rp. 10.600	Rp. 10.600	Rp. 10.800
Minggu 5	Rp. 10.600	Rp. 11.400	Rp. 10.600	Rp. 10.600	Rp. 10.800
Minggu 6	Rp. 10.600	Rp. 11.200	Rp. 10.400	Rp. 10.600	Rp. 10.800
Minggu 7	Rp. 10.600	Rp. 11.000	Rp. 10.400	Rp. 10.600	Rp. 10.800
Minggu 8	Rp. 10.600	Rp. 11.000	Rp. 10.400	Rp. 10.600	Rp. 10.800
			...		
Minggu 45	Rp. 10.600	Rp. 10.200	Rp. 10.000	Rp. 10.600	Rp. 10.600



pangan tahun 2018-2021 dengan data *testing* harga pangan tahun 2022. Pembagian data *training* dan *testing* yaitu 80% untuk data *training* 20% untuk data *testing* dengan jumlah data *training* yaitu sebanyak 204 data dan data *testing* sebanyak 52 data dari total 256 data harga pangan perkomoditi yang digunakan.

### 3.3 Normalisasi

Sesuai dengan *range* fungsi aktivasi yang digunakan yaitu fungsi aktivasi *sigmoid biner* dengan *range* nilai dari 0 sampai 1 sehingga data yang dihasilkan tidak dalam jumlah yang terlalu besar maka perhitungan untuk normalisasi data dapat dilakukan dengan menggunakan persamaan (2.20):

$$X = (10550 - 10000)/(11400 - 10000) = 0,39$$

Keterangan :

$X$  = nilai data sebelum dinormalisasi = 10550

$Min(X)$  = nilai minimum dari data = 10000

$Max(X)$  = nilai maksimum dari data = 11400

Hasil Normalisasi data dapat dilihat pada tabel 3 dibawah ini :

Tabel 3 Hasil normalisasi data

$x_1$	$x_2$	$x_4$	$x_4$	$y$
0.39285714	0.39285714	0.39285714	0.42857143	0.42857143
0.39285714	0.39285714	0.42857143	0.42857143	0.42857143
0.39285714	0.42857143	0.42857143	0.42857143	0.42857143
0.39285714	0.42857143	0.42857143	0.42857143	0.42857143
		....		
0.42857143	0.42857143	0.42857143	0.42857143	0.42857143
0.42857143	0.42857143	0.42857143	0.42857143	0.42857143
0.42857143	0.42857143	0.42857143	0.42857143	0.42857143
0.42857143	0.42857143	0.42857143	0.42857143	0.42857143

### 3.4 Penerapan Model Prediksi Optimasi *Backpropagation Neural Network* dan Algoritma Genetika

Pada tahapan ini akan dilakukan metode optimasi parameter *learning rate* pada *Backpropagation neural network* dengan menggunakan Algoritma Genetika untuk memprediksi harga bahan pangan perminggunya. Adapun tahapannya sebagai berikut:

#### 3.4.1 Menentukan Parameter

Sebelum menjalankan program Algoritma Genetika perlu dilakukan inisialisasi atau menentukan parameter dari Algoritma Genetika itu sendiri, seperti rentang nilai variable, panjang kromosom, jumlah populasi dan generasi, nilai probabilitas *crossover* dan probabilitas mutasi. Untuk pengujian populasi yang diujikan yaitu 5, 10 dan 15 populasi dan banyak generasi yang diujikan yaitu dari 60 sampai 100 generasi. Berdasarkan hasil pengujian parameter tersebut diperoleh parameter terbaik yaitu untuk populasi sebanyak 10 menghasilkan rata-rata akurasi sebesar 98,14% dan jumlah generasi sebanyak 100 menghasilkan rata-rata akurasi 98,19% dan untuk nilai probabilitas mutasi dan *crossover* terbaik hasil pengujian yaitu 1,0.

