

Prediksi Harga Komoditas Pokok dengan Holt-Winter dan Neural Network

Khaerunnisa Hanapi^{1*}

¹Universitas Dipa Makassar, Indonesia

¹khaerunnisa.hanapi@undipa.ac.id



Histori Artikel:

Diajukan: 25 Agustus 2024

Disetujui: 31 Agustus 2024

Dipublikasi: 31 Agustus 2024

Kata Kunci:

Prediksi Harga; Bahan Pokok; Holt-Winter; Neural Network; Exponential Smoothing

Digital Transformation

Technology (Digitech) is an Creative Commons License This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International (CC BY-NC 4.0).

Abstrak

Dalam dinamika pasar yang semakin fluktuatif, pengusaha seringkali dihadapkan pada tantangan signifikan dalam memenuhi permintaan konsumen yang terus meningkat. Bagi para pengusaha, tantangan utama adalah bagaimana memenuhi permintaan pasar yang terus berubah tanpa mengalami kekurangan atau kelebihan stok. Oleh karena itu, peramalan permintaan menjadi langkah strategis yang krusial bagi perusahaan dalam merumuskan kebijakan produksi, inventori, dan pemasaran yang efektif. Di antara berbagai metode peramalan yang ada, metode Exponential Smoothing telah terbukti menjadi pendekatan yang populer dalam menganalisis data deret waktu. Metode ini memberikan bobot yang lebih besar pada data terbaru, sehingga mampu menangkap tren dan fluktuasi musiman yang sering terjadi dalam data permintaan. Namun, kinerja metode Exponential Smoothing sangat bergantung pada pemilihan nilai parameter α yang tepat. Nilai parameter α yang optimal akan meminimalkan kesalahan peramalan dan meningkatkan akurasi prediksi. Salah satu teknik yang umum digunakan untuk mengestimasi nilai parameter α adalah metode Ordinary Least Squares. Metode ini memiliki nilai parameter yang sangat berpengaruh terhadap hasil peramalan. Dengan meminimalkan jumlah kuadrat sisaan antara nilai aktual dan nilai yang diprediksi, metode ini memungkinkan kita untuk memperoleh nilai α yang optimal. Hasil peramalan yang diperoleh melalui metode Exponential Smoothing dengan parameter α yang optimal dapat digunakan sebagai dasar dalam pengambilan keputusan bisnis yang lebih baik.

PENDAHULUAN

Volatilitas harga komoditas pangan pokok di berbagai wilayah Indonesia telah menciptakan dinamika pasar yang kompleks dan penuh ketidakpastian. Fluktuasi harga yang signifikan, yang sering kali dipicu oleh faktor-faktor seperti perubahan iklim, kebijakan pemerintah, dan permintaan pasar yang tidak stabil (Yusuf et al., 2022), telah menimbulkan tantangan serius bagi seluruh rantai pasok pangan, mulai dari produsen hingga konsumen. Keadaan ini tidak hanya berdampak pada kesejahteraan petani dan pelaku usaha kecil, tetapi juga mengancam ketahanan pangan nasional (Rani et al., n.d.). Dalam UU RI Nomor 7 Tahun 1996 dan definisi ketahanan pangan oleh FAO (1996), terdapat empat (4) komponen yang harus dipenuhi untuk mencapai kondisi ketahanan pangan dalam pemenuhan kebutuhan dasar, yaitu:

- Kecukupan ketersediaan pangan
- Stabilitas dari musim ke musim atau dari tahun ke tahun
- Aksesibilitas/keterjangkauan pangan dan
- Kualitas/keamanan pangan.

Namun, terkadang hal ini tidak sesuai dengan kenyataan yang sering terjadi di beberapa daerah di Indonesia, terutama dalam hal informasi mengenai prediksi harga komoditas pokok. Baik ketika permintaan meningkat maupun pada saat panen bagi petani, terutama yang tinggal di pedesaan yang ingin menjual hasil panennya, namun tidak mengetahui harga jual di pasar. Banyak tengkulak yang memanfaatkan situasi ini dengan membeli hasil panen di bawah harga jual di pasar, yang menyebabkan kesejahteraan petani tidak meningkat. Berdasarkan uraian di atas, penulis mencoba memberikan masukan dalam bentuk prediksi harga bahan pokok dengan menggunakan metode Holt-Winter dan Jaringan Saraf Tiruan (Neural Network), sehingga di masa depan dapat membantu masyarakat atau petani dalam memprediksi harga jual komoditas pokok dan perubahan harga barang-barang yang menjadi tidak stabil, terutama menjelang hari-hari besar seperti puasa hingga Idul Fitri. Dengan demikian, ketahanan pangan dapat terwujud dan menyambut Masyarakat Ekonomi ASEAN (MEA) yang akan diberlakukan bulan depan.

