

Penerapan GRU Dalam Memprediksi Harga Penutupan Saham Sektor Perbankan Berdasarkan Data Yahoo Finance

Ega Berto Ananta*, Sintia Artika, Arya Shadiwa, Imam Saputra

Program Studi S1 Manajemen, Sekolah Tinggi Ilmu Manajemen Sukma, Medan, Indonesia

Email: ^{1,*}egabertoananta@gmail.com, ²sintiaartika58@gmail.com, ³aryasahdiwa2@gmail.com, ⁴saputraimam69@gmail.com

(* : coresponding author)

Abstrak

Harga saham sektor perbankan memiliki peranan vital sebagai indikator stabilitas ekonomi, namun karakteristiknya yang fluktuatif dan non-linear sering kali menyulitkan analisis prediktif konvensional. Penelitian ini bertujuan untuk mengoptimalkan akurasi peramalan harga penutupan saham PT Bank Central Asia Tbk (BBCA.JK) dengan mengimplementasikan arsitektur *Deep Learning* berbasis *Gated Recurrent Unit* (GRU). Data historis yang digunakan mencakup rentang waktu harian dari 1 Januari 2020 hingga 31 Desember 2025, yang mencakup berbagai siklus pasar mulai dari fase krisis hingga fase koreksi. Metodologi penelitian dimulai dari pra-proses data menggunakan *MinMaxScaler* dan teknik *sliding window* (60 hari) untuk membentuk struktur *supervised learning*. Arsitektur GRU dikonfigurasi dengan dua lapisan tersembunyi berukuran 50 unit dan lapisan *Dropout* 20% untuk meminimalkan *overfitting*. Hasil eksperimen menunjukkan bahwa model GRU mampu mencapai titik konvergensi *loss* yang stabil dengan performa prediktif yang sangat akurat. Berdasarkan evaluasi pada data pengujian, model ini memperoleh nilai *Root Mean Squared Error* (RMSE) sebesar 213.39, *Mean Absolute Error* (MAE) sebesar 162.22, dan *Mean Absolute Percentage Error* (MAPE) sebesar 1.93%. Nilai MAPE yang berada di bawah ambang batas 10% mengklasifikasikan model ini ke dalam kategori *highly accurate forecasting*. Visualisasi hasil prediksi menunjukkan bahwa kurva model GRU mampu mengikuti fluktuasi harga aktual dengan sangat presisi, termasuk pada fase tren penurunan harga yang tajam. Hasil penelitian ini memberikan implikasi praktis bagi investor dan manajer investasi dalam mengoptimalkan strategi perdagangan dan mitigasi risiko berbasis data di pasar modal Indonesia.

Kata Kunci: Gated Recurrent Unit (GRU), Prediksi Harga Saham, Deep Learning, Deret Waktu (Time-Series), Highly Accurate Forecasting

1. PENDAHULUAN

Pasar modal memegang peranan yang sangat krusial dalam mengakselerasi roda perekonomian suatu negara melalui alokasi dana masyarakat ke sektor-sektor produktif. Di dalam dinamika Bursa Efek Indonesia, industri perbankan secara konsisten bertindak sebagai motor penggerak utama yang memiliki bobot kapitalisasi pasar terbesar serta tingkat likuiditas yang sangat tinggi [1]. Saham-saham perbankan berkategori *blue-chip*, seperti PT Bank Central Asia Tbk (BBCA), sering kali dijadikan sebagai acuan atau indikator utama oleh para investor domestik maupun institusi global untuk menilai kesehatan stabilitas finansial nasional [2]. Kendati demikian, pergerakan harga saham di sektor perbankan ini terkenal memiliki karakteristik yang sangat fluktuatif, kompleks, serta rentan terhadap perubahan sentimen pasar yang cepat [3]. Volatilitas yang melekat pada instrumen saham ini secara langsung berimplikasi pada tingginya risiko ketidakpastian yang harus dihadapi oleh para pelaku pasar modal setiap harinya. Oleh karena itu, kemampuan untuk memproyeksikan pergerakan harga saham di masa depan menjadi sebuah instrumen yang sangat vital bagi manajemen risiko investasi. Tanpa adanya alat bantu prediksi yang berbasis ilmiah, para pelaku pasar cenderung terjebak dalam spekulasi liar yang memperbesar potensi kerugian modal dalam skala besar. Fenomena inilah yang mendasari urgensi diperlukannya sebuah pendekatan kuantitatif yang cerdas, adaptif, dan mampu mengolah data historis keuangan secara objektif. Perkembangan teknologi komputasi dan informatika di era modern telah mengubah paradigma analisis finansial dari metode konvensional menuju pendekatan berbasis kecerdasan buatan. Analisis teknikal tradisional yang mengandalkan indikator statistik sederhana seperti *Moving Average* atau *Relative Strength Index* dinilai mulai kurang memadai dalam menangani kompleksitas data pasar saham modern [4]. Hal ini disebabkan oleh sifat dasar data harga saham yang tidak linear, mengandung banyak *noise*, serta memiliki ketergantungan temporal yang sangat kuat dari waktu ke waktu [5]. Menjawab tantangan tersebut, implementasi algoritma *Machine Learning* dan *Deep Learning* hadir sebagai solusi mutakhir yang menawarkan kapabilitas komputasi tingkat tinggi untuk mengekstrak pola tersembunyi [6]. Berbagai riset di bidang sains data telah membuktikan bahwa model berbasis jaringan saraf tiruan mampu melampaui performa model ekonometrika klasik dalam hal akurasi peramalan [7]. Melalui pemanfaatan platform berbasis *cloud* seperti Google Colab, para peneliti kini dapat melatih model arsitektur kecerdasan buatan yang kompleks secara efisien tanpa terkendala keterbatasan perangkat keras lokal. Pustaka terbuka seperti TensorFlow dan Keras juga semakin mempercepat siklus eksperimen dalam menguji berbagai macam konfigurasi model prediktif. Integrasi antara ilmu informatika dan sektor keuangan ini pada akhirnya menciptakan sebuah domain riset baru yang sangat dinamis dan aplikatif di industri *fintech*.