#### 3.4.2 Inisialisasi Populasi Awal dan Fungsi *Fitness*

Setelah menginisialisasi parameter, selanjutnya adalah membangkitkan populasi awal sesuai dengan jumlah populasi dan panjang kromosom yang telah ditentukan. Melakukan inisialisasi

populasi awal dengan memilih nilai secara *random* dari rentang nilai minimum dan maksimum untuk *learning rate* yang telah ditentukan sebelumnya. Inisialisasi populasi awal dapat dilihat pada *output* program yang disajikan dalam tabel 4 dibawah ini:

Tabel 4 Inisialisasi Populasi awal

Index	X	Fitness
0	0.01	19.671.801
1	0.02	11.499.735
2	0.03	10.824.945
3	0.04	5.917.132
4	0.05	6.369.572
5	0.06	3.768.213
6	0.07	5.196.532
7	0.08	7.623.891
8	0.09	3.964.445
9	0.10	16.926.683

Setelah proses inisialisasi populasi awal selanjutnya masuk ke tahap Algoritma *Backpropagation* sebagai fungsi evaluasi nilai *fitness* dari Algoritma Genetika. Proses BPNN dilakukan dengan tujuan mendapatkan nilai MAPE dari masing-masing kromosom. Nilai MAPE tersebut dijadikan sebagai fungsi *fitness* pada Algoritma Genetika untuk mengevaluasi populasi dari setiap kromosom.

### 3.4.3 Seleksi

Metode Seleksi yang digunakan pada penelitian ini adalah *Random Selection*. Untuk setiap baris dari populasi yang dibangkitkan dilakukan permutasi kemudian dipilih dua kromosom secara *random* dengan posisi yang ditentukan sebelumnya. Pada pemilihan kromosom ini dipilih pada posisi teratas yang telah diurutkan dari nilai *fitness* terbaik sehingga yang terambil hanyalah kromosom dengan nilai *fitness* yang paling baik.

### 3.4.4. Crossover

Selanjutnya hasil seleksi tadi dilakukan proses *crossover* dengan menginisialisasikannya didalam variabel *a* dan *b* dari hasil *random selection*. Pada setiap baris dari populasi kemudian dicari nilai rata-rata dari dua kromosom yang diperoleh dari hasil *random selection*.

### 3.4.5 Mutasi

Tahap Mutasi dilakukan setelah mendapatkan kromosom-kromosom hasil *crossover*. Pada proses mutasi yang dilakukan pada penelitian ini hasil dari *crossover* kemudian dimutasi dengan representasi *floating point* dengan penambahan bilangan kecil yang di *random* untuk pengkodean bilangan riil sehingga menghasilkan individu baru.

### 3.4.6 Denormalisasi Data

Tahapan selanjutnya adalah Denormalisasi data untuk melihat hasil prediksi dengan menggunakan persamaan 2.21.

$$Y = (0,614 * (11400 - 10000)) + 10000 = 10860,77$$

Ket:

$Y$  = nilai data sebelum didenormalisasi = 0,614

$Min(X)$  = nilai minimum dari data = 10000

$Max(X)$  = nilai maksimum dari data = 11400

Hasil denormalisasi data prediksi dapat dilihat pada tabel 5 berikut:

Tabel 5 Hasil denormalisasi data

Hasil Prediksi	Hasil Denormalisasi
0.61483742	10.861
0.59477474	10.833
0.57744215	10.808
0.55825573	10.782
0.54235871	10.759
...	
0.47340702	10.663
0.47340702	10.663
0.47340702	10.663
0.47340702	10.663
0.47340702	10.663

### 3.5 Hasil Pengujian dan Pembahasan

Pembuatan model dilakukan beberapa kali percobaan untuk mencari model yang terbaik dari proses pelatihan. Adapun hasil pengujian dari beberapa parameter yang diujikan yaitu:

#### 3.5.1 Pengujian Parameter BPNN

##### a. Pengujian Jumlah *hidden layer*

Adapun pengujian jumlah *hidden layer* yang diujikan pada penelitian ini yaitu dari *hidden layer* sebanyak 10 sampai 50. Setelah dilakukan percobaan sebanyak 5 kali *running program* dengan inisialisasi bobot yang di *random* dari rentang nilai -0,46 sampai 0,56 dan bias dari -0.24 sampai 0.22 didapatkan hasil akurasi tertinggi pada *hidden layer* sebanyak 30 dengan rata-rata akurasinya yaitu 93,17%. Hal ini menunjukkan bahwa banyaknya *hidden layer* akan mengakibatkan perantara antara *input neuron* dengan *output neuron* semakin banyak pula sehingga dapat menerima informasi yang ada dan pembelajaran jaringan dapat berjalan dengan lebih baik, namun jumlah *hidden layer* yang terlalu banyak juga dapat menyebabkan *overfitting*.

