

Penerapan GRU untuk Prediksi Volatilitas Saham Perusahaan E-Commerce Berdasarkan Data Yahoo Finance

Al Fandi¹, Alfind Haswari¹, Imam Saputra^{2,*}

¹Program Studi Manajemen, Sekolah Tinggi Ilmu Manajemen Sukma, Medan, Indonesia

²Program Studi Bisnis Digital, Sekolah Tinggi Ilmu Manajemen Sukma, Medan, Indonesia

Email: ¹alfandi261006@gmail.com, ²alfindhaswari19@gmail.com, ^{3,*}saputraimam69@gmail.com

(* : coresponding author)

Abstrak

Volatilitas harga saham perusahaan e-commerce cenderung tinggi dan sulit diprediksi secara akurat menggunakan model ekonometrika konvensional seperti ARCH/GARCH karena sifatnya yang non-linear. Penelitian ini mengembangkan model Gated Recurrent Unit (GRU) multivariate untuk memprediksi volatilitas harga saham Amazon (AMZN) dengan mengintegrasikan data historis Yahoo Finance dan indeks popularitas merek dari Google Trends sebagai variabel eksternal. Data periode 2021–2026 diproses menggunakan skema sliding window 60 hari dan dibagi dengan rasio 80:20 untuk data latih dan data uji. Model dilatih selama 50 epoch menggunakan dua lapisan GRU dengan masing-masing 50 unit dan dropout 20%. Hasil pelatihan menunjukkan konvergensi loss yang stabil tanpa indikasi overfitting, namun evaluasi pada data uji menghasilkan R^2 Score negatif (-0,0711), yang mengindikasikan model belum mampu menangkap variansi volatilitas aktual secara memadai. Temuan ini menunjukkan bahwa arsitektur GRU dua lapisan dengan fitur yang digunakan masih terbatas dalam menangkap sifat stokastik volatilitas saham jangka pendek, sehingga diperlukan pengembangan arsitektur dan rekayasa fitur lebih lanjut.

Kata Kunci: Volatilitas Saham, Gated Recurrent Unit, Google Trends, Deep Learning, E-commerce

1. PENDAHULUAN

Perkembangan industri e-commerce dalam lima tahun terakhir telah mengalami eskalasi yang sangat masif, mentransformasi lanskap retail global dan domestik secara fundamental [1]. Sebagai sektor yang padat modal dan sangat bergantung pada adopsi teknologi, kinerja keuangan perusahaan e-commerce di pasar modal dicirikan oleh tingkat ketidakpastian yang tinggi [2]. Volatilitas harga saham pada sektor ini merepresentasikan risiko sekaligus peluang bagi para investor dan pengelola dana (fund managers) [3]. Ketidakstabilan harga saham e-commerce tidak hanya dipengaruhi oleh indikator makroekonomi atau performa laporan keuangan internal konvensional, melainkan juga sangat sensitif terhadap persepsi publik dan dinamika pasar digital secara real-time [4]. Dalam manajemen keuangan modern, kemampuan untuk memprediksi volatilitas secara presisi menjadi instrumen krusial dalam mitigasi risiko portofolio, penetapan harga opsi, dan pengambilan keputusan investasi yang strategis [5].

Di sisi lain, era digitalisasi telah menggeser paradigma pemasaran, di mana aktivitas brand awareness dan interaksi konsumen di dunia maya menciptakan jejak data digital yang masif [6]. Indeks popularitas merek (brand popularity index) yang tercermin melalui intensitas pencarian mesin pencari kini diakui sebagai indikator proksi bagi minat beli konsumen dan sentimen pasar [7]. Kampanye pemasaran yang agresif secara teoretis mampu meningkatkan brand equity, yang pada gilirannya menstimulasi volume perdagangan dan memengaruhi stabilitas harga saham perusahaan di bursa efek [8]. Oleh karena itu, mengintegrasikan data volatilitas keuangan historis dari platform seperti Yahoo Finance dengan metrik pemasaran digital berupa indeks popularitas merek menjadi pendekatan interdisipliner yang sangat relevan untuk menangkap anomali pasar secara komprehensif [9].

