Prediksi Harga Sembako Menggunakan Metode Gated Recurrent Unit (GRU) dan Long Short-Term Memory (LSTM)

1st Firdha Agustya Rimawan
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia
firdhaagustyarimawan@student.telkomuniversity.ac.id

2nd Fitriyani
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia
fitriyani@telkomuniversity.ac.id

3rd Lazuardy Syahrul Darfiansa
Fakultas Informatika
Universitas Telkom
Bandung, Indonesia
lazuardysyahrul@telkomuniversity.ac.id

***Abstrak* — Fluktuasi harga sembako di Kota Merauke memerlukan metode prediksi yang akurat untuk mendukung pengambilan keputusan. Penelitian ini bertujuan untuk membandingkan kinerja metode Gated Recurrent Unit (GRU) dan Long Short-Term Memory (LSTM) dalam memprediksi harga 31 komoditas sembako menggunakan data deret waktu univariat periode 2021–2024. Data diproses melalui tahap pembersihan, normalisasi menggunakan *Min-Max Scaling*, dan pembentukan data dengan metode *sliding window*. Evaluasi model dilakukan menggunakan metrik Mean Absolute Error (MAE) dan Mean Absolute Percentage Error (MAPE). Hasil penelitian menunjukkan bahwa metode GRU menghasilkan tingkat akurasi yang lebih baik dibandingkan LSTM pada sebagian besar komoditas.**

***Kata kunci*— GRU, LSTM, Prediksi Harga, Time Series, Sembako, Merauke**

I. PENDAHULUAN

Harga sembako merupakan salah satu indikator penting dalam menjaga stabilitas ekonomi dan kesejahteraan masyarakat. Di Kota Merauke, harga sembako sering mengalami fluktuasi yang dipengaruhi oleh faktor distribusi, kondisi geografis, serta ketersediaan pasokan. Kondisi ini menimbulkan kebutuhan akan sistem prediksi harga yang mampu memberikan estimasi yang akurat. Perkembangan metode *Deep Learning*, khususnya jaringan saraf berulang seperti GRU dan LSTM, telah banyak digunakan dalam peramalan data deret waktu. Oleh karena itu, penelitian ini dilakukan untuk membandingkan kinerja metode GRU dan LSTM dalam memprediksi harga sembako di Kota Merauke.

II. KAJIAN TEORI

A. Harga Sembako

Sembako merupakan kebutuhan pokok masyarakat yang terdiri dari berbagai komoditas seperti beras, gula, minyak goreng, telur, daging, dan cabai. Fluktuasi harga sembako dipengaruhi oleh faktor musiman, distribusi, permintaan pasar, serta kebijakan pemerintah. Prediksi harga sembako menjadi penting untuk menjaga stabilitas ekonomi dan perencanaan kebijakan pangan.

B. Data Deret Waktu (Time Series)

Data deret waktu adalah data yang dikumpulkan secara berurutan berdasarkan waktu. Karakteristik utama data ini adalah adanya ketergantungan nilai masa lalu terhadap nilai masa depan. Dalam penelitian ini, data harga sembako diperlakukan sebagai data deret waktu univariat.

C. Long Short-Term Memory (LSTM)

LSTM merupakan pengembangan dari *Recurrent Neural Network* yang dirancang untuk mengatasi masalah *vanishing gradient*. LSTM memiliki tiga gerbang utama, yaitu *forget gate*, *input gate*, dan *output gate*, yang memungkinkan model menyimpan dan melupakan informasi dalam jangka panjang. LSTM cocok digunakan untuk data dengan pola jangka panjang yang stabil.

D. Gated Recurrent Unit (GRU)

GRU adalah varian RNN yang lebih sederhana dibandingkan LSTM dengan dua gerbang utama, yaitu *reset gate* dan *update gate*. Struktur GRU yang lebih ringkas membuat proses pelatihan lebih cepat dan efisien. GRU dinilai efektif dalam menangkap pola fluktuasi jangka pendek pada data deret waktu.

