

Model Prediksi Manajemen Stok Produk Berbasis Deep Learning Gated Recurrent Unit untuk Optimalisasi Rantai Pasok E-Commerce

Darmawan Lahru Riatma^{1*}, Yusuf Fadhlilla Rahman¹, Trisna Ari Roshinta¹, Masbahah¹, Ahmad Faisal Sani¹, Rifa Khoirunisa¹, Nur Azizul Haqimi¹

¹Diploma Tiga Teknik Informatika, Sekolah Vokasi Universitas Sebelas Maret, Indonesia.

Artikel Info

Kata Kunci:

Deep Learning;
Gated Recurrent Unit (GRU);
Manajemen Stok.

Keywords:

Deep Learning;
Gated Recurrent Unit (GRU);
Stock Management.

Riwayat Artikel:

Submitted: 27 Februari 2025
Accepted: 30 Maret 2025
Published: 31 Maret 2025

Abstrak: Perkembangan pesat e-commerce mendorong kebutuhan akan sistem manajemen stok produk yang adaptif dan presisi tinggi untuk menjaga kesinambungan rantai pasok. Ketidakseimbangan antara permintaan konsumen dan ketersediaan stok dapat menyebabkan kerugian signifikan, baik dalam bentuk overstock maupun stockout. Penelitian ini bertujuan untuk merancang model prediksi manajemen stok produk berbasis algoritma deep learning Gated Recurrent Unit (GRU) untuk meningkatkan efisiensi rantai pasok e-commerce. Metode yang digunakan mencakup pengumpulan data historis penjualan, preprocessing data (normalisasi, pembersihan, dan pembagian data pelatihan dan pengujian), perancangan arsitektur model GRU, serta pelatihan dan evaluasi model menggunakan metrik RMSE, MAE, MAPE, dan koefisien determinasi R^2 . Hasil eksperimen menunjukkan bahwa model GRU memberikan performa terbaik pada epoch ke-200 dengan RMSE 622.94, MAE 451.04, MAPE 0.15, dan nilai R^2 sebesar 0.70. Temuan ini menunjukkan bahwa GRU efektif dalam memodelkan data deret waktu untuk prediksi permintaan produk. Kesimpulannya, model GRU dapat menjadi pendekatan yang inovatif dan andal dalam mendukung keputusan manajerial berbasis data guna meningkatkan efisiensi rantai pasok e-commerce.

Abstract: The rapid expansion of e-commerce has intensified the need for adaptive and accurate stock management systems to ensure the continuity of supply chains. Imbalances between customer demand and inventory levels often result in financial losses due to overstocking or stockouts. This study aims to develop a predictive model for product stock management using the Gated Recurrent Unit (GRU), a deep learning algorithm designed for time series forecasting. The methodology involves collecting historical sales data, preprocessing the dataset (including normalization, cleaning, and splitting into training and testing sets), designing the GRU architecture, and training the model across various epochs. The model's performance is evaluated using Root Mean Square Error (RMSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), and the coefficient of determination (R^2). Experimental results demonstrate that the GRU model achieves optimal performance at the 200th epoch, with an RMSE of 622.94, MAE of 451.04, MAPE of 0.15, and an R^2 of 0.70. These findings highlight the effectiveness of GRU in modeling temporal patterns for accurate product demand forecasting. In conclusion, the GRU-based model offers a reliable and innovative solution to support data-driven decision-making in stock management and enhance the efficiency of e-commerce supply chains.

Corresponding Author:

Darmawan Lahru Riatma
Email: darmawanlr@staff.uns.ac.id

PENDAHULUAN

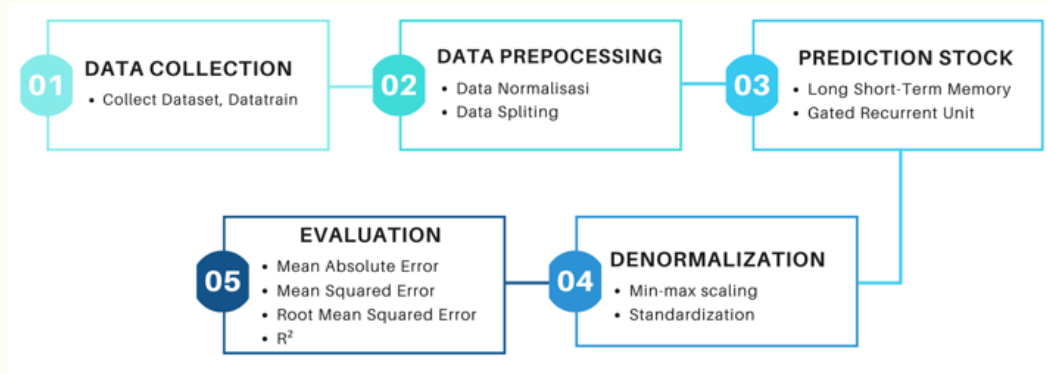
E-commerce saat ini mengalami tren peningkatan pengguna dan penjualan, para reseller semakin tertarik untuk bekerjasama serta mengadopsi strategi marketing karena hal ini berdampak juga dengan mengatur pembelian, logistic atau penyimpanan produk secara real-time (Zeng et al., 2019) (van Steenberg & Mes, 2020) (Chaudhuri et al., 2021). Ketidaktepatan dalam memprediksi kebutuhan stok dapat menyebabkan terjadinya *stockout* (kehabisan stok), yang berdampak pada hilangnya peluang penjualan dan penurunan kepuasan pelanggan. Sebaliknya, *overstock* (kelebihan stok) dapat meningkatkan biaya penyimpanan dan risiko kerugian akibat barang kadaluarsa atau tidak laku. Pesatnya perkembangan bisnis ritel e-commerce yang sangat cepat, menjadikan peramalan bisnis menjadi sangat penting untuk perencanaan dan operasional profit segmen ritel (Corsten & Gruen, 2003). Prediksi yang tidak akurat dapat mengakibatkan kekurangan atau kelebihan persediaan (Andrade & Cunha, 2023). Dengan kata lain, jika perkiraan lebih rendah dari permintaan pelanggan, maka akan terjadi kejadian kehabisan stok yang menyebabkan hilangnya pendapatan yang sering kali tidak dapat diperbaiki, karena konsumen yang tidak puas mungkin akan beralih ke jaringan ritel lain.

Permasalahan utama yang dihadapi dalam konteks ini adalah bagaimana membangun model prediksi stok produk yang mampu mengakomodasi pola permintaan yang kompleks dan dinamis. Penelitian sebelumnya membandingkan performa GRU dengan berbagai teknik optimasi, menunjukkan bahwa GRU efektif dalam memprediksi harga saham sektor perbankan di Nepal Stock Exchange (Saud & Shakya, 2019). Sementara itu penelitian lain menunjukkan bahwa model GRU memiliki performa prediksi yang superior dibandingkan model deep learning tradisional dan SVM dalam memprediksi indeks saham seperti HSI, DAX, dan S&P 500 (Shen et al., 2018). RNN unggul dalam bidang yang memerlukan informasi berurutan, seperti deret waktu, teks, audio dan video (Yu et al., 2022). RNN diperkenalkan sebagai pengembangan dari jaringan feedforward, sehingga dapat memproses urutan dengan panjang yang bervariasi atau bahkan tak hingga. Beberapa arsitektur RNN yang paling populer adalah long short-term memory (LSTM) dan gated recurrent units (GRU) (DiPietro & Hager, 2020). GRU adalah jaringan RNN yang biasa digunakan untuk memprediksi komponen di masa depan (Waqas & Humphries, 2024) (Wang & Ying, 2023) (Ait Mansour et al., 2024) (Ait Mansour et al., 2024; Islam & Hossain, 2021; Yao et al., 2023; Zarzycki & Ławryńczuk, 2022; Zhao et al., 2023), beberapa contoh kasus prediksi di masa depan menggunakan GRU (Johnny et al., 2022)(Ozdemir et al., 2022a), Pendekatan ini diharapkan mampu meningkatkan ketepatan prediksi stok serta mendukung pengambilan keputusan logistik yang lebih efisien.

Tujuan dari penelitian ini adalah untuk mengembangkan model prediksi stok berbasis deep learning GRU yang dapat meningkatkan efisiensi rantai pasok e-commerce dan mengurangi risiko kerugian akibat kesalahan manajemen stok. Penelitian ini diharapkan memberikan kontribusi praktis bagi pelaku industri e-commerce serta kontribusi akademik dalam pengembangan metode prediksi berbasis AI. Selain itu, pendekatan ini juga dapat diadopsi oleh sektor lain yang memiliki karakteristik permintaan yang fluktuatif, seperti sektor logistik, retail, dan distribusi barang konsumsi.

METODE

Penelitian ini menggunakan pendekatan kuantitatif eksperimental dengan tahapan utama berupa pengumpulan data historis penjualan produk e-commerce, pemrosesan data deret waktu (*time series*), pelatihan model prediksi menggunakan algoritma *Gated Recurrent Unit* (GRU). Proses penelitian terbagi menjadi lima tahapan, yaitu: (1) pengumpulan data, (2) praproses data, (3) pengembangan model GRU, (4) Denormalisasi, dan (5) Evaluasi kinerja model sebagaimana disajikan pada Gambar 1.