Untuk memproses karakteristik data runtun waktu (time-series) yang memiliki kompleksitas tinggi, non-linear, dan penuh dengan noise, pendekatan ekonometrika klasik seperti ARCH/GARCH dinilai memiliki keterbatasan dalam menangkap hubungan non-linear jangka panjang [10]. Sebagai solusinya, pemanfaatan algoritma Deep Learning menjadi tren dominan dalam komputasi keuangan [11]. Arsitektur Recurrent Neural Network (RNN), khususnya Gated Recurrent Unit (GRU), menawarkan efisiensi komputasi yang tinggi karena menyederhanakan struktur gerbang (gate) dibandingkan dengan Long Short-Term Memory (LSTM), namun tetap mempertahankan akurasi tinggi dalam mengenali dependensi temporal pada data keuangan yang volatil [12].

2. METODOLOGI PENELITIAN

2.1 Desain Penelitian dan Alur Sistem (Research Design)

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental berbasis simulasi komputasi *Deep Learning*. Fokus utama dari desain penelitian ini adalah memodelkan dan memprediksi nilai volatilitas harga saham sektor *e-commerce* menggunakan integrasi data multivariate runtun waktu (*time-series*). Eksperimen dirancang untuk mengevaluasi kontribusi variabel pemasaran digital (indeks popularitas merek) ketika dikombinasikan dengan data finansial historis (Yahoo Finance) terhadap performa akurasi algoritma *Gated Recurrent Unit* (GRU).

ISSN 2962-7966 (media online)
 Vol 4 No 1, Hal: 452-458

Seluruh tahapan eksperimen komputasi dijalankan menggunakan lingkungan berbasis *cloud* Google Colab dengan dukungan akselerasi perangkat keras T4 GPU (*Graphics Processing Unit*). Implementasi kode pemrosesan data dan penataan arsitektur model dibangun menggunakan bahasa pemrograman Python 3.12 dengan pustaka utama Keras dan TensorFlow.

Secara komprehensif, rangkaian prosedur eksperimen dan aliran pemrosesan data dalam penelitian ini dibagi menjadi lima tahapan utama yang terstruktur. Alur sistem makro tersebut digambarkan melalui diagram alir (*pipeline*) sistem pada Gambar 1 berikut:



Gambar 1. Diagram Alir (Pipeline) Sistem Penelitian

Berdasarkan Gambar 1, visualisasi arsitektur sistem dapat dijabarkan ke dalam rincian tahapan operasional sebagai berikut.

Tahap Akuisisi Data: Sistem melakukan penarikan data mentah secara otomatis melalui API (Application Programming Interface). Data volatilitas keuangan diunduh dari Yahoo Finance menggunakan pustaka *yfinance* untuk emiten Amazon (AMZN), sedangkan data indikator pemasaran digital diekstraksi dari mesin pencari Google Trends menggunakan kata kunci representatif dari merek terkait. Rentang waktu data yang diambil mencakup periode 5 tahun terhitung dari 1 Januari 2021 hingga 1 Januari 2026.

Tahap Prapemrosesan Data: Karena karakteristik kedua sumber data berbeda, tahap ini melakukan penyelarasan tanggal (*data alignment*). Data Google Trends yang bersifat harian penuh disinkronkan dengan hari kerja aktif bursa saham Yahoo Finance. Selanjutnya, fitur target berupa nilai volatilitas historis dihitung secara matematis. Untuk menghilangkan disparitas satuan antar variabel (harga saham bernilai ratusan indeks sedangkan popularitas merek berskala 0–100), seluruh fitur ditransformasikan ke dalam rentang nilai 0 hingga 1 menggunakan metode *MinMaxScaler*.

Tahap Konstruksi Data (Sliding Window): Data runtun waktu yang telah dinormalisasi diubah strukturnya menjadi format matriks tiga dimensi (3D) yang sesuai dengan kebutuhan input jaringan saraf berulang (*Recurrent Neural Network*). Menggunakan skema *sliding window* dengan ukuran *time steps* sebesar 60 hari, sistem mengemas data historis 60 hari ke belakang untuk memproyeksikan nilai volatilitas pada 1 hari berikutnya. Setelah struktur 3D terbentuk, data dipisah secara kronologis dengan rasio 80% sebagai himpunan data latih (*training set*) dan 20% sebagai himpunan data uji (*testing set*).

