

# Pendekatan Hibrid Double Exponential Smoothing dan GRU untuk Optimasi Prediksi Harga Cabai Rawit Merah

Ika Fadila\*, Budi Hartono

Fakultas Teknologi Informasi dan Industri, Program Studi Teknik Informatika, Universitas Stikubank (Unisbank), Kota Semarang, Indonesia

Email: <sup>1</sup>\*ikafadila@mhs.unisbank.ac.id, <sup>2</sup>budihartono@edu.unisbank.ac.id

Email Penulis Korespondensi: ikafadila@mhs.unisbank.ac.id

Submitted: 22/01/2025; Accepted: 26/02/2025; Published: 01/03/2025

**Abstrak**—Cabai rawit merah merupakan salah satu bahan pangan pokok pendamping yang penting bagi masyarakat. Kenaikan harga cabai rawit merah dapat menimbulkan dampak signifikan pada perekonomian masyarakat. Penelitian ini mengembangkan metode *Double Exponential Smoothing* (DES) dengan optimasi parameter *grid search* dan pendekatan hibrid menggunakan *Gated Recurrent Unit* (GRU) untuk memprediksi harga cabai rawit merah. Tujuan dari pendekatan tersebut adalah untuk meningkatkan akurasi prediksi dan menemukan solusi tepat untuk menyempurnakan model peramalan dengan *double exponential smoothing*. Pada penelitian ini metode DES digunakan untuk menangkap tren jangka pendek dalam data historis, sedangkan GRU digunakan untuk menangkap pola jangka panjang dan *non-linear* dalam data yang tidak dapat dijelaskan oleh DES. Dengan proporsi pembagian data pelatihan sebesar 80% dan data pengujian sebesar 20% didapatkan hasil *Mean Absolute Percentage Error* (MAPE) terendah adalah sebesar 9.51%. Hasil ini lebih baik dari prediksi dengan tanpa mengkombinasikan GRU, dimana peramalan dengan metode tunggal DES memberikan hasil MAPE sebesar 32.74%. Penelitian ini juga terbukti mampu meningkatkan akurasi terhadap metode lain yang memiliki rata-rata tingkat kesalahan sebesar 22.32%. Dengan demikian, pendekatan ini menjadi pilihan unggul sebagai alat pendukung pengambilan keputusan dan perencanaan yang lebih baik untuk mengantisipasi kenaikan harga yang ekstrem.

**Kata Kunci:** Peramalan; Prediksi Harga; Deret Waktu; Double Exponential Smoothing; GRU; MAPE

**Abstract**—Red chili is one of the staple complementary food ingredients essential to society. A rise in the price of red chili peppers can have a significant impact on the community's economy. This study develops a method combining Double Exponential Smoothing (DES) with parameter optimization through grid search and a hybrid approach using a Gated Recurrent Unit (GRU) to predict red chili prices. The goal of this approach is to improve prediction accuracy and find an appropriate solution to refine the forecasting model using double exponential smoothing. In this study, the DES method is used to capture short-term trends in historical data, while the GRU is employed to capture long-term and non-linear patterns in the data that cannot be explained by DES alone. With a data split ratio of 80% for training and 20% for testing, the lowest Mean Absolute Percentage Error (MAPE) achieved is 9.51%. This result is significantly better than using DES alone, which only yielded a MAPE of 32.74%. This study also proves to be able to improve accuracy compared to other methods, which have an average error rate of 22.32%. Therefore, this approach becomes the superior choice as a decision-support tool to anticipate extreme price increases.

**Keywords:** Forecasting; Price Prediction; Time Series; Double Exponential Smoothing; GRU; MAPE

## 1. PENDAHULUAN

Cabai rawit merah merupakan salah satu komoditas penting sebagai bahan makanan yang mempengaruhi harga pasar, ekonomi, dan budaya konsumsi masyarakat. Komoditas ini juga menjadi salah satu bahan pokok yang harganya terus melambung dan menjadi komoditas paling berfluktuasi di antara jenis cabai yang diketahui oleh masyarakat [1][2]. Berdasarkan data Pusat Informasi Harga Pangan Strategis (PIHPS) Nasional, rata-rata harga cabai rawit merah di pasar tradisional Kota Semarang Pada bulan Juli 2024 adalah Rp.40,000/kg naik sebesar Rp.31,250 atau sekitar 43.86% menjadi Rp.71,250/kg pada bulan berikutnya. Beberapa faktor yang mempengaruhi naik - turunnya harga cabai rawit merah adalah musim, cuaca, permintaan dan penawaran, serta kebijakan pemerintah. Kenaikan harga ini berdampak bagi berbagai pihak. Bagi masyarakat, naiknya harga cabai dapat meningkatkan biaya hidup dan menurunkan daya beli sehingga membuat konsumsi berkurang. Hal ini berimbas pada pedagang dan UMKM karena ketika biaya produksi meningkat, penjualan menurun sehingga keuntungan ikut menurun. Untuk menghadapi tantangan ini, diperlukan upaya untuk meminimalisir dampak fluktuasi harga melalui perencanaan dan pengambilan keputusan yang baik. Salah satu langkah tersebut adalah dengan mengembangkan metode peramalan yang akurat.