Gambar 1. Metode Penelitian

Pengumpulan Data

Data yang digunakan adalah data historis penjualan dari platform e-commerce dengan jangkauan waktu minimal dua tahun. Penggunaan data deret waktu historis untuk prediksi permintaan terbukti efektif dalam berbagai studi serupa. Jenis data meliputi tanggal transaksi, jumlah penjualan, kategori produk, serta informasi promosi.

Pada penelitian ini pengumpulan data menggunakan data penjualan roti dalam pada bulan Januari Tahun 2021 Hingga September 2022, total data yang digunakan sebanyak 129.270 data. Data didapatkan dari database penjualan salah satu marketplace di Taiwan. Contoh data penjualan tersaji pada tabel 1.

Tabel 1. Contoh Data Penjualan Roti

No	Date	Product	QTY	Price
1	2021-01-02	BAGUETTE	1	0,90 €
2	2021-01-02	PAIN AU CHOCOLAT	3	1,20 €
3	2021-01-02	CROISSANT	3	1,10 €

Praproses Data

Setelah data terkumpul tahap selanjutnya adalah *preprocessing* data, tahap ini bertujuan agar model yang dihasilkan lebih baik dan akurat serta menentukan atribut yang digunakan pada penelitian.

a. Data Normalisasi

Data – data tersebut dinormalisasi ke dalam dua interval yaitu $[-1,1]$ dan $[0,1]$ dengan tujuan memastikan interval mana yang menghasilkan nilai terbaik. Tujuan dari Normalisasi yaitu untuk menghilangkan kerangkapan data, untuk mengurangi kompleksitas, untuk mempermudah melakukan modifikasi data.

$$x_n = \frac{x_0 - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Dimana x_n adalah nilai hasil normalisasi, x_0 nilai data actual, x_{min} adalah nilai minimum dari data actual, x_{max} adalah nilai maksimum dari data actual.

b. Splitting Data

Dataset yang telah dilakukan preprocessing akan digunakan sebagai data input yaitu dibedakan menjadi data training dan data test sesuai periode prediksi yang diharapkan. Data training inilah yang digunakan untuk melatih model pada algoritma LSTM, agar menghasilkan model dengan performa atau akurasi yang baik pada data training itu sendiri dan pada data yang belum pernah dilihat sebelumnya (data test).

Pemodelan GRU

Jaringan GRU memiliki struktur sel yang mirip dengan jaringan LSTM. Namun, mekanisme pengaturannya yang lebih sederhana dibandingkan dengan jaringan LSTM memungkinkan sistem untuk melakukan perhitungan kompleks dengan sumber daya yang lebih sedikit dan dalam waktu yang lebih singkat. Dengan demikian, pelatihan jaringan ini dilakukan dengan kecepatan yang lebih tinggi (Ozdemir et al., 2022b).

Model GRU dikembangkan dengan dua lapisan tersembunyi, dropout untuk mencegah overfitting, dan lapisan output padat. GRU dipilih karena efisien dalam menangani data time series dengan ketergantungan jangka Panjang.

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (2)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (3)$$

$$h'_t = \tan h(W_h \cdot [r_t \odot h_{t-1}, x_t] + b_h) \quad (4)$$

$$h_t = (1 - z_t \odot h_{t-1} + z_t \odot h'_t) \quad (5)$$

Di mana h_t adalah vektor lapisan tersembunyi, x_t adalah vektor input, b_z , b_r , dan b_h adalah vektor bias, W_z , W_r , dan W_h adalah matriks parameter (Zor & Bulus, 2021).

Denormalisasi Data

Output yang dihasilkan dari proses prediksi masih dalam bentuk data normalisasi, sehingga dilakukan denormalisasi yaitu pengubahan data kembali ke nilai real. Setelah itu akan dihasilkan persentase data training dan data testing yang kemudian dapat dihitung error atau persentase errornya. Karena data masih berbentuk range interval yang sebelumnya telah dilakukan normalisasi data. Minmax scaler digunakan untuk menormalkan data dan persamaan berikut (Eq. (6)) adalah representasi matematis dari minmax scaler (ArunKumar et al., 2022).

$$dn_i = (n_i + 1)(x_{\max} - x_{\min}) + \left(\frac{2(x_{\min})}{2}\right) \quad (6)$$

Dimana dn_i adalah data hasil denormalisasi, n_i adalah data normalisasi, x_{\min} adalah nilai minimum data real dan x_{\max} adalah nilai maksimum data real. Tujuan dilakukannya denormalisasi adalah untuk mempermudah saat membaca nilai output yang dihasilkan.