Tahap Pelatihan Model (Training Model): Data latih dimasukkan ke dalam arsitektur model *Sequential GRU* yang telah dikonfigurasi. Model ini terdiri dari lapisan *Input Layer*, dua lapisan inti *GRU* dengan masing-masing 50 units untuk mengeksplorasi dependensi temporal non-linear, dua lapisan *Dropout* dengan laju 20% sebagai instrumen regularisasi pencegah *overfitting*, serta diakhiri oleh satu lapisan *Dense* sebagai *output layer* prediksi tunggal. Model dioptimasi menggunakan fungsi kerugian *Mean Squared Error (MSE)* dan algoritma optimasi *Adam* [11]. Proses training dikondisikan berjalan selama 50 epochs dengan alokasi 10% data latih dialihkan sebagai *validation data* guna memantau pergerakan konvergensi *loss*.

Tahap Evaluasi dan Visualisasi: Model *GRU* yang telah dilatih kemudian diuji kemampuannya menggunakan data uji (*testing data*) yang belum pernah dikenali sebelumnya. Hasil keluaran model dipetakan ke dalam metrik evaluasi statistik standar jurnal ilmiah, yaitu *Mean Squared Error (MSE)*, *Root Mean Squared Error (RMSE)*, *Mean Absolute Error (MAE)*, dan *R-Squared (R² Score)*. Tahap akhir ditutup dengan visualisasi grafis yang memplot kurva pergerakan nilai volatilitas aktual berdampingan dengan kurva hasil prediksi model *GRU* untuk dianalisis signifikansinya pada bab pembahasan.

2.2 Volatilitas Harga Saham dan Pendekatan Peramalannya

Volatilitas harga saham merupakan ukuran statistik yang merepresentasikan besaran fluktuasi return suatu aset dalam periode waktu tertentu, dan secara luas digunakan sebagai proksi risiko dalam manajemen portofolio serta

penetapan harga instrumen derivatif [13]. Secara tradisional, peramalan volatilitas banyak mengandalkan model ekonometrika seperti Autoregressive Conditional Heteroskedasticity (ARCH) dan pengembangannya, Generalized ARCH (GARCH), yang mengasumsikan volatilitas hari ini dipengaruhi oleh residual dan varians pada periode-periode sebelumnya [14].

Meskipun model ARCH/GARCH terbukti efektif untuk menangkap fenomena volatility clustering, pendekatan ini memiliki keterbatasan struktural karena bersifat linear dan mengasumsikan distribusi data yang relatif stasioner, sehingga kurang mampu menangkap pola non-linear dan interaksi kompleks antar variabel yang menjadi ciri khas data pasar keuangan modern [15]. Keterbatasan inilah yang mendorong berkembangnya pendekatan berbasis pembelajaran mesin dan pembelajaran mendalam (deep learning) sebagai alternatif pemodelan volatilitas yang lebih adaptif [16].

2.3 Recurrent Neural Network dan Gated Recurrent Unit (GRU)

Recurrent Neural Network (RNN) merupakan arsitektur jaringan saraf tiruan yang dirancang khusus untuk memproses data sekuensial atau runtun waktu, karena memiliki mekanisme umpan balik (feedback loop) yang memungkinkan informasi dari langkah waktu sebelumnya dipertahankan dan memengaruhi prediksi pada langkah waktu berikutnya. Namun, RNN konvensional rentan mengalami permasalahan vanishing gradient pada data dengan dependensi jangka panjang [17].

Gated Recurrent Unit (GRU) selanjutnya diperkenalkan sebagai penyederhanaan dari LSTM, dengan hanya menggunakan dua gerbang yaitu reset gate dan update gate. Reset gate berfungsi menentukan seberapa besar informasi masa lalu yang diabaikan, sedangkan update gate mengatur proporsi informasi lama yang dipertahankan dan informasi baru yang ditambahkan ke dalam status tersembunyi (hidden state) [18]. Dengan struktur yang lebih ringkas, GRU umumnya menawarkan efisiensi komputasi yang lebih tinggi dibandingkan LSTM, sembari tetap mempertahankan kemampuan yang setara dalam menangkap dependensi temporal pada data time-series yang volatil.

2.4 Google Trends sebagai Proksi Sentimen dan Perhatian Investor

Dalam kerangka teori keuangan perilaku (behavioral finance), keputusan investasi tidak semata-mata dipengaruhi oleh informasi fundamental, tetapi juga oleh perhatian (attention) dan sentimen investor terhadap suatu aset atau merek [19]. Volume pencarian pada mesin pencari, yang direpresentasikan melalui indeks popularitas merek dari Google Trends, telah digunakan dalam berbagai penelitian sebagai indikator proksi bagi tingkat perhatian publik dan investor ritel terhadap suatu entitas, karena mencerminkan minat pencarian informasi secara real-time yang sulit ditangkap oleh data finansial konvensional [20].