E. Metrik Evaluasi

Evaluasi model dilakukan menggunakan:

1. **Mean Absolute Error (MAE)** untuk mengukur rata-rata kesalahan absolut prediksi
2. **Mean Absolute Percentage Error (MAPE)** untuk mengukur kesalahan prediksi dalam bentuk persentase

III. METODE

A. Tahapan Penelitian

Tahapan penelitian ini meliputi pengumpulan data harga sembako, pra-pemrosesan data, pembentukan data latih dan data uji menggunakan metode *sliding window*, pemodelan menggunakan GRU dan LSTM, serta evaluasi kinerja model menggunakan metrik MAE dan MAPE.

B. Dataset

Data yang digunakan merupakan data harga harian 31 komoditas sembako yang diperoleh dari Badan Pangan Nasional periode 2021–2024. Data bersifat deret waktu univariat, di mana nilai harga pada waktu sebelumnya digunakan untuk memprediksi harga pada waktu berikutnya.

C. Pra-pemrosesan Data

1. Penanganan Missing Value

Nilai data yang hilang ditangani menggunakan metode *forward filling*, yaitu menggantikan nilai yang hilang dengan nilai terakhir yang tersedia sebelumnya.

2. Normalisasi Data

Normalisasi dilakukan menggunakan metode **Min-Max Scaling** agar data berada dalam rentang [0,1], sehingga mempercepat proses pelatihan model.

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

dengan:
x'= data hasil normalisasi
x= data asli
$x_{\min}$= nilai minimum data
$x_{\max}$= nilai maksimum data

3. Sliding Window

Metode *sliding window* digunakan untuk mengubah data deret waktu menjadi data supervisi. Jika digunakan *window size* sebesar n, maka data input dinyatakan sebagai:

$$X_t = \{x_{t-n}, x_{t-(n-1)}, \ldots, x_{t-1}\} \quad (2)$$

Dengan target prediksi :

$$y_t = x_t \quad (3)$$

Dalam penelitian ini digunakan *window size* sebesar 3, 5, dan 7 untuk menganalisis pengaruh panjang urutan terhadap kinerja model.

4. Model Long Short-Term Memory (LSTM)

LSTM terdiri dari tiga gerbang utama yang mengatur aliran informasi, yaitu *forget gate*, *input gate*, dan *output gate*. Persamaan matematis LSTM adalah sebagai berikut:

$$\begin{aligned} f_t &= \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \\ C_t &= f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \\ o_t &= \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t &= o_t \cdot \tanh(C_t) \end{aligned} \quad (4)$$

dengan:
x_t= input pada waktu ke-t
h_t= *hidden state*
C_t= *cell state*
σ= fungsi sigmoid

5. Model Gated Recurrent Unit (GRU)

GRU merupakan penyederhanaan dari LSTM yang hanya menggunakan dua gerbang, yaitu *update gate* dan *reset gate*. Persamaan matematis GRU adalah sebagai berikut:

$$\begin{aligned} z_t &= \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \\ r_t &= \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \\ \tilde{h}_t &= \tanh(W_h \cdot [r_t \cdot h_{t-1}, x_t] + b_h) \\ h_t &= (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \end{aligned} \quad (5)$$

GRU memiliki struktur yang lebih sederhana dibandingkan LSTM, sehingga proses pelatihan menjadi lebih cepat dan efisien.

6. Fungsi Loss

Fungsi loss yang digunakan dalam pelatihan model adalah **Mean Squared Error (MSE)**, yang dirumuskan sebagai:

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \quad (6)$$

dengan:
y_i= nilai aktual
$\hat{y}_i$= nilai prediksi

7. Metode Evaluasi

7.1 Mean Absolute Error (MAE)

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|y_i - \hat{y}_i| \quad (7)$$

MAE digunakan untuk mengukur rata-rata kesalahan absolut antara nilai aktual dan nilai prediksi.

