

Prediksi Kebutuhan Beras Di Jawa Timur Menggunakan Metode Gated Recurrent Unit (GRU)

Hozairi¹, Muhsi², Nadira Hijriani Putri³

^{1,3} Teknik Informatika, Fakultas Teknik, Universitas Islam Madura, Jl. PP. Miftahul Ulum Bettet, Pamekasan, 69317, Indonesia

² Sistem Informasi, Fakultas Teknik, Universitas Islam Madura, Jl. PP. Miftahul Ulum Bettet, Pamekasan, 69317, Indonesia

Info Artikel

Riwayat Artikel:

Received 2025-05-19

Revised 2025-08-29

Accepted 2025-08-30

Corresponding Author:

Nadira Hijriani Putri

Email:

nadirahijriani26@gmail.com,



This is an open access article under the [CC BY 4.0](https://creativecommons.org/licenses/by/4.0/) license.

Abstract – Food security is a strategic issue that affects economic stability and community welfare, especially in ensuring the availability of rice as a staple food in East Java. Uncertainty in food planning can cause an imbalance between rice production and consumption. Consequently, a precise forecast technique is necessary to aid decision-making. The objective of this research is to forecast or predict rice needs using the Gated Recurrent Unit (GRU) model to support more effective food management. The research methods include Min-Max Scaling normalization, and data division into 80% training and 20% testing. The GRU model has two main layers with 64 and 32 neuron units. The system was trained for 100 epochs with a batch size of 32 using the Adam optimizer and the MSE loss function. The evaluation results show high performance with MAE 0.0103, MSE 0.0001, RMSE 0.0116, and R² 0.9935, indicating low error and good generalization. The Training and Validation Loss graph shows a stable learning model without overfitting. This model can be a reliable prediction tool in food planning. Implementation of the model can help the government maintain the balance of rice supply and optimize agricultural policies.

Keywords: Gated Recurrent Unit; Prediction; Rice Needs

Abstrak – Ketahanan pangan merupakan isu strategis yang mempengaruhi stabilitas ekonomi dan kesejahteraan masyarakat, terutama dalam memastikan ketersediaan beras sebagai bahan pangan pokok di Jawa Timur. Ketidakpastian dalam perencanaan pangan dapat menyebabkan ketidakseimbangan antara produksi dan konsumsi beras, sehingga diperlukan metode prediksi yang akurat untuk mendukung pemerintah dalam mengambil keputusan. Tujuan dari penelitian ini untuk memprediksi kebutuhan beras menggunakan model Gated Recurrent Unit (GRU) guna mendukung manajemen pangan yang lebih efektif. Metode penelitian mencakup normalisasi teknik Min-Max Scaling, serta membagi data menjadi 80% untuk pelatihan dan 20% untuk pengujian. Model GRU memiliki dua lapisan utama dengan 64 dan 32 unit neuron, menggunakan optimizer Adam dan fungsi loss MSE, serta dilatih selama 100 epoch dengan batch size 32. Hasil evaluasi menunjukkan performa tinggi dengan MAE 0,0103, MSE 0,0001, RMSE 0,0116, dan R² 0,9935, menandakan kesalahan rendah dan generalisasi baik. Grafik Training and Validation Loss menunjukkan model belajar stabil tanpa overfitting. Model ini dapat menjadi alat prediksi yang andal dalam perencanaan pangan. Implementasi model dapat membantu pemerintah menjaga keseimbangan pasokan beras dan mengoptimalkan kebijakan pertanian.

Kata Kunci: Gated Recurrent Unit, Kebutuhan Beras, Prediksi.

I. PENDAHULUAN

Penduduk Indonesia, khususnya di Jawa Timur adalah salah satu pusat produksi beras nasional[1]. Berdasarkan data dari Badan Pusat Statistik (BPS) Jawa Timur untuk tahun 2021–2025 dengan perhitungan perkabupaten atau kota, produsen utamanya adalah sejumlah kabupaten, termasuk Lamongan dan Ngawi. Meskipun Jawa Timur memiliki potensi produksi beras yang tinggi, terdapat tantangan signifikan yang harus dihadapi, termasuk fluktuasi produksi akibat perubahan iklim, jumlah penduduk yang semakin meningkat, dan penurunan luas lahan pertanian. Penurunan produksi beras dapat berdampak langsung pada ketersediaan pangan dan harga beras di pasaran. Hal ini menunjukkan bahwa peningkatan produksi beras harus dilakukan secara strategis[2]. Maka dari itu, prediksi kebutuhan beras yang akurat sangat penting untuk menghindari kekurangan atau kelebihan pasokan.

Tujuan dari penelitian ini adalah untuk menciptakan dan mengembangkan model prediksi berbasis GRU (*Gated Recurrent Unit*) yang mampu memperkirakan kebutuhan beras di Jawa Timur dengan tingkat akurasi yang tinggi. Dengan memanfaatkan kemampuan GRU dalam memproses data sekuensial, diharapkan model yang dihasilkan dapat memberikan prediksi yang lebih akurat sehingga dapat digunakan untuk menentukan kondisi surplus (jika produksi beras lebih besar daripada konsumsi) atau defisit (jika konsumsi beras lebih besar daripada produksi) dan membantu pemerintah, produsen, pedagang, serta masyarakat dalam mengambil keputusan yang lebih baik terkait pengelolaan beras.