Peningkatan intensitas pencarian terhadap suatu merek dapat mengindikasikan lonjakan minat pasar, baik yang bersifat positif (misalnya peluncuran produk atau kampanye pemasaran) maupun negatif (misalnya isu atau kontroversi), yang keduanya berpotensi memicu peningkatan volume perdagangan dan volatilitas harga saham emiten terkait [21]. Atas dasar inilah, penelitian ini memosisikan indeks popularitas merek sebagai variabel fitur eksternal yang relevan untuk diintegrasikan ke dalam model prediksi volatilitas berbasis GRU, guna melengkapi informasi yang tidak tertangkap oleh data harga dan volume historis semata.

2.5 Sumber Data dan Variabel Penelitian (Data Source and Variables)

Penelitian ini menggunakan dua sumber data sekunder yang diintegrasikan secara temporal. Sumber pertama adalah data historis keuangan yang diperoleh dari platform Yahoo Finance melalui pustaka yfinance, mencakup harga saham harian emiten Amazon (AMZN) berupa Open, High, Low, Close, dan Volume (OHLCV) untuk periode 1 Januari 2021 hingga 1 Januari 2026 (5 tahun observasi). Dari data OHLCV tersebut, variabel target penelitian yaitu volatilitas harga saham dihitung menggunakan pendekatan log return harian, kemudian ditransformasikan menjadi rolling standard deviation untuk merepresentasikan fluktuasi harga dalam jendela waktu tertentu. Sumber kedua adalah data indeks popularitas merek (brand popularity index) yang diperoleh dari Google Trends menggunakan kata kunci representatif terkait merek Amazon, direpresentasikan dalam skala relatif 0–100 berdasarkan volume pencarian harian. Kombinasi variabel finansial internal dan variabel pemasaran digital eksternal ini menjadi dasar pendekatan multivariate yang membedakan penelitian ini dari studi volatility forecasting konvensional yang bersifat univariat. Secara ringkas, variabel penelitian yang digunakan disajikan pada Tabel 1 berikut.

Tabel 1. Variabel Penelitian

No	Variabel	Sumber	Peran
1	Harga Penutupan (Close)	Yahoo Finance	Fitur input
2	Volume Perdagangan	Yahoo Finance	Fitur input
3	Volatilitas Historis	Turunan Close	Target (Y)
4	Indeks Popularitas Merek	Google Trends	Fitur input eksternal

2.6 Prapemrosesan Data (Data Preprocessing)

Tahap prapemrosesan diperlukan karena kedua sumber data memiliki karakteristik struktural yang berbeda. Data Google Trends bersifat kontinu (mencakup seluruh hari kalender), sedangkan data Yahoo Finance hanya tersedia pada hari kerja bursa efek (trading days). Oleh karena itu, dilakukan penyelarasan tanggal (date alignment) dengan menyaring data Google Trends agar hanya mengambil observasi pada hari-hari perdagangan aktif, sehingga kedua deret waktu memiliki indeks tanggal yang identik.

Setelah data selaras, dilakukan penanganan nilai hilang (missing values) menggunakan metode forward-fill, mengingat karakteristik data finansial time-series di mana nilai terakhir yang diketahui merupakan estimasi paling wajar untuk hari libur bursa.

Tahap berikutnya adalah normalisasi fitur. Karena skala antar variabel sangat berbeda harga saham bernilai ratusan hingga ribuan indeks, sedangkan indeks popularitas merek berskala 0–100 seluruh fitur ditransformasikan ke rentang 0 hingga 1 menggunakan metode MinMaxScaler, dengan formula sebagai berikut:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

dengan X adalah nilai asli sebelum normalisasi, X_{min} dan X_{max} masing-masing adalah nilai minimum dan maksimum pada data, sedangkan X_{norm} adalah nilai hasil normalisasi dalam rentang 0 hingga 1. Normalisasi ini penting agar gradien pada proses pelatihan GRU tidak didominasi oleh variabel dengan skala numerik lebih besar, serta mempercepat konvergensi model selama training.