Peramalan adalah proses memperkirakan hasil yang akan diperoleh berdasarkan input yang dimasukkan dalam pengembangan rencana [3]. *Time series model* adalah metode peramalan secara kualitatif dengan menggunakan waktu sebagai dasar peramalan [4]. Harga cabai rawit merah dapat berubah sewaktu-waktu sehingga dapat dikategorikan sebagai data bertipe *time series* [5]. *Double Exponential Smoothing* (DES) merupakan salah satu metode peramalan dengan model *time series* yang melakukan proses pemulusan (*smoothing*) pada setiap data prediksi terhadap objek pengamatan terbaru, dalam penerapannya terdapat faktor pertumbuhan (*trend factor*) sebagai upaya untuk membawa perkiraan [6]. DES mampu menggabungkan dua komponen peramalan level dan tren memungkinkan analisis pola perubahan harga cabai rawit merah dari waktu ke waktu, yang sangat penting untuk mengantisipasi perubahan harga yang ekstrem [7]. *Gated Recurrent Unit* (GRU) adalah variasi dari model *Long Short-Term Memory* (LSTM) yang menggunakan parameter lebih sedikit dengan menggunakan dua *gate* yaitu *update gate* dan *reset gate*[8]. *Mean Absolute Percentage Error* (MAPE) adalah metrik yang digunakan dalam analisis peramalan untuk

mengukur sejauh mana peramalan atau prediksi deviasi dari nilai aktual dalam bentuk persentase rata-rata [9]. Semakin kecil nilai kesalahan peramalan maka semakin akurat hasil yang diperoleh [10]

Peramalan harga cabai rawit telah menjadi subjek dari berbagai penelitian sebelumnya. Dalam penelitian yang dilakukan oleh Moha Lalapa, dkk, digunakan metode *regresi linear* untuk memprediksi harga cabai rawit. Penelitian tersebut menghasilkan nilai MAPE sebesar 24% menggunakan data bulanan pada tahun 2020 [11]. Penelitian selanjutnya dilakukan oleh Fadhila Fiqa, dkk, tentang perbandingan metode ARIMA dan *prophet* dalam peramalan harga cabai rawit. Penelitian tersebut menghasilkan tingkat error terkecil yang dihitung menggunakan RMSE sebesar 18723.92 dan MAPE sebesar 19.48% pada data dengan rentang waktu tahun 2020 – 2023 [12]. Penelitian lainnya yaitu peramalan harga cabai menggunakan metode Kalman Filter oleh Nabila Asiqotur Rohmah. Penelitian tersebut menghasilkan prediksi harga cabai rawit merah dengan tingkat error terkecil sebesar 31.76% dari data pada periode Maret 2023 – Februari 2024 [13]. Penelitian selanjutnya oleh Arwini Arisandi, dkk menghasilkan peramalan harga cabai rawit merah dengan metode ARIMA diperoleh tingkat akurasi yang diukur dengan MAPE sebesar 15.9% [14]. Kemudian penelitian oleh Vida Komaria, dkk, mengkaji peramalan harga cabai rawit dengan hasil MAPE sebesar 13.09% dari data pada periode April 2017 - Februari 2023 [15]. Adapun penelitian oleh Fadilla Zundina Ulya, tentang peramalan harga cabai dan bawang menggunakan metode ARIMA yang menghasilkan model dengan tingkat error 0.69% untuk komoditas bawang putih dan 18.16 % untuk komoditas cabai rawit yang diukur menggunakan MAPE pada data dengan rentang periode tahun 2022 – 2023 [16].


Metode peramalan yang ada saat ini memiliki masing-masing keterbatasannya sendiri. Penelitian sebelumnya menggunakan metode tunggal dan kombinasi berbasis statistik. Metode berbasis statistik memiliki keterbatasan dalam menangkap pola *non-linear*, tidak mampu memahami ketergantungan jangka panjang, tidak mampu belajar dan beradaptasi pada data yang beragam, serta hanya terfokus pada pola sederhana seperti tren, musiman, atau siklus saja. DES dikenal sebagai metode peramalan yang mampu menangkap pola tren dan level dalam data dengan baik. Namun, metode ini tidak mampu menangani data dengan pola yang kompleks dan *non-linear* seperti harga cabai rawit merah. Di sisi lain, metode berbasis *deep learning* yang juga bagian dari *Recurrent Neural Network* (RNN), seperti *Gated Recurrent Unit* (GRU), memiliki kemampuan untuk mempelajari karakteristik data dan memodelkan pola data yang lebih kompleks dengan mempertimbangkan dependensi jangka panjang. Oleh karena itu, penelitian ini menggabungkan kedua metode tersebut untuk memperoleh model prediksi yang lebih akurat dan memberikan solusi terhadap keterbatasan penelitian sebelumnya. Metode ini dirancang untuk memanfaatkan keunggulan DES dalam mendeteksi pola tren dan GRU dalam menangkap pola *non-linear* yang kompleks. Dengan mengintegrasikan kedua pendekatan ini, diharapkan hasil peramalan dapat lebih akurat dan relevan untuk mendukung pengambilan keputusan.

## 2. METODOLOGI PENELITIAN

Penelitian ini dilakukan secara terstruktur melalui serangkaian tahapan mulai dari pengumpulan data, prapemrosesan, penerapan metode, hingga evaluasi model.

### 2.1 Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan untuk menghasilkan sistem peramalan harga yang akurat seperti pada Gambar 1.



Gambar 1. Tahapan penelitian

Berdasarkan Gambar 1. Tahapan pengumpulan data pada penelitian ini menggunakan data dari situs resmi Pusat Informasi Harga Pangan Strategis (PIHPS) Nasional yang menyediakan informasi harga pangan secara *real time*. Data yang digunakan adalah data bulanan harga cabai rawit merah pada periode Agustus 2022 – Desember 2024 sebanyak 25 data.

Tahap selanjutnya yaitu melakukan pra-pemrosesan data. Data yang diperoleh diolah dan dipastikan tidak ada *missing* data atau nilai yang tidak valid. Setelah dirapikan, data tersebut dibagi menjadi data *training* dan data *testing*. Persentase data training harus lebih besar dibanding dengan data testing. Data testing yang dapat digunakan 10% sampai 30% dari total data [17]. Komposisi data train dan data testing dalam penelitian ini adalah sebagai berikut:

- Data train: sebanyak 80% dari total data digunakan untuk melatih model
- Data test: sebanyak 20% dari total data digunakan untuk menguji model dan membandingkan dengan hasil prediksi.