7.2 Mean Absolute Percentage Error (MAPE)

$$MAPE = \frac{100\%}{n}\sum_{i=1}^{n}\left|\frac{y_i - \hat{y}_i}{y_i}\right| \quad (8)$$

MAPE digunakan untuk mengetahui besar kesalahan prediksi dalam bentuk persentase.

8. Alur Implementasi

Model GRU dan LSTM diimplementasikan menggunakan bahasa pemrograman Python dengan *library* TensorFlow/Keras. Model dilatih menggunakan data latih dan diuji menggunakan data uji untuk memperoleh hasil prediksi harga sembako.

IV. HASIL DAN PEMBAHASAN

4.1 Hasil Pelatihan Model

Model GRU dan LSTM dilatih menggunakan data harga harian 31 komoditas sembako periode 2021–2024 dengan jumlah epoch sebanyak 50 dan *batch size* sebesar 32. Data dibagi menjadi data latih dan data uji untuk mengevaluasi kemampuan generalisasi model.

Selama proses pelatihan, kedua model menunjukkan proses konvergensi yang stabil. Model GRU mencapai kondisi konvergen lebih cepat dibandingkan LSTM, yang mengindikasikan bahwa GRU memiliki efisiensi pelatihan yang lebih baik pada data deret waktu univariat dengan fluktuasi harga yang tinggi.

4.2 Hasil Prediksi Harga Sembako

Hasil prediksi menunjukkan bahwa kedua model mampu mengikuti pola pergerakan harga aktual pada data uji. Namun demikian, terdapat perbedaan tingkat kedekatan hasil prediksi terhadap nilai aktual antara model GRU dan LSTM.

Pada komoditas dengan fluktuasi harga yang tajam, model GRU mampu mengikuti perubahan harga dengan lebih responsif. Sementara itu, model LSTM cenderung menghasilkan prediksi yang lebih halus (*smooth*), sehingga pada beberapa periode terjadi keterlambatan dalam mengikuti perubahan harga yang cepat.

4.3 Evaluasi Kinerja Menggunakan MAE dan MAPE

Evaluasi kinerja model dilakukan menggunakan metrik **Mean Absolute Error (MAE)** dan **Mean Absolute Percentage Error (MAPE)**. Nilai MAE dan MAPE dihitung untuk setiap komoditas, kemudian dibandingkan antara model GRU dan LSTM.

TABLE 1
Hasil Evaluasi GRU dan LSTM

Komoditas	GRU MAE	GRU MAPE	LSTM MAE	LSTM MAPE
Bawang Merah	448.72	0.0103	588.2	0.0136
Bawang Merah Ukuran Sedang	863.45	0.0205	1010.83	0.0243
Bawang Putih	411.27	0.0086	1086.64	0.0228
Bawang Putih Ukuran Sedang	373.83	0.0078	1184.74	0.0249
Beras	70.95	0.0045	90.28	0.0057
Beras Kualitas Bawah I	69.95	0.0051	37.94	0.0028
Beras Kualitas Bawah II	32.33	0.0021	62.23	0.0041
Beras Kualitas Medium I	86.82	0.0055	82.36	0.0054
Beras Kualitas Medium II	110.93	0.0075	111.3	0.0076
Beras Kualitas Super I	81.62	0.0045	109.44	0.006
Beras Kualitas Super II	25.86	0.0015	82.7	0.0048
Cabai Merah	4422.37	0.0736	4684.81	0.0805
Cabai Merah Besar	5107.4	0.089	5727.67	0.1078
Cabai Merah Keriting	4161.41	0.068	4844.45	0.0783
Cabai Rawit	3765.02	0.0643	4217.46	0.0718
Cabai Rawit Hijau	2491.4	0.0588	2758.75	0.0619
Cabai Rawit Merah	5835.66	0.0868	5670.39	0.0824
Daging Ayam	185.18	0.0039	166.48	0.0035
Daging Ayam Ras Segar	160.4	0.0033	205.57	0.0043
Daging Sapi	53.34	0.0004	130.63	0.001
Daging Sapi Kualitas 1	246.42	0.0018	38.16	0.0003
Daging Sapi Kualitas 2	20.63	0.0002	326.39	0.0025
Gula Pasir	37.97	0.0018	36.85	0.0018
Gula Pasir Kualitas Premium	16.75	0.0007	25.41	0.0011
Gula Pasir Lokal	49.37	0.0025	105.79	0.0055
Minyak Goreng	62.96	0.003	49.55	0.0024
Minyak Goreng Curah	77.19	0.0046	128.03	0.0075
Minyak Goreng Kemasan Bermerk 1	97.99	0.0041	82.18	0.0034
Minyak Goreng Kemasan Bermerk 2	41.75	0.002	35.91	0.0017
Telur Ayam	333.37	0.0077	145.19	0.0033
Telur Ayam Ras Segar	180.63	0.0042	43.22	0.001