Untuk mengatasi permasalahan ini, diperlukan suatu sistem peramalan harga yang akurat dan reliabel. Peramalan yang tepat akan memungkinkan pemerintah, pelaku bisnis, dan masyarakat umum untuk mengambil keputusan yang lebih baik dalam pengelolaan pasokan pangan, sehingga dapat mencegah terjadinya kelangkaan atau kelebihan pasokan. Metode peramalan tradisional seringkali terbatas dalam mengakomodasi kompleksitas

data pasar yang dinamis. Oleh karena itu, pendekatan yang menggabungkan metode statistik seperti Holt-Winters dengan kecerdasan buatan, seperti jaringan saraf tiruan, menawarkan potensi yang menjanjikan untuk meningkatkan akurasi peramalan. Metode exponential smoothing adalah teknik peramalan yang menghitung rata-rata bergerak dengan memberikan bobot yang semakin menurun secara eksponensial terhadap nilai pengamatan masa lalu.

Revolusi deep learning telah memberikan dampak yang signifikan pada industri penjualan (Hu et al., 2021). Dengan kemampuannya dalam mengolah data yang kompleks dan menemukan pola yang tersembunyi, deep learning telah membuka jalan bagi pengembangan model prediksi yang lebih akurat untuk pasar (Abbas, 2016). Keberhasilan algoritma reinforcement learning dalam permainan catur telah menginspirasi para peneliti untuk menerapkannya dalam bidang keuangan, sehingga membuka peluang baru dalam pengambilan keputusan investasi.

Model peramalan yang diusulkan dalam penelitian ini bertujuan untuk memberikan kontribusi dalam mengatasi tantangan tersebut. Dengan menggabungkan kekuatan kedua metode tersebut, model ini diharapkan dapat menghasilkan prediksi harga yang lebih akurat dan responsif terhadap perubahan kondisi pasar. Selain itu, model ini juga dapat memberikan wawasan yang lebih mendalam mengenai faktor-faktor yang mempengaruhi fluktuasi harga, sehingga dapat digunakan sebagai dasar untuk merumuskan kebijakan yang lebih efektif dalam menjaga stabilitas harga pangan.

STUDI LITERATUR

Prediksi harga telah menjadi topik penelitian yang signifikan dalam berbagai bidang, termasuk keuangan, ekonomi, pertanian, dan e-commerce (Ji et al., 2021). Prediksi harga melibatkan penggunaan berbagai model statistik dan algoritma pembelajaran mesin untuk memperkirakan harga suatu aset, komoditas, atau produk di masa depan. Tujuan dari prediksi harga adalah untuk membantu pengambilan keputusan dalam investasi, pengelolaan persediaan, penetapan harga produk, dan lainnya. Penelitian mengenai prediksi harga telah dilakukan sebelumnya (Linear et al., 2023) dimana penelitian tersebut memprediksi harga beras menggunakan model regresi linear yang berhasil memprediksi harga beras dengan nilai prediksi mendekati nilai aktual dengan nilai RMSE yang diperoleh sebesar 337.996 menunjukkan tingkat kesalahan prediksi. Semakin kecil nilai RMSE, semakin akurat prediksi.

Prediksi harga dipengaruhi praktik monopoli harga oleh tengkulak telah menciptakan ketidakseimbangan yang signifikan dalam rantai pasok pertanian (Adi & Sudiarto, 2022). Petani, sebagai produsen utama, seringkali menjadi pihak yang paling dirugikan akibat asimetri informasi dan lemahnya posisi tawar mereka. Minimnya akses terhadap informasi pasar terkini, coupled dengan ketergantungan petani pada tengkulak untuk menyalurkan hasil panen, membuat mereka rentan terhadap eksploitasi. Akibatnya, harga jual komoditas di tingkat petani jauh di bawah harga pasar yang seharusnya, sementara tengkulak meraup keuntungan yang sangat besar. Kondisi ini tidak hanya berdampak pada kesejahteraan petani, tetapi juga menghambat pertumbuhan sektor pertanian secara keseluruhan.