Tujuan pembagian ini adalah untuk mengukur seberapa baik model mampu melakukan prediksi pada data yang belum pernah dilihat.

## 2.2 Penerapan Double Exponential Smoothing

*Double exponential smoothing* adalah salah satu metode peramalan deret waktu yang cocok digunakan untuk data dengan tren linier. Metode ini menggunakan dua komponen utama yaitu level dan tren yang dihitung menggunakan bobot  $\alpha$  dan  $\beta$ . Penggunaan Metode Double Exponential Smoothing relevan ketika data masa lalu menunjukkan adanya tren [18]. Pada tahap ini metode DES digunakan untuk menangkap pola tren dalam data historis. Adapun mekanisme pendekatan metode ini adalah sebagai berikut:

### a. Menentukan parameter $\alpha$ dan $\beta$ dengan *grid search*

Parameter ini berfungsi untuk menangkap komponen level dan tren dalam data. Besaran nilai  $\alpha$  dan  $\beta$  berada di rentang 0 sampai dengan 1 [19]. Semakin besar nilai  $\alpha$ , semakin besar pula pengaruh data terbaru terhadap peramalan [20]. Sementara itu, semakin besar nilai  $\beta$  semakin responsif pula model terhadap perubahan tren. Untuk menentukan nilai  $\alpha$  dan  $\beta$  optimum dilakukan dengan menggunakan metode *grid search*. Dalam *grid search*, berbagai kombinasi nilai  $\alpha$  dan  $\beta$  diuji untuk meminimalkan kesalahan peramalan menggunakan metrik *Mean Absolute Error* (MAE).

### b. Melakukan inisialisasi komponen level dan tren

Inisialisasi merupakan tahap untuk menentukan titik awal proses peramalan. Komponen level merepresentasikan estimasi nilai rata-rata terkini, sedangkan komponen tren merepresentasikan tingkat perubahan atau *slope* data dari waktu ke waktu. Jika tidak ada data historis sebelumnya maka inisialisasi level awal ( $L_0$ ) dan tren awal ( $T_0$ ) dapat dilakukan dengan persamaan 1 dan 2.

$$L_0 = 0 \quad (1)$$

$$T_0 = 0 \quad (2)$$

Jika data historis ada namun sedikit, inisialisasi dapat dilakukan dengan persamaan 3 dan 4.

$$L_t = Y_t \quad (3)$$

$$T_t = Y_t - Y_{t-1} \quad (4)$$

### c. Menghitung komponen level dan tren

Komponen level ( $L_t$ ) dan tren ( $T_t$ ) dihitung melalui persamaan 5 dan 6

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (5)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (6)$$

### d. Menghitung nilai prediksi


Nilai prediksi ( $F_{t+m}$ ) dapat dihitung melalui persamaan 7.

$$F_{t+m} = L_t + m \cdot T_t \quad (7)$$

Berdasarkan uraian di atas,  $\alpha$  (*alpha*) dan  $\beta$  (*beta*) adalah parameter yang digunakan untuk mengatur tingkat pemulusan data.  $Y_t$  merepresentasikan nilai aktual pada periode ke- $t$ , sementara  $L_t$  menunjukkan level pada periode tersebut.  $T_t$  menggambarkan tren yang terjadi pada periode ke- $t$ . Adapun  $F_t$  adalah hasil prediksi untuk periode ke- $t$  dan  $m$  menunjukkan banyaknya periode yang digunakan dalam peramalan.

## 2.3 Penerapan Gated Recurrent Unit (GRU)

*Gated Recurrent Unit* adalah salah satu jenis *recurrent neural network* (RNN) hasil modifikasi *Long Short-Term Memory* (LSTM). Perbedaan antara keduanya adalah GRU memiliki arsitektur lebih sederhana karena tidak memiliki *cell state* dan hanya menggunakan *hidden state*. Hal ini menjadikan GRU lebih ringan dan efisien dalam hal komputasi. GRU juga menggunakan lebih sedikit parameter dibanding LSTM, sehingga memerlukan waktu pelatihan lebih singkat tanpa mengurangi tingkat akurasi. Penelitian ini memilih GRU karena dapat menghasilkan akurasi tinggi dengan *overhead* komputasi lebih rendah. Pada tahap ini penerapan GRU digunakan untuk mempelajari pola non-linear dan dependensi jangka panjang dari data hasil *smoothing* DES. Arsitektur GRU dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur GRU

Berdasarkan Gambar 2, *Update gate* ( $z_t$ ) mengontrol seberapa banyak informasi dari waktu sebelumnya ( $h_{t-1}$ ) yang akan dibawa ke waktu sekarang ( $h_t$ ), sedangkan *reset gate* ( $r_t$ ) mengontrol seberapa banyak informasi dari state sebelumnya ( $h_{t-1}$ ) yang akan digunakan untuk menghitung *candidate state* ( $\tilde{h}_t$ ). *Candidate state* dihitung berdasarkan input saat ini ( $x_t$ ) dan informasi dari state sebelumnya ( $h_{t-1}$ ) dengan mempertimbangkan *reset gate*. Gabungan dari *candidate state* dan *state* sebelumnya yang dikontrol oleh *update gate* ini disebut dengan *current state*.

$$z_t = \sigma (W_z \cdot x_t + U_z \cdot h_{t-1} + b_z) \quad (8)$$

$$r_t = \sigma (W_r \cdot x_t + U_r \cdot h_{t-1} + b_r) \quad (9)$$

$$\tilde{h}_t = \tanh (W_h \cdot x_t + r_t \odot (U_h \cdot h_{t-1}) + b_h) \quad (10)$$