Dalam spektrum *Deep Learning* untuk data deret waktu (*time-series*), arsitektur *Recurrent Neural Network* (RNN) telah menjadi fondasi utama yang paling banyak diadopsi oleh para pengembang sistem [8]. RNN dirancang khusus dengan memori internal yang memungkinkan informasi masa lalu tetap tersimpan dan memengaruhi hasil prediksi pada urutan waktu berikutnya [9]. Namun, RNN konvensional memiliki kelemahan struktural yang

sangat fatal ketika dihadapkan pada data historis jangka panjang, yaitu masalah *vanishing gradient* [10]. Masalah ini menyebabkan model melupakan informasi penting yang terjadi pada periode-periode awal ketika proses *training* berjalan terlalu lama. Guna mengatasi keterbatasan mekanis tersebut, arsitektur *Long Short-Term Memory* (LSTM) diperkenalkan dengan memperkenalkan konsep *cell state* dan beberapa pintu gerbang informasi (*gates*) [11]. LSTM terbukti sukses mempertahankan informasi jangka panjang dan menjadi standar emas dalam prediksi volatilitas keuangan selama beberapa tahun terakhir. Meskipun demikian, kompleksitas struktural LSTM yang memiliki tiga buah *gate* menyebabkan proses komputasi menjadi sangat berat, memakan waktu lama, dan membutuhkan sumber daya memori yang besar. Hal ini mendorong ditemukannya arsitektur alternatif yang lebih efisien namun tetap mempertahankan keunggulan fungsionalitas dari LSTM tersebut.

Arsitektur *Gated Recurrent Unit* (GRU) muncul sebagai modifikasi mutakhir dari LSTM yang menawarkan struktur jauh lebih ringkas dan efisien tanpa mengorbankan performa akurasi secara signifikan [12]. GRU memangkas komponen internal dengan hanya menggunakan dua buah pintu gerbang, yaitu *update gate* dan *reset gate* [13]. *Reset gate* berfungsi untuk menentukan seberapa banyak informasi masa lalu yang harus dilupakan, sedangkan *update gate* mengontrol seberapa banyak informasi baru yang akan diteruskan ke tahap berikutnya. Pengurangan jumlah gerbang ini secara otomatis memotong jumlah parameter bobot yang harus dihitung oleh komputer selama proses pembelajaran berlangsung. Hasilnya, model GRU mampu melakukan konvergensi nilai kesalahan (*loss*) dengan durasi waktu *training* yang jauh lebih cepat dibandingkan dengan pendahulunya. Karakteristik GRU yang tangkas dan efisien ini sangat cocok diterapkan pada industri keuangan yang membutuhkan pemrosesan data secara cepat dan *real-time*. Keunggulan matematis inilah yang menjadikan GRU sebagai objek riset yang sangat menarik perhatian para akademisi di bidang informatika keuangan belakangan ini. Melalui penyederhanaan arsitektur ini, risiko terjadinya *overfitting* pada dataset yang tidak terlalu besar juga dapat diminimalisasi secara optimal.

Meskipun potensi teoritis dari algoritma GRU sudah banyak diakui, sebagian besar penelitian terdahulu masih menyisakan celah analisis (*gap analysis*) yang cukup signifikan. Banyak studi prediksi saham terdahulu menguji model mereka pada indeks pasar global yang memiliki karakteristik pasar yang sudah sangat matang dan cenderung stabil [14]. Karakteristik tersebut tentu sangat berbeda dengan kondisi pasar modal di negara berkembang seperti Indonesia yang cenderung memiliki volatilitas lebih tinggi dan rentan intervensi domestik. Selain itu, terdapat kecenderungan di mana peneliti terdahulu mengabaikan pentingnya penggunaan data historis yang mencakup fase krisis multidimensi yang ekstrem. Sebagai contoh, fluktuasi tajam harga saham perbankan pasca-pandemi global hingga dinamika pengetatan kebijakan moneter global sering kali dieksklusi dari rentang waktu eksperimen. Padahal, pengujian model pada fase pasar yang sedang mengalami tren penurunan (*downtrend*) ekstrem merupakan indikator validitas performa model yang sesungguhnya. Jurnal-jurnal mutakhir juga jarang yang berfokus secara spesifik membedakan saham perbankan *blue-chip* lokal dengan variasi parameter *sliding window* yang mendalam. Akibatnya, generalisasi model GRU standar sering kali dipertanyakan ketika langsung diimplementasikan pada sektor perbankan Indonesia yang memiliki sensitivitas makroekonomi yang unik.