Penelitian ini menawarkan inovasi dalam bidang pertanian melalui pengembangan alat prediksi harga komoditas. Dengan memanfaatkan teknologi informasi, diharapkan petani dapat mengakses informasi pasar secara real-time dan membuat keputusan bisnis yang lebih baik. Hal ini sejalan dengan upaya untuk modernisasi sektor pertanian dan meningkatkan daya saing produk pertanian Indonesia.

Metode Holt-Winter dalam prediksi harga telah dilakukan oleh beberapa penelitian sebelumnya. Salah satu hasil penelitian analisis menunjukkan bahwa jumlah penumpang pesawat di Bandara Hasanuddin mengalami pertumbuhan yang stabil (Nurhamidah et al., 2020). Metode Additive Holt-Winters telah berhasil menangkap tren kenaikan ini dan dapat digunakan sebagai alat bantu dalam perencanaan kapasitas bandara. Penelitian lain menganalisis perbandingan terhadap tiga metode peramalan menggunakan nilai MAPE, MAD, dan MSE, metode yang paling sesuai untuk meramalkan permintaan tabung gas LPG di PT Petrogas Prima Services adalah Double Exponential Smoothing. Hasil peramalan menggunakan metode Double Exponential Smoothing menunjukkan perkiraan permintaan sebesar 71.625 tabung pada bulan November, 69.345 tabung pada bulan Desember, dan 67.037 tabung pada bulan Januari. Validasi error menunjukkan bahwa Double Exponential Smoothing lebih akurat dibandingkan metode Moving Average dan Single Exponential Smoothing (Aziza, 2022).

Penggunaan metode jaringan saraf tiruan (neural network) dalam prediksi harga telah dilakukan sejak lama (Åkesson & Toivonen, 2006; Liu et al., 2017; Wu et al., 2020). Penelitian (Pang et al., 2020) memberikan bukti empiris bahwa RNN merupakan alat yang lebih baik dibandingkan ANN dalam memprediksi radiasi matahari. Hasil penelitian ini memiliki implikasi yang signifikan bagi pengembangan sistem energi surya, terutama dalam perencanaan dan pengoperasian pembangkit listrik tenaga surya. Dengan meningkatkan akurasi prediksi radiasi matahari, kita dapat mengoptimalkan pemanfaatan energi surya dan mengurangi ketergantungan pada sumber energi fosil. Sementara penelitian lain dapat disimpulkan bahwa model ANN mampu menangani berbagai masalah pemodelan di sungai, danau, waduk, instalasi pengolahan air limbah (WWTP), air tanah, kolam, dan aliran air (Chen et al., 2020).

METODE

Penelitian ini menggunakan dataset harga komoditi dasar di makassar yang kemudian akan diuji menggunakan metode Holt-Winter dan Neural Network. Pada Gambar 1 pengumpulan data dilakukan dari tahun 2000 hingga 2015. Selanjutnya, dilakukan praproses data dengan teknik normalisasi. Setelah itu, data dibagi menjadi dua set, yaitu set latih dan set uji, untuk membangun model prediksi menggunakan arsitektur Holt-Winter dan Neural Network. Model yang diperoleh akan digunakan untuk melakukan prediksi harga komoditas pokok.



Gambar 1. Alur Penelitian

1. Data

Dalam penelitian ini, prediksi komoditas pokok dengan metode Holt-Winters dan jaringan saraf dilakukan menggunakan data set tahun 2000 hingga 2015 dari pasar swasta Makassar.

2. Preprocessing Data

Preprocessing data bertujuan untuk menghasilkan deret waktu yang bersih dan konsisten. Untuk mengatasi masalah data hilang, kami mengimputasi nilai yang hilang dengan rata-rata bulanan. Normalisasi min-max kemudian diterapkan pada data untuk mentransformasikan nilai ke dalam rentang 0 sampai 1. Hal ini diperlukan untuk meningkatkan kinerja model prediksi dan mencegah dominasi fitur dengan rentang nilai yang sangat besar.

3. Holt-Winter

Exponential smoothing adalah prosedur untuk merevisi secara terus-menerus suatu perkiraan berdasarkan pengalaman yang lebih baru (Safitri et al., 2017). Exponential Smoothing memberikan bobot yang menurun secara eksponensial seiring bertambahnya usia pengamatan. Dengan kata lain, pengamatan terbaru diberikan bobot yang relatif lebih besar dalam peramalan daripada pengamatan yang lebih lama.