Berbagai penelitian tentang "Peramalan Nilai Ekspor Migas di Indonesia dengan Model *Long Short Term Memory (LSTM)* dan *Gated Recurrent Unit (GRU)*" telah banyak dilakukan oleh berbagai akademisi, salah satunya adalah [3]. Hasil penelitian menunjukkan bahwa model LSTM terbaik dengan optimasi Adam memiliki akurasi yang paling tinggi dalam memprediksi nilai ekspor migas dengan nilai MAPE 12,8% dan akurasi 87,2%. Penelitian

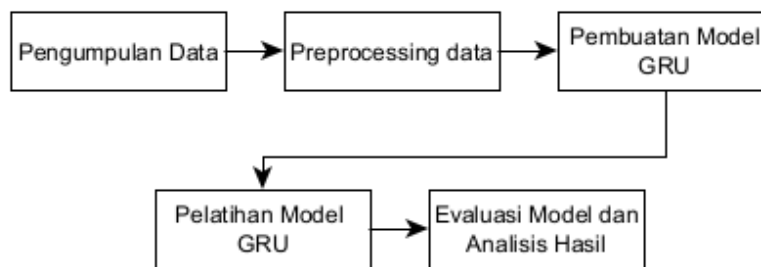
"Perbandingan Metode Decision Tree dan Deep Learning dalam Memprediksi Jumlah Siswa Putus Sekolah Berdasarkan Nilai Akademik" [4] menemukan bahwa metode decision tree C5.0 memiliki kinerja terbaik, dengan tingkat akurasi 95%, RMSE 0,130, dan MAPE 2,26%. Dengan nilai akurasi 92% dan persentase kesalahan RMSE 0,187 MAPE 4,69%, pada pengujian metode deep learning lebih rendah tingkat akurasinya dibandingkan decision tree C5.0. Penelitian juga oleh [5] tentang "Prediksi Harga Laptop Menggunakan Algoritma GRU dan BiLSTM" dengan hasil prediksi BiLSTM yang lebih baik kinerjanya jika dibandingkan metode GRU dengan berbagai keunggulan. Meskipun model *Gated Recurrent Unit* (GRU) telah banyak diaplikasikan pada berbagai bidang seperti prediksi harga saham, peramalan lalu lintas, maupun analisis deret waktu finansial, penerapannya dalam konteks informatika pertanian, khususnya prediksi kebutuhan beras, masih sangat terbatas. Oleh karena itu, penelitian ini memberikan kontribusi ilmiah yang signifikan dengan mengadaptasi dan mengimplementasikan GRU pada permasalahan ketahanan pangan di sektor pertanian.

Metodologi penelitian ini akan melibatkan pengumpulan data historis produksi dan konsumsi beras pada beberapa kabupaten/kota di Jawa Timur dari sumber-sumber terpercaya seperti BPS. Untuk menemukan pola dan tren yang relevan, data ini akan diproses dan diperiksa. Data tersebut kemudian akan digunakan untuk membuat dan membangun model GRU. Untuk memaksimalkan akurasi prakiraan, parameter model akan dioptimalkan. Metrik seperti MAE, MSE, RMSE, dan R^2 akan digunakan untuk menilai kinerja model[6]. Selain itu, visualisasi data akan dibuat untuk menyajikan hasil prediksi secara jelas dan mudah dipahami.

Penelitian ini memiliki urgensi yang tinggi mengingat pentingnya beras sebagai komoditas pangan pokok di Indonesia, khususnya di Jawa Timur. Prediksi kebutuhan beras yang akurat sangat penting untuk menjaga stabilitas pasokan dan harga, serta menghindari krisis pangan[7]. Dengan adanya model prediksi yang handal, pemerintah dan pihak terkait lainnya dapat lebih mudah dan tepat dalam mengambil keputusan untuk pengelolaan stok beras, perencanaan produksi, dan distribusi. penelitian ini diharapkan dapat memberikan kontribusi ilmiah untuk pengembangan model prediksi berbasis deep learning untuk sektor pertanian.

II. METODE

Pada penelitian ini metode kuantitatif digunakan dengan desain penelitian pertahun atau *time series analysis*. Pendekatan ini dipilih karena tujuan penelitian adalah untuk memprediksi kebutuhan beras berdasarkan data historis, yang merupakan karakteristik utama dari analisis deret waktu. Penelitian ini akan memanfaatkan data sekunder, terutama data produksi beras dan jumlah penduduk Jawa Timur dari BPS, serta data konsumsi beras per kapita. Alat yang digunakan meliputi komputer dengan software *Python* dalam *google colab* serta *library* pendukung seperti *NumPy*, *Pandas*, *Scikit-learn*, dan *Matplotlib* dengan pustaka seperti *TensorFlow* atau *PyTorch* untuk implementasi model GRU[8]. Gambar 1 menunjukkan langkah-langkah dalam melakukan prediksi kebutuhan beras di Jawa Timur:



Gambar 1. Tahapan Penelitian

A. Pengumpulan Data

Informasi atau data ini bersumber dari Badan Pusat Statistik (BPS) Jawa Timur. Data yang digunakan dalam penelitian ini adalah jumlah penduduk, konsumsi beras, kebutuhan beras (surplus atau defisit), dan produksi beras. Data produksi beras menunjukkan fluktuasi dari tahun ke tahun. Data diambil melalui BPS (Badan Pusat Statistik) dari tahun 2021-2025 dengan data tahunan dan perhitungan melalui beberapa jumlah kabupaten atau kota se- Jawa Timur. Semakin meningkatnya permintaan beras dipengaruhi oleh pertumbuhan penduduk yang pesat mengingat bahwasanya beras merupakan makanan pokok bagi masyarakat Indonesia. Setiap penduduk diharapkan memperoleh sekitar 1.800 kalori, maka karbohidrat dari konsumsi beras per hari untuk pola hidup sehat perkapita kurang lebih 700 kkal[9],[10]. Penelitian ini membatasi kebutuhan kalori untuk konsumsi beras atau pemenuhan karbohidrat setiap penduduk dengan 700 kkal atau kurang lebih 0,54 kg beras/orang/hari.

B. Preprocessing Data

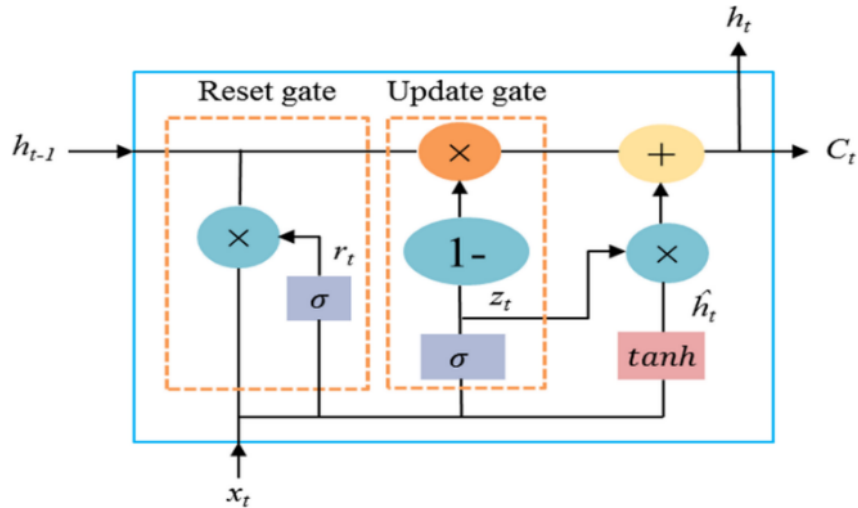
Normalisasi Data dalam penelitian ini, akan diterapkan metode *Min-Max Scaling* untuk normalisasi[11]. Metode ini berfungsi untuk mengubah nilai-nilai data menjadi rentang yang berkisar antara 0 hingga 1 dengan menggunakan rumus.

$$X_{scaled} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Dalam proses pembagian data ini Data dipisahkan menjadi dua kategori: Sebanyak 80% dari data yang ada digunakan untuk data pelatihan, sedangkan 20% sebagai data uji (*Train-Test Split*).

C. Pembuatan Model GRU

Pengolahan data dilakukan setelah pra-pemrosesan data. Model GRU digunakan dalam pengolahan data dengan menggunakan tiga gerbang utama[5] :



Gambar 2. Model GRU

Reset Gate: gate (gerbang) yang disebut *reset gate* akan menentukan seberapa banyak informasi dari input sebelumnya yang akan dilupakan. Dengan persamaan matematika

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r). \quad (2)$$

Update Gate: akan menentukan seberapa banyak informasi baru yang akan diperbarui ke state (keadaan) hidden.

$$\text{Proses: } z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z). \quad (3)$$

Candidate Hidden State baru dihitung dengan menggabungkan hidden state sebelumnya dan candidate hidden state baru, berdasarkan nilai update gate.

$$\text{Candidate Hidden State } (h\hat{t}) = \tanh(W_h \cdot [r_t * h_{t-1}, x_t] + b_h). \quad (4)$$

$$\text{Hidden State } (h_t) = z_t * h_{t-1} + (1 - z_t) * h\hat{t}. \quad (5)$$

D. Pelatihan Model

Proses pelatihan model GRU diawali dengan normalisasi data dan transformasi ke bentuk tiga dimensi. Selanjutnya, data tersebut dibagi menjadi dua bagian, yaitu 80% untuk pelatihan dan 20% untuk pengujian[12]. Model terdiri dari dua lapisan GRU (64 dan 32 unit) dengan dropout untuk mencegah overfitting serta lapisan Dense sebagai output. Dikompilasi menggunakan optimizer Adam dan loss MSE, kemudian dilatih selama 50,100,150 *epoch* dengan *batch size* 32, *activation relu*, *dropout rate* (0,2), *scaler fit scope* (global), *window* (2). Evaluasi dilakukan menggunakan MAE, MSE, RMSE dan R² untuk mengukur akurasi prediksi. Hasil pelatihan divisualisasikan dalam grafik loss dan prediksi, serta diekspor ke Excel untuk analisis lebih lanjut guna memastikan model dapat mengenali pola data secara optimal.