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot \tilde{h}_t \quad (11)$$

Jika  $z_t$  mendekati 1: lebih banyak informasi  $h_{t-1}$  dipertahankan

Jika  $z_t$  mendekati 0: lebih banyak informasi baru  $\tilde{h}_t$  digunakan

#### 2.4 Mean Absolute Percentage Error (MAPE)

*Mean Absolute Percentage Error* (MAPE) merupakan salah satu metode pengukuran kesalahan prediksi dalam bentuk persentase. Untuk mencari nilai MAPE perlu dilakukan perhitungan dengan menemukan kesalahan absolute setiap periode, kemudian melakukan pembagian dengan nilai observasi pada periode tersebut dan mencari rata-rata persentase absolut-nya[21]. Nilai MAPE dapat dihitung melalui persamaan 12.

$$MAPE = \frac{1}{n} \sum \left( \frac{|Y_t - Ft|}{Y_t} \right) \times 100\% \quad (12)$$

Tabel 1. Interpretasi MAPE

Persentase	Keterangan
< 10% MAPE	Sangat Baik
10% - 20%	Baik
20% - 50%	Cukup
> 50%	Kurang

Tabel 1 adalah interpretasi umum nilai MAPE. Semakin mendekati 0 nilai MAPE maka semakin tinggi pula akurasi suatu model peramalan.

### 3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil dari implementasi metode *Double Exponential Smoothing* (DES) pada data harga cabai rawit merah, mulai dari tahap awal pengolahan data hingga evaluasi prediksi. Setiap langkah dalam proses ini, termasuk prapemrosesan data, perhitungan parameter, dan analisis hasil peramalan, dijelaskan untuk memastikan transparansi metode dan validitas hasil yang diperoleh.

### 3.1 Hasil Prapemrosesan Data

Penelitian ini menggunakan 25 data laporan bulanan pada Agustus 2022 – Desember 2024. Kemudian membaginya menjadi 80% data training dan 20% data testing.

**Tabel 2.** Hasil prapemrosesan data harga cabai rawit merah

Periode	Data Aktual
2022-08-01	56,250.00
2022-09-01	51,250.00
2022-10-03	55,750.00
...	...
2024-07-01	40,000.00
2024-08-01	71,250.00
2024-09-02	32,250.00
2024-10-01	35,250.00
2024-11-01	34,000.00
2024-12-02	23,250.00

Pada Tabel 2 data dengan blok oranye adalah data pengujian dan data dengan blok putih adalah data pelatihan. Grafik pembagian data historis dapat dilihat pada Gambar 3.



**Gambar 3.** Grafik bulanan data harga cabai rawit merah

Berdasarkan Gambar 3. Ditunjukkan data training (area berwarna putih) digunakan untuk melatih model peramalan, sementara data testing (area berwarna oranye) digunakan untuk mengevaluasi performa model.

### 3.2 Hasil Penerapan Double Exponential Smoothing

Untuk menghitung prediksi, diperlukan inisialisasi nilai parameter  $\alpha$  dan  $\beta$  untuk menentukan level dan tren. Pemilihan parameter ini sangat penting untuk memastikan bahwa model dapat menangkap pola data dengan baik tanpa mengabaikan fluktuasi yang signifikan. Hasil percobaan dengan *grid search* menunjukkan bahwa nilai  $\alpha = 0.9$  dan  $\beta = 0.2$  merupakan nilai terbaik dengan MAPE 7.17% berdasarkan data cabai rawit merah.

a. Inisialisasi awal:

$$L_0 = 0$$

$$T_0 = 0$$

b. Prediksi pada periode pertama

$$L_1 = 51,250$$

$$T_1 = 52,350 - 56,250 = -5000$$

$$F_1 = 51,250 + (-5000) = 46,250$$

c. Prediksi pada periode kedua:

$$L_2 = 0.9 \cdot 55,750 + (1 - 0.9) \cdot (51,250 + (-5000)) = 54,800$$

$$T_2 = 0.4 \cdot (54,800 - 51,250) + (1 - 0.4) \cdot (-5000) = -1,580$$

$$F_2 = 54,800 + (-1,580) = 53,220$$


Ringkasan hasil prediksi *in-sample* dengan DES dapat dilihat pada Tabel 3.

**Tabel 3.** Perhitungan prediksi *in-sample* dengan DES

Periode	Nilai Aktual	Level	Trend	Nilai Prediksi	Error
2022-08-01	56,250.00	0	0	0	0
2022-09-01	51,250.00	51,250.00	- 5,000.00	46,250.00	0.098
2022-10-03	55,750.00	54,800.00	- 1,580.00	53,220.00	0.045
2022-11-01	33,750.00	35,697.00	- 8,589.20	27,107.80	0.197
2022-12-01	43,500.00	41,860.78	- 2,688.01	39,172.77	0.099
2023-01-02	68,750.00	65,792.28	7,959.79	73,752.07	0.073
2023-02-01	54,000.00	55,975.21	849.05	56,824.26	0.052

...	...	...	...	...	...
2023-12-01	86,250.00	86,343.88	14,319.99	100,663.86	0.167
2024-02-01	38,750.00	44,941.39	- 7,969.00	36,972.38	0.046
2024-03-01	60,000.00	57,697.24	320.94	58,018.18	0.033
2024-04-01	32,500.00	35,051.82	- 8,865.60	26,186.21	0.194
2024-06-03	33,750.00	32,993.62	- 6,142.64	26,850.98	0.204
2024-07-01	40,000.00	38,685.10	- 1,408.99	37,276.10	0.068

Tabel 3 menunjukkan besaran nilai level dan tren yang bergerak pada tiap periodenya dengan disertai nilai *error* sebagai representasi tingkat akurasi nilai prediksi terhadap nilai aktual. Hasil prediksi ini kemudian dijadikan masukan pada proses selanjutnya.



Gambar 4. Grafik prediksi harga cabai terhadap data aktual

Pada Gambar 4 ditampilkan grafik hasil prediksi yang menggambarkan sejauh mana hasil prediksi dapat mencerminkan pola pergerakan harga sebenarnya. Garis biru merepresentasikan data aktual, sementara garis merah menunjukkan hasil prediksi model yang digunakan.