##### b. Pengujian *Learning rate*

Pengujian *Learning rate* yang diujikan adalah *learning rate* dari rentang 0,01-0,1. Percobaan ini dilakukan 5 kali *running program*, didapatkan nilai *learning rate* terbaik pada nilai 0,09 dengan nilai rata-rata akurasinya sebesar 93,02%.

##### c. Pengujian Iterasi

Pada pengujian iterasi yang diujikan yaitu dari 100-500 diperoleh iterasi ke 400 menghasilkan rata-rata akurasi sebesar 92,36% dan lebih baik dari jumlah iterasi yang lain yang telah dilakukan pengujian. Ini menunjukkan bahwa Iterasi yang terlalu besar menjadikan rerata nilai MAPE yang didapatkan semakin besarsedangkan, Iterasi yang kecil dapat menyebabkan kurangnya pelatihan pada jaringan.


#### 3.5.2 Pengujian arsitektur terbaik

Berdasarkan hasil pengujian arsitektur terbaik yang diperoleh dari pengujian BPNN adalah 30 *hidden layer*, 0.09 *learning rate* dengan 400 iterasi. Untuk pengujian arsitektur BPNN dengan parameter terbaik hasil pengujian dengan 5 kali percobaan *running program* dengan uji coba pada

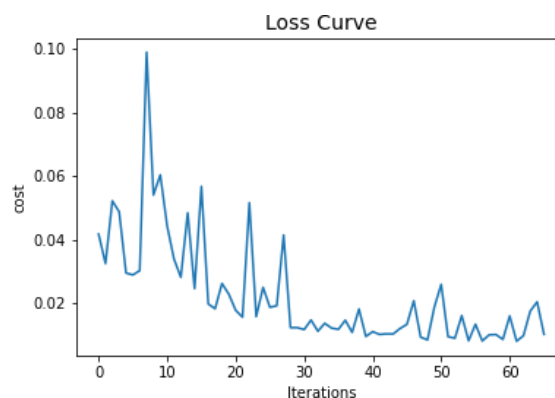
data *train* beras, diperoleh rata-rata akurasi sebesar 92,02% dengan parameter jaringan yang digunakan yaitu 30 *hidden layer*, 0.09 *learning rate* dan 400 iterasi dengan rentang nilai bobot dari -0.46 sampai 0.56 dan bias dari -0.24 sampai 0.22. Dari Hasil pengujian yang diperoleh mengalami perubahan akurasi yang tidak terlalu signifikan namun nilai akurasi yang diperoleh tidak stabil karena proses pembelajaran *Backpropagation* menggunakan inisialisasi bobot dan bias yang *dirandom* sehingga setiap program yang dijalankan akan memberikan hasil akurasi yang berbeda-beda. Hasil dari pengujian tersebut dapat dilihat pada tabel 4 dan grafik perbandingan data produksi dan aktualnya pada gambar 2 berikut.

Tabel 6 Pengujian BPNN

Percobaan	MSE	MAD	MAPE	Akurasi
1	0,002	0,046	8,8	91,19
2	0,001	0,028	5,36	94,63
3	0,001	0,031	5,94	94,05
4	0,003	0,045	9,11	90,88
5	0,001	0,029	5,61	94,38
Rata-rata	0,0016	0,0358	6,964	93,026