E. Evaluasi dan Analisis Hasil

Setelah melakukan pelatihan model, dilakukan evaluasi pada kinerja model untuk mengukur akurasi prediksi terhadap data aktual menggunakan metrik MAE, MSE, RMSE dan R² sebagai berikut[13]:

Mean Absolute Error (MAE) : MAE menentukan perbedaan rata-rata antara data aktual dan hasil yang diharapkan. MAE mudah diartikan sebagai ukuran seberapa besar kesalahan rata-rata model karena nilainya selalu positif.

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (6)$$

Mean Squared Error (MSE) : Mengukur rata-rata kuadrat kesalahan untuk menilai performa model secara keseluruhan.

$$MSE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i|^2 \quad (7)$$

Root Mean Square Error (RMSE): RMSE menunjukkan seberapa besar rata-rata kesalahan prediksi. Semakin kecil nilainya, semakin akurat hasil prediksi model[14].

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (f_i - \hat{y}_i)^2} \quad (8)$$

R-Squared (R²) : *R-Squared (R²)* merupakan metrik untuk mengevaluasi seberapa efektif model regresi, seperti model GRU, dapat menjelaskan variasi dalam data target (label)

$$R\text{-Squared} = 1 - \frac{SS_{tot}}{SS_{res}} \quad (9)$$

Jika tingkat akurasi pada model ini tinggi, maka model GRU ini bisa digunakan untuk membantu memprediksi kebutuhan beras di Jawa Timur dan dapat dijadikan referensi untuk penelitian berikutnya.


III. HASIL DAN PEMBAHASAN

A. Hasil


Dalam upaya untuk memberikan prediksi yang akurat mengenai kebutuhan beras di Jawa Timur, penelitian ini telah menerapkan model GRU, dan hasil yang diperoleh akan dijelaskan secara rinci.

1) *Preprocessing Data*: Sebelum pemodelan GRU dilakukan, perlu melakukan preprocessing terlebih dahulu dengan beberapa tahapan untuk meningkatkan kualitas data. Tahapan-tahapan preprocessing tersebut adalah sebagai berikut: Pembersihan data: proses menghilangkan atau memperbaiki data yang tidak akurat. Pembagian data features (input) dan target (output): data input yang di jadikan features berupa (tahun, populasi, produksi padi, konsumsi padi dan kebutuhan beras) sedangkan data Output atau target berupa Kebutuhan Beras. Normalisasi Data: dalam penelitian ini, metode Min-Max Scaling akan digunakan untuk melakukan normalisasi. Pembagian Data latih dan Data uji: data akan dibagi menjadi dua bagian, dengan 80% untuk data latih dan 20% untuk data uji.

2) *Hasil pemodelan Gated Recurrent Unit*: Proses pelatihan model GRU diawali dengan normalisasi data dan transformasi ke bentuk tiga dimensi, kemudian membagi data. Model terdiri dari dua lapisan GRU (64 dan 32 unit) dengan dropout untuk mencegah overfitting serta lapisan Dense sebagai output. Dikompilasi menggunakan *optimizer Adam* dan *loss MSE*, kemudian dilatih selama 50,100,150 *epoch* dengan *batch size 32*, *activation relu*, *dropout rate (0,2)*, *scaler fit scope (global)*, *window (2)*. Setelah pelatihan model GRU menggunakan 50, 100 dan 150 *epoch* serta jumlah lapisan GRU (128 dan 64 unit) seta (64 dan 32 unit), grafik menunjukkan bahwa loss training dan Validation seperti pada gambar 3,4,5.




(a)




(b)

Gambar 3. Grafik hasil perbandingan epoch 50 dengan jumlah neuron (a). 128,64 dan (b). 64,32