3.1. Single Exponential Smoothing

Ini juga dikenal sebagai simple exponential smoothing. Simple smoothing digunakan untuk peramalan jangka pendek, biasanya hanya satu bulan ke depan. Model ini mengasumsikan bahwa data berfluktuasi sekitar rata-rata yang cukup stabil (tidak ada tren atau pola pertumbuhan yang konsisten).

Rumus spesifik untuk simple exponential smoothing adalah:

$$F_{t+1} = \alpha X_t + (1 - \alpha) F_t \quad (1)$$

Ketika diterapkan secara rekursif pada setiap pengamatan berurutan dalam deret, setiap nilai yang dihaluskan (perkiraan) yang baru dihitung sebagai rata-rata berbobot dari pengamatan saat ini dan pengamatan yang dihaluskan sebelumnya; pengamatan yang dihaluskan sebelumnya dihitung pada gilirannya dari nilai yang diamati sebelumnya dan nilai yang dihaluskan sebelum pengamatan sebelumnya, dan seterusnya. Dengan demikian, pada dasarnya, setiap nilai yang dihaluskan adalah rata-rata berbobot dari pengamatan sebelumnya, di mana bobotnya menurun secara eksponensial tergantung pada nilai parameter (α). Jika sama dengan 1 (satu), maka pengamatan sebelumnya diabaikan sepenuhnya; jika sama dengan 0 (nol), maka pengamatan saat ini diabaikan sepenuhnya, dan nilai yang dihaluskan terdiri sepenuhnya dari nilai yang dihaluskan sebelumnya (yang pada gilirannya dihitung dari pengamatan yang dihaluskan sebelum itu, dan seterusnya; Dengan demikian semua nilai yang dihaluskan akan sama dengan nilai yang dihaluskan awal S_0). Nilai di antara akan menghasilkan hasil menengah.

Nilai Awal

Nilai awal S_t memainkan peran penting dalam menghitung semua nilai berikutnya. Mengatur nilainya ke y_1 adalah salah satu metode inisialisasi. Kemungkinan lain adalah dengan merata-ratakan empat atau lima pengamatan pertama. Semakin kecil nilai α , semakin penting pemilihan nilai awal S_t .

3.2. Double Exponential Smoothing

Metode ini digunakan ketika data menunjukkan tren. Exponential smoothing dengan tren berfungsi mirip dengan simple smoothing, kecuali bahwa dua komponen harus diperbarui setiap periode - level dan tren. Level

adalah estimasi yang dihaluskan dari nilai data pada akhir setiap periode. Tren adalah estimasi yang dihaluskan dari pertumbuhan rata-rata pada akhir setiap periode. Rumus spesifik untuk simple exponential smoothing adalah:

$$S_t = \alpha * y_t + (1 - \alpha) * (S_t - 1 + b_t - 1) \quad 0 < \alpha < 1 \quad (2)$$

Catatan untuk ilai saat ini dari deret digunakan untuk menghitung penggantian nilai yang dihaluskannya dalam double exponential smoothing.

Nilai Awal

Ada beberapa metode untuk memilih nilai awal untuk S_t dan b_t .

S_1 secara umum diatur ke y_1 .

Tiga bentuk untuk b_1 :

$$b_1 = y_2 - y_1 \quad (3)$$

$$b_1 = [(y_2 - y_1) + (y_3 - y_2) + (y_4 - y_3)]/3 \quad (4)$$

$$b_1 = (y_n - y_1)/(n - 1) \quad (5)$$

3.3. Triple Exponential Smoothing

Triple Exponential Smoothing adalah metode peramalan yang digunakan untuk data deret waktu yang menunjukkan tren dan musim. Metode ini merupakan perluasan dari Single dan Double Exponential Smoothing, dengan menambahkan komponen musiman untuk mengakomodasi pola berulang yang terjadi secara teratur. Komponen dalam metode ini ada tiga yaitu level, tren, dan musiman.