### 3.3 Penerapan Gated Recurrent Unit (GRU)

Penerapan GRU digunakan untuk menangkap pola non-linear dalam data. Data hasil *smoothing* DES ( $X_{smooth}$ ) dinormalisasi menggunakan *min-max scaling* untuk meningkatkan efisiensi pelatihan model GRU dan menghilangkan *outlier*. Setelah data dinormalisasi dilakukan pemodelan GRU menggunakan tensorflow.js, hasil model ini kemudian di-denormalisasi untuk mengembalikan data ke skala asli.

Tabel 4. Hasil MAPE model GRU

Percobaan	Unit GRU	Learning rate	Optimizer	Epoch	Batch size	Lookback	Activation	MAPE
1	50	-	Adam	1000	8	3	tanh -	45%
2	50	-	Adam	500	16	5	tanh -	27%
3	128	8	Adam	500	8	4	tanh relu6	10.75%
4	128	8	Adam	300	8	4	- -	15.76%
5	128	4	Adam	500	8	4	tanh relu6	9.51%
6	128	64	Adam	500	8	4	tanh relu6	21.74%
7	128	8	Adam	500	16	4	tanh relu6	25.74%

Berdasarkan Tabel 4 diperoleh nilai MAPE terkecil adalah pada percobaan ke-5 yaitu sebesar 9.51%. Penggunaan 2 layer GRU menunjukkan hasil lebih optimal pada model tersebut. Kombinasi unit pada keduanya dengan nilai 128 dan 4 juga menunjukkan hasil lebih baik dengan fungsi aktivasi relu6 pada layer terakhir.



Gambar 5. Hasil prediksi *out-sample* dengan metode hibrid DES-GRU

Pada Gambar 5, ditampilkan grafik hasil prediksi *out-sample* menggunakan metode hibrid DES dan GRU. Garis merah menunjukkan hasil prediksi, yang menggambarkan perkiraan tren harga di luar sampel data pelatihan. Pola fluktuasi pada garis merah mencerminkan bagaimana model menangkap dinamika perubahan harga, dengan

beberapa perbedaan dibandingkan data aktual. Visualisasi ini membantu dalam mengevaluasi sejauh mana akurasi model dalam memprediksi pergerakan harga di masa mendatang.

**Tabel 5.** Hasil perbandingan nilai prediksi DES-GRU dengan data aktual

Periode	Aktual	Prediksi	Error
21	71,250	61,260.68	0.140
22	32,250	35,452.88	0.099
23	35,250	42,042.80	0.193
24	34,000	35,306.02	0.038
25	23,250	23,362.28	0.005
MAPE			9.509%

Tabel 5 menyajikan hasil perbandingan pada percobaan kelima antara nilai prediksi yang dihasilkan oleh metode hibrid DES-GRU dengan data aktual untuk beberapa periode tertentu. Kolom *Error* menunjukkan selisih relatif antara nilai aktual dan prediksi, yang mencerminkan tingkat kesalahan model dalam memperkirakan harga.

### 3.4 Evaluasi Kinerja Model

Untuk mengukur efektivitas model hibrid, akan dilakukan perbandingan hasil peramalan dengan dan tanpa menggunakan GRU. Berikut ini adalah hasil perhitungan prediksi dengan DES menggunakan nilai parameter yang sama dengan percobaan sebelumnya disertai optimasi level dan tren awal menggunakan agregasi rata-rata level dan tren terakhir.

a. Inisialisasi awal dan hasil prediksi periode ke-21:

$$L_1 = 47,117.87$$

$$T_1 = -1,957.27$$

$$F_1 = 47,117.87 + (-1,957.27) = 45,160.60$$

b. Prediksi pada periode ke-22:

$$L_2 = 45,160.60$$


$$T_2 = 0.2 \cdot (45,160.60 - 47,117.87) + (1 - 0.2) \cdot (-1,957.27) = -1,957.27$$

$$F_2 = 45,160.60 + (-1,957.27) = 43,203.32$$

**Tabel 6.** Hasil perbandingan prediksi *out-sample* DES dengan data aktual

Periode	Aktual	Prediksi	Error
21	71,250	45,160.60	0.366
22	32,250	43,203.32	0.340
23	35,250	41,246.05	0.170
24	34,000	39,288.78	0.156
25	23,250	37,331.51	0.606
MAPE			32.74%

Pada Tabel 6, ditampilkan perbandingan hasil prediksi metode tunggal DES terhadap data aktual. Nilai *error* dalam tabel tersebut menggambarkan selisih antara hasil prediksi dan data aktual, yang menjadi indikator akurasi model.



**Gambar 6.** Hasil prediksi *out-sample* dengan metode tunggal DES

Gambar 6 merupakan hasil prediksi dengan metode tunggal DES. Berdasarkan grafik tersebut dapat dilihat perbedaan antara kinerja metode DES secara *in-sample* dengan DES secara *out-sample*.