2.7 Arsitektur Model Gated Recurrent Unit (GRU)

Model prediksi dibangun menggunakan arsitektur Sequential GRU melalui pustaka Keras (TensorFlow backend). Struktur arsitektur model terdiri dari enam lapisan utama, yaitu:

- Input Layer menerima data berbentuk matriks 3D (samples, timesteps, features) hasil dari tahap sliding window (60 timesteps).
- GRU Layer 1 50 unit, return_sequences=True, berfungsi menangkap dependensi temporal jangka panjang dan meneruskan seluruh urutan output ke lapisan berikutnya.
- Dropout Layer 1 rate 20%, mencegah overfitting dengan menonaktifkan sebagian neuron secara acak selama training.
- GRU Layer 2 50 unit, return_sequences=False, mengkompresi representasi temporal menjadi vektor konteks tunggal.
- Dropout Layer 2 rate 20%.
- Dense Layer (Output) 1 unit dengan fungsi aktivasi linear, menghasilkan prediksi nilai volatilitas skalar untuk t+1.

Pemilihan GRU dibandingkan LSTM didasarkan pada pertimbangan efisiensi komputasi. GRU hanya memiliki dua gerbang (reset gate dan update gate), lebih sederhana dibandingkan tiga gerbang pada LSTM, namun tetap mampu mempertahankan performa akurasi yang setara pada data finansial volatil, sebagaimana dikonfirmasi pada studi terdahulu.

2.8 Skenario Pengujian dan Validasi Data (Experimental Setup)

Dataset dibagi secara kronologis (bukan acak, guna menghindari data leakage pada time-series) dengan rasio 80:20, yaitu 80% data digunakan sebagai training set dan 20% sisanya sebagai testing set. Dari porsi data latih, 10% dialokasikan sebagai validation set untuk memantau kurva loss selama training dan mendeteksi potensi overfitting. Konfigurasi hyperparameter pelatihan model disajikan pada Tabel 2 berikut.

Tabel 2. Konfigurasi Hyperparameter Model

Parameter	Nilai
Loss Function	Mean Squared Error (MSE)
Optimizer	Adam
Epochs	50
Batch Size	32
Timesteps (Sliding Window)	60 hari
Validation Split	10% dari data latih

Untuk menguji kontribusi variabel indeks popularitas merek terhadap performa model, penelitian ini merancang dua skenario eksperimen komparatif, yaitu Skenario A (Baseline) di mana model GRU hanya menggunakan fitur finansial (OHLCV) dari Yahoo Finance, dan Skenario B (Proposed) di mana model GRU menggunakan fitur finansial yang diperkaya dengan indeks popularitas merek dari Google Trends. Perbandingan performa kedua skenario ini

menjadi dasar untuk menjawab tujuan penelitian kedua, yaitu menganalisis pengaruh integrasi variabel pemasaran digital terhadap akurasi prediksi.

2.9 Metrik Evaluasi Performa (*Evaluation Metrics*)

Evaluasi performa model dilakukan pada data uji menggunakan empat metrik statistik standar dalam riset prediksi time-series, sebagai berikut.

Mean Squared Error (MSE) mengukur rata-rata kuadrat selisih antara nilai aktual dan prediksi, sensitif terhadap outlier.

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

dengan y_i adalah nilai volatilitas aktual pada data ke- i , $\hat{y}_i$ adalah nilai volatilitas hasil prediksi model pada data ke- i , n adalah jumlah total data uji, dan $\bar{y}$ adalah nilai rata-rata dari seluruh data aktual.

Root Mean Squared Error (RMSE) akar dari MSE, dinyatakan dalam satuan yang sama dengan variabel target sehingga lebih mudah diinterpretasikan.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3)$$

Mean Absolute Error (MAE) rata-rata nilai absolut error, lebih robust terhadap outlier dibandingkan MSE/RMSE.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

R-Squared (R^2 Score) mengukur proporsi variansi data aktual yang mampu dijelaskan oleh model, dengan nilai mendekati 1 menunjukkan performa prediksi yang semakin baik.