$$S'_t = \alpha X_t + (1 - \alpha) S'_t - 1 \quad (6)$$

$$S''_t = \alpha S'_t + (1 - \alpha) S''_t - 1 \quad (7)$$

$$S'''_t = \alpha S''_t + (1 - \alpha) S'''_t - 1 \quad (8)$$

$$a_t = 3S'_t - 3S''_t + S'''_t \quad (9)$$

$$b_t = a / 2(1 - \alpha)(6 - 5\alpha) S'_t - (10 - 8\alpha) S''_t + (4 - 3\alpha) S'''_t \quad (10)$$

$$c_t = a2 / (1 - \alpha) 2(S'_t - 2S''_t + S'''_t) \quad (11)$$

$$F_{t+m} = a_t + b_t(1) + \frac{1}{2} c_t(1) \quad (12)$$

Keterangan :

S'_t = nilai pemulusan eksponensial tunggal (Single)

S''_t = nilai pemulusan eksponensial ganda (Double)

S'''_t = nilai pemulusan eksponensial rangkap tiga (Triple)

α = parameter pemulusan eksponensial yang besarnya $0 < \alpha < 1$

a, b, c = konstanta pemulusan

F_{t+m} = hasil peramalan periode ke depan yang di ramalkan

4. Neural Network

Neural network, sebuah konstruksi komputasional yang terinspirasi oleh kompleksitas jaringan saraf biologis, merupakan sistem pemrosesan informasi adaptif yang mampu belajar dari data. Mirip dengan otak manusia, jaringan saraf buatan terdiri dari unit-unit pemrosesan sederhana yang saling terhubung, dikenal sebagai neuron buatan atau node. Interkoneksi yang rumit antara neuron-neuron ini memungkinkan jaringan untuk mengenali pola, membuat prediksi, dan bahkan melakukan generalisasi pada data yang belum pernah ditemui sebelumnya.

Arsitektur jaringan saraf, yang merujuk pada organisasi dan struktur interkoneksi antar neuron, merupakan faktor penentu dalam kemampuan jaringan untuk menyelesaikan tugas-tugas tertentu. Salah satu klasifikasi arsitektur jaringan saraf yang umum adalah berdasarkan jumlah lapisan neuron. Jaringan saraf single-layer memiliki struktur yang paling sederhana, dengan neuron input yang menerima data dan neuron output yang menghasilkan hasil akhir. Di sisi lain, jaringan saraf multilayer, yang lebih kompleks, memiliki satu atau lebih lapisan tersembunyi di antara lapisan input dan output. Lapisan tersembunyi ini memungkinkan jaringan untuk mengekstrak fitur-fitur yang lebih abstrak dari data, sehingga meningkatkan kemampuannya dalam menyelesaikan tugas-tugas yang kompleks.

Karakteristik fundamental lainnya dari jaringan saraf adalah algoritma pembelajaran dan fungsi aktivasi. Algoritma pembelajaran menentukan bagaimana jaringan menyesuaikan bobot koneksi antar neuron untuk meminimalkan kesalahan prediksi. Fungsi aktivasi, di sisi lain, menentukan cara neuron memproses input dan menghasilkan output. Kombinasi yang tepat antara arsitektur jaringan, algoritma pembelajaran, dan fungsi aktivasi sangat penting untuk mencapai kinerja yang optimal dalam berbagai aplikasi.

HASIL DAN PEMBAHASAN

Sebagai langkah awal, kami melakukan eksplorasi data harga komoditas untuk mengidentifikasi pola dan tren. Visualisasi data dalam bentuk deret waktu menunjukkan adanya data yang hilang (missing values). Untuk mengatasi masalah ini, kami melakukan imputasi data dengan menghitung rata-rata harga pada bulan yang sama di tahun-tahun sebelumnya. Hasil imputasi dapat dilihat pada Tabel 1 dan Tabel 2. Metode imputasi ini dipilih karena diasumsikan bahwa harga komoditas memiliki pola musiman

Tabel 1. Hasil penanganan *missing values* pada dataset bahan pokok

Tahun	Pasar
2000	1370
2001	1441
2002	1525
2003	1646
2004	1720
2005	1806
2006	1882
2007	2016
2008	2102
2009	2276
2010	2423
2011	2755
2012	2942
2013	3253
2014	3378
2015	3475

Untuk mendapatkan pemahaman yang lebih baik mengenai dinamika harga komoditas, data yang telah diproses divisualisasikan dalam bentuk grafik garis pada Gambar 2. Visualisasi ini memungkinkan kita untuk mengidentifikasi pola-pola seperti tren, musiman, dan fluktuasi acak yang terjadi selama periode lima belas tahun.