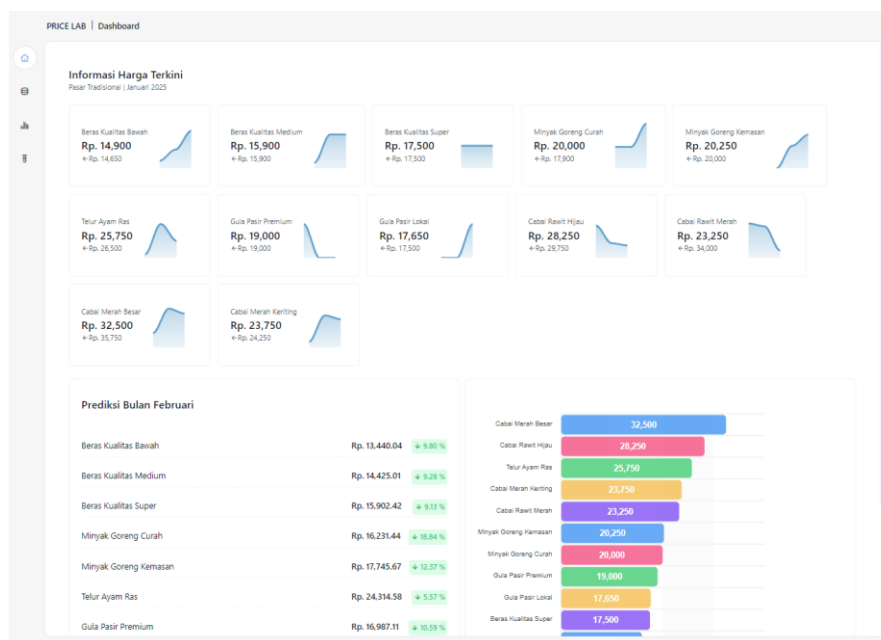
Berdasarkan hasil prediksi menggunakan metode hibrid dan tunggal, diperoleh bahwa prediksi dengan mengkombinasikan GRU berhasil menurunkan nilai MAPE dari 32.74% menjadi 9.51%. Jika dilihat berdasarkan gambar 6, hasil prediksi di luar sampel menggunakan DES cenderung linear dan tidak mampu membaca perubahan mendadak seperti pada bulan Juli 2024 dari 40,000 meningkat pada periode selanjutnya menjadi 71,250 kemudian

turun lagi menjadi 32,250. Hal ini disebabkan karena DES hanya mengandalkan level dan tren yang cenderung tidak mempertimbangkan hubungan jangka panjang. Kelemahan tersebut dapat teratasi dengan mengkombinasikan GRU ke dalam DES. GRU terbukti sangat mempengaruhi hasil prediksi. Ketika harga cabai naik tajam dalam satu periode, GRU dapat mempelajari hubungan sebab-akibat dari data historis, sementara DES akan memperhalus data, mengabaikan fluktuasi besar tersebut. Hal ini dikarenakan GRU menggunakan mekanisme *gating* (*update gate* dan *reset gate*) yang memungkinkan model untuk menyimpan informasi penting dari data sebelumnya dalam *hidden state*. GRU belajar menggunakan data hasil *smoothing* DES kemudian membuat prediksi *out-sample* berdasarkan pola yang sudah dipelajari selama pelatihan sehingga mampu menciptakan prediksi yang lebih mendekati data aktual.

### 3.5 Implementasi

Tujuan dari implementasi adalah untuk menerapkan metode hibrid DES-GRU ke dalam sistem dan memastikan bahwa sistem prediksi harga bekerja dengan akurasi yang baik dan memberikan hasil yang sesuai dengan kebutuhan pengguna.

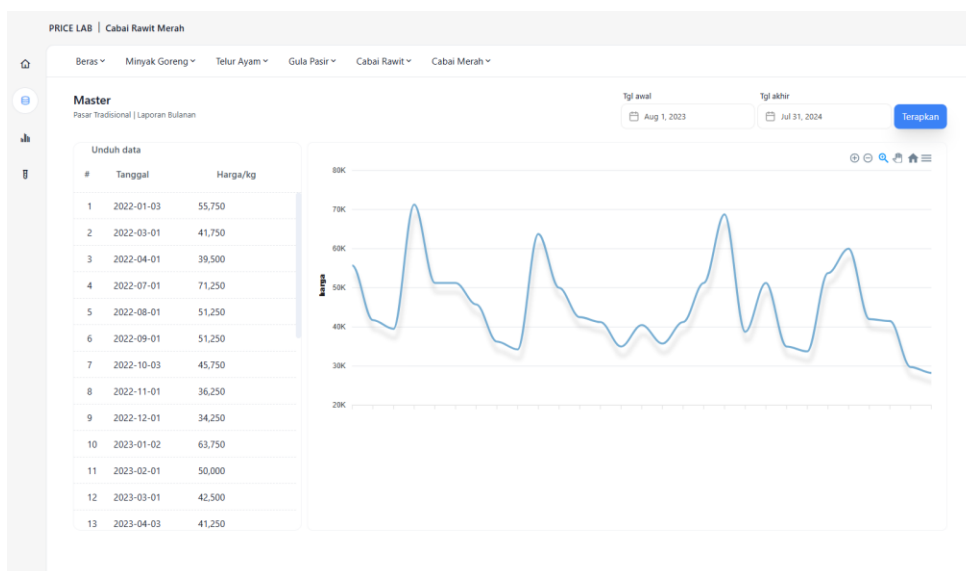
#### a. Halaman dashboard



Gambar 7. Tampilan halaman dashboard

Pada Gambar 7, ditampilkan data harga terkini dan hasil prediksi singkat dengan visualisasi grafik. Halaman dashboard ini memungkinkan pengguna mengetahui harga terkini dan prediksi cepat untuk satu bulan berikutnya.