$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5)$$

Keempat metrik ini digunakan secara komplementer: MSE dan RMSE untuk menilai besaran error secara umum, MAE untuk ketahanan terhadap outlier, dan R^2 untuk menilai kekuatan penjelas model secara keseluruhan, sejalan dengan tujuan penelitian ketiga.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan Model (Training Results)

Proses pelatihan model GRU dijalankan selama 50 epoch dengan batch size 32 dan validation split sebesar 10% dari data latih. Pada epoch pertama, nilai training loss tercatat sebesar 0.1862 dengan validation loss sebesar 0.1271. Nilai loss kemudian turun tajam pada epoch kedua menjadi 0.1047 (training) dan 0.0875 (validation), menandakan proses optimisasi bobot jaringan berjalan dengan baik pada tahap awal training. Memasuki epoch ke-10 hingga epoch ke-50, baik training loss maupun validation loss menunjukkan pola konvergen dan stabil pada kisaran 0.087–0.093, tanpa penurunan signifikan lebih lanjut. Pada epoch terakhir (epoch 50), tercatat training loss sebesar 0.0877 dan validation loss sebesar 0.0874, dengan selisih yang sangat tipis antara keduanya. Kurva loss pada Gambar 2 memperlihatkan bahwa validation loss secara konsisten berada sedikit di bawah atau sejajar dengan training loss sepanjang proses training, tanpa terjadi divergensi (celah yang melebar) antar kedua kurva. Pola ini mengindikasikan bahwa model tidak mengalami overfitting. Namun demikian, plateau loss yang terjadi sejak epoch awal ($\pm$ epoch ke-5) dan tidak kunjung turun signifikan hingga epoch ke-50 menunjukkan indikasi underfitting, yaitu kondisi di mana model belum mampu mempelajari pola kompleks yang terkandung dalam data secara optimal.



Gambar 2. Grafik Loss Selama Proses Training

3.2 Hasil Evaluasi Performa Model (Model Evaluation Results)

Setelah proses training selesai, model diuji menggunakan data uji (testing set) yang belum pernah dilihat model sebelumnya. Hasil evaluasi performa model terhadap keempat metrik yang telah ditetapkan pada bagian 3.6 disajikan pada Tabel 3 berikut.

Tabel 3. Hasil Evaluasi Performa Model GRU


Metrik	Nilai
Mean Squared Error (MSE)	0,0859
Root Mean Squared Error (RMSE)	0,2931
Mean Absolute Error (MAE)	0,2628
R-Squared (R^2 Score)	-0,0711

Nilai MSE dan RMSE yang diperoleh relatif rendah dalam skala data ternormalisasi (0–1), yang pada pandangan awal tampak menjanjikan. Akan tetapi, temuan yang lebih penting untuk diperhatikan adalah nilai R^2 Score sebesar -0,0711. Nilai R^2 negatif menunjukkan bahwa model prediksi yang dibangun berkinerja lebih buruk dibandingkan model dasar (baseline) yang hanya menebak nilai rata-rata (mean) dari data aktual. Dengan kata lain, secara statistik, GRU pada eksperimen ini belum berhasil mempelajari pola volatilitas yang sesungguhnya, meskipun nilai loss selama training tampak stabil dan rendah.

Fenomena ini menegaskan bahwa metrik loss (MSE) selama training semata tidak cukup untuk menilai kualitas prediksi suatu model time-series secara menyeluruh; metrik R^2 diperlukan untuk mengonfirmasi apakah model benar-benar menangkap variansi data aktual atau hanya mengarah pada nilai rata-rata.

3.3 Analisis Perbandingan Nilai Aktual dan Prediksi (Actual vs Predicted Analysis)

Untuk memahami lebih dalam pola kegagalan model dalam menangkap variansi data, dilakukan visualisasi perbandingan antara nilai volatilitas aktual dan hasil prediksi model pada data uji, sebagaimana disajikan pada Gambar 3.



Gambar 3. Komparasi Nilai Volatilitas Aktual vs Prediksi Model GRU

Grafik pada Gambar 3 memperlihatkan pola yang konsisten dengan nilai R^2 negatif pada Tabel 3. Garis prediksi (merah putus-putus) bergerak relatif datar di sekitar nilai 0,4–0,5 dan gagal mengikuti fluktuasi tajam pada data aktual (biru) yang berayun dari mendekati 0,0 hingga hampir 1,0 dalam rentang waktu yang singkat. Model cenderung menghasilkan prediksi yang mendekati nilai rata-rata historis, sebuah perilaku yang umum terjadi ketika model belum mampu mengekstraksi hubungan non-linear yang kompleks antar fitur input dan target volatilitas.