Gambar 2. Grafik harga komoditas pokok tahun 2000 hingga 2015

1. Evaluasi Metode Holt-Winter

Data yang telah dikumpulkan pada tabel 1 akan menjadi dasar untuk menerapkan model peramalan menggunakan pendekatan eksponensial smoothing Holt-Winters dan pendekatan jaringan saraf tiruan. Dengan mengatur parameter smoothing α , γ , dan β masing-masing sebesar 0,2, model Holt-Winters akan memberikan bobot yang sama pada observasi terbaru, tren, dan komponen musiman. Hasil peramalan dari kedua model ini nantinya akan disajikan secara visual dalam bentuk grafik dan tabel untuk memudahkan interpretasi dan perbandingan.

Evaluasi kinerja model menggunakan metrik *Mean Absolute Percentage Error* (MAPE) menunjukkan hasil yang sangat memuaskan. Berdasarkan Tabel 2, nilai MAPE terendah yang diperoleh adalah 4.95%, mengindikasikan akurasi prediksi yang tinggi pada beberapa periode. Namun, terdapat juga beberapa periode dengan nilai MAPE yang lebih tinggi, mencapai 6.66%. Secara keseluruhan, nilai MAPE rata-rata sebesar 5.8% menunjukkan bahwa model peramalan mampu memberikan prediksi yang sangat baik.

Tabel 2. Parameter Metode Holt-Winter


Model Summary	Triple ES	Double ES
Variable	Pasar	Pasar
Included Observation	16	16
Smoothing Constant		
Alpha (for data)	0,2	0,2
Gamma (for trend)	0,2	0,2
Beta (for seasonal)	0,2	0,2
Accuracy Measures		
Mean Absolute Error (MAE)	148,595327	133,1572
Sum Square Error	463358,028	565844,9526
Mean Squared Error (MSE)	28959,87675	35365,30936
Mean Percentage Error (MPE)	0,420873	4,823542
Mean Absolute Percentage Error (MAPE)	6,662916	4,953309

Model yang telah dilatih dan menghasilkan nilai MAPE terkecil selama proses evaluasi dianggap sebagai model optimal. Model ini kemudian diaplikasikan pada dataset uji yang terpisah untuk mengukur kemampuannya dalam memprediksi data baru yang belum pernah dilihat sebelumnya. Proses ini bertujuan untuk menguji kemampuan generalisasi model.


Berdasarkan hasil pengujian komprehensif yang disajikan pada Gambar 3, dapat disimpulkan bahwa model prediksi yang telah dikembangkan memiliki tingkat akurasi yang cukup baik dalam memprediksi harga pada periode sebelumnya. Sementara itu, proyeksi harga untuk tahun mendatang, yang ditampilkan secara detail dalam Gambar 4, mengindikasikan adanya potensi peningkatan harga yang signifikan pada tahun berikutnya. Hasil yang diperoleh kemudian divisualisasikan dalam bentuk grafik di Gambar 5 untuk menunjukkan perbandingan harga asli dan prediksi model.

	Actual	Smoothed	Trend	Predicted	Residual
2000	1370.0000	1200.7412	154.0894	1158.4265	211.5735
2001	1441.0000	1372.0645	157.5362	1354.8306	86.1694
2002	1525.0000	1528.6805	157.3522	1529.6007	-4.6007
2003	1646.0000	1678.0262	155.7509	1686.0327	-40.0327
2004	1720.0000	1811.0216	151.1998	1833.7770	-113.7770
2005	1806.0000	1930.9771	144.9509	1962.2214	-156.2214
2006	1882.0000	2037.1424	137.1938	2075.9280	-193.9280
2007	2016.0000	2142.6690	130.8603	2174.3362	-158.3362
2008	2102.0000	2239.2235	123.9992	2273.5293	-171.5293
2009	2276.0000	2345.7781	120.5103	2363.2226	-87.2226
2010	2423.0000	2457.6307	118.7787	2466.2884	-43.2884
2011	2755.0000	2612.1276	125.9224	2576.4094	178.5906
2012	2942.0000	2778.8399	134.0804	2738.0499	203.9501
2013	3253.0000	2980.9362	147.6836	2912.9203	340.0797
2014	3378.0000	3178.4958	157.6588	3128.6198	249.3802
2015	3475.0000	3363.9237	163.2126	3336.1546	138.8454

