

## Prediksi Harga Komoditas Pangan di Indonesia Menggunakan *Backpropagation*

Olief Ilmandira Ratu Farisi<sup>1</sup>, Nurul Jannah<sup>2</sup>, Ribki Insania<sup>3</sup>  
<sup>1,2,3</sup>Universitas Nurul Jadid, Paiton, Probolinggo, Indonesia

### Info Artikel

#### Riwayat Artikel

Diterima: 02-04-2022

Disetujui: 24-06-2022

#### Kata Kunci

prediksi;  
komoditas pangan;  
jaringan syaraf tiruan;  
*backpropagation*;

farisi@unuja.ac.id

### ABSTRAK

*Pangan merupakan kebutuhan paling mendasar bagi sumber daya manusia. Ketahanan pangan suatu bangsa dapat diukur dari tersedianya pangan dalam jumlah dan kualitas yang cukup. Pemerintah memiliki tanggung jawab dan pengendalian dalam ketersediaan bahan pangan pokok. Oleh karena itu, perlu kebijakan dari pemerintah untuk menentukan harga eceran tertinggi, salah satu caranya adalah memprediksi harga sedini mungkin dengan menggunakan Backpropagation. Pada penelitian ini, diuji beberapa arsitektur yang untuk menentukan kestabilan model yang digunakan. Hasil uji coba menunjukkan bahwa arsitektur 10-10-1 cukup stabil digunakan untuk memprediksi berbagai jenis data harga komoditas pangan yang berbeda karakteristiknya dengan tingkat akurasi di atas 90%. Rata-rata akurasi dari prediksi harga komoditas pangan di Indonesia yaitu sebesar 96,448% dengan waktu rata-rata adalah 6,8495 detik.*

### 1. PENDAHULUAN

Pangan merupakan kebutuhan paling mendasar bagi sumber daya manusia pada suatu negara. Ketahanan pangan dapat tercapai jika negara dapat memenuhi ketersediaan pangan dalam jumlah dan kualitas yang cukup. Oleh karena itu, pemerintah perlu menyediakan dan mendistribusikan kebutuhan pangan sehari-hari yang harganya terjangkau dan aman dikonsumsi masyarakat [1].

Komoditas pangan adalah barang dagang unggulan dalam kegiatan ekspor impor yang dapat menunjang perekonomian suatu masyarakat di negara agraris. Dalam tiga tahun terakhir, berbagai upaya yang dijalankan oleh pemerintah pusat dan daerah untuk mengendalikan komoditas pangan menunjukkan hasil yang positif, yaitu ditandai dengan menurunnya pengaruh komponen bahan pangan terhadap inflasi. Berdasarkan beberapa kriteria BAPOK (Barang Kebutuhan Pokok), terdapat sepuluh komoditas pangan di Indonesia yang termasuk ke dalam barang kebutuhan pokok masyarakat diantaranya beras, bawang merah, bawang putih, cabai merah, cabai rawit, daging sapi, daging ayam ras, gula pasir, minyak goreng, dan telur ayam ras[2].

Penentuan harga dipengaruhi oleh banyak pasokan dan banyak permintaan. Pada waktu tertentu, seperti perayaan hari besar, harga komoditas pangan cenderung naik yang akhirnya dapat menyebabkan inflasi. Pemerintah dalam hal ini telah melakukan langkah antisipatif dalam menjaga perkembangan harga yang wajar, yaitu dengan mengeluarkan kebijakan Harga Eceran Tertinggi (HET) [3]. HET dapat ditentukan dengan melakukan prediksi harga sedini mungkin.

Salah satu teknik prediksi yang dapat digunakan adalah dengan menggunakan Backpropagation. Algoritma Backpropagation adalah salah satu metode dalam Jaringan Syaraf Tiruan dengan pembelajaran supervisi (*supervised*) yang banyak digunakan untuk pengelompokan dan prediksi atau peramalan[4][5]. Pada Dalam algoritma backpropagation, terdapat lapisan masukan (*input layer*), lapisan tersembunyi (*hidden layer*), dan lapisan


keluaran (*output layer*) di mana setiap unit pada tiap lapisan terhubung oleh bobot (*weight*) [6].

Beberapa peneliti telah menggunakan algoritma Backpropagation untuk prediksi. Andriyani dan Sitohang memprediksi harga jual kelapa sawit yang dipengaruhi oleh tujuh variabel[7]. Pada penelitian tersebut, akurasi yang didapat oleh algoritma Backpropagation sebesar 99%. Setti dan Wanto memprediksi banyak pengguna internet dunia di 25 negara dan mendapatkan tingkat akurasi 92%[8]. Fardhani dkk memprediksi harga eceran beras di 33 Kota di Indonesia[9]. Tingkat akurasi yang didapat dari 5 struktur Backpropagation yang diuji adalah sebesar 88%. Sijabat dkk memprediksi harga komoditi kopi lokal[10]. Pada penelitian tersebut, algoritma Backpropagation menghasilkan akurasi 99%.