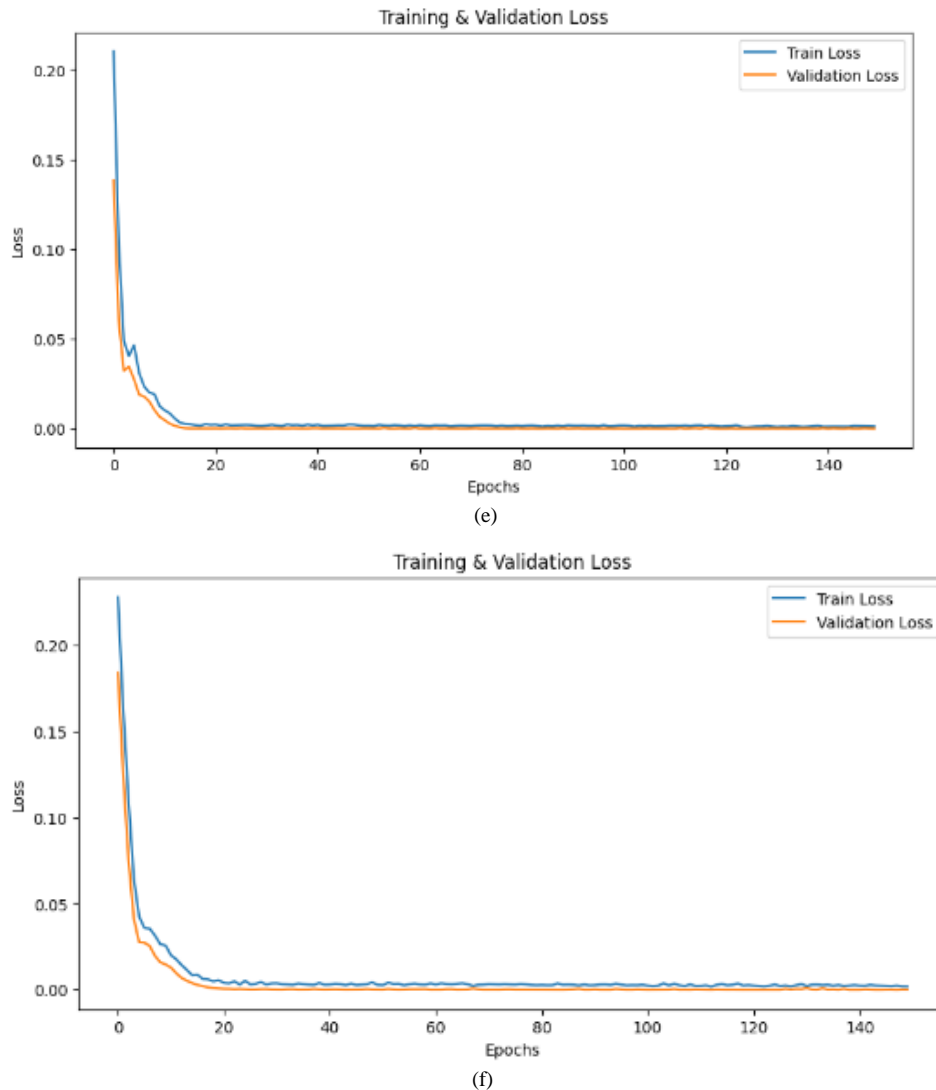


(c)



(d)

Gambar 4. Grafik hasil perbandingan epoch 100 dengan jumlah neuron (c). 128,64 dan (d). 64,32



Gambar 5. Grafik hasil perbandingan epoch 150 dengan jumlah neuron (e). 128,64 dan (f). 64,32

Pada gambar 3,4,5. pelatihan model GRU menunjukkan *Training and Validation Loss* dalam pelatihan model GRU untuk prediksi kebutuhan beras. *Train Loss* (garis biru) dan *Validation Loss* (garis oranye) menurun tajam di awal dan stabil setelah beberapa epoch, menandakan model belajar dengan baik tanpa overfitting. Kedua loss tetap berdekatan, menunjukkan generalisasi yang baik.

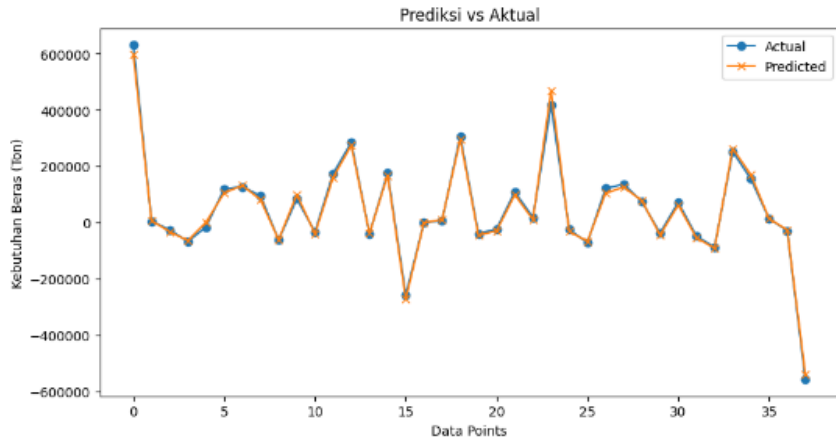
3) *Evaluasi Model dan Hasil*: Evaluasi dilakukan menggunakan MAE, MSE, RMSE dan R^2 untuk mengukur akurasi prediksi dengan beberapa eksperimen menggunakan jumlah epoch dan jumlah neuron pada model GRU. Hasil evaluasi ditunjukkan pada tabel 1.

TABEL 1
HASIL EVALUASI

Epoch	Neuron	MAE	MSE	RMSE	R^2
50	64, 32	0,0175	0,0004	0,0214	0,9806
50	128, 64	0,0121	0,0002	0,0156	0,9894
100	64, 32	0,0103	0,0001	0,0116	0,9935
100	128, 64	0,0111	0,0001	0,0129	0,9926
150	64, 32	0,0114	0,0001	0,0115	0,9932
150	128, 64	0,0143	0,0003	0,0188	0,9846