Error Analysis

Analisis error pada algoritma LSTM untuk memastikan bahwa model memprediksi dengan akurasi yang baik dan meminimalkan kesalahan. Analisa error algoritma LSTM pada penelitian ini menggunakan Mean Absolute Error, Mean Squared Error, Root Mean Squared Error, Mean Absolute Percentage Error. Untuk mengevaluasi hasil kinerja, digunakan mean absolute percentage error (MAPE) dan perhitungan kesalahan dilakukan berdasarkan rumus berikut (Ozdemir et al., 2022c).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (7)$$

Dalam konteks ini, " y_i " adalah output yang sebenarnya, " \hat{y} " adalah output yang diperkirakan, dan " n " menunjukkan jumlah contoh yang ada.

Kami mengevaluasi kinerja model-model ini menggunakan RMSE, Residuals (RES), mean absolute error (MAE), dan koefisien korelasi (R). Fungsi-fungsi ini dapat ditulis sebagai berikut (Tang et al., 2024):

$$RSME = \sqrt{\sum \frac{(y' - y)^2}{n}} \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (10)$$

Dimana, y adalah nilai prediksi model, y_i adalah nilai aktual.

HASIL DAN PEMBAHASAN

Data Eksperimen

Data penjualan roti dalam pada bulan Januari Tahun 2021 Hingga September 2022, total data yang digunakan sebanyak 129.270 data. Data dibersihkan, difilter berdasarkan input pengguna, dan diolah menjadi data penjualan bulanan yang dinormalisasi. Dengan menggunakan data 12 bulan sebelumnya untuk memprediksi bulan berikutnya, dataset dibagi menjadi training dan testing set. Model GRU dibangun, dikompilasi, dan dilatih dengan ModelCheckpoint untuk menyimpan model terbaik, kemudian data dinormalisasi, Normalisasi terbukti memperbaiki efisiensi pelatihan dan kinerja model. (Yang et al., 2020) menunjukkan bahwa normalisasi input dalam arsitektur deep learning sangat penting terutama pada data deret waktu agar pembelajaran berlangsung stabil. Setelah pelatihan, model digunakan untuk membuat prediksi pada data pengujian dan evaluasi dilakukan dengan metrik RMSE, MAE, MAPE, dan R-squared. Proses ini menggunakan alat bantu tensorflow keras dan Bahasa pemrograman python.

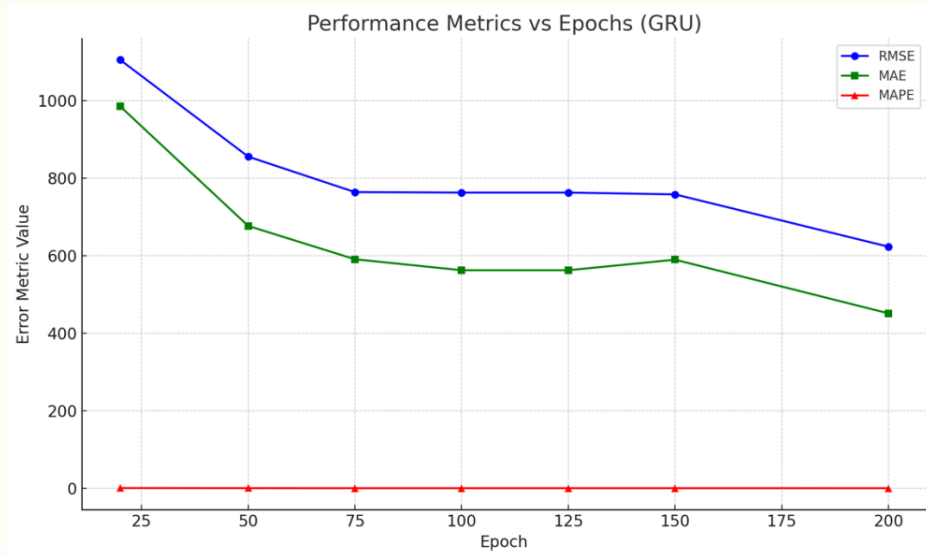
Evaluasi GRU

Pada penelitian ini evaluasi menggunakan RMSE (Root Mean Squared Error), MAPE (Mean Absolute Percentage Error) dan MAE (Mean Absolute Error). Pengujian dilakukan dengan mencoba beberapa kali epoch yaitu 20,50,75,100,125,150 dan 200. Tabel 2 dan gambar 3 menunjukkan performa model pada algoritma GRU. Penelitian oleh (Rashid et al., 2019) menunjukkan bahwa GRU mampu menghasilkan hasil prediksi yang akurat pada sistem manajemen logistik berbasis prediksi permintaan.