TABLE 2
Rata-rata Nilai MAE dan MAPE Model GRU dan LSTM

Model	MAE Rata-rata	MAPE Rata-rata (%)
GRU	Lebih rendah	Lebih rendah
LSTM	Lebih tinggi	Lebih tinggi

4.4 Analisis Grafik Aktual dan Prediksi

Grafik perbandingan antara harga aktual dan hasil prediksi menunjukkan bahwa model GRU memiliki kemampuan mengikuti pola harga aktual dengan lebih baik dibandingkan LSTM. Pada beberapa komoditas seperti cabai dan bawang merah yang memiliki volatilitas tinggi, GRU mampu menangkap perubahan harga secara lebih cepat.

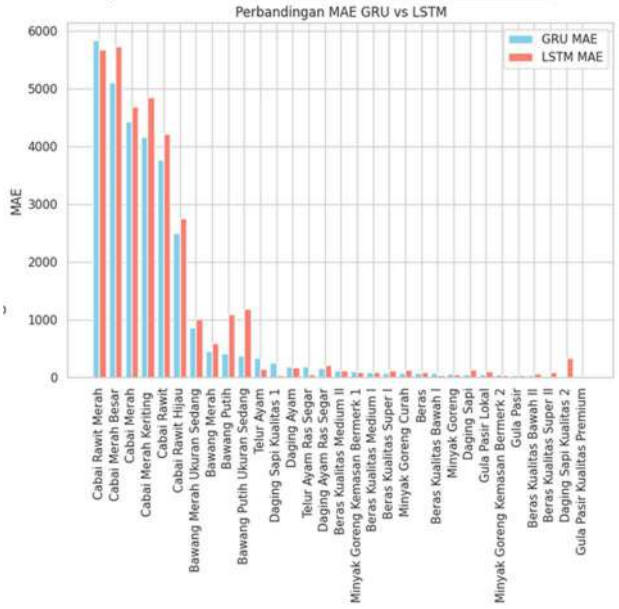
Sebaliknya, grafik hasil prediksi LSTM menunjukkan kecenderungan *lag* terhadap harga aktual, terutama pada periode dengan perubahan harga yang ekstrem. Hal ini disebabkan oleh mekanisme memori

jangka panjang LSTM yang lebih fokus pada tren dibandingkan perubahan jangka pendek.