Beberapa faktor yang secara umum dapat menyebabkan kondisi tersebut antara lain: (1) representasi fitur input yang belum sepenuhnya menangkap dinamika pasar dan sentimen digital secara memadai, (2) kompleksitas arsitektur model yang relatif sederhana (dua lapisan GRU dengan 50 unit) sehingga kapasitas pembelajaran pola non-linear masih terbatas, dan (3) karakteristik data volatilitas saham yang secara inheren bersifat sangat stokastik (mendekati random walk pada rentang waktu pendek), sehingga sulit diprediksi hanya dari pola historisnya sendiri tanpa sinyal tambahan yang lebih kuat.

Temuan ini menjadi catatan penting bagi pengembangan model pada penelitian lanjutan, yaitu perlunya eksplorasi arsitektur yang lebih kompleks (misalnya penambahan lapisan, mekanisme attention, atau hybrid model), rekayasa fitur tambahan (feature engineering) yang lebih relevan, maupun evaluasi ulang terhadap kualitas dan granularitas data indeks popularitas merek yang digunakan sebagai variabel eksternal.

4. KESIMPULAN

Penelitian ini mengembangkan model Gated Recurrent Unit (GRU) multivariate untuk memprediksi volatilitas harga saham Amazon (AMZN) dengan mengintegrasikan data historis Yahoo Finance dan indeks popularitas merek dari Google Trends. Proses pelatihan menunjukkan konvergensi loss yang stabil tanpa indikasi overfitting, namun evaluasi pada data uji menghasilkan R^2 Score negatif (-0,0711), yang mengindikasikan model belum mampu menangkap variansi volatilitas aktual dan cenderung memprediksi nilai mendekati rata-rata historis. Temuan ini menunjukkan bahwa arsitektur GRU dua lapisan dengan representasi fitur saat ini masih terbatas dalam menangkap sifat stokastik volatilitas saham jangka pendek. Penelitian lanjutan disarankan untuk mengeksplorasi arsitektur yang lebih kompleks (mekanisme attention atau model hybrid), memperkaya rekayasa fitur eksternal, serta memastikan validitas pipeline data sebelum pelatihan model, guna menghasilkan model prediksi volatilitas yang lebih andal bagi pelaku investasi di sektor e-commerce.