Table 2. Hasil Evaluasi Algoritma LSTM dan GRU

		EPOCH						
Algoritma	Metric	20	50	75	100	125	150	200
GRU	RMSE	1104.90	855.20	763.75	762.48	762.48	757.86	622.94
	MAE	985.01	676.52	590.55	562.26	562.26	589.41	451.04
	MAPE	0,54	0,28	0,20	0,20	0,20	0,24	0,15

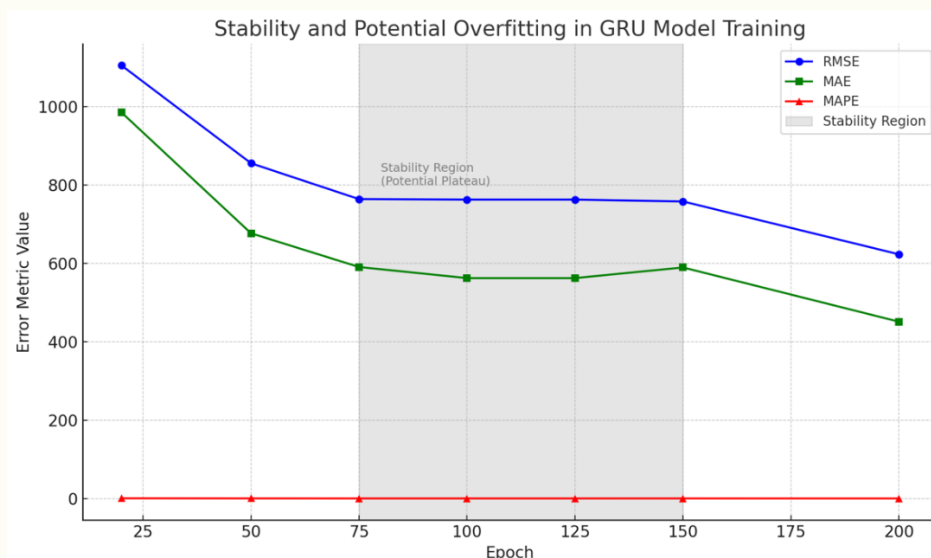
Pengujian RMSE dilakukan untuk mengukur akar dari rata-rata kesalahan kuadrat antara nilai prediksi dan nilai aktual. Semakin kecil nilai RMSE, semakin baik model dalam memprediksi hasil yang mendekati nilai aktual. Tabel 1 menunjukkan algoritma GRU, RMSE (Root Mean Square Error) menurun drastis dari 1104.90 pada 20 EPOCH menjadi 622.94 pada 200 EPOCH. Ini menunjukkan bahwa seiring bertambahnya iterasi pelatihan, model semakin mampu mempelajari pola data dan menghasilkan prediksi yang lebih akurat. Gambar 1 menunjukkan visualisasi hubungan antara jumlah EPOCH dan tiga metrik performa (RMSE, MAE, MAPE) pada model GRU. Grafik ini menunjukkan tren penurunan error seiring meningkatnya EPOCH, dengan hasil terbaik pada EPOCH ke-200.



Gambar 2. Performace Metric VS Epoch GRU

MAE (Mean Absolute Error) juga menunjukkan tren penurunan yang signifikan, dari 985.01 ke 451.04. Hal ini menegaskan bahwa rata-rata kesalahan prediksi menurun seiring peningkatan EPOCH. MAPE (Mean Absolute Percentage Error) mengalami penurunan dari 0.54 (54%) menjadi 0.15 (15%), menandakan bahwa model menjadi semakin presisi dalam memprediksi permintaan relatif terhadap nilai sebenarnya.

Mulai dari EPOCH ke-75 hingga 150, nilai RMSE dan MAE cenderung stagnan (sekitar 762 dan 562), tetapi pada EPOCH ke-200 terjadi penurunan yang signifikan. Ini menunjukkan bahwa model mungkin masih terus belajar secara positif tanpa overfitting, atau model mulai mengatasi *plateau* setelah sejumlah epoch tertentu. Gambar 2 Visualisasi tren metrik error (RMSE, MAE, MAPE) terhadap jumlah EPOCH pada model GRU.