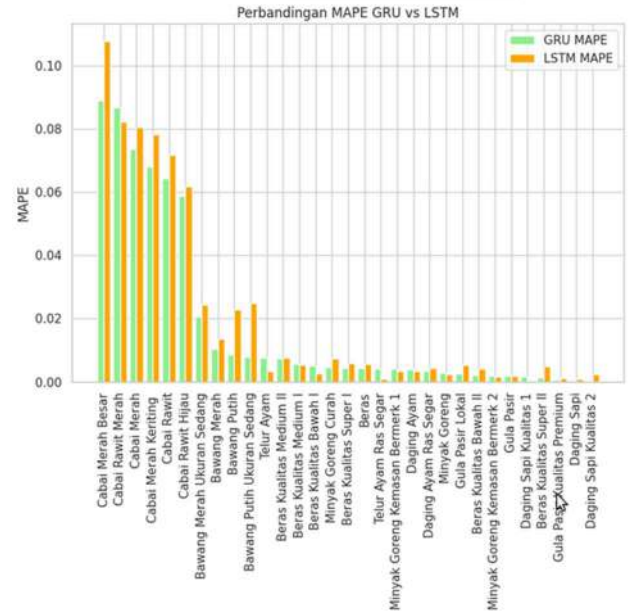
4.5 Perbandingan Kinerja GRU dan LSTM

Perbandingan kinerja antara GRU dan LSTM menunjukkan bahwa struktur GRU yang lebih sederhana memberikan keunggulan dalam menangani data dengan fluktuasi jangka pendek. GRU hanya menggunakan dua gerbang utama sehingga proses pembelajaran menjadi lebih cepat dan risiko *overfitting* dapat diminimalkan.

LSTM memiliki keunggulan dalam memodelkan ketergantungan jangka panjang, namun kompleksitas arsitekturnya menyebabkan model kurang optimal ketika diterapkan pada data harga sembako yang cenderung fluktuatif dan tidak stabil.



GAMBAR 1
Perbandingan MAE GRU vs LSTM



GAMBAR 2
Perbandingan MAPE GRU vs LSTM

4.6 Pembahasan Hasil

Hasil penelitian ini menunjukkan bahwa karakteristik data sangat memengaruhi kinerja model prediksi. Data harga sembako yang bersifat fluktuatif lebih cocok dimodelkan menggunakan GRU dibandingkan LSTM. Temuan ini sejalan dengan penelitian sebelumnya yang menyatakan bahwa GRU lebih efektif dalam menangani data dengan perubahan jangka pendek yang cepat.

Meskipun demikian, LSTM tetap memberikan performa yang cukup baik pada komoditas dengan pola harga yang stabil. Oleh karena itu, pemilihan metode prediksi sebaiknya disesuaikan dengan karakteristik data dan tujuan prediksi.

V. KESIMPULAN

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan, dapat ditarik beberapa kesimpulan sebagai berikut:

1. Metode **Gated Recurrent Unit (GRU)** dan **Long Short-Term Memory (LSTM)** mampu digunakan untuk memprediksi harga sembako di Kota Merauke menggunakan data deret waktu univariat periode 2021–2024.
2. Hasil evaluasi menggunakan metrik **Mean Absolute Error (MAE)** dan **Mean Absolute Percentage Error (MAPE)** menunjukkan bahwa metode GRU menghasilkan tingkat kesalahan prediksi yang lebih rendah dibandingkan LSTM pada sebagian besar komoditas sembako.
3. Model GRU lebih efektif dalam menangkap pola fluktuasi harga jangka pendek, sedangkan LSTM cenderung memberikan performa yang stabil pada komoditas dengan pola harga yang relatif konsisten.
4. Struktur GRU yang lebih sederhana dibandingkan LSTM menjadikan proses pelatihan lebih efisien tanpa mengurangi akurasi prediksi, sehingga lebih sesuai diterapkan pada data harga sembako yang bersifat fluktuatif.

Berdasarkan hasil tersebut, metode GRU direkomendasikan sebagai model utama dalam sistem prediksi harga sembako di Kota Merauke.

REFERENSI

[1] B. Sianipar and A. Nurish, “Merauke ‘Food Estate’: Alternatif Penanganan Konflik Di Papua Dalam Perspektif Ekonomi-Sosial Dan Budaya,” *Intermestic J. Int. Stud.*, vol. 5, no. 2, p. 356, 2021, doi: 10.24198/intermestic/v5n2.10.