REFERENCES

- [1] N. P. Novy, C. Dewi, D. Aditia, and D. Nasution, "Jurnal Pijar Studi Manajemen dan Bisnis Pentingnya Penerapan E-Commerce Bagi Umkm Sebagai Salah Satu Bentuk Pemasaran Digital Dalam Menghadapi Revolusi Industri 4.0," vol. 1, no. 3, pp. 566–577, 2023, [Online]. Available: <https://e-journal.naurendigiton.com/index.php/pmb>
- [2] F. Febriani and E. Yanti Nasution, "Analisis Adopsi Teknologi, Akses Pasar Digital, Dan Inovasi Produk Terhadap Daya Saing UMKM Di Era Transformasi Digital," 2025.
- [3] H. Rosyida, A. Firmansyah, and S. B. Wicaksono, "Volatilitas Harga Saham: Leverage, Ukuran Perusahaan, Pertumbuhan Aset," *JAS (Jurnal Akuntansi Syariah)*, vol. 4, no. 2, pp. 196–208, Dec. 2020, doi: 10.46367/jas.v4i2.256.
- [4] R. A. Nasution, A. Nafisa, S. Faitha, N. S. Darmawan, and A. Sofieta, "Menganalisa Expected Return Dan Standar Deviasi Pada Saham Lq45 Sektor E-Commerce," 2025.
- [5] M. Risiko, D. Investasi, and D. Perbankan, *Manajemen Risiko Keuangan*.
- [6] Muhammad Rifaldi, Sri Hartati, and Muhammad Alfin Vajriansyah, "Strategi Pemasaran Digital untuk Meningkatkan Brand Awareness di Era E-Commerce," *JURNAL Riset MANAJEMEN DAN EKONOMI (JRIME)*, vol. 3, no. 1, pp. 58–65, Dec. 2024, doi: 10.54066/jrime-itb.v3i1.2790.
- [7] S. Wibisono, W. Hadikurniawati, E. Lestariningsih, E. N. Wahyudi, and T. D. Cahyono, "Social Network Analysis untuk Peningkatan Popularitas Makanan Cepat Saji Menggunakan Metode PSI," 2024.
- [8] S. Budiman, "Strategi Pemasaran Digital Berbasis Evaluasi Kinerja Internal Guna Mengembangkan Bisnis Startup Era Baru," vol. 5, pp. 350–357, doi: 10.55903/juria.v5i1.405.
- [9] M. Faiq Abdi, "Implementasi Sistem Prediksi Saham Real-Time dengan Integrasi Yahoo Finance API dan Machine Learning di Google Colab: Analisis dan Evaluasi Performa Model," *TEKNOMATIKA*, vol. 15, no. 01, 2025.
- [10] "Pengaruh Volatilitas Harga Terhadap Inflasi Di Kota Malang : Pendekatan Model Arch/Garch Jurnal Ilmiah."
- [11] A. Rachman Andhika and E. Bayunanda, "Studi Literature Review Pemanfaatan Machine Learning Dalam Multisektor," *Integrative Perspectives of Social and Science Journal*, vol. 2, no. 3, p. 2025.
- [12] Y. Perdana *et al.*, "Analisis Perbandingan Model Gru Dan Lstm Untuk Prediksi Harga Saham Bank Rakyat Indonesia."
- [13] H. Romli, M. Febrianti Wulandari, and T. Sartika Pratiwi, "Faktor-Faktor Yang Mempengaruhi Volatilitas Harga Saham Pada Pt Waskita Karya Tbk", [Online]. Available: www.idx.co.id
- [14] P. Paulina, "Analisis Volatilitas Variabel Makroekonomi dan Harga Saham Menggunakan Generalized Autoregressive Conditional Heteroscedasticity (Garch Model)," *Jurnal Manajemen Strategi dan Aplikasi Bisnis*, vol. 5, no. 1, pp. 127–141, Jun. 2022, doi: 10.36407/jmsab.v5i1.533.
- [15] E. Rafulta, F. Yanuar, D. Devianto, and Maiyastri, "Pemodelan dan Peramalan Volatilitas Memori Panjang pada Return Saham ANTM Studi Komparatif Model GARCH dan FIGARCH," *Lattice Journal: Journal of Mathematics Education and Applied*, vol. 5, no. 1, pp. 75–89, Jun. 2025, doi: 10.30983/lattice.v5i1.9525.
- [16] untuk Menjawab Tantangan Pendidikan, Y. Hesta, and V. Mandailina, "Self-Supervised Pretraining untuk Deret Waktu Multivariat dalam Preadiksi Inflasi dan Nilai Tukar di Indonesia".
- [17] S. Juliardi Sinaga, S. Gultom, R. Manurung, and P. Dame Togatorop, "Implementasi Deep Learning Berbasis Recurrent Neural Network (Rnn) Untuk Memprediksi Kemampuan Pemecahan Masalah Matematis Siswa," 2026.
- [18] K. E. ArunKumar, D. V. Kalaga, C. Mohan Sai Kumar, M. Kawaji, and T. M. Brenza, "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*, vol. 61, no. 10, pp. 7585–7603, Oct. 2022, doi: 10.1016/j.aej.2022.01.011.
- [19] S. A. Hidayati, S. Wahyulina, and E. Suryani, "Pengaruh Financial Attitude Dan Financial Knowledge Terhadap Keputusan Keuangan Pada Pemilik Usaha Kecil Dan Menengah (Ukm) Di Pulau Lombok: Suatu Perspektif Behavioral Finance," *JURNAL SOSIAL EKONOMI DAN HUMANIORA*, vol. 6, no. 2, pp. 166–178, Dec. 2020, doi: 10.29303/jseh.v6i2.93.
- [20] L. Trilestari, N. A. Shovmayanti, D. Kurniawan, and A. Prakosa, "Pemanfaatan Google Trends Untuk Menganalisis Pola Penggunaan Media Sosial Di Indonesia."
- [21] D. Puspasari and R. Hadithya, "Pemanfaatan Sosial Media Marketing Melalui Konten pada Instagram dalam Upaya Meningkatkan Brand Image Sebuah Produk," *Jurnal Manajemen Bisnis dan Keuangan*, vol. 4, no. 2, pp. 239–252, Oct. 2023, doi: 10.51805/jmbk.v4i2.122.