Dengan mempertimbangkan kemudahan pengimplementasiannya, pada penelitian ini algoritma Backpropagation akan digunakan untuk memprediksi (*forecasting*) harga sepuluh komoditas pangan yang ada di Indonesia. Dengan adanya prediksi ini diharapkan dapat membantu pemerintah dalam menentukan harga yang terjangkau dan memasok kebutuhan pangan sehari-hari untuk masyarakat.

## 2. METODE

Backpropagation adalah salah satu metode jaringan syaraf tiruan dengan supervised learning, yaitu dalam proses pelatihannya memerlukan target. Disebut *backpropagation* karena dalam proses pelatihannya, *error* yang dihasilkan dipropagasikan kembali ke unit-unit dibawahnya. Backpropagation adalah jaringan saraf multi-layer. Gambar 1 menunjukkan arsitektur backpropagation dengan n input (unit X), m output (unit Y), dan satu lapisan unit tersembunyi (unit Z). Bobot  $w_{ij}$  adalah bobot unit input ke unit tersembunyi ( $v_{j0}$  adalah bias dari unit tersembunyi  $Z_j$ ) sedangkan  $w_{kj}$  adalah bobot unit lapisan tersembunyi ke unit output ( $w_{k0}$  adalah bias unit output  $Y_k$ )



Gambar 1. Arsitektur Backpropagation

### *Pelatihan Algoritma Backpropagation*

Terdapat tiga fase dalam algoritma pelatihan Backpropagation. Fase pertama adalah propagasi maju. Pada fase ini, dihitung pola masukan secara maju mulai dari *layer* masukan hingga *layer* keluaran menggunakan fungsi aktivasi yang ditentukan. Nilai pada tiap unit masukan diteruskan ke unit tersembunyi dan dihitung dengan

$$z_{net_k} = v_{j0} + \sum_{i=1}^n x_i v_{ji} \quad (1)$$

$$z_j = f(z_{net_k}) \quad (2)$$

dimana  $z_j$  adalah nilai pada unit tersembunyi  $Z_j$  yang didapat dari penghitungan fungsi aktivasi yang ditentukan. Bias  $v_{j0}$  merupakan bobot bias di unit masukan ke unit tersembunyi  $z_j$ , masukan  $x_i$  adalah masukan pada tiap  $X_i$ , dan  $v_{ji}$  adalah bobot yang menghubungkan  $X_i$  dan  $Z_j$ . Setelah unit pada layer tersembunyi memiliki nilai, maka akan diteruskan ke unit tersembunyi selanjutnya, jika ada, atau ke unit keluaran. Nilai pada unit keluaran dihitung dengan

$$y_{net_k} = w_{k0} + \sum_{j=1}^p z_j w_{kj} \quad (3)$$

$$y_k = f(y_{net_k}) \quad (4)$$

dimana  $w_{k0}$  merupakan bobot bias di unit tersembunyi ke unit keluaran  $w_k$  dan  $w_{kj}$  adalah bobot yang menghubungkan  $Z_j$  dan  $Y_k$ .

Fase kedua adalah propagasi mundur. Pada fase ini, dilakukan penghitungan selisih yang ada antara keluaran jaringan ( $y_k$ ) dengan target ( $t_k$ ) yang diinginkan dimulai dari unit-unit di *layer* keluaran sebagai berikut.

$$\delta_k = (t_k - y_k) f'(y_{net_k}) \quad (5)$$

Faktor  $\delta_k$  merupakan unit kesalahan di setiap unit keluaran  $y_k$ . Setelah itu, hitung perubahan bobot pada  $w_{kj}$  menggunakan

$$\Delta w_{kj} = \alpha \delta_k z_j \quad (6)$$

dengan  $\alpha$  adalah laju pembelajaran (learning rate). Nilai  $\alpha$  berada antara 0 dan 1. Semakin besar nilai laju pembelajaran, maka semakin cepat proses pelatihannya. Sedangkan untuk menghitung perubahan bobot bias menggunakan

$$\Delta w_{k0} = \alpha \delta_k \quad (7)$$

Nilai  $\delta_k$  selanjutnya dikirim ke *layer* di bawahnya, yaitu layer tersembunyi, dan digunakan untuk menghitung unit kesalahan dengan perhitungan

$$\delta_{net_j} = \sum_{k=1}^m \delta_k w_{kj} \quad (8)$$

$$\delta_j = \delta_{net_j} f'(z_{net_j}) \quad (9)$$

Faktor  $\delta_j$  merupakan unit kesalahan di setiap unit tersembunyi  $z_j$ . Setelah nilai unit kesalahan didapat, maka akan diteruskan ke perhitungan faktor  $\delta$  dari unit kesalahan layer tersembunyi di bawahnya, jika ada, atau unit masukan. Pada unit masukan, faktor  $\delta$  digunakan untuk menghitung perubahan bobot unit masukan.