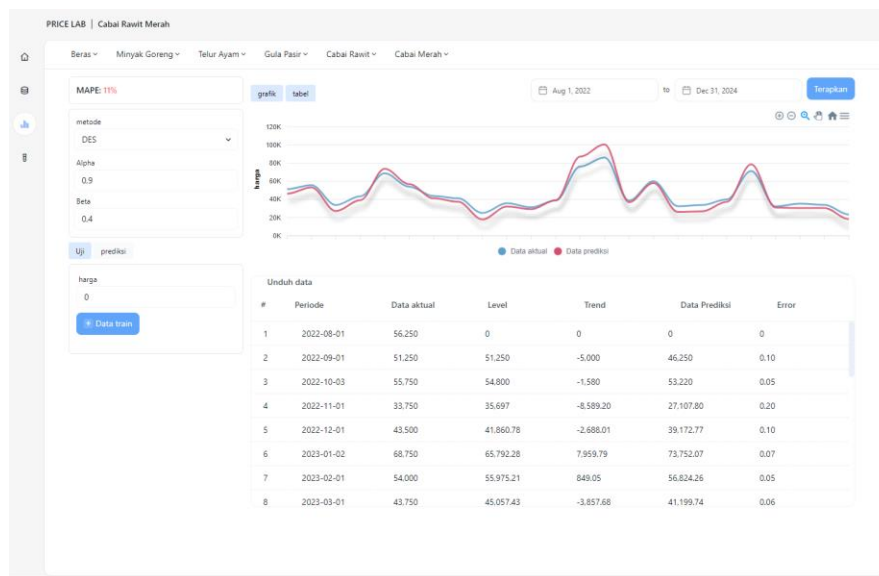
#### b. Halaman master



Gambar 8. Tampilan halaman master

Pada Gambar 8 tampilan halaman master, sistem mampu menampilkan data harga komoditas tertentu berdasarkan periode tertentu dengan disertai visualisasi grafik. Halaman ini juga menyediakan fitur ekspor data dalam format excel untuk mendukung kebutuhan analisis lebih lanjut. Fitur ini memberikan fleksibilitas kepada pengguna, terutama bagi mereka yang membutuhkan data untuk keperluan penelitian atau pelaporan.

c. Halaman prediksi



Gambar 9. Tampilan halaman prediksi

Pada Gambar 9, ditampilkan hasil prediksi disertai dengan visualisasi grafik dan dapat menampilkan besar nilai MAPE. Halaman ini memungkinkan pengguna mengatur parameter, melakukan prediksi untuk beberapa periode ke depan. Selain itu, halaman ini juga dilengkapi dengan fitur simulasi yang memungkinkan pengguna memasukkan skenario tertentu, seperti perubahan parameter atau nilai awal, untuk melihat dampaknya terhadap hasil prediksi.

## 4. KESIMPULAN

Berdasarkan hasil penelitian diperoleh kesimpulan bahwa mengkombinasikan metode GRU dengan DES terbukti mampu meningkatkan akurasi daripada hanya menggunakan metode tunggal *Double Exponential Smoothing*. Hal ini disebabkan karena DES tidak mampu membaca pola *non linear* pada prediksi di luar sampel. Penelitian ini juga memberikan hasil terbaik dengan menyempurnakan metode yang pernah dilakukan penelitian sebelumnya dan berhasil meningkatkan akurasi peramalan pada data dengan fluktuasi tajam dengan performa akurasi mencapai 90.49%. Meskipun demikian, masih terdapat keterbatasan dalam model ini. Prediksi dengan metode hibrid DES dan GRU memerlukan waktu komputasi lebih lama dibandingkan dengan metode tunggal DES saja. Selain itu, DES merupakan metode *exponential* yang mana diketahui sangat bergantung pada parameter  $\alpha$  dan  $\beta$  [22] yang harus dioptimalkan untuk setiap jenis data. Hasil peramalan juga sangat bergantung pada inisialisasi level dan tren awal. Nilai  $\alpha$  dan  $\beta$  terbaik pada prediksi *in-sample* belum tentu optimal untuk prediksi *out-of-sample*. Sebagai saran untuk penelitian selanjutnya, penting untuk melakukan optimalisasi parameter  $\alpha$  dan  $\beta$  secara general seperti *cross validation* atau metode *methauristik* untuk menentukan nilai  $\alpha$  dan  $\beta$  secara otomatis [23]. Sementara itu, metode GRU masih memiliki kemungkinan untuk menghasilkan model yang lebih baik dengan melakukan lebih banyak percobaan pada *hyperparameter*. Hal ini berarti penting melakukan optimasi parameter dengan metode lain seperti *grid search* atau *bayesian optimization*. Pertimbangan juga penggunaan optimizer yang lebih adaptif seperti AdamW, Nadam atau RMSprop untuk melihat perbedaan hasil. Eksperimen menggunakan layer tambahan juga dapat dipertimbangkan mengingat hasil prediksi dengan dua layer lebih baik dibandingkan dengan satu layer.

## REFERENCES

- [1] Z. M. Nawawi, A. Soemitra, dan M. Dalimunthe, "Women's Economic Empowerment Through Sharia Micro-Finance Institutions In Indonesia: A Qualitative Research," *Iqtishadia*, vol. 15, no. 2, hlm. 255, Des 2022, doi: 10.21043/iqtishadia.v15i2.15902.
- [2] T. S. Wahyuni, R. Satriani, dan A. N. Mandamdari, "Mimbar Agribisnis: Jurnal Pemikiran Masyarakat Ilmiah Berwawasan Agribisnis Pengaruh Fluktuasi Harga Cabai Rawit Merah Terhadap Inflasi di Kabupaten Banyumas," vol. 10, no. 2, hlm. 1866–1877, [Daring]. Tersedia pada: [www.antara.jatengnews](http://www.antara.jatengnews),
- [3] J. SPT, *Sistem Informasi Manajemen*, 1 ed. Yogyakarta: Deepublish Publisher, 2016.