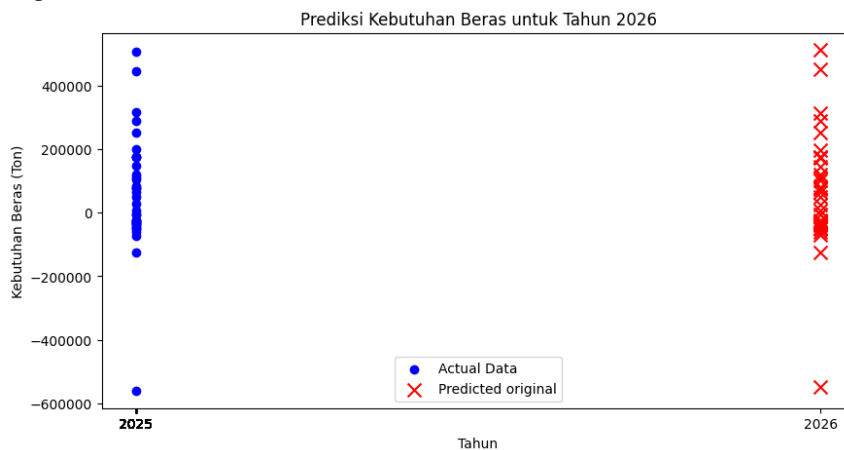
Berdasarkan hasil evaluasi di atas, hasil paling baik performanya yang dilakukan pada percobaan menggunakan jumlah epoch dan jumlah neuron pada model GRU menunjukkan bahwa nilai MAE dan MSE dalam skala ternormalisasi paling rendah adalah percobaan pada jumlah epoch 100 dan jumlah neuron (64,32) sehingga model

memiliki kesalahan yang rendah, RMSE senilai 0,0116 menunjukkan menunjukkan bahwa rata-rata kesalahan prediksi model masih dalam batas yang kecil dan dapat diterima sedangkan nilai R^2 0,9935 yang mendekati 1 berarti model mampu menjelaskan sekitar 99,35% variabilitas dalam data, menunjukkan performa yang sangat baik.



Gambar 6. Visualisasi Perbandingan Nilai aktual dan prediksi

Gambar 6. Grafik menunjukkan bahwa model GRU memiliki performa prediksi yang sangat baik dalam memperkirakan kebutuhan beras di Jawa Timur. Kedekatan garis prediksi dengan data aktual menegaskan bahwa model dapat dijadikan alat bantu andal dalam perencanaan ketahanan pangan untuk mendeteksi kondisi surplus atau defisit beras pada periode tertentu.



Gambar 7. Visualisasi Prediksi Satu Tahun Kedepan

Pada gambar 7. Grafik ini menunjukkan kebutuhan beras di Jawa Timur dari tahun 2021 hingga 2025, di mana data tahun 2021 hingga 2025 merupakan data aktual yang ditunjukkan pada titik biru dengan ditandai sebagai tahun 2025, sedangkan tahun 2026 adalah hasil prediksi. Hasil prediksi beras satu tahun berdasarkan kabupaten menunjukkan hasil seperti pada tabel 2.

TABEL 2
 HASIL PREDIKSI KEBUTUHAN BERAS 2026 (KG)

Actual (2021–2025)	Prediction (2026)	Surplus/Defisit
631.295.039.615	597.225.687.500	Surplus
5.879.869.615	7.578.929.688	Surplus
-25.195.954.231	-31.664.824.219	Defisit
-66.341.405.000	-63.434.808.594	Defisit
-15.309.337.692	1.706.786.499	Surplus
...
252.663.376.538	263.161.562.500	Surplus
155.518.654.231	170.664.750.000	Surplus
14.743.508.077	15.202.964.844	Surplus
-27.977.416.923	-26.194.322.266	Defisit
-556.253.916.154	-539.478.937.500	Defisit

Sumber: Data Aktual BPS Jawa Timur

Hasil prediksi kebutuhan beras per kabupaten dalam satu tahun disajikan pada Tabel 2. Nilai prediksi yang muncul dapat berupa angka positif maupun negatif. Angka positif menunjukkan kondisi surplus, yaitu jumlah produksi beras lebih besar daripada kebutuhan konsumsi di kabupaten tersebut. Sebaliknya, angka negatif menunjukkan kondisi defisit, yaitu jumlah produksi beras lebih kecil dibandingkan kebutuhan konsumsi. Elipsis "...” menandakan tabel terpotong karena hasil terlalu panjang.

Setiap tahunnya, produksi padi mengalami surplus, namun jumlah kelebihannya tidak stabil. Ada tahun di mana surplus beras tinggi, sementara di tahun lainnya lebih rendah, menunjukkan fluktuasi dalam tingkat produksi dan konsumsi beras di wilayah tersebut. Kabupaten dengan tingkat fluktuasi tinggi dalam kebutuhan beras, seperti adanya perubahan signifikan dalam produksi atau konsumsi dari tahun ke tahun, dapat menyebabkan grafik prediksi tampak tidak stabil. Diakibatkan oleh beberapa faktor yang memengaruhi kebutuhan beras, seperti luas lahan pertanian yang berubah, pola konsumsi masyarakat dan sebagainya. Model GRU yang digunakan memiliki tingkat akurasi tinggi dengan error yang sangat kecil dan kemampuan prediksi yang sangat baik. Model ini dapat diandalkan untuk memprediksi kebutuhan beras dengan performa yang optimal[15]

B. Pembahasan

Penelitian ini menunjukkan bahwa model *Gated Recurrent Unit* (GRU) mampu memprediksi kebutuhan beras dengan akurasi tinggi[16]. Proses preprocessing data, seperti pembersihan, normalisasi *Min-Max Scaling*, pembagian data, berperan penting dalam meningkatkan kualitas data sebelum pemodelan. Pernyataan ini sesuai dengan hasil penelitian sebelumnya yang menekankan bahwa data yang telah melalui proses normalisasi cenderung lebih mudah dipelajari oleh model deep learning dan menghasilkan prediksi yang lebih akurat[17].