$$\Delta v_{ji} = \alpha \delta_j x_i \quad (10)$$

Perubahan bobot bias dihitung dengan menggunakan

$$\Delta v_{j0} = \alpha \delta_j \quad (11)$$

Fase terakhir adalah modifikasi bobot untuk menurunkan kesalahan yang terjadi. Perubahan bobot yang menuju unit keluaran dihitung dengan

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj} \quad (12)$$

untuk  $k = 1, 2, \dots, m$  dan  $j = 0, 1, 2, \dots, p$

Dengan cara yang sama, perubahan bobot yang menuju unit tersembunyi didefinisikan

$$v_{ji}(\text{baru}) = v_{ji}(\text{lama}) + \Delta v_{ji} \quad (13)$$

untuk  $j = 1, 2, \dots, p$  dan  $i = 0, 1, 2, \dots, n$ .

Setelah proses pelatihan selesai, jaringan dapat digunakan untuk proses pengujian. Pada proses pengujian, dilakukan perhitungan propagasi maju dengan bobot akhir yang dihasilkan oleh jaringan.

#### *Fungsi Aktivasi Backpropagation*

Dalam *Backpropagation*, fungsi aktivasi yang dipakai harus memenuhi beberapa syarat yaitu kontinu, terdiferensial dengan mudah dan merupakan fungsi yang tidak turun. Pada penelitian ini digunakan fungsi aktivasi ReLU (*Rectified Linear Unit*)[11] dimana nilai dari fungsi ReLU adalah  $\max(0, x)$  atau didefinisikan dengan

$$f(x) = \begin{cases} 0, & \text{jika } x \leq 0 \\ x, & \text{lainnya} \end{cases} \quad (14)$$

Sehingga turunan dari fungsi aktivasi ReLU adalah sebagai berikut.

$$\frac{dy}{dx} = \begin{cases} 0, & \text{jika } x \leq 0 \\ 1, & \text{lainnya} \end{cases} \quad (15)$$

Setelah melakukan pengujian, perlu dilakukan pengukuran ketepatan pengujian. Tujuannya adalah untuk mengetahui akurasi dari prediksi atau peramalan (*forecasting*) yang dihasilkan dengan data sesungguhnya. Kesalahan atau *error* sangat biasa terjadi dalam memprediksi suatu hal. Akurasi didapatkan dari kesalahan atau error yang dihasilkan oleh metode prediksi. Dengan mengetahui kesalahan yang dihasilkan oleh metode prediksi, maka dapat dinilai pula realibilitas dan manfaat dari metode yang digunakan sehingga dapat digunakan sebagai pertimbangan dalam pengambilan keputusan.

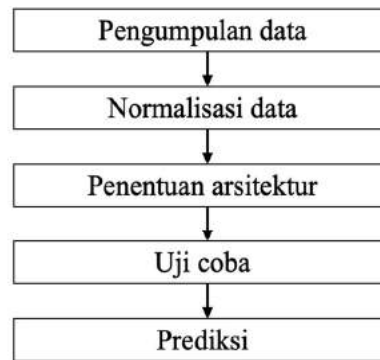
Pada penelitian ini, metode pengukuran *error* teknik *forecasting* yang digunakan adalah *Mean Absolute Percentage Error* (MAPE). Pada metode MAPE, kesalahan atau error dihitung dari rata-rata dari selisih mutlak setiap rentang waktu tertentu dibagi dengan nilai aktual pada waktu tersebut seperti yang didefinisikan oleh

$$MAPE = \frac{1}{n} \sum_{k=1}^n \frac{|\hat{Y}_t - Y_t|}{Y_t} \quad (16)$$

dengan  $Y_t$  adalah nilai aktual pada waktu  $t$  dan  $\hat{Y}_t$  adalah nilai prediksi pada waktu  $t$ .

Tahapan dalam metode Backpropagation pada penelitian ini ditunjukkan oleh Gambar 2.