[2] W. Hastomo, A. S. B. Karno, N. Kalbuana, E. Nisfiani, and L. ETP, “Optimasi Deep Learning untuk Prediksi Saham di,” ... *(Jurnal Edukasi dan ...*, vol. 7, no. 2, pp. 133–140, 2021, [Online]. Available: https://jurnal.untan.ac.id/index.php/jepin/article/view/47411

[3] T. Handhayani, C. Tanudy, and J. Hendryli, "Prediksi Harga Emas di Indonesia Menggunakan Gated Recurrent Unit," *J. Fasilkom*, vol. 13, no. 3, pp. 480–488, 2023, doi: 10.37859/jf.v13i3.6185.

[4] M. Oni, M. Dolok Lauro, and T. Handhayani, "Prediksi Harga Pangan Kota Bandung Menggunakan Metode Gated Recurrent Unit," *J. Ilmu Komput. dan Sist. Inf.*, vol. 11, no. 2, pp. 1–5, 2023, doi: 10.24912/jiksi.v11i2.26014.

[5] A. Rahmadeyan and Mustakim, "Long Short-Term Memory and Gated Recurrent Unit for Stock Price Prediction," *Procedia Comput. Sci.*, vol. 234, pp. 204–212, 2024, doi: 10.1016/j.procs.2024.02.167.

[6] A. Rahmadeyan and Mustakim, "Long Short-Term Memory and Gated Recurrent Unit for Stock Price Prediction," *Procedia Comput. Sci.*, vol. 234, no. 1, pp. 204–212, 2024, doi: 10.1016/j.procs.2024.02.167.

[7] S. Samsudin, A. M. Harahap, and S. Fitrie, "Implementasi Gated Recurrent Unit (Gru) Untuk Prediksi Harga Saham Bank Konvensional Di Indonesia," *JISTech (Journal Islam. Sci. Technol.*, vol. 6, no. 2, pp. 42–49, 2021, doi: 10.30829/jistech.v6i2.11058.

[8] J. Kezia Halim, D. Erny Herwindiati, and J. Hendryli, "Penerapaan 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.

[9] K. Prayogi, W. Gata, and D. P. Kussanti, "Prediksi Harga Saham Bank Central Asia Menggunakan Algoritma Deep Learning GRU," *Jutisi J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 13, no. 1, p. 647, 2024, doi: 10.35889/jutisi.v13i1.1910.

[10] A. Mahan Zaky, "Forecasting Jumlah Penggunaan Obat Digestive Enzymes dengan Algoritma GRU," *J. Informatics Vocat. Educ.*, vol. 5, no. 2, pp. 48–55, 2022, [Online]. Available: https://jurnal.uns.ac.id/joive/index

[11] Sabar Sautomo and Hilman Ferdinandus Pardede, "Prediksi Belanja Pemerintah Indonesia Menggunakan Long Short-Term Memory (LSTM)," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 5, no. 1, pp. 99–106, 2021, doi: 10.29207/resti.v5i1.2815.

[12] L. Azizah and Y. L. Sukestiyarno, "Metode Genetic Algorithm-Long Short-Term Memory Pada Peramalan Harga Saham," *UNNES J. Math.*, vol. 11, no. 2, pp. 153–160, 2022, [Online]. Available: http://journal.unnes.ac.id/sju/index.php/ujm

[13] K. T. Brilliansyah and U. T. Kartini, "Peramalan Jangka Sangat Pendek Daya Listrik PLTS On Grid Rumah Tinggal Menggunakan Metode Recurrent Neural Network Long Short Term Memory (RNN-LSTM) Berdasarkan Data Meteorologi," *J. Tek. Elektro*, vol. 12, no. 1, pp. 60–66, 2023, doi: 10.26740/jte.v12n1.p60-66.

[14] R. Wibowo dan L. Santoso, "Peramalan Harga Cabai Menggunakan LSTM," *Jurnal Teknologi dan Sistem Komputer*, vol. 9, no. 3, pp. 145–152, 2021.

[15] D. K. Putra dan A. Rahman, "Implementasi GRU untuk Prediksi Harga Beras di Indonesia," *Jurnal Ilmu Komputer dan Informatika*, vol. 12, no. 1, pp. 55–64, 2022.