Dari hasil pelatihan, grafik *Training and Validation Loss* menunjukkan tren penurunan yang stabil tanpa indikasi overfitting, yang berarti model mampu belajar dengan baik dan tidak hanya menghafal pola dalam data latih. Evaluasi performa model menunjukkan MAE 0,0103, MSE 0,0001, RMSE 0,0116, dan R^2 0,9935, yang mengindikasikan kesalahan prediksi yang sangat kecil serta kemampuan model dalam menangkap pola kebutuhan beras dengan baik. Temuan ini sejalan dengan studi terdahulu yang membandingkan berbagai metode deep learning dan menemukan bahwa GRU unggul dalam menangani data time series dengan pola kompleks[18].

Dengan hasil ini, model GRU dapat menjadi alat prediksi yang andal dalam mendukung perencanaan pangan berbasis data. Meski demikian, untuk meningkatkan performa lebih lanjut, penelitian di masa depan dapat mengeksplorasi kombinasi GRU dengan metode lain, seperti GRU-LSTM atau CNN-GRU, yang telah terbukti mampu meningkatkan akurasi prediksi[19]. Selain itu, penggunaan dataset yang lebih besar dan *tuning hyperparameter* yang lebih optimal dapat menjadi strategi untuk meningkatkan ketahanan atau kemampuan model dalam menangani variasi data yang lebih luas[20].

IV. SIMPULAN

Penelitian ini bertujuan untuk menciptakan dan mengembangkan model prediksi berbasis GRU (*Gated Recurrent Unit*) yang mampu memperkirakan kebutuhan beras di Jawa Timur dengan tingkat akurasi yang tinggi. Penelitian ini menunjukkan bahwa model *Gated Recurrent Unit* (GRU) dapat digunakan secara efektif untuk memprediksi kebutuhan beras di Jawa Timur dengan tingkat akurasi yang sangat tinggi. Tahapan preprocessing data, seperti pembersihan, normalisasi *Min-Max Scaling*, serta pembagian data 80% latih dan 20% uji, berperan penting dalam meningkatkan kualitas data sebelum pemodelan. Hasil evaluasi model menunjukkan MAE sebesar 0,0103, MSE 0,0001, RMSE 0,0116, dan R^2 0,9935, yang menandakan bahwa model memiliki kesalahan prediksi yang sangat kecil serta kemampuan generalisasi yang baik. Grafik *Training and Validation Loss* juga menunjukkan bahwa model belajar dengan stabil tanpa indikasi overfitting. Dengan hasil ini, model GRU dapat diandalkan sebagai alat prediksi kebutuhan beras dan dapat menjadi dasar dalam pengambilan keputusan terkait perencanaan pangan. Untuk penelitian selanjutnya, disarankan menggunakan dataset yang lebih luas dengan cakupan data yang lebih detail, tidak hanya data tahunan per kabupaten/kota, melakukan tuning parameter secara lebih optimal, serta membandingkan kinerja model dengan metode deep learning lainnya guna memperoleh hasil prediksi yang lebih akurat.

UCAPAN TERIMAKASIH

Penulis ingin mengungkapkan rasa terima kasih yang besar kepada Universitas Islam Madura, dengan penghargaan khusus kepada Fakultas Teknik, atas fasilitas dan dukungan yang konsisten selama proses penyusunan artikel ini. Apresiasi yang mendalam juga diberikan kepada dosen pembimbing atas bimbingan penuh wawasan dan dorongan selama masa penelitian. Ucapan terima kasih yang sebesar-besarnya juga disampaikan kepada setiap individu yang berkontribusi dalam pengumpulan dan analisis data. Penulis berharap bahwa temuan dari penelitian ini dapat secara signifikan meningkatkan pengetahuan dan aplikasinya dalam bidang yang relevan.