Melalui identifikasi celah riset tersebut, bagian *state-of-the-art* (SOTA) dari penelitian ini difokuskan pada pengujian ketahanan (*robustness*) model GRU tunggal yang dioptimalkan pada data spesifik BBCEA.JK. Kebaruan (*novelty*) dari artikel ilmiah ini terletak pada pemanfaatan rentang data historis teraktual dari Yahoo Finance yang mencakup tahun 2020 hingga akhir tahun 2025. Rentang waktu ini sangat krusial karena merekam anomali pasar yang sangat lengkap, mulai dari kejatuhan pasar akibat krisis kesehatan, fase pemulihan ekonomi (*recovery*), hingga fase koreksi pasar yang terjadi pada tahun 2025. Kami mengonfigurasi struktur data menggunakan pendekatan *sliding window* berbasis 60 hari ke belakang untuk menangkap memori jangka pendek dan menengah secara presisi sebelum melakukan proyeksi satu hari ke depan. Penelitian ini juga menerapkan teknik normalisasi skala data yang ketat menggunakan komponen *MinMaxScaler* guna menghindari bias magnitudo harga. Berbeda dengan studi sejenis yang sekadar menampilkan hasil prediksi kasar, penelitian ini menyajikan visualisasi grafis performa model secara mendetail pada fase *downtrend*. Dengan demikian, tulisan ini memberikan kontribusi teoritis baru mengenai sejauh mana efisiensi struktur dua gerbang GRU dapat beradaptasi pada anomali pergerakan saham perbankan di Indonesia.

Urgensi dari pelaksanaan penelitian ini juga didorong oleh kebutuhan mendesak dari sisi praktisi keuangan dan manajer investasi terhadap sistem pendukung keputusan yang berbasis sains data. Selama ini, analisis peramalan harga saham di lingkungan lokal masih didominasi oleh pendekatan kualitatif atau pemodelan statistik linear yang kaku. Pendekatan kualitatif sangat rentan terhadap bias psikologis manusia, sementara model linear sering kali gagal menangkap lonjakan volatilitas mendadak di pasar modal [15]. Kegagalan sistem dalam memprediksi arah tren penurunan harga dapat berakibat pada hancurnya portofolio investasi yang dikelola oleh lembaga finansial. Kehadiran model berbasis *Deep Learning* seperti GRU diharapkan mampu menjembatani kesenjangan tersebut dengan menyediakan basis metrik evaluasi yang dapat dipertanggungjawabkan secara matematis. Akurasi prediksi yang dihasilkan oleh model ini dapat dimanfaatkan untuk menyusun algoritma perdagangan otomatis

(*algorithmic trading*) yang adaptif. Selain itu, hasil riset ini juga dapat menjadi bahan rujukan penting bagi regulator dalam mengawasi stabilitas transaksi saham di sektor perbankan nasional. Oleh karena itu, penggabungan aspek teoritis informatika dan aspek praktis keuangan dalam penelitian ini memiliki nilai kemanfaatan yang bersifat timbal balik.

Untuk menjamin objektivitas dan replikasi hasil penelitian, seluruh eksperimen komputasi dijalankan secara transparan menggunakan ekosistem Google Colab yang terintegrasi dengan akselerator perangkat keras GPU Tesla T4. Penggunaan GPU ini sangat esensial karena proses pembaruan bobot pada jaringan saraf GRU melibatkan operasi matriks berdimensi tinggi yang berulang [16]. Dengan memanfaatkan pustaka eksternal open-source seperti *yfinance*, integritas data historis yang bersumber langsung dari server Yahoo Finance dapat dijamin sepenuhnya terbebas dari kesalahan manipulasi manual. Data penutupan harga (*Close Price*) dipilih sebagai variabel tunggal utama karena mencerminkan konsensus akhir para pelaku pasar pada setiap hari perdagangan resmi [17]. Seluruh tahapan rekayasa data, mulai dari pembersihan data hilang (*handling missing values*), transformasi array, hingga pemisahan proporsi data training dan testing dilakukan secara sekuensial. Metodologi yang rigid ini sengaja dirancang agar hasil pengujian model tidak terjebak dalam masalah kebocoran data (*data leakage*) yang sering merusak validitas riset kecerdasan buatan. Evaluasi performa akhir model juga tidak hanya mengandalkan satu metrik saja, melainkan mengombinasikan tiga metrik standar internasional sekaligus.

Pengukuran performa akurasi model prediktif dalam riset ini diukur secara kuantitatif melalui perhitungan nilai *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE) [18]. RMSE digunakan untuk memberikan penalti yang lebih besar terhadap kesalahan prediksi yang fatal, sementara MAE mencerminkan rata-rata kesalahan absolut secara linear [19]. Di sisi lain, MAPE bertindak sebagai indikator utama yang paling disukai dalam dunia publikasi jurnal ilmiah karena menyajikan nilai kesalahan dalam bentuk persentase yang universal [20]. Nilai MAPE yang berada di bawah ambang batas tertentu akan menjadi bukti empiris kelayakan model GRU untuk diimplementasikan dalam skenario dunia nyata. Melalui kombinasi ketiga metrik tersebut, karakteristik kesalahan dari model GRU yang dibangun dapat dibedah secara komprehensif dari berbagai sudut pandang statistik. Pengujian performa ini dilakukan pada fase data testing yang mencakup 20% porsi dari total keseluruhan data historis yang tersedia. Hasil evaluasi inilah yang nantinya akan disajikan dalam bentuk tabel komparatif dan grafik visual multi-warna pada bab hasil dan pembahasan jurnal ini.