Gambar 3. Hasil Prediksi Double Smoothing



Gambar 4. Prediksi Harga Tahun 2016



Gambar 5. Grafik Prediksi dan Aktual


2. Evaluasi Metode Neural Network

Model jaringan saraf tiruan yang dikembangkan untuk memprediksi harga kebutuhan pokok telah berhasil dilatih dengan dengan $\alpha = 0,5$, $\gamma = 0,5$, dan $\beta = 0,5$. Model ini memiliki arsitektur feedforward dengan satu lapisan tersembunyi yang terdiri dari 12 neuron, serta lapisan input sebanyak 8 neuron yang merepresentasikan fitur-fitur penting seperti harga pada periode sebelumnya, indeks inflasi, dan tingkat pendapatan per kapita. Hasil evaluasi, yang ditunjukkan oleh nilai Mean Squared Error (MSE) sebesar 702.790227 dan Mean Absolute Error (MAE) sebesar 20.965483, mengindikasikan bahwa model mampu menangkap pola kompleks dalam data harga kebutuhan pokok. Hasil secara rinci untuk pengaturan model dapat dilihat di Tabel 3 dibawah:

Tabel 3. Neural Network in data market


Model Summary	Value
Variable	Pasar
Included Observation	8 (After Adjusting Endpoints)
Input layer Neurons	8
Hidden Layer Neurons	12
Output Layer Neurons	1
Activation Function	BipolarSignoidFunction
Back Propagation Learning	
Learning Rate	0.05
Momentum	0.5
Criteria	
Error	0.002095
MSE	702,790227
MAE	20,965483

Tahap berikutnya adalah melakukan evaluasi komprehensif terhadap kinerja model yang telah dilatih pada dataset yang tersedia. Hasil prediksi model dan visualisasi data akan disajikan secara rinci pada Gambar 6 dan grafik pada Gambar 7 untuk memberikan gambaran yang lebih jelas mengenai akurasi dan kemampuan generalisasi model.



	Actual	Predicted	Residual
2000	1370.0000	NaN	NaN
2001	1441.0000	NaN	NaN
2002	1525.0000	NaN	NaN
2003	1646.0000	NaN	NaN
2004	1720.0000	NaN	NaN
2005	1806.0000	NaN	NaN
2006	1882.0000	NaN	NaN
2007	2016.0000	NaN	NaN
2008	2102.0000	2105.1709	-3.1709
2009	2276.0000	2261.8091	14.1909
2010	2423.0000	2458.9368	-35.9368
2011	2755.0000	2707.1846	47.8154
2012	2942.0000	2978.7927	-36.7927
2013	3253.0000	3232.6166	20.3834
2014	3378.0000	3385.8344	-7.8344
2015	3475.0000	3473.4006	1.5994

Gambar 6. Actual, Predicted and Residual



Gambar 7. Actual and Predicted Graph

Tahapan akhir dari penelitian ini adalah melakukan prediksi terhadap harga bahan pokok pada tahun 2016 dengan menggunakan model jaringan saraf tiruan yang telah teruji validitasnya seperti yang terlihat pada Tabel 4.

Tabel 4. Forecasted

	Forecasted
2016	3508,3895

KESIMPULAN

Hasil penelitian ini mengindikasikan bahwa penerapan metode Holt-Winters dan jaringan saraf tiruan dalam memprediksi harga pangan dapat menghasilkan model prediksi yang lebih akurat dan terperinci dibandingkan dengan metode konvensional. Kemampuan kedua metode ini dalam menangkap pola musiman dan tren jangka panjang pada data harga pangan secara signifikan meningkatkan kualitas prediksi. Akurasi prediksi yang tinggi ini memiliki implikasi yang luas bagi berbagai pihak, termasuk pemerintah, produsen, distributor, dan konsumen. Meskipun demikian, masih terdapat ruang untuk perbaikan, terutama dalam mengurangi nilai MSE yang relatif tinggi pada model Neural Network, yang mungkin disebabkan oleh adanya outlier atau noise dalam data. Prediksi harga yang dihasilkan oleh model ini dapat dimanfaatkan oleh pemerintah sebagai dasar dalam merumuskan kebijakan yang tepat untuk menjaga stabilitas harga pangan dan melindungi konsumen dari fluktuasi harga yang signifikan. Di sisi lain, pelaku industri seperti produsen dan distributor dapat memanfaatkan prediksi ini untuk mengoptimalkan proses produksi dan distribusi, sehingga dapat menghindari terjadinya surplus atau defisit pasokan. Bagi konsumen, informasi mengenai prediksi harga dapat membantu dalam perencanaan keuangan dan pengambilan keputusan terkait konsumsi.