DAFTAR PUSTAKA

- [1] S. Dwi Ariyanti *et al.*, “Pemenuhan Kebutuhan Produksi Beras Nasional Dalam Meningkatkan Kesejahteraan Masyarakat Menurut Perspektif Ekonomi Islam,” *J. Ekon. Syariah dan Bisnis*, vol. 7, no. 1, pp. 82–93, 2024, doi: 10.31949/maro.v7i1.9121.
- [2] M. Y. Kandi Sri, Muhammad Syahril, “Penerapan Data Mining untuk Memprediksi Hasil Panen Pertanian Tanaman Padi Daerah Serdang Bedagai Menggunakan Metode C4.5 Pada Dinas Tanaman Pangan Dan Holtikultura Sumut,” *J. Sains Manaj. Inform. dan Komput.*, vol. 1, no. 1, pp. 01–07, 2020.
- [3] N. Prissy, M. Al Haris, and P. R. Arum, “Peramalan Nilai Ekspor Migas Di Indonesia Menggunakan Model Long Short Term Memory Dan *Gated Recurrent Unit*,” *J Stat.*, vol. 16, no. 1, pp. 12–26, 2022.
- [4] D. W. Puteri, P. W. Buana, and I. M. Sukarsa, “Komparasi Metode Decision Tree dan Deep Learning dalam Meramalkan Jumlah Mahasiswa Drop Out Berdasarkan Nilai Akademik,” *J. Internet Softw. Eng.*, vol. 1, no. 2, p. 12, 2024, doi: 10.47134/pjise.v1i2.2327.
- [5] E. Novela Waroi, A. Arief, and K. Khusnawi, “Prediksi Harga Laptop Menggunakan Algoritma GRU dan BILSTM,” *J. Sos. Teknol.*, vol. 4, no. 7, pp. 408–424, 2024, doi: 10.59188/jurnalsostech.v4i7.1278.
- [6] J. Kezia Halim, D. Erny Herwindiati, and J. Hendryli, “Penerapan *Gated Recurrent Unit* Untuk Prediksi Zat Pencemar Udara,” *J. Ilmu Komput. dan Sist. Inf.*, vol. 10, no. 2, 2022, doi: 10.24912/jiksi.v10i2.22540.
- [7] A. Adinata, A. Irma Purnamasari, and I. Ali, “Penerapan Data Mining Dalam Prediksi Produksi Beras Menggunakan Metode Regresi Linear,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 2, pp. 2020–2026, 2024, doi: 10.36040/jati.v8i2.8494.
- [8] T. P. SHELLA, “HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) – *GATED RECURRENT UNIT* (GRU) DALAM PERAMALAN HARGA SAWIT PADA PT. SAWIT SUMBERMAS SARANA DI KALIMANTAN TENGAH,” *AT-TAWASSUTH J. Ekon. Islam*, vol. VIII, no. I, pp. 1–19, 2023.
- [9] M. Ansori, “Analisis Pola Konsumsi Pangan Penduduk Kabupaten Lebak,” *J. Gizi Kerja dan Produkt.*, vol. 2, no. 2, p. 38, 2021, doi: 10.52742/jgkp.v2i2.12842.
- [10] I. K. B. Widowati, S. Nurhayati, Cynthia Gracia Christina Lopulalan, *ILMU PANGAN JILID 1*, Edisi Pert. Sumatera Barat: CV HEI PUBLISHING INDONESIA, 2024.
- [11] M. Martanto, I. Ali, and M. Mulyawan, “Prediksi Tingkat Kelulusan Mahasiswa Menggunakan Machine Learning dengan Teknik Deep Learning,” *J. Inform. J. Pengemb. IT*, vol. 4, no. 2–2, pp. 191–194, 2019, doi: 10.30591/jpit.v4i2-2.1877.
- [12] T. F. Handoyo and M. P. K. Putra, “Optimasi Bobot Kelas LSTM untuk Deteksi URL Phishing pada Dataset Tidak Berimbang,” *J. Inform. J. Pengemb. IT*, vol. 10, no. 1, pp. 20–36, 2025, doi: 10.30591/jpit.v10i1.8128.
- [13] R. N. Silalahi, “Perbandingan Kinerja Metode Linear Regression , LSTM dan GRU untuk Prediksi Harga Penutupan Saham Coca-Cola,” vol. 13, 2024, doi: 10.34010/komputika.v13i2.12265.
- [14] R. Wardhani, N. Nafiyah, and M. A. Haydar, “Algoritma Deep Learning dalam Memprediksi Hasil Panen Padi di Kabupaten Lamongan,” *J. Inform. J. Pengemb. IT*, vol. 7, no. 1, pp. 13–17, 2022, doi: 10.30591/jpit.v7i1.2581.
- [15] H. S. Munir, S. Ren, M. Mustafa, C. N. Siddique, and S. Qayyum, “Attention based GRU-LSTM for software defect prediction,” *PLoS One*, vol. 16, no. 3 March, pp. 1–19, 2021, doi: 10.1371/journal.pone.0247444.
- [16] Y. Zhang *et al.*, “Temporal Characteristics of Stress Signals Using GRU Algorithm for Heavy Metal Detection in Rice Based on Sentinel-2 Images,” *Int. J. Environ. Res. Public Health*, vol. 19, no. 5, 2022, doi: 10.3390/ijerph19052567.
- [17] A. M. A. R. Muhammad, “Implementasi model lstm, gru, bilstm, dan bigru dalam prediksi harga nikel,” vol. 7, no. 2, pp. 413–420, 2024.
- [18] D. Suluh, D. E. Herwindiati, and J. Hendryli, “Peramalan Pertumbuhan Jumlah Outlet Menggunakan Metode *Gated Recurrent Unit* (Studi Kasus: PT XYZ),” *Comput. J. Comput. Sci. Inf. Syst.*, vol. 8, no. 1, pp. 62–72, 2024, doi: 10.24912/computatio.v8i1.21234.
- [19] R. S. Andromeda, N. Anisa, and S. Winarsih, “Perbandingan Kinerja Metode LSTM dan GRU dalam Prediksi Harga Close Cryptocurrency Performance Comparison of LSTM and GRU Methods in Predicting Cryptocurrency Closing Prices,” vol. 14, pp. 366–379, 2025.
- [20] H. Wang, H. Zhu, H. Wu, X. Wang, X. Han, and T. Xu, “A densely connected gru neural network based on coattention mechanism for chinese rice-related question similarity matching,” *Agronomy*, vol. 11, no. 7, 2021, doi: 10.3390/agronomy11071307.