Secara umum, tujuan utama dari penulisan artikel ilmiah ini adalah untuk membangun, menguji, dan mengevaluasi keandalan model *Deep Learning* berbasis Gated Recurrent Unit (GRU) dalam memprediksi harga penutupan saham PT Bank Central Asia Tbk (BBCA.JK). Secara lebih spesifik, penelitian ini bertujuan untuk membuktikan efektivitas struktur dua gerbang (*update* dan *reset gate*) GRU dalam meminimalkan nilai *error* prediksi di tengah volatilitas pasar saham perbankan Indonesia yang tinggi. Tujuan berikutnya adalah menghasilkan sebuah visualisasi perbandingan model yang presisi yang dapat dimanfaatkan oleh para investor sebagai panduan praktis dalam mengambil keputusan beli atau jual aset. Melalui pencapaian tujuan-tujuan tersebut, diharapkan riset ini dapat memberikan kontribusi signifikan terhadap khazanah keilmuan informatika keuangan, khususnya dalam penerapan *machine learning* untuk pasar modal negara berkembang. Sistematika penulisan artikel ini selanjutnya akan disusun secara runtun mulai dari penjelasan metodologi penelitian secara detail, penyajian hasil eksperimen komputasi, pembahasan mendalam mengenai implikasi temuan, hingga penarikan kesimpulan serta saran untuk pengembangan riset di masa depan.

2. METODOLOGI PENELITIAN


2.1. Alur Penelitian (*Research Framework*)

Kerangka kerja penelitian ini disusun secara sistematis guna memastikan setiap tahapan eksperimen komputasi, mulai dari perumusan masalah hingga evaluasi model, berjalan secara terstruktur dan terkontrol. Pendekatan metodologis yang rigid sangat diperlukan dalam pemodelan *Deep Learning* berbasis runtun waktu untuk menghindari bias serta kesalahan fatal seperti kebocoran data (*data leakage*).

Secara umum, alur pelaksanaan penelitian ini dibagi ke dalam 6 (enam) tahapan utama yang digambarkan melalui diagram alir berikut:

Kerangka kerja penelitian ini disusun secara sistematis guna memastikan setiap tahapan eksperimen komputasi, mulai dari perumusan masalah hingga evaluasi model, berjalan secara terstruktur dan terkontrol. Pendekatan metodologis yang rigid sangat diperlukan dalam pemodelan *Deep Learning* berbasis runtun waktu untuk menghindari bias serta kesalahan fatal seperti kebocoran data (*data leakage*).

Secara umum, alur pelaksanaan penelitian ini dibagi ke dalam 6 (enam) tahapan utama yang digambarkan melalui diagram alir berikut:



Gambar 1. Alur penelitian

Tahap 1: Studi Literatur dan Perumusan Masalah Penelitian diawali dengan melakukan kajian pustaka mendalam terhadap jurnal-jurnal terakreditasi berskala nasional maupun internasional dalam kurun waktu 5 tahun terakhir. Fokus utama studi literatur ini adalah memetakan perkembangan arsitektur *Recurrent Neural Network* (RNN) dan modifikasinya, serta mengidentifikasi celah riset (*gap analysis*) terkait volatilitas saham sektor perbankan di Indonesia. Berdasarkan hasil kajian tersebut, dirumuskanlah masalah mengenai bagaimana mengoptimalkan model prediksi berbasis data runtun waktu yang efisien namun tetap akurat.

Tahap 2: Pengumpulan Data Historis Tahap berikutnya adalah melakukan akuisisi data sekunder berupa harga saham historis dari PT Bank Central Asia Tbk (BBCA.JK). Pengumpulan data dilakukan secara otomatis melalui pemanggilan API *open-source* Yahoo Finance menggunakan pustaka *yfinance* pada lingkungan Python. Data yang ditarik mencakup rentang waktu harian dari tanggal 1 Januari 2020 hingga 31 Desember 2025 guna mendapatkan representasi pergerakan harga yang komprehensif, mulai dari fase krisis ekonomi, pemulihan, hingga tren penurunan pasar.

Tahap 3: Pra-proses Data (*Data Preprocessing*) Data mentah yang telah diperoleh tidak dapat langsung dimasukkan ke dalam jaringan saraf tiruan, melainkan harus melewati tiga sub-proses standardisasi. Pertama, fitur harga penutupan (*Close Price*) diisolasi dan dinormalisasi ke dalam rentang skala 0 hingga 1 menggunakan metode *MinMaxScaler*. Kedua, array data ditransformasikan ke dalam format *supervised learning* dengan menerapkan metode *sliding window* berukuran 60 hari ke belakang sebagai fitur input (*X*) untuk memproyeksikan 1 hari ke depan sebagai target (*y*). Ketiga, dataset yang telah terstruktur dibagi secara sekuensial berdasarkan urutan waktu dengan proporsi 80% sebagai data pelatihan (*training data*) dan 20% sebagai data pengujian (*testing data*).

Tahap 4: Pemodelan dan Pelatihan Arsitektur GRU Pada tahap ini, arsitektur *Gated Recurrent Unit* (GRU) dibangun secara sekuensial menggunakan *framework* Keras/TensorFlow. Model dirancang dengan mengonfigurasi lapisan input, dua lapisan utama GRU yang masing-masing memiliki 50 *hidden units*, lapisan *Dropout* sebesar 20% untuk meminimalisasi risiko *overfitting*, serta diakhiri oleh sebuah lapisan *Dense* (lapisan *output*) dengan 1 neuron tunggal. Model kemudian dikompilasi menggunakan fungsi *loss Mean Squared Error* (MSE) dan dioptimalkan menggunakan *optimizer* Adam sebelum dilatih (*training*) sebanyak 20 *epochs* dengan ukuran *batch* (*batch size*) 32.