Gambar 1 Grafik hasil prediksi BPNN



Gambar 2 Kurva pelatihan BPNN



### 3.5.3 Pengujian Parameter BPNN-GA

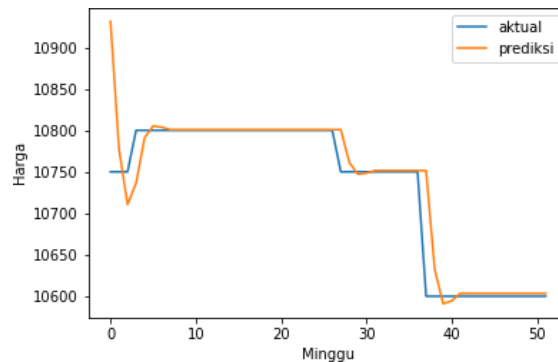
Untuk pengujian parameter *Backpropagation neural network* dan Algoritma Genetika (BPNN-GA) didapatkan parameter dengan rata-rata nilai akurasi yang cenderung hampir sama dari percobaan yang dilakukan dengan 5 kali program dijalankan dengan data *train* yang sama, dengan parameter terbaik yang didapatkan yaitu 10 *popsize* dan 100 generasi. [9] Semakin besar jumlah populasi dan generasi yang digunakan semakin tinggi kemungkinan menemukan solusi yang lebih baik, namun peningkatan jumlah populasi dan generasi juga dapat menyebabkan peningkatan waktu komputasi dan konsumsi sumber daya.

Nilai probabilitas mutasi dan *crossover* yang digunakan yaitu 1.0 serta rentang nilai bobot hasil random dari *library MLPRegressor* yang didapat yaitu dari rentang nilai -0.51 sampai 0.51 dan untuk nilai bias dari -0.36 sampai 0.36. Nilai *learning rate* yang optimal yang diperoleh dari percobaan 1-5 diperoleh nilai *learning rate* yang berbeda-beda mulai dari 0,01 sampai 0,1. [10] Dari hasil Pengujian tersebut menghasilkan rata-rata akurasi sebesar 98,12%. Adapun hasil percobaan pengujian dari BPNN-GA diuraikan dalam tabel 7 sebagai berikut:


Tabel 7 Pengujian BPNN-GA

Percobaan	<i>Learning rate</i>	MSE	MAD	MAPE	Akurasi
1	0,07	0,0007	0,009	1,89	98,1
2	0,07	0,0006	0,009	1,84	98,15
3	0,1	0,0006	0,009	1,84	98,15
4	0,06	0,0006	0,009	1,84	98,15
5	0,07	0,0009	0,009	1,91	98,08
Rata-rata		0,00068	0,009	1,864	98,126

Untuk grafik hasil prediksinya dapat dilihat pada gambar 3 dengan kurva hasil pelatihannya pada gambar 4 dibawah ini:



Gambar 3 Grafik hasil prediksi BPNN-G



Gambar 4 Kurva pelatihan BPNN-GA

### 3.6 Analisis Perbandingan

Setelah dilakukan proses pengujian parameter terbaik dari kedua algoritma, yakni BPNN dan BPNN yang di optimasi dengan GA dapat dilihat pada gambar 2 untuk hasil prediksi dengan BPNN dan gambar 4 untuk prediksi menggunakan BPNN-GA, *Backpropagation neural network* yang dioptimasi dengan Algoritma Genetika menghasilkan rata-rata akurasi yang lebih baik dari pada *Backpropagation neural network* tanpa optimasi ini menunjukkan bahwa pembelajaran *Backpropagation neural network* dapat diperbaiki dengan optimalisasi pada parameter *Backpropagation neural network* menggunakan Algoritma Genetika. Disamping itu, pembelajaran menggunakan *Backpropagation neural network* yang dioptimasi dengan algoritma genetika menunjukkan bahwa hasil yang diperoleh relatif lebih stabil dan lebih baik dari pada pembelajaran *Backpropagation neural network* tanpa optimasi. Hal ini dibuktikan dengan hasil kurva pelatihan pada BPNN dan BPNN-GA yang masing-masing ditunjukkan pada gambar 3 dan 5 dimana pembelajaran pada BPNN-GA menghasilkan iterasi yang lebih sedikit dan lebih stabil dibanding dengan pembelajaran yang hanya menggunakan BPNN. Pembelajaran dengan menggunakan *Backpropagation* tidak selalu baik, hal ini dikarenakan salah satu kelemahannya yaitu pembelajaran yang tidak stabil sehingga sering terjebak pada lokal minimum. Namun pembelajaran pada *Backpropagation neural network* tidak bergantung hanya pada salah satu parameter yang mempengaruhinya, namun arsitektur bobot dan bias jaringan juga menjadi penentu dalam proses pembelajaran. Untuk hasil perbandingan pelatihan jaringan menggunakan *Backpropagation neural network* (BPNN) dan *Backpropagation neural network* dengan Algoritma Genetika (BPNN-GA) dengan pengujian pada 10 harga bahan pangan dapat dilihat pada tabel 8 dibawah ini:

Tabel 8 Perbandingan BPNN dan BPNN GA dengan *testing* tahun 2021

Data <i>train</i>	BPNN				BPNN+GA			
	MSE	MAD	MAPE	Akurasi	MSE	MAD	MAPE	Akurasi
Beras	0,001	0,028	5,36	94,63	0,0007	0,009	1,85	98,14
Telur Ayam	0,002	0,031	15,34	84,65	0,0002	0,019	10,1	89,89
Daging Ayam	0,01	0,08	10,19	89,9	0,0007	0,049	6,08	93,91
Daging Sapi	0,002	0,041	4,5	95,49	0,0003	0,005	0,53	99,46

Bawang Merah	0,006	0,048	11,84	88,15	0,001	0,032	7,61	92,38
Bawang Putih	0,007	0,011	7,65	92,34	0,0005	0,005	3,52	96,47
Cabai Merah	0,003	0,038	15,29	84,7	0,0024	0,025	10,57	89,42
Cabai Rawit	0,003	0,042	16,31	83,68	0,0033	0,029	12,1	87,89
Gula Pasir	0,001	0,293	4,15	95,84	0,0008	0,009	1,4	98,59
Minyak Goreng	0,015	0,073	17,13	82,86	0,0067	0,039	10,19	89,8
Rata-rata	0,005	0,0685	10,776	89,224	0,00166	0,0221	6,395	93,595


Berdasarkan tabel 8 diatas dapat diketahui bahwa Algoritma *Backpropagationneural network* yang di optimasi dengan Algoritma Genetika menghasilkan rata-rataMSE, MAD dan MAPE yang lebih kecil dibandingkan dengan Algoritma *Backpropagation neural network* tanpa optimasi . Oleh karena itu dapat disimpulkanbahwa *Backpropagation neural network* yang di optimasi dengan Algoritma Genetika lebih baik dari pada *Backpropagation neural network* tanpa dioptimasi dalam proses pembelajaran (*training data*) untuk melakukan prediksi. Proses pelatihan data menggunakan BPNN-GA jauh lebih baik dan stabil dibanding pembelajaran menggunakan BPNN saja dengan selisih MAPE sebesar 4,4 dan selisihakurasi sebesar 4,37%.

### 3.7 Hasil Prediksi

Setelah proses *training* selesai dilakukan didapat model terbaik hasil pelatihan, model tersebut disimpan dalam sebuah file dengan menggunakan *library pickle*. Model terbaik hasil pelatihan menggunakan *Backpropagation neural network* yang dioptimasi dengan Algoritma genetika tersebut digunakan untuk memprediksi harga bahan pangan ditahun berikutnya dengan menggunakan data *testing* yang telah disiapkan. Proses prediksi hanya menggunakan Algoritma *Backpropagation* tetapi dengan arsitektur jaringan hasil pelatihan yang terbaik yang akan digunakan untuk melakukan prediksi. Adapun hasil prediksi dari 10 Bahan pangan adalah sebagai berikut:

#### 3.7.1 Hasil Prediksi Harga Beras


Berdasarkan hasil prediksi harga beras dengan menggunakan data *testing* yaitu data harga beras tahun 2022 dengan nilai bobot awal yang digunakan dari -9 sampai 9 dan nilai bias dari -0.3 sampai 0.3 diperoleh nilai *learning rate* optimalyaitu 0,06 dengan akurasi sebesar 98.33% dan MAPE sebesar 1.66. Hasil prediksi harga beras pada tahun 2022 dapat dilihat pada gambar 5 berikut:



Gambar 5 Grafik Prediksi Harga Beras

### 3.7.2 Hasil Prediksi Harga Telur Ayam

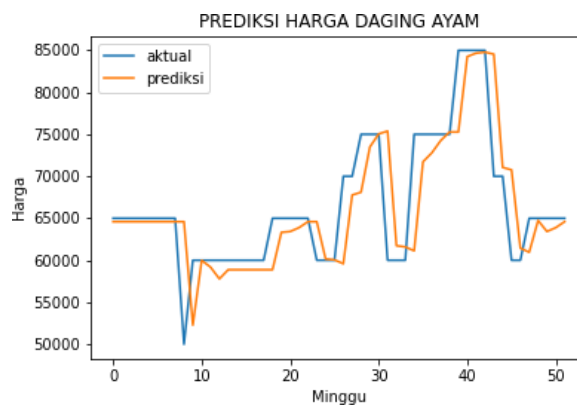
Untuk hasil prediksi harga Telur ayam diperoleh akurasi sebesar 98,05% dengan MAPE sebesar 1.94, dengan nilai *learning rate* optimalnya yaitu 0.05. Adapun hasil prediksi untuk harga telur ayam pada tahun 2022 dapat dilihat pada gambar 6 berikut ini:



Gambar 6 Grafik Prediksi Harga Telur Ayam

### 3.7.3 Hasil Prediksi Daging Ayam


Pada pengujian data harga daging ayam dengan menggunakan data *testing*, yaitu data harga pangan 2022 didapat MAPE sebesar 4,63 dengan akurasi sebesar 95,36% dengan nilai *learning rate* 0,1. Hasil prediksi dapat dilihat pada gambar 7 berikut:



Gambar 7 Grafik Prediksi Harga Daging Ayam

### 3.7.4 Hasil Prediksi Daging Sapi


Untuk hasil pengujian dengan data harga daging sapi diperoleh akurasi sebesar 98,49% dengan MAPE sebesar 1,50 dan *learning rate* yaitu 0,09. Grafik hasil prediksinya dapat dilihat pada gambar 8 Berikut hasil prediksi harga daging sapi di tahun 2022:



Gambar 8 Grafik Prediksi Harga Daging Sapi

### 3.7.5 Hasil Prediksi Bawang Merah

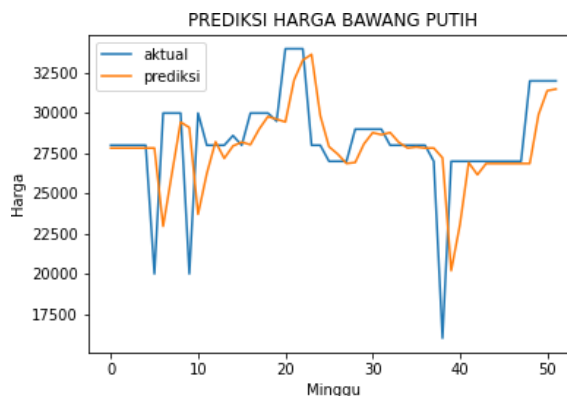
Berdasarkan pengujian yang dilakukan pada data harga bawang merah diperoleh nilai *learning rate* 0,1 dengan akurasi sebesar 96,44 dan MAPE 3,55. Untuk prediksi harga bawang merah di tahun 2022 dapat dilihat pada gambar 9 berikut:



Gambar 9 Grafik prediksi Harga Bawang Merah

### 3.7.6 Hasil Prediksi Harga Bawang Putih


Hasil pengujian dengan data harga bawang putih diperoleh MAPE sebesar 7,41 dengan akurasi sebesar 92,57% dan *learning rate* optimalnya yaitu 0,1. Hasilprediksi harga bawang putih dapat dilihat pada gambar 10 berikut:



Gambar 10 Grafik Prediksi Harga Bawang Putih

### 3.7.7 Hasil Prediksi Cabai Merah

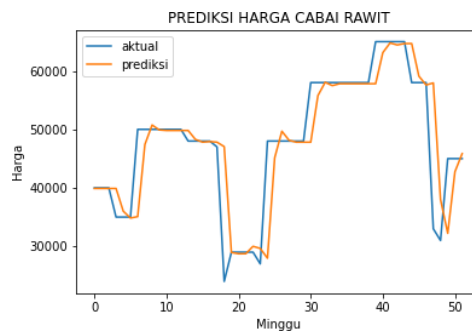
Pada pengujian berikutnya untuk prediksi harga cabai merah menghasilkan MAPE sebesar 6,08 dengan akurasinya sebesar 93,91%. Nilai *learning rate* optimal yang diperoleh yaitu 0,1. Grafik hasil prediksinya dapat dilihat pada gambar 11 berikut ini:



Gambar 11 Grafik prediksi harga cabai merah

### 3.7.8 Hasil Prediksi Cabai Rawit


Untuk pengujian data harga cabai rawit menghasilkan akurasi sebesar 92,04% dengan MAPE sebesar 7,95 dan *learning rate* optimalnya 0,1. Berikut tabel hasil prediksinya: Hasil prediksinya dapat dilihat pada gambar 12 berikut:



Gambar 12 Grafik hasil prediksi cabai rawit

### 3.7.9 Hasil Prediksi Gula Pasir


Untuk pengujian data harga gula pasir menghasilkan akurasi tertinggi dari 9 bahan pangan lainnya yaitu akurasi sebesar 99,33% dan MAPE sebesar 0,06 dengan *learning rate* 0,09. Berikut hasil prediksi harga Gula pasir di tahun 2022: Adapun grafik hasil prediksinya dapat dilihat gambar 13 berikut.



Gambar 13 Grafik prediksi harga gula pasir

### 3.7.10 Hasil Prediksi Minyak Goreng

Hasil prediksi harga minyak goreng diperoleh akurasi sebesar 95,78% dengan MAPE sebesar 4,21 dan nilai *learning rate* optimal yaitu 0,1. Untuk prediksi harga Minyak goreng di tahun 2022 dapat dilihat pada gambar 14 berikut



Gambar 14 Grafik prediksi harga minyak goreng

Untuk hasil pengujian dari 10 bahan pangan dapat dilihat pada tabel dibawah ini:

Tabel 9 Hasil Prediksi dengan Data *testing* tahun 2022

Data testing	MSE	MAD	MAPE	Akurasi
Beras	106497,35	187,048	1,66	98,33
Telur Ayam	928900,73	472,33	1,94	98,05
Daging Ayam	2714785,8	3006,15	4,63	95,3
Daging Sapi	17389162	1788,19	1,5	98,49
Bawang Merah	5338996,1	1134,22	3,55	96,44
Bawang Putih	10477467	1851,1	7,42	92,57
Cabai Merah	8692911,9	1847,68	6,08	93,91
Cabai Rawit	43498575	3095,61	7,95	92,04
Gula Pasir	63144,58	94,09	0,66	99,33
Minyak Goreng	2375986,2	979,03	4,21	95,78
Rata-rata	9158642,7	1445,54	3,96	96,024

Dari hasil pengujian untuk sepuluh bahan pangan dapat disimpulkan bahwa dari hasil prediksi 10 bahan pangan menghasilkan predikat akurasi Sangat baik sesuai dengan tabel 2 dengan akurasi tertinggi didapat pada prediksi harga gula pasir sebesar 99,33% dan dari hasil pengujian yang dilakukan ini merupakan akurasi yang paling tinggi dikarenakan data untuk harga gula pasir relatif lebih stabil ketika mengalami kenaikan harga ataupun penurunan harga. Untuk hasil prediksi harga Cabai rawit dan Bawang putih menunjukkan hasil akurasi dibawah 95% dikarenakan perubahan harganya yang cenderung mengalami perubahan yang cukup jauh tiap minggunya atau data harga perminggunya tidak stabil sehingga algoritma kurang optimal dalam mempelajari datanya. MAPE terkecil yang diperoleh dari hasil prediksi yaitu sebesar 0,66 dan MAPE terbesar yang diperoleh dari hasil prediksi yaitu 7,95 dengan rata-rata MAPE yang diperoleh yaitu 3,96. Untuk rata-rata MSE dan MAD hasil pengujian menggunakan data *testing* dapat dilihat pada tabel