REFERENSI

- Abbas, I. (2016). Penerapan Metode Moving Average (MA) Berbasis Algoritma Support Vector Machine (SVM) untuk Membandingkan Pola Kurva dengan Trend Kurva pada Trading Forex Online. *ILKOM Jurnal Ilmiah*, 8(1), 37–43. <https://doi.org/10.33096/ilkom.v8i1.20.37-43>
- Adi, R. M. S., & Sudianto, S. (2022). Prediksi Harga Komoditas Pangan Menggunakan Algoritma Long Short-Term Memory (LSTM). *Building of Informatics, Technology and Science (BITS)*, 4(2). <https://doi.org/10.47065/bits.v4i2.2229>
- Åkesson, B. M., & Toivonen, H. T. (2006). A neural network model predictive controller. *Journal of Process Control*, 16(9), 937–946. <https://doi.org/10.1016/j.jprocont.2006.06.001>
- Aziza, J. N. (2022). Perbandingan Metode Moving Average, Single Exponential Smoothing, dan Double Exponential Smoothing Pada Peramalan Permintaan Tabung Gas LPG PT Petrogas Prima Services. In *Jurnal Teknologi dan Manajemen Industri Terapan / JTMIT* (Vol. 1).
- Chen, Y., Song, L., Liu, Y., Yang, L., & Li, D. (2020). A review of the artificial neural network models for water quality prediction. In *Applied Sciences (Switzerland)* (Vol. 10, Issue 17). MDPI AG. <https://doi.org/10.3390/app10175776>
- Hu, Z., Zhao, Y., & Khushi, M. (2021). A survey of forex and stock price prediction using deep learning. In *Applied System Innovation* (Vol. 4, Issue 1, pp. 1–30). MDPI AG. <https://doi.org/10.3390/ASI4010009>
- Ji, X., Wang, J., & Yan, Z. (2021). A stock price prediction method based on deep learning technology. *International Journal of Crowd Science*, 5(1), 55–72. <https://doi.org/10.1108/IJCS-05-2020-0012>
- Linear, P. R., Prediksi, U., Beras, H., Indonesia, D., Arinal, V., & Azhari, M. (2023). Penerapan Regresi Linear Untuk Prediksi Harga Beras Di Indonesia. *Jurnal Sains Dan Teknologi*, 5(1), |pp. <https://doi.org/10.55338/saintek.v5i1.1417>
- Liu, W., Wang, Z., Liu, X., Zeng, N., Liu, Y., & Alsaadi, F. E. (2017). A survey of deep neural network architectures and their applications. *Neurocomputing*. <https://doi.org/10.1016/j.neucom.2016.12.038>
- Nurhamidah, N., Nussyirwan, N., & Faisol, A. (2020). Forecasting Seasonal Time Series Data Using The Holt-Winters Exponential Smoothing Method Of Additive Models. *Jurnal Matematika Integratif*, 16(2), 151. <https://doi.org/10.24198/jmi.v16.n2.29293.151-157>
- Pang, Z., Niu, F., & O'Neill, Z. (2020). Solar radiation prediction using recurrent neural network and artificial neural network: A case study with comparisons. *Renewable Energy*, 156, 279–289. <https://doi.org/10.1016/j.renene.2020.04.042>
- Rani, B., Wulandani, D., & Anggraini, W. (n.d.). *Di Desa Wanasaba*.
- Safitri, T., Dwidayati, N., Safitri, T., Dwidayati, N., & Peramalan, S. P. (2017). Menggunakan Exponential Smoothing Holt-Winters dan Arima. *Unnes Journal of Mathematics*, PISSN 2252-6943, EISSN 2460-5859, 6(1), 48–58.
- Wu, Z., Pan, S., Chen, F., Long, G., Zhang, C., & Yu, P. S. (2020). A Comprehensive Survey on Graph Neural Networks. *IEEE Transactions on Neural Networks and Learning Systems*. <https://doi.org/10.1109/tnnls.2020.2978386>
- Yusuf, A., Yusuf Nugroho, A., & Aisyah, S. (2022). Pengaruh Kebijakan Moneter dan Fluktuasi Harga Komoditas Terhadap Pertumbuhan Ekonomi Indonesia Tahun. 7(7), 10. <https://doi.org/10.36418/syntax>