Tahap pertama adalah pengumpulan data harga sepuluh komoditas pangan di Indonesia yang terdiri dari beras, bawang merah, bawang putih, cabai rawit, cabai merah, daging sapi,



**Gambar 2.** Tahapan Penelitian

daging ayam ras, telur ayam ras, gula pasir, dan minyak goreng. Data didapat dari Pusat Informasi Harga Pangan Strategis Nasional (PIHPS Nasional). Data yang digunakan adalah data harga bulanan komoditas pangan di pasar tradisional dari Juli 2017 hingga Mei 2022.

Tahap kedua adalah menormalisasi data yang telah didapatkan. Karena pecahan terkecil pada data harga adalah 50 rupiah, maka pada penelitian ini, perhitungan normalisasi data didefinisikan

$$x' = \frac{x}{50} \quad (17)$$

dengan  $x$  adalah nilai aktual dan  $x'$  adalah nilai hasil normalisasi.

Tahap ketiga adalah menentukan arsitektur Backpropagation yang tepat. Data harga yang digunakan dalam penelitian ini termasuk dalam data *univariate time series* yaitu data yang terdiri dari serangkaian pengamatan tunggal dengan urutan waktu dan model diperlukan untuk mempelajari rangkaian pengamatan masa sebelumnya untuk memprediksi nilai berikutnya dalam urutan. Karena data yang digunakan adalah data yang berbentuk satu barisan, maka perlu adanya penentuan banyak input yang digunakan sehingga menghasilkan data yang akurat dan efisien.

Tahap keempat adalah melakukan uji coba dengan arsitektur, data pelatihan, data pengujian, dan parameter yang ditentukan. Banyak data pelatihan dan data pengujian yang digunakan pada penelitian ini berturut-turut 70% dan 30%. Penentuan ini juga dipengaruhi banyak unit input terbaik yang didapat pada tahap sebelumnya dengan perhitungan sebagai berikut.

$$\text{Banyak data uji} = \text{round}(p(n_d + 1 - n)) \quad (18)$$

dengan  $n_d$  adalah banyak dataset pada satu time-series dan  $n$  adalah banyak unit input. Bilangan  $p$  adalah persentase data uji yang digunakan. Karena pada penelitian ini menggunakan 30% data sebagai data uji, maka  $p = 0,3$ .

Tahap terakhir adalah mendapatkan hasil prediksi yang kemudian dilakukan pengukuran ketepatan hasil prediksi dengan nilai aktual untuk menentukan keefektifan metode yang digunakan. Pada penelitian ini, tingkat akurasi dari metode dapat dihitung dengan

$$\text{Akurasi} = 100\% - \text{MAPE} \quad (19)$$

### 3. HASIL DAN PEMBAHASAN

Uji coba pada penelitian ini dilakukan dengan menggunakan Python. Sesuai dengan tahapan penelitian, sebelum dilakukan uji coba, data harga dinormalisasi terlebih dahulu. Tabel 1 menunjukkan sebagian data harga komoditas pangan di Indonesia dari Juni 2021 hingga Mei 2022 dan Tabel 2 menunjukkan hasil normalisasi data.

**Tabel 1.** Data Harga Komoditas Pangan di Indonesia Maret 2021-Mei 2022

Jenis	03/21	04/21	05/21	06/21	07/21	08/21	09/21	10/21	11/21	12/21	01/22	02/22	03/22	04/22	05/22
Beras	11800	11750	11750	11750	11700	11650	11650	11650	11650	11650	11750	11800	11800	11800	11750
Bawang Merah	33850	33200	31500	31500	33350	34700	30550	29650	28350	28700	30750	34650	36650	35150	39700
Bawang Putih	30100	30450	30000	30000	30150	30600	29800	29550	29450	29550	30350	30550	31650	32900	32750
Cabai Merah	48350	40500	33400	33400	37800	30300	28900	34350	40600	49250	41300	42300	53150	49650	45550
Cabai Rawit	65650	53950	48650	48650	57150	42900	36750	38600	38350	68750	59450	50750	58500	51500	46100
Daging Ayam	36550	37500	37200	37200	33900	32550	34900	35850	35550	35950	38600	35650	36400	37650	40350
Daging Sapi	121450	125450	123650	123650	124750	124000	124000	124150	124250	124450	124500	125000	127700	130950	134550
Gula Pasir	14250	14250	14200	14200	14150	14100	14050	14050	14050	14100	14500	14750	14900	15250	15400
Minyak Goreng	14850	15100	15300	15300	15400	15750	16050	16650	18150	19400	20150	18800	20850	24350	27800
Telur Ayam	25800	26100	26250	26250	25650	25600	23700	23150	24850	26850	28100	24400	25050	25900	24450