Tahap 5: Pengujian dan Prediksi Data Testing Setelah model GRU selesai dilatih dan mencapai titik konvergensi nilai *loss* yang minimum, model tersebut diuji menggunakan porsi data pengujian (20% data sisa) yang sama sekali belum pernah dikenali oleh model selama proses pelatihan. Hasil prediksi yang dikeluarkan oleh model GRU pada tahap ini masih berupa nilai pecahan desimal berskala 0 hingga 1. Oleh sebab itu, dilakukan proses denormalisasi (*inverse transform*) menggunakan parameter interpolasi *scaler* sebelumnya untuk mengembalikan nilai prediksi tersebut ke dalam satuan mata uang asli, yaitu Rupiah (IDR).

Tahap 6: Evaluasi Performa Model dan Visualisasi Tahap akhir dari alur penelitian ini adalah melakukan penilaian kualitas prediksi model secara kuantitatif dan kualitatif. Secara kuantitatif, ketepatan model diuji menggunakan tiga metrik evaluasi standar internasional, yaitu *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Secara kualitatif, dilakukan pembuatan visualisasi grafis multi-kurva yang memetakan pergerakan data *training*, data *testing* aktual, dan hasil proyeksi model GRU guna mempermudah analisis perilaku model di dalam bab hasil dan pembahasan.

2.2 Sumber dan Karakteristik Data (*Data Source and Collection*)

Data yang digunakan dalam penelitian ini sepenuhnya merupakan data sekunder berjenis runtun waktu (*time-series*) yang mencerminkan rekam jejak aktivitas transaksi harian di pasar modal. Data tersebut diakuisisi secara otomatis dari server Yahoo Finance sebuah platform penyedia data finansial global yang valid dan terintegrasi menggunakan pustaka (*library*) *open-source* *yfinance* pada bahasa pemrograman Python. Penarikan data dilakukan tanpa melibatkan manipulasi manual guna menjamin integritas, keaslian, serta akuntabilitas dataset sebelum memasuki tahapan pemodelan *Deep Learning*.

Objek spesifik yang dipilih dalam eksperimen ini adalah saham PT Bank Central Asia Tbk dengan kode emiten BBKA.JK. Pemilihan instrumen ini didasarkan pada signifikansi fundamental emiten yang bertindak sebagai saham dengan kapitalisasi pasar (*market capitalization*) terbesar di Bursa Efek Indonesia (BEI) sekaligus menjadi salah satu motor penggerak utama Indeks Harga Saham Gabungan (IHSG). Rentang waktu pengumpulan data ditetapkan secara sekuensial dari tanggal 1 Januari 2020 hingga 31 Desember 2025. Penetapan jendela waktu sepanjang 6 tahun ini dinilai sangat ideal untuk melatih jaringan saraf tiruan karena merekam anomali serta siklus pasar secara komprehensif, meliputi:

- Fase kejatuhan pasar akibat krisis kesehatan global (2020–2021).
- Fase pemulihan ekonomi nasional (*economic recovery*) dan pertumbuhan agresif (2022–2024).
- Fase koreksi pasar serta tren penurunan harga yang signifikan akibat dinamika moneter makro (2025).

Secara struktural, data mentah yang diunduh dari API Yahoo Finance terdiri dari 5 (lima) fitur numerik utama dan 1 (satu) fitur penanda waktu (*Date*) yang bertindak sebagai indeks. Karakteristik, definisi operasional, serta tipe data dari masing-masing variabel tersebut dijabarkan secara rinci pada Tabel 2.2 berikut:

Tabel 1. Struktur dan Karakteristik Fitur Dataset Saham BBKA.JK

No	Nama Fitur	Definisi Operasional	Tipe Data	Satuan
1	Date	Penanda waktu kalender bursa saat transaksi berlangsung (Format: YYYY-MM-DD).	Datetime	Indeks
2	Open	Harga pembukaan yang disepakati pada awal jam perdagangan resmi bursa.	Float64	Rupiah (IDR)
3	High	Titik harga tertinggi yang berhasil dicapai saham dalam satu hari perdagangan.	Float64	Rupiah (IDR)
4	Low	Titik harga terendah yang berhasil disentuh saham dalam satu hari perdagangan.	Float64	Rupiah (IDR)
5	Close	Harga penutupan resmi pada akhir jam perdagangan bursa (Variabel Target).	Float64	Rupiah (IDR)
6	Volume	Total volume lembar saham yang ditransaksikan antar pelaku pasar dalam sehari.	Int64	Lembar

Meskipun Yahoo Finance menyediakan lima fitur pergerakan harga dan volume, penelitian ini secara spesifik mengisolasi dan menetapkan fitur Close Price (Harga Penutupan) sebagai variabel tunggal utama yang diolah oleh algoritma *Gated Recurrent Unit* (GRU). Penetapan harga penutupan sebagai objek peramalan didukung oleh teori efisiensi pasar modal yang menyatakan bahwa harga akhir mencerminkan titik titik ekuilibrium tertinggi serta konsensus final dari seluruh pelaku pasar baik investor institusi maupun ritel setelah menyerap seluruh informasi makro dan mikro ekonomi yang beredar sepanjang hari tersebut. Total sampel data harian bersih yang berhasil dihimpun setelah melewati eliminasi hari libur resmi bursa (*non-trading days*) adalah sebanyak kurang lebih 1.450 baris data, jumlah yang sangat memadai untuk proses pembelajaran arsitektur *Deep Learning* jangka pendek.