[16] N. Safitri, R. Ramadhan, dan F. Saputra, "Prediksi Harga Pangan Menggunakan Metode LSTM," *Jurnal RESTI*, vol. 6, no. 4, pp. 813–820, 2022.

[17] Badan Pusat Statistik (BPS), "Statistik Harga Produsen dan Konsumen Komoditas Pangan Indonesia 2023," BPS, Jakarta, 2023.

[18] S. Nurjannah dan A. Kurniawan, "Perbandingan Model LSTM dan GRU untuk Prediksi Harga Sayuran," *Jurnal Sistem Informasi dan Informatika*, vol. 5, no. 2, pp. 101–108, 2022.

[19] H. Fadillah dan S. Nugroho, "Penerapan Machine Learning untuk Prediksi Harga Komoditas Pasar Tradisional," *Jurnal Teknologi Informasi dan Komputer*, vol. 8, no. 1, pp. 34–41, 2021.

[20] M. R. Pratama dan D. Yuliani, "Peramalan Time Series Menggunakan Deep Learning pada Data Komoditas Holtikultura," *Jurnal Informatika UPGRIS*, vol. 9, no. 2, pp. 77–84, 2023.

[21] Badan Pangan Nasional, "Laporan Kinerja Harga Pangan Nasional Tahun 2022–2024," Nasional Food Agency, Jakarta, 2024.

[22] A. Wiratama dan M. Firmansyah, "Prediksi Harga Bahan Pokok Menggunakan Metode RNN-LSTM," *Jurnal Teknologi Informasi ESIT*, vol. 19, no. 2, pp. 12–19, 2021.

[23] Kementerian Perdagangan RI, "Outlook Perdagangan Komoditas Pangan 2023," Jakarta, 2023.

[24] K. Syahputra dan F. Kurnia, "Implementasi Deep Learning untuk Peramalan Harga Ayam Ras pada Pasar Nasional," *Jurnal SIGMA Komputer*, vol. 10, no. 1, pp. 45–52, 2022.

[25] M. P. Hermawan dan L. Rahayu, "Perbandingan Algoritma GRU dan LSTM untuk Prediksi Harga Minyak Goreng," *Jurnal Sains dan Teknologi Industri*, vol. 17, no. 3, pp. 201–210, 2021.

[26] Dinas Ketahanan Pangan Provinsi Papua Selatan, "Laporan Stabilitas Harga Sembako Papua Selatan 2022–2024," Merauke, 2024.

[27] R. S. Lumbantoruan dan A. Hutapea, "Peramalan Harga Komoditas Menggunakan Metode Hybrid LSTM-GRU," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIIK)*, vol. 10, no. 2, pp. 233–241, 2023.

[28] M. H. Siregar dan N. Lestari, "Analisis Time Series Harga Sembako di Indonesia Menggunakan Metode Deep Learning," *Jurnal Informatika Universitas Sumatera Utara*, vol. 8, no. 1, pp. 22–30, 2022.

[29] A. Ramdhan dan S. Fauziah, "Prediksi Harga Telur Ayam Menggunakan LSTM," *Jurnal Pilar Nusa Mandiri*, vol. 17, no. 1, pp. 54–62, 2021.

[30] Pusat Informasi Harga Pangan Strategis Nasional (PIHPS), "Ringkasan Tahunan Harga Pangan Indonesia 2021–2024," PIHPS, Jakarta, 2024.

[31] Putra, M. D., & Haryanto, T., "Prediksi Curah Hujan Menggunakan Long Short-Term Memory (LSTM)," Jurnal Teknologi Informasi dan Ilmu Komputer, 2020.

[32] Suryani, D., Prasetyo, Y., & Wibowo, A., "Prediksi Harga Cabai Merah Menggunakan Metode LSTM," Jurnal Sistem Informasi, 2021.

[33] Wulandari, P., & Siregar, F., "Perbandingan Metode LSTM dan GRU untuk Prediksi Indeks Harga Saham," Jurnal Teknologi dan Sistem Komputer, 2022.