**Tabel 2.** Hasil Normalisasi Data Harga Komoditas Pangan di Indonesia Maret 2021-Mei 2022

Jenis	03/21	04/21	05/21	06/21	07/21	08/21	09/21	10/21	11/21	12/21	01/22	02/22	03/22	04/22	05/22
Beras	838	235	235	235	234	233	233	233	233	233	235	236	236	236	235
Bawang Merah	677	664	630	630	667	694	611	593	567	574	615	693	733	703	794
Bawang Putih	602	609	600	600	603	612	596	591	589	591	607	611	633	658	655
Cabai Merah	967	810	668	668	756	606	578	687	812	985	826	846	1063	993	911
Cabai Rawit	1313	1079	973	973	1143	858	735	772	767	1375	1189	1015	1170	1030	922
Daging Ayam	731	750	744	744	678	651	698	717	711	719	772	713	728	753	807
Daging Sapi	2429	2509	2473	2473	2495	2480	2480	2716	2485	2489	2490	2500	2554	2619	2691
Gula Pasir	285	285	284	284	283	282	281	281	281	282	290	295	298	305	308
Minyak Goreng	297	302	306	306	308	315	321	333	363	388	403	376	417	487	556
Telur Ayam	516	522	525	525	513	512	474	463	497	537	562	488	501	518	489

Setelah data dinormalisasi, maka dilakukan uji coba untuk menentukan banyak unit input yang digunakan. Tujuannya adalah agar model arsitektur dapat digunakan di berbagai data komoditas. Uji coba ini menggunakan satu layer tersembunyi dengan 10 unit dan 1 unit pada layer keluaran. Fungsi aktivasi yang digunakan adalah ReLU dengan optimizer *Adaptive moment estimation* (Adam). Parameter yang digunakan dalam proses uji coba antara lain *learning rate*  $\alpha = 0,001$  dan *epoch* = 1000. Hasil uji coba dari beberapa arsitektur dengan menggunakan data harga cabai rawit ditunjukkan oleh Tabel 3 berikut.

**Tabel 3.** Hasil Uji Coba Unit Input

Arsitektur	Akurasi (%)	Waktu (s)
2-10-1	84,94	6,3124
3-10-1	86,58	4,3696
5-10-1	87,34	6,3182
7-10-1	89,50	6,2290
10-10-1	92,06	6,2415
15-10-1	91,88	4,5359

Dari Tabel 3 terlihat bahwa arsitektur 10-10-1 menghasilkan akurasi yang terbaik dibandingkan dengan arsitektur lainnya. Terlihat bahwa semakin banyak unit input maka akurasi akan semakin baik. Arsitektur 15-10-1 menghasilkan akurasi yang baik dengan waktu yang cepat. Namun, uji coba yang dilakukan pada data komoditas lainnya, tidak semua komoditas mendapatkan akurasi yang baik dengan menerapkan arsitektur 15-10-1. Sehingga, pada penelitian ini digunakan unit input sebanyak 10.

Dengan menggunakan 10 unit input yang telah didapat, dilakukan uji coba untuk menentukan banyak unit pada layer tersembunyi. Uji coba dilakukan pada arsitektur 10-5-1, 10-8-1, dan 10-10-1. Hasil uji coba dari ketiga arsitektur dengan menggunakan data harga cabai rawit ditunjukkan oleh Tabel 4 berikut.

**Tabel 4.** Hasil Uji Coba Unit Layer Tersembunyi

Arsitektur	Akurasi (%)	Waktu (s)
10-5-1	90,68	6,3486
10-8-1	91,21	8,6970
10-10-1	92,06	6,2415

Dari Tabel 4 terlihat bahwa arsitektur 10-10-1 menghasilkan akurasi yang terbaik dengan waktu tercepat. Dari uji coba ini dapat disimpulkan bahwa banyak unit pada layer tersembunyi cukup mempengaruhi tingkat akurasi dari metode Backpropagation. Sehingga, pada penelitian ini banyak unit pada layer tersembunyi yang digunakan adalah 10.

Dengan arsitektur 10-10-1 dan parameter yang telah disebutkan sebelumnya, dilakukan pelatihan dan pengujian pada semua data komoditas. Untuk memprediksi harga komoditas di bulan tertentu, maka data yang digunakan sebagai data uji adalah harga komoditas di sepuluh bulan sebelumnya, sesuai dengan banyak unit input yang telah diujicobakan. Sehingga, jika data harga yang digunakan dari Juni 2017 hingga Mei 2022, maka banyak data yang dapat digunakan dengan pengambilan sepuluh harga pada setiap barisannya adalah sebanyak 50. Sesuai dengan rumus (18) dengan bilangan  $p = 0,3$ , didapat bahwa data uji yang digunakan

adalah sebanyak 15 dengan target seperti yang ditunjukkan pada Tabel 1. Hasil uji untuk semua komoditas pangan ditunjukkan oleh Tabel 5 berikut.