2.3. Pra-proses Data (*Data Preprocessing*)

Sebelum dieksekusi oleh algoritma *Gated Recurrent Unit* (GRU), data harga penutupan saham mentah yang telah dikumpulkan tidak dapat langsung diumpankan ke dalam model jaringan saraf tiruan. Data deret waktu (*time-series*) finansial secara natural memiliki rentang nilai magnitudo yang besar, tingkat *noise* yang tinggi, dan variasi struktural yang membutuhkan penyesuaian khusus. Oleh karena itu, tahapan pra-proses data (*data preprocessing*)

dilakukan secara esensial melalui tiga mekanisme komputasi utama: normalisasi skala, restrukturisasi dimensi berbasis *sliding window*, dan pemisahan proporsi dataset secara kronologis.

2.3.1 Normalisasi Data (*Data Normalization*)

Model *Deep Learning*, khususnya arsitektur berbasis *Recurrent Neural Network* (RNN) seperti GRU, sangat sensitif terhadap skala nilai input matriks. Data harga saham BBKA.JK yang berada pada rentang ribuan (berkisar antara Rp3.600 hingga di atas Rp10.000) dapat memicu ketidakstabilan pada proses pembaruan bobot (*weight updates*) selama fase *training*, yang sering kali berujung pada masalah eksploitasi gradien (*exploding gradient*). Untuk mengatasi kendala matematis tersebut, fitur *Close Price* ditransformasikan ke dalam skala rasio 0 hingga 1 menggunakan metode *MinMaxScaler*. Persamaan matematis dari transformasi ini dirumuskan

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

representasi nilai data setelah dinormalisasi, X merupakan nilai harga penutupan aktual pada waktu tertentu, $X_{\min}$ adalah nilai harga penutupan terendah di dalam seluruh himpunan observasi, dan $X_{\max}$ adalah nilai harga penutupan tertinggi. Melalui normalisasi linier ini, proses konvergensi model untuk mencapai titik *error* yang minimum akan berjalan secara lebih efisien dan stabil.

2.3.2 Pembentukan *Sliding Window* (*Time-Series to Supervised Learning*)

Algoritma GRU beroperasi di bawah paradigma pembelajaran terarah (*supervised learning*), yang mengharuskan dataset memiliki pasangan fitur masukan (variabel independen/ X) dan fitur target (variabel dependen/ y). Mengingat data historis bursa saham pada dasarnya berbentuk deret waktu tunggal berdimensi satu, dataset harus direstrukturisasi secara artifisial menggunakan teknik *sliding window* (jendela geser). Pada penelitian ini, parameter ukuran jendela waktu (*window size*) ditetapkan sebesar 60 hari ($t=60$). Hal ini mengartikan bahwa model akan menggunakan pola pergerakan harga selama 60 hari perdagangan terakhir untuk memproyeksikan harga penutupan pada 1 hari berikutnya. Secara matematis, vektor input dan target pada titik waktu t direpresentasikan melalui rumus

$$X_t = [x_{\{t-60\}}, x_{\{t-59\}}, \dots, x_{\{t-1\}}] \quad (2)$$

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

Matriks berdimensi dua yang dihasilkan dari proses *sliding window* ini kemudian diubah bentuknya (*reshape*) ke dalam struktur array tiga dimensi dengan format [samples, time steps, features] (yaitu [jumlah sampel, 60, 1]) agar memenuhi standar spesifikasi tensor masukan pada pustaka komputasi TensorFlow/Keras.

2.3.3 Pembagian Dataset (*Data Splitting*)

Tahap krusial terakhir dari pra-proses adalah membagi dataset yang telah terstruktur ke dalam dua himpunan bagian yang independen, yakni data pelatihan (*training data*) dan data pengujian (*testing data*). Berbeda dengan pemodelan klasifikasi gambar atau teks di mana pembagian dapat dilakukan secara acak (*random shuffling*), partisi data deret waktu finansial mutlak dilakukan secara sekuensial (kronologis) guna menjaga urutan memori waktu. Penelitian ini menerapkan rasio pembagian data standar 80:20.

Sebanyak 80% data awal (tahun 2020 hingga pertengahan siklus) dialokasikan sebagai data pelatihan untuk mengajarkan jaringan saraf dalam mengenali tren, siklus, dan volatilitas pasar saham perbankan. Sementara itu, 20% porsi data sisa di bagian akhir observasi (yang mencakup fase koreksi harga saham pada tahun 2025) diisolasi murni sebagai data pengujian. Isolasi data yang ketat ini sangat krusial untuk mencegah terjadinya kebocoran informasi (*data leakage*), sehingga metrik evaluasi yang dihasilkan pada tahap akhir benar-benar merepresentasikan ketangguhan (*robustness*) model GRU dalam menghadapi kondisi pasar di dunia nyata yang belum pernah dilihat sebelumnya (*unseen data*).