Gambar 3. Visualisasi tren metrik error (RMSE, MAE, MAPE) terhadap jumlah EPOCH pada model GRU

Hasil visualisasi menunjukkan bahwa model GRU mengalami fase stabil atau *plateau* antara EPOCH 75 hingga 150, sebagaimana ditandai dengan perubahan yang relatif kecil pada nilai RMSE (763.75 → 757.86) dan MAE (590.55 → 589.41). Fase ini dapat diinterpretasikan sebagai titik kestabilan

pembelajaran, di mana model telah memahami pola data utama namun belum cukup mengeneralisasi secara optimal.

Menariknya, pada EPOCH 200 terdapat penurunan signifikan pada ketiga metrik, khususnya RMSE (menjadi 622.94) dan MAE (menjadi 451.04), yang menandakan bahwa proses pelatihan masih memberikan peningkatan kinerja. Ini menunjukkan bahwa model GRU tidak mengalami overfitting dalam kurva ini, dan justru memperoleh manfaat dari pelatihan jangka panjang. Implikasinya, EPOCH yang lebih tinggi dari 150 patut dieksplorasi lebih lanjut dalam pengujian untuk menemukan titik optimal, sekaligus memastikan tidak terjadi overfitting pada rentang yang lebih panjang.

Determinasi Koefisien R

Koefisien determinasi (R^2) merupakan metrik statistik yang menunjukkan proporsi variabilitas dalam data target yang dapat dijelaskan oleh model. Nilai R^2 berkisar dari 0 hingga 1, di mana nilai yang lebih tinggi menunjukkan bahwa model mampu menjelaskan variasi data dengan lebih baik. Penelitian oleh (Tuo et al., 2019) mengungkapkan bahwa GRU memiliki kapasitas lebih rendah dalam overfitting dibanding LSTM pada dataset yang berukuran sedang. Tabel 3 Menunjukan untuk metric koefisien determinan R.


Tabel 3. Metric Koefisien Determinan R

Metric R^2	Epoch						
	20	50	75	100	125	150	200
GRU	0.074	0.44	0.55	0.55	0.55	0.56	0.70

EPOCH 20: $R^2 = 0.074 \rightarrow$ artinya hanya 7,4% variasi data stok dapat dijelaskan oleh model GRU. Ini menunjukkan model masih sangat lemah dalam menangkap pola pada fase awal pelatihan. EPOCH 50: R^2 meningkat signifikan menjadi 0.44, menandakan peningkatan kemampuan model dalam mempelajari pola data. EPOCH 75 hingga 125: R^2 stabil di angka 0.55, mengindikasikan model telah mulai mencapai fase stabilitas (*plateau*), di mana penambahan epoch tidak memberikan peningkatan signifikan. EPOCH 150: R^2 sedikit meningkat menjadi 0.56, menunjukkan sedikit perbaikan. EPOCH 200: R^2 melonjak ke 0.70, artinya model dapat menjelaskan 70% variabilitas data stok produk, yang menunjukkan performa prediktif yang cukup kuat dan akurat.

Efektifitas Model GRU

Secara keseluruhan, model GRU menunjukkan kemampuan yang baik dalam mempelajari pola data penjualan. Penurunan nilai ketiga metrik secara konsisten menunjukkan bahwa GRU cocok untuk prediksi time series dalam konteks manajemen stok e-commerce. Gambar 3 menampilkan performa akhir model GRU pada EPOCH ke-200 berdasarkan tiga metrik evaluasi utama, yaitu RMSE, MAE, dan MAPE. Nilai RMSE sebesar 622.94 menunjukkan bahwa rata-rata akar kuadrat dari selisih antara nilai aktual dan prediksi relatif rendah, menandakan bahwa prediksi model cukup dekat dengan nilai sebenarnya dalam skala absolut. Lebih lanjut, nilai MAE sebesar 451.04 mengindikasikan bahwa rata-rata kesalahan absolut pada prediksi juga cukup kecil, memperkuat bukti bahwa model memiliki ketepatan prediksi yang baik. Sementara itu, nilai MAPE sebesar 0.15 atau 15% mengindikasikan bahwa secara relatif, model hanya membuat kesalahan sekitar 15% terhadap nilai aktualnya. Nilai ini tergolong baik dalam konteks prediksi stok e-commerce yang bersifat fluktuatif. Gambar 4 menunjukan efektifitas akhir model GRU pada Epoch 200.