**Tabel 5.** Hasil Prediksi Harga Komoditas Pangan di Indonesia Maret 2021-Mei 2022

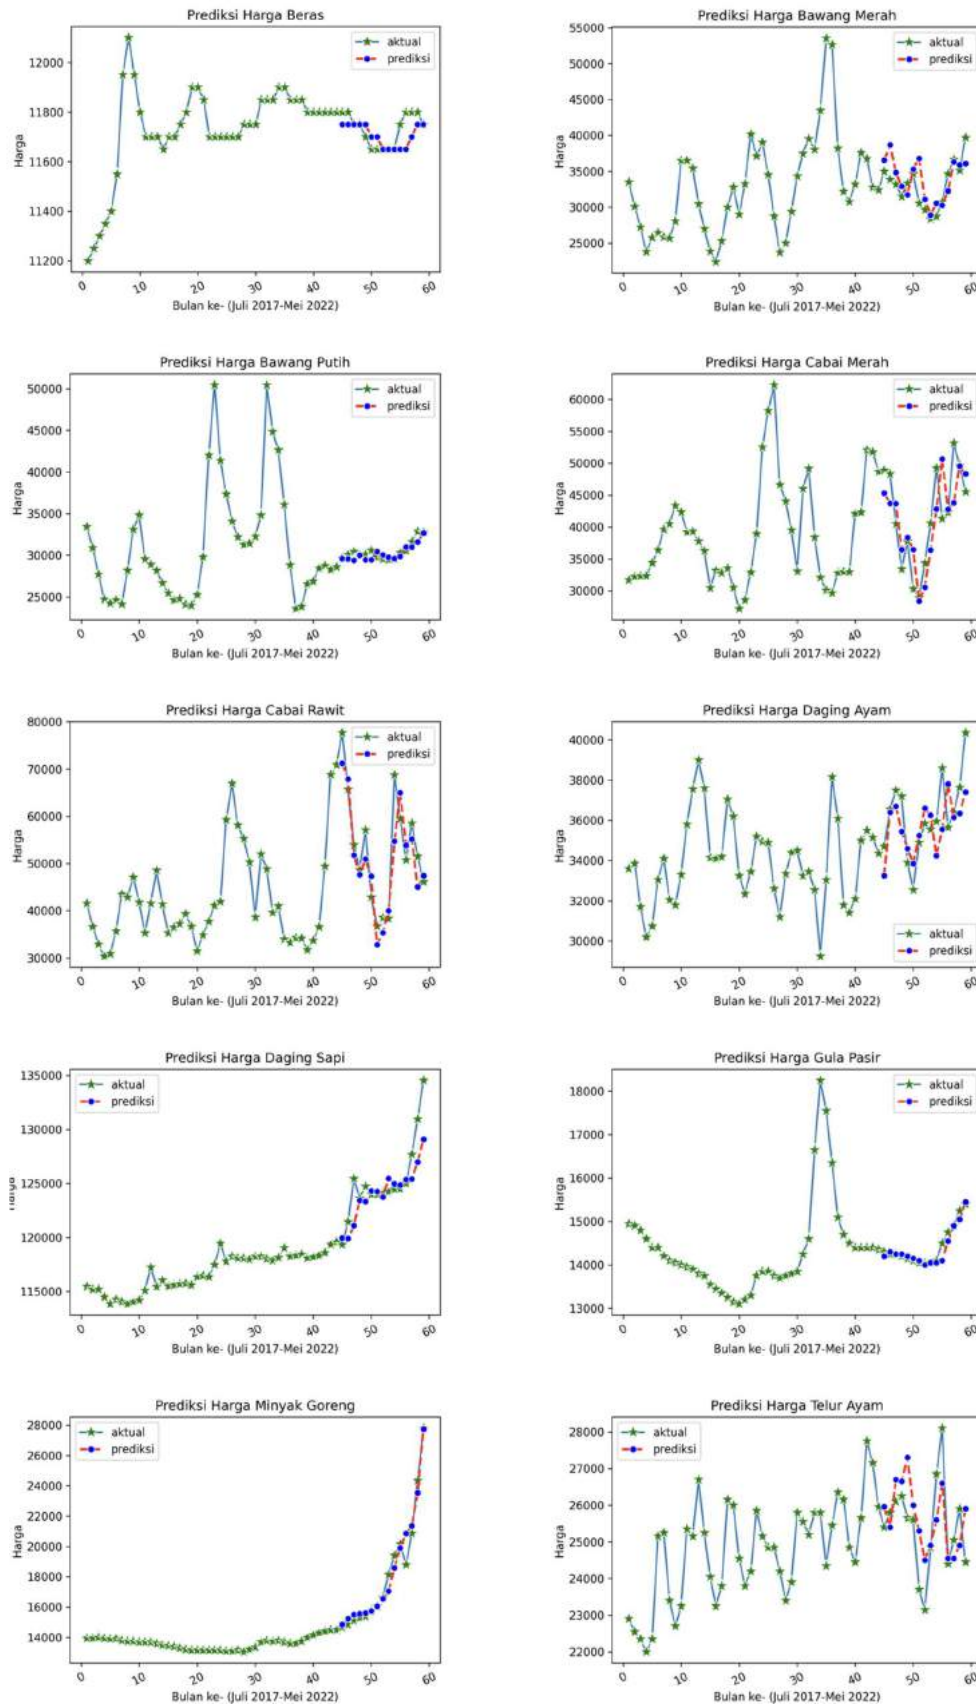
Jenis	03/21	04/21	05/21	06/21	07/21	08/21	09/21	10/21	11/21	12/21	01/22	02/22	03/22	04/22	05/22
Beras	11750	11750	11750	11750	11750	11700	11700	11650	11650	11650	11650	11650	11700	11750	11750
Bawang Merah	36550	38700	34850	32900	31750	35300	36800	31100	28900	30550	30250	32250	36300	35900	36100
Bawang Putih	29600	29550	29400	30000	29450	29450	30450	30050	29750	29600	29900	31000	31000	31600	32650
Cabai Merah	45300	43700	43650	36450	38350	36450	28400	30550	36400	42800	50650	42750	43800	49550	48350
Cabai Rawit	71250	67850	51800	47650	50900	47300	32800	35350	40000	54700	65000	53850	55200	45050	47400
Daging Ayam	33250	36400	36700	35450	34600	33850	35250	36600	36250	34250	35550	37800	36150	36350	37400
Daging Sapi	119950	119900	121100	123450	123350	124300	124250	123750	125450	124950	124850	125350	125400	127000	129100
Gula Pasir	14200	14300	14250	14250	14200	14150	14100	14000	14050	14050	14100	14550	14900	15050	15450
Minyak Goreng	14850	15250	15500	15550	15600	15750	16050	16550	17050	18600	19900	20850	21350	23550	27750
Telur Ayam	25950	25400	26700	26650	27300	26000	25300	24500	24900	25600	26600	24550	24550	24900	25900