2.4 Arsitektur Model Gated Recurrent Unit (GRU)

Dalam memodelkan data deret waktu finansial yang sarat akan volatilitas, penelitian ini mengimplementasikan arsitektur *Gated Recurrent Unit* (GRU). GRU merupakan pengembangan mutakhir dari *Recurrent Neural Network* (RNN) tradisional yang dirancang secara khusus untuk mengatasi masalah gradien menghilang (*vanishing gradient problem*) saat memproses sekuens data yang panjang. Dibandingkan dengan *Long Short-Term Memory* (LSTM), GRU memiliki keunggulan dari segi efisiensi komputasi karena mereduksi jumlah pintu gerbang (*gates*) dari tiga menjadi dua, yaitu *Update Gate* dan *Reset Gate*, tanpa mengorbankan performa prediksi secara signifikan. Secara matematis, mekanisme aliran informasi di dalam sel memori GRU pada waktu t dikendalikan oleh fungsi-fungsi berikut:

- a. *Update Gate* (z_t) Gerbang pembaruan berfungsi untuk menentukan seberapa banyak informasi dari masa lalu (langkah waktu sebelumnya) yang perlu dipertahankan dan diteruskan ke masa depan. Persamaannya

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (4)$$

- b. *Reset Gate* (r_t) Gerbang pengaturan ulang bertugas memutuskan seberapa banyak informasi memori dari masa lalu yang tidak lagi relevan dan harus dilupakan oleh model. Persamaannya rumus

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (5)$$

- c. *Candidate Hidden State* ($\{h\}_t$) Ini merupakan representasi informasi memori baru yang diekstrak menggunakan fungsi aktivasi tangen hiperbolik, yang perhitungannya dikontrol oleh *Reset rumus*

$$\{h\}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t] + b) \quad (6)$$

- d. *Final Hidden State* (h_t) Keluaran akhir dari sel GRU pada waktu t , yang merupakan kombinasi linear antara memori masa lalu yang dipertahankan dan memori kandidat baru, dikendalikan oleh *Update rumus*

Keterangan variabel:

1. z_t : Nilai aktivasi *update gate* pada waktu t .
2. σ : Fungsi aktivasi sigmoid.
3. W_z : Matriks bobot yang terhubung dengan *update gate*.
4. h_{t-1} : *Hidden state* pada waktu sebelumnya.
5. x_t : Input data pada waktu t .
6. b_z : Vektor *bias* untuk *update gate*.

2.4.1 Konfigurasi Model Eksperimen

Berdasarkan landasan teoritis tersebut, rancang bangun jaringan saraf GRU pada penelitian ini disusun secara sekuensial (*Sequential Model*) menggunakan pustaka Keras/TensorFlow dengan spesifikasi topologi sebagai berikut:

- a. Lapisan Masukan (*Input Layer*): Menerima matriks data hasil *sliding window* dengan dimensi masukan tunggal (60, 1).
- b. Lapisan GRU Pertama: Terdiri dari 50 *hidden units* dengan parameter `return_sequences=True` agar keluaran dari setiap langkah waktu diteruskan secara utuh ke lapisan berikutnya.
- c. Lapisan *Dropout* Pertama: Ditetapkan dengan nilai probabilitas 0.2 (20%). Lapisan ini secara acak akan menonaktifkan 20% neuron selama proses pelatihan untuk mencegah jaringan terlalu menghafal data pelatihan (*overfitting*).
- d. Lapisan GRU Kedua: Terdiri dari 50 *hidden units* dengan parameter `return_sequences=False`, yang berarti lapisan ini hanya akan mengembalikan *hidden state* terakhir sebagai ringkasan fitur dari seluruh rangkaian waktu masukan.
- e. Lapisan *Dropout* Kedua: Ditetapkan sebesar 0.2 (20%) sebagai lapis perlindungan tambahan terhadap *overfitting*.
- f. Lapisan Keluaran (*Dense Layer*): Sebuah *fully connected layer* yang terdiri dari 1 neuron tanpa fungsi aktivasi tambahan (aktivasi linear), yang bertugas melakukan regresi untuk mengestimasi satu nilai kontinu, yaitu harga penutupan saham untuk hari berikutnya ($t+1$).

Untuk mengoptimalkan pembaruan bobot matriks selama fase pelatihan, model ini dikompilasi menggunakan fungsi kerugian *Mean Squared Error* (MSE) sebagai evaluator metrik internal, serta algoritma *Adam* (*Adaptive Moment Estimation*) sebagai *optimizer*. Penggunaan Adam dipilih karena kemampuannya dalam menyesuaikan laju pembelajaran (*learning rate*) secara dinamis pada setiap parameter, sehingga mempercepat model mencapai titik konvergensi lokal minimum.

2.5 Lingkungan Eksperimen Komputasi (*Experimental Setup*)

Untuk menjamin tingkat transparansi, validitas, dan reproduisibilitas dari hasil penelitian, seluruh tahapan eksperimen komputasi mulai dari ekstraksi data, prapemrosesan, hingga pelatihan dan evaluasi model jaringan saraf tiruan dijalankan pada lingkungan komputasi awan (*cloud computing*). Penggunaan infrastruktur berbasis *cloud* dipilih untuk mengatasi keterbatasan sumber daya perangkat keras lokal, terutama dalam menangani operasi perkalian matriks berdimensi tinggi yang intensif selama proses pelatihan algoritma *Deep Learning*. Rincian spesifikasi lingkungan eksperimen yang digunakan dalam penelitian ini dibagi menjadi tiga komponen utama, yaitu perangkat keras, perangkat lunak, dan parameter hiper (*hyperparameters*) pelatihan:

- a. Spesifikasi Perangkat Keras (*Hardware*) Eksperimen dieksekusi menggunakan layanan komputasi awan Google Colaboratory (Colab). Untuk mengakselerasi waktu komputasi (waktu konvergensi) model *Gated*

Recurrent Unit (GRU), lingkungan *runtime* dikonfigurasi dengan menggunakan akselerator perangkat keras *Graphics Processing Unit* (GPU).