#### 4. KESIMPULAN

Berdasarkan tahapan-tahapan yang telah dilakukan dalam memprediksi harga bahan pangan dengan menggunakan Algoritma *Backpropagation neural network* dan Algoritma Genetika penulis dapat menyimpulkan dari hasil penelitian yang diperoleh yaitu Algoritma Genetika mampu mengoptimasi parameter dari *Backpropagation neural network* dalam kasus prediksi harga bahan pangan dan menunjukkan hasil *train* dan *testing* dari *Backpropagation neural network* yang dioptimasi dengan algoritma genetika memberikan hasil prediksi yang lebih baik dibanding *Backpropagation* tanpa optimasi. Pada pengujian yang telah dilakukan hasil akurasi prediksi terbaik didapatkan akurasi sebesar 99,33% pada prediksi harga gula pasir dengan MAPE sebesar 0,66 dan akurasi terendah didapat pada prediksi harga cabai rawit dengan akurasi sebesar 92,04% dan MAPE 7,95 dengan arsitektur jaringan *Backpropagation neural network* yaitu 4 *input layer*, 30 *hidden layer*, dan 1 *output layer* dengan 400 iterasi dengan parameter pada algoritma genetika yang digunakan yaitu 10 populasi, 100 generasi dan 1.0 probabilitas mutasi dan *crossover*. Pelatihan dan pengujian yang telah dilakukan menghasilkan nilai prediksi yang berbeda-beda, karena disebabkan fungsi nilai *random* pada bobot dan bias *Backpropagation neural network*. Pembelajaran *Backpropagation neural network* selain bergantung pada *learning rate* juga bergantung pada arsitektur jaringan *Backpropagation neural network*.

#### REFERENSI

- [1] D. Saputra, M. Safii, M. Fauzan, and S. Tunas Bangsa, "Implementasi Algoritma Backpropagation Dalam Memprediksi Harga Bahan Pangan," 2020.
- [2] N. P. Dewi and I. Listiowarni, "Implementasi Holt-Winters Exponential Smoothing untuk Peramalan Harga Bahan Pangan di Kabupaten Pamekasan," *Digital Zone: Jurnal Teknologi Infomrasi & Komunikasi*, vol. 11, no. 2, pp. 219–231, 2020, doi: 10.31849/digitalzone.v11i2.4797ICCS.
- [3] A. Irianti, P. H. Rantelinggi, and A. Taufik, "IMPLEMENTATION OF BACKPROPAGATION ARTIFICIAL NEURAL NETWORK FOR FOOD PRICE PREDICTION IN MAJENE CENTRAL MARKET Artificial intelligence View project Menghitung Jumlah Telur Dengan Image Processingg View project," 2022, doi: 10.20884/1.jutif.2022.3.3.226.
- [4] M. Bansal, A. Goyal, and A. Choudhary, "Stock Market Prediction with High Accuracy using Machine Learning Techniques," *Procedia Comput Sci*, vol. 215, pp. 247–265, 2022, doi: 10.1016/j.procs.2022.12.028.
- [5] S. Lahmiri, "Wavelet low- and high-frequency components as features for predicting stock prices with backpropagation neural networks," *Journal of King Saud University - Computer and Information Sciences*, vol. 26, no. 2, pp. 218–227, 2014, doi: 10.1016/j.jksuci.2013.12.001.
- [6] R. Hrasco, A. G. C. Pacheco, and R. A. Krohling, "Time series prediction using restricted boltzmann machines and backpropagation," in *Procedia Computer Science*, Elsevier B.V., 2015, pp. 990–999. doi: 10.1016/j.procs.2015.07.104.
- [7] M. A. Ridla, "Particle Swarm Optimization sebagai Penentu Nilai Bobot pada Artificial Neural Network Berbasis Backpropagation untuk Prediksi Tingkat Penjualan Minyak Pelumas Pertamina," 2018.
- [8] M. Badrul, N. Mandiri Jakarta, J. Damai No, and W. Jati Barat Jakarta Selatan, "Optimasi Neural Network Dengan Algoritma Genetika Untuk Prediksi Hasil Pemilukada," *Bina Insani ICT Journal*, vol. 3, no. 1, pp. 229–242, 2020.
- [9] R. Hammad, A. Zuli Amrullah, and P. Irfan, "Optimasi Neural Network Dengan Menggunakan Algoritma Genetika Untuk Prediksi Jumlah Kunjungan Wisatawan (Neural Network Optimization Using Genetic Algorithm For Prediction Number of Tourist Visits)," *Jurnal Teknologi Informasi dan Multimedia*, vol. 3, no. 4, pp. 227–235, 2022.
- [10] F. Halawa, "Penerapan Algoritma Genetika Dan Backpropagation Neural Network Untuk Memprediksi Jumlah Penduduk Kota Medan," *Jurnal Informasi dan Teknologi Ilmiah*, vol. 7, no. 3, pp. 203–207, 2020.