Perbandingan target dengan hasil prediksi untuk semua harga komoditas pangan dari Maret 2021 hingga Mei 2022 dapat dilihat pada Gambar 3. Sehingga, sesuai dengan rumus (19), didapatkan akurasi dari prediksi yang dihasilkan seperti yang ditunjukkan pada Tabel 6.

**Tabel 6.** Akurasi Hasil Prediksi Harga Komoditas Pangan di Indonesia

Jenis	Akurasi (%)	Waktu (s)
Beras	99,63	6,2507
Bawang Merah	94,06	6,4245
Bawang Putih	98,28	5,6081
Cabai Merah	91,71	6,3459
Cabai Rawit	92,06	6,2415
Daging Ayam	96,49	6,0591
Daging Sapi	98,79	7,0426
Gula Pasir	99,40	11,7135
Minyak Goreng	97,44	6,5012
Telur Ayam	96,62	6,3077





Gambar 3. Perbandingan Harga Aktual dengan Hasil Prediksi Harga Komoditas Pangan di Indonesia

Berdasarkan Tabel 6, hasil prediksi di semua komoditas pangan mendapatkan tingkat akurasi di atas 90%. Rata-rata akurasi dari prediksi harga komoditas pangan di Indonesia yaitu sebesar 96,448% dengan waktu rata-rata adalah 6,8495 detik. Hal ini menunjukkan bahwa model yang dibangun memiliki tingkat keakuratan yang tinggi dalam memprediksi harga komoditas pangan di Indonesia dengan waktu yang cukup singkat. Dapat disimpulkan pula bahwa model Backpropagation yang diimplementasikan cukup stabil terhadap berbagai macam data yang ada.