Gambar 4. Efektifitas Akhir Model GRU Pada Epoch 200

Secara keseluruhan, ketiga metrik ini mengonfirmasi bahwa model GRU memiliki efektivitas yang tinggi dalam memprediksi stok produk pada rantai pasok e-commerce, bahkan tanpa mengalami overfitting hingga EPOCH ke-200. Dengan demikian, GRU menjadi pilihan yang layak untuk diterapkan dalam sistem prediksi stok berbasis time series karena kestabilan, keakuratan, dan kemampuannya dalam menangani data berurutan.

KESIMPULAN

Penelitian ini menunjukkan bahwa model Gated Recurrent Unit (GRU) mampu mempelajari pola data time series stok produk e-commerce secara efektif seiring peningkatan jumlah epoch pelatihan. Evaluasi dilakukan dengan menggunakan tiga metrik utama: Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE), serta ditambahkan metrik koefisien determinasi (R^2) sebagai indikator kekuatan prediktif model. Hasil menunjukkan bahwa nilai RMSE dan MAE terus menurun signifikan dari epoch 20 hingga 200, sementara nilai MAPE menunjukkan tren penurunan dari 54% menjadi hanya 15% pada epoch 200. Hal ini menandakan bahwa model semakin akurat dalam memprediksi stok produk. Sementara itu, nilai R^2 meningkat dari 0.074 pada epoch 20 menjadi 0.70 pada epoch 200, yang menunjukkan bahwa model mampu menjelaskan 70% variabilitas stok produk berdasarkan data historis. Peningkatan performa ini menunjukkan bahwa GRU tidak hanya stabil, tetapi juga tidak mengalami overfitting hingga 200 epoch. Model ini terbukti efektif dan efisien untuk diterapkan dalam sistem manajemen rantai pasok berbasis prediksi stok e-commerce, karena mampu memberikan estimasi yang akurat untuk mendukung pengambilan keputusan logistik dan pengadaan produk. Dengan demikian, pendekatan deep learning berbasis GRU layak digunakan sebagai komponen utama dalam sistem pendukung keputusan rantai pasok e-commerce, khususnya dalam konteks pemantauan dan prediksi stok yang dinamis.

DAFTAR PUSTAKA

- Ait Mansour, A., Tilioua, A., & Touzani, M. (2024). Bi-LSTM, GRU and 1D-CNN models for short-term photovoltaic panel efficiency forecasting case amorphous silicon grid-connected PV system. *Results in Engineering*, 21, 101886. <https://doi.org/10.1016/j.rineng.2024.101886>
- Andrade, L. A. C. G., & Cunha, C. B. (2023). Disaggregated retail forecasting: A gradient boosting approach. *Applied Soft Computing*, 141, 110283. <https://doi.org/10.1016/j.asoc.2023.110283>
- ArunKumar, K. E., Kalaga, D. V., Mohan Sai Kumar, Ch., Kawaji, M., & Brenza, T. M. (2022). Comparative analysis of Gated Recurrent Units (GRU), long Short-Term memory (LSTM) cells, autoregressive Integrated moving average (ARIMA), seasonal autoregressive Integrated moving average (SARIMA) for forecasting COVID-19 trends. *Alexandria Engineering Journal*, 61(10), 7585–7603. <https://doi.org/10.1016/j.aej.2022.01.011>
- Chaudhuri, N., Gupta, G., Vamsi, V., & Bose, I. (2021). On the platform but will they buy? Predicting customers' purchase behavior using deep learning. *Decision Support Systems*, 149, 113622. <https://doi.org/10.1016/j.dss.2021.113622>
- Corsten, D., & Gruen, T. (2003). Desperately seeking shelf availability: an examination of the extent, the causes, and the efforts to address retail out-of-stocks. *International Journal of Retail & Distribution Management*, 31(12), 605–617. <https://doi.org/10.1108/09590550310507731>
- DiPietro, R., & Hager, G. D. (2020). Deep learning: RNNs and LSTM. In *Handbook of Medical Image Computing and Computer Assisted Intervention* (pp. 503–519). Elsevier. <https://doi.org/10.1016/B978-0-12-816176-0.00026-0>
- Islam, M. S., & Hossain, E. (2021). Foreign exchange currency rate prediction using a GRU-LSTM hybrid network. *Soft Computing Letters*, 3, 100009. <https://doi.org/10.1016/j.socl.2020.100009>
- Johny, K., Pai, M. L., & S., A. (2022). A multivariate EMD-LSTM model aided with Time Dependent Intrinsic Cross-Correlation for monthly rainfall prediction. *Applied Soft Computing*, 123, 108941. <https://doi.org/10.1016/j.asoc.2022.108941>
- Ozdemir, A. C., Buluş, K., & Zor, K. (2022a). Medium- to long-term nickel price forecasting using LSTM and GRU networks. *Resources Policy*, 78, 102906. <https://doi.org/10.1016/j.resourpol.2022.102906>
- Ozdemir, A. C., Buluş, K., & Zor, K. (2022b). Medium- to long-term nickel price forecasting using LSTM and GRU networks. *Resources Policy*, 78, 102906. <https://doi.org/10.1016/j.resourpol.2022.102906>
- Ozdemir, A. C., Buluş, K., & Zor, K. (2022c). Medium- to long-term nickel price forecasting using LSTM and GRU networks. *Resources Policy*, 78, 102906. <https://doi.org/10.1016/j.resourpol.2022.102906>
- Rashid, H., Zafar, N., Iqbal, M. J., Dawood, H., & Dawood, H. (2019). Single Image Dehazing using CNN. *Procedia Computer Science*, 147, 124–130. <https://doi.org/10.1016/j.procs.2019.01.201>
- Saud, A. S., & Shakya, S. (2019). Analysis of Gradient Descent Optimization Techniques with Gated Recurrent Unit for Stock Price Prediction: A Case Study on Banking Sector of Nepal Stock Exchange. *Journal of Institute of Science and Technology*, 24(2), 17–21. <https://doi.org/10.3126/jist.v24i2.27247>
- Shen, G., Tan, Q., Zhang, H., Zeng, P., & Xu, J. (2018). Deep Learning with Gated Recurrent Unit Networks for Financial Sequence Predictions. *Procedia Computer Science*, 131, 895–903. <https://doi.org/10.1016/j.procs.2018.04.298>
- Tang, J., Liu, C., Yang, D., & Ding, M. (2024). Prediction of ionospheric TEC using a GRU mechanism method. *Advances in Space Research*, 74(1), 260–270. <https://doi.org/10.1016/j.asr.2024.03.050>