- [4] U. Yudatama, A. Dianto, A. Fergina, dan R. Tisnawati, *Sistem Enterprise di Era Digital: Inovasi, Transformasi, dan Keberlanjutan*, 1 ed. Bandung: Kaizen Media Publishing, 2023.
- [5] R. F. Sholeh, B. A. Dermawan, dan I. Maulana, “Peramalan Harga Emas Di Indonesia Menggunakan Algoritma Double Exponential Smoothing Damped Trend” *Journal of Information Technology and Computer Science (INTECOMS)*, vol. 4, no. 2, hlm. 2021, doi: 10.31539/intecom.v4i2.2821.
- [6] M. Noor Arridho dan M. Rudyanto Arief, “Pergerakan Nilai Aktiva Bersih (NAB) Berdasarkan Evaluasi Kesalahan Metode Double Exponential Smoothing pada Reksa Dana BNI-AM Dana Lancar Syariah,” *Teknimedia*, vol. 3, Des 2022, doi: 10.46764/teknimedia.v3i2.64.
- [7] E. Shafira Helmi *dkk.*, “Penerapan Metode Time Series Analysis pada Sistem Informasi Posyandu untuk Mengetahui Pola Berat Badan Anak menggunakan Whatsapp Gateway,” *Journal of Information System Research*, vol. 6, no. 1, hlm. 617–628, 2024, doi: 10.47065/josh.v6i1.6083.
- [8] J. A. Ripto dan H. Heryanto, “Penerapan Gated Recurrent Unit untuk Prediksi Pergerakan Harga Saham pada Bursa Efek Indonesia.”
- [9] Z. Ngabidin, A. Sanwidi, dan E. R. Arini, “Implementasi Metode Double Exponential Smoothing Brown Untuk Meramalkan Jumlah Penduduk Miskin,” *Euler : Jurnal Ilmiah Matematika, Sains dan Teknologi*, vol. 11, no. 2, hlm. 328–338, Des 2023, doi: 10.37905/euler.v11i2.23054.
- [10] Wahyu Hadi Sutiyono dan Widya Setiafindari, “Analisis Penerapan Forecasting Penjualan Untuk Menentukan Jumlah Tenaga Kerja Efektif Produksi Tepung Mocaf Pada UMKM XYZ,” *Jupiter: Publikasi Ilmu Keteknikan Industri, Teknik Elektro dan Informatika*, vol. 2, no. 4, hlm. 181–194, Jul 2024, doi: 10.61132/jupiter.v2i4.423.
- [11] N. Moha Lalapa dan W. Yunus, “Implementasi Metode Regresi Linear Sederhana Untuk Prediksi Harga Cabai Rawit,” *Jurnal Ilmiah Ilmu Komputer Banthayo Lo Komputer*, vol. 2, no. 2, hlm. 96, 2023, doi: 10.37195/balok.v2i2.121.
- [12] H. Fadhila Fiqa, A. Ratna Dewi, dan R. Pandiya, “Perbandingan Metode ARIMA dan Prophet dalam Prediksi Harga Cabai Rawit di Provinsi Jawa Timur,” *Seminar Nasional Sains Data*, 2024.
- [13] N. A. Rohmah, “Prediksi Harga Cabai Di Kabupaten Ponorogo Menggunakan Algoritma Kalman Filter,” 2024. [Daring]. Tersedia pada: <https://siskaperbapo.jatimprov.go.id/harga-komoditas>.
- [14] A. Arisandi, I. Gaffar, dan A. R. Makkulawu, “Application Of The Arima Method In Forecasting The Price Red Cayenne Pepper In Makassar City,” *Parameter: Journal of Statistics*, vol. 4, no. 1, hlm. 30–36, Jun 2024, doi: 10.22487/27765660.2024.v4.i1.17120.
- [15] V. Komaria, N. El Maidah, dan M. A. Furqon, “Prediksi Harga Cabai Rawit di Provinsi Jawa Timur Menggunakan Metode Fuzzy Time Series Model Lee,” *Komputika : Jurnal Sistem Komputer*, vol. 12, no. 2, hlm. 37–47, Sep 2023, doi: 10.34010/komputika.v12i2.10644.
- [16] F. Zundina Ulya, A. Rony Wijaya, dan P. Laras Puspita, “Peramalan Harga Cabai dan Bawang di Pasar Tradisional Purwokerto dengan Model Autoregressive Integrated Moving Average (ARIMA),” *Seminar Nasional Official Statistics 2023*.
- [17] S. Aisyah dan S. Wahyuningsih, “Peramalan Jumlah Titik Panas Provinsi Kalimantan Timur Menggunakan Metode Radial Basis Function Neural Network,” *Jambura Journal of Probability and Statistics*, vol. 2, no. 2, hlm. 64–74, Nov 2021, doi: 10.34312/jjps.v2i2.10292.
- [18] R. A. A. Putra, H. Z. Zahro’, dan D. Rudhistiar, “Penerapan Metode Double Exponential Smoothing Untuk Peramalan Penjualan Unit Mobil,” *Jurnal Mahasiswa Teknik Informatika*, vol. 7, no.5, Oktober 2023, doi: 10.36040/jati.v7i4.7493.
- [19] M. H. Kurniawan dan D. Herwanto, “Penerapan Metode Double Exponential Smoothing dan Moving Average pada Peramalan Permintaan Produk Gasket Cap di PT. Nesinak Industries,” *Serambi Engineering*, vol. VII, no. 1, 2022, doi: 10.32672/jse.v7i1.3709.
- [20] M. A. Ilham, dan S. Achmadi, dan K. A. Sari, “Implementasi Metode Double Exponential Smoothing untuk Sistem Peramalan Penjualan Alat Musik,” *Jurnal Teknologi Terpadu*, vol. 10, Des 2024, doi: 10.54914/jtt.v10i2.1490.
- [21] Z. A. Sari dan M. Andarwati, “Peramalan Double Moving Average Dan Double Exponential Smoothing Jumlah Penumpang Di Stasiun Kotabaru Malang,” *Journal of Information Systems Management and Digital Business (JISMDB)*, vol. 1, no. 2, 2024, doi: 10.59407/jismdb.v1i2.436.
- [22] M. Hakimah, W. Mistarika Rahmawati, dan A. Yuldian Afandi, “Pengukuran Kinerja Metode Peramalan Tipe Exponential Smoothing Dalam Parameter Terbaiknya,” *Jurnal Ilmiah NERO*, vol. 5, no. 1, 2020, doi: 10.21107/nero.v5i1.
- [23] W. Nugraha dan A. Sasongko, “Hyperparameter Tuning on Classification Algorithm with Grid Search,” *SISTEMASI*, vol. 11, no. 2, hlm. 391, Mei 2022, doi: 10.32520/stmsi.v11i2.1750.