#### 4. KESIMPULAN DAN SARAN

Penelitian ini bertujuan untuk memprediksi (*forecasting*) data *time-series* dari sepuluh komoditas pangan di Indonesia. Agar dapat digunakan dalam sepuluh jenis data yang berbeda karakteristiknya, dilakukan uji coba untuk mendapatkan arsitektur Backpropagation yang stabil. Dari hasil uji coba, arsitektur 10-10-1 menghasilkan akurasi yang cukup baik dengan waktu yang cukup singkat. Hasil prediksi dari semua komoditas pangan mendapatkan akurasi di atas 90% dengan akurasi rata-rata 96,448% dan waktu rata-rata 6,8495 detik. Dengan melihat hasil penelitian ini, model Backpropagation yang diusulkan dapat digunakan sebagai referensi untuk memprediksi harga ke depannya dengan menentukan Harga Eceran Tertinggi (HET).

#### 5. DAFTAR PUSTAKA

- [1] Y. Purwaningsih, “KETAHANAN PANGAN: SITUASI, PERMASALAHAN, KEBIJAKAN, DAN PEMBERDAYAAN MASYARAKAT,” *J. Ekon. Pembang. Kaji. Masal. Ekon. dan Pembang.*, vol. 9, no. 1, p. 1, Jun. 2008, doi: 10.23917/JEP.V9I1.1028.
- [2] “Pusat Informasi Harga Pangan Strategis Nasional.,” May 15, 2022. <https://hargapangan.id> (accessed May 15, 2022).
- [3] D. W. Prabowo, “INFLASI (dalam Analisis Perkembangan Harga Pangan Pokok di Pasar Domestik dan Internasional),” *Pus. Pengkaj. Perdagang. Dalam Negeri*, Jul. 2021.
- [4] A. T. W. Utami and B. S. S. Ulama, “Penerapan Backpropagation untuk Meningkatkan Efektivitas Waktu dan Akurasi pada Data Wall-Following Robot Navigation,” *J. Sains dan Seni ITS*, vol. 4, no. 2, pp. 2337–3520, Jan. 2016, doi: 10.12962/J23373520.V4I2.11189.
- [5] L. Nurhani, A. Gunaryati, S. Andryana, and I. Fitri, “JARINGAN SYARAF TIRUAN DENGAN METODE BACKPROPAGATION UNTUK MEMREDIKSI JUMLAH MAHASISWA BARU,” 2018, [Online]. Available: <https://ojs.amikom.ac.id/index.php/semnasteknomedia/article/view/2004>.
- [6] D. D. Santika, B. Susanti, W. Anderson, and K. Wongso, “IMPLEMENTASI METODE BACKPROPAGATION DALAM KLASIFIKASI OBJEK,” *CommIT (Communication Inf. Technol. J.*, vol. 1, no. 1, pp. 30–37, May 2007, doi: 10.21512/COMMIT.V1I1.465.
- [7] S. Andriyani dan N. Sihombing, “IMPLEMENTASI METODE BACKPROPAGATION UNTUK PREDIKSI HARGA JUAL KELAPA SAWIT BERDASARKAN KUALITAS BUAH,” *JURTEKSI (Jurnal Teknol. dan Sist. Informasi)*, vol. 4, no. 2, pp. 155–164, Jun. 2018, doi: 10.33330/JURTEKSI.V4I2.40.

- [8] 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, pp. 110–115, Feb. 2019, doi: 10.15575/JOIN.V3I2.205.
- [9] A. A. Fardhani, D. I. N. Simanjuntak, and A. Wanto, "Prediksi Harga Eceran Beras Di Pasar Tradisional Di 33 Kota Di Indonesia Menggunakan Algoritma Backpropagation," *J. InfomediaTeknik Inform. Multimed. Jar.*, vol. 3, no. 1, pp. 25–30, Aug. 2018, doi: 10.30811/JIM.V3I1.625.
- [10] P. I. Sijabat *et al.*, "Algoritma Backpropagation Prediksi Harga Komoditi terhadap Karakteristik Konsumen Produk Kopi Lokal Nasional," *Digit. Zo. J. Teknol. Inf. dan Komun.*, vol. 11, no. 1, pp. 96–107, May 2020, doi: 10.31849/DIGITALZONE.V11I1.3880.
- [11] A. C. Sitepu dan M. Sigiuro, "ANALISIS FUNGSI AKTIVASI RELU DAN SIGMOID MENGGUNAKAN OPTIMIZER SGD DENGAN REPRESENTASI MSE PADA MODEL BACKPROPAGATION | " *JUTISAL Jurnal Teknik Informatika Universal*, vol. 1, no.1, pp.12-25, Jun 2021.