- Tuo, Q., Zhao, H., & Hu, Q. (2019). Hierarchical feature selection with subtree based graph regularization. *Knowledge-Based Systems*, 163, 996–1008. <https://doi.org/10.1016/j.knosys.2018.10.023>
- van Steenberg, R. M., & Mes, M. R. K. (2020). Forecasting demand profiles of new products. *Decision Support Systems*, 139, 113401. <https://doi.org/10.1016/j.dss.2020.113401>
- Wang, M., & Ying, F. (2023). Point and interval prediction for significant wave height based on LSTM-GRU and KDE. *Ocean Engineering*, 289, 116247. <https://doi.org/10.1016/j.oceaneng.2023.116247>
- Waqas, M., & Humphries, U. W. (2024). A critical review of RNN and LSTM variants in hydrological time series predictions. *MethodsX*, 13, 102946. <https://doi.org/10.1016/j.mex.2024.102946>
- Yang, J., Zhao, C., Yu, H., & Chen, H. (2020). Use GBDT to Predict the Stock Market. *Procedia Computer Science*, 174, 161–171. <https://doi.org/10.1016/j.procs.2020.06.071>
- Yao, Z., Wang, Z., Wang, D., Wu, J., & Chen, L. (2023). An ensemble CNN-LSTM and GRU adaptive weighting model based improved sparrow search algorithm for predicting runoff using historical meteorological and runoff data as input. *Journal of Hydrology*, 625, 129977. <https://doi.org/10.1016/j.jhydrol.2023.129977>
- Yu, J., de Antonio, A., & Villalba-Mora, E. (2022). Deep Learning (CNN, RNN) Applications for Smart Homes: A Systematic Review. *Computers*, 11(2), 26. <https://doi.org/10.3390/computers11020026>
- Zarzycki, K., & Ławryńczuk, M. (2022). Advanced predictive control for GRU and LSTM networks. *Information Sciences*, 616, 229–254. <https://doi.org/10.1016/j.ins.2022.10.078>
- Zeng, M., Cao, H., Chen, M., & Li, Y. (2019). User behaviour modeling, recommendations, and purchase prediction during shopping festivals. *Electronic Markets*, 29(2), 263–274. <https://doi.org/10.1007/s12525-018-0311-8>
- Zhao, L., Li, Z., Qu, L., Zhang, J., & Teng, B. (2023). A hybrid VMD-LSTM/GRU model to predict non-stationary and irregular waves on the east coast of China. *Ocean Engineering*, 276, 114136. <https://doi.org/10.1016/j.oceaneng.2023.114136>
- Zor, K., & Bulus, K. (2021). A benchmark of GRU and LSTM networks for short-term electric load forecasting. *2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)*, 598–602. <https://doi.org/10.1109/3ICT53449.2021.9581373>