1. Tipe GPU: NVIDIA Tesla T4
 2. Kapasitas Memori (RAM) Sistem: 12.67 GB
 3. Kapasitas Memori GPU: 16 GB GDDR6
- b. Spesifikasi Perangkat Lunak (*Software*) Seluruh baris kode algoritma dikembangkan menggunakan bahasa pemrograman Python versi 3.12. Eksekusi instruksi komputasi didukung oleh berbagai pustaka (*library*) *open-source* berstandar industri dengan rincian fungsionalitas sebagai berikut:
1. TensorFlow dan Keras: Bertindak sebagai *framework* utama (*backend*) dalam perancangan, kompilasi, dan pelatihan arsitektur jaringan saraf GRU.
 2. yfinance: Digunakan sebagai modul antarmuka pemrograman aplikasi (API) untuk mengunduh data deret waktu historis saham BBCA secara *real-time* dan otomatis dari server Yahoo Finance.
 3. Scikit-Learn: Dimanfaatkan untuk kebutuhan prapemrosesan data spesifik, yaitu normalisasi matriks menggunakan fungsi *MinMaxScaler* dan komputasi metrik evaluasi model (RMSE dan MAE).
 4. Pandas dan NumPy: Digunakan untuk manipulasi struktur data tingkat rendah, transformasi *array* multi-dimensi, dan operasi aljabar linier.
 5. Matplotlib: Diimplementasikan untuk merender visualisasi grafis, termasuk grafik perbandingan pergerakan harga aktual versus harga prediksi.
- c. Parameter Hiper Pelatihan (*Training Hyperparameters*), Untuk mengontrol bagaimana jaringan saraf belajar dari fungsi kerugian (*loss function*) selama fase *training*, model GRU diatur menggunakan konfigurasi parameter hiper statis. Konfigurasi ini diperoleh berdasarkan praktik terbaik (*best practices*) pada pemodelan prediksi deret waktu finansial:
1. Fungsi Kerugian (*Loss Function*): *Mean Squared Error* (MSE), dipilih karena memberikan penalti kuadratik yang lebih tegas terhadap *error* prediksi yang ekstrem (pencilan harga).
 2. Algoritma Optimasi (*Optimizer*): *Adam* (*Adaptive Moment Estimation*) digunakan untuk memperbarui bobot jaringan secara dinamis dengan efisiensi memori yang tinggi.
 3. Ukuran *Batch* (*Batch Size*): Ditetapkan sebesar 32 sampel per iterasi. Angka ini memberikan keseimbangan optimal antara kecepatan komputasi dan stabilitas pembaruan gradien.
 4. Jumlah *Epoch* (*Epochs*): Ditetapkan sebanyak 20 siklus pelatihan penuh (melewati seluruh data *training*). Jumlah ini terbukti cukup komprehensif bagi arsitektur GRU untuk mencapai titik konvergensi nilai kerugian terendah tanpa mengalami *overfitting* dini.

2.6. Metrik Evaluasi Performa

Tahap akhir dalam metodologi eksperimen ini adalah mengevaluasi keandalan dan akurasi prediksi dari model *Gated Recurrent Unit* (GRU) pada data pengujian (*testing data*). Proses peramalan harga saham merupakan masalah regresi, sehingga performa model tidak dapat diukur menggunakan akurasi klasifikasi, melainkan harus dinilai berdasarkan tingkat penyimpangan atau kesalahan (*error*) antara nilai harga yang diprediksi oleh model dengan nilai harga penutupan aktual di pasar.

Penelitian ini menggunakan tiga metrik pengukuran statistik standar yang diakui secara luas dalam literatur prediksi deret waktu (*time-series forecasting*), yaitu:

2.6.1 Root Mean Squared Error (RMSE)

RMSE mengukur standar deviasi dari residu (kesalahan prediksi). Metrik ini sangat berguna karena mengkuadratkan nilai *error* sebelum dirata-ratakan, sehingga memberikan penalti (bobot) yang lebih besar pada kesalahan prediksi yang berukuran besar atau ekstrem. Nilai RMSE yang semakin mendekati nol mengindikasikan bahwa model semakin akurat. Formulasi matematis RMSE didefinisikan rumus

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (7)$$

2.6.2 Mean Absolute Error (MAE)

Berbeda dengan RMSE yang memberikan penalti ekstra pada *error* besar, MAE mengukur rata-rata dari selisih absolut antara nilai prediksi dan nilai aktual secara linier. Metrik ini memberikan gambaran langsung mengenai seberapa besar rata-rata penyimpangan harga (dalam nominal mata uang Rupiah) yang dihasilkan oleh model. Formulasi matematis MAE dirumuskan

$$= (1 - z_t) \cdot h_{t-1} + z_t \cdot \tanh(W \cdot [r_t * h_{t-1}, x_t] + b) \quad (8)$$

2.6.3 Mean Absolute Percentage Error (MAPE)

MAPE mengukur tingkat kesalahan dalam bentuk persentase relatif terhadap nilai aktualnya. Metrik ini merupakan instrumen evaluasi yang paling esensial dalam penelitian ekonomi dan keuangan karena sifatnya yang universal dan mudah diinterpretasikan, tanpa terpengaruh oleh besaran skala data aktual. Menurut literatur statistik umum, nilai MAPE di bawah 10% menunjukkan bahwa model memiliki kemampuan peramalan yang sangat akurat (*highly accurate forecasting*). Persamaan matematis MAPE rumusnya

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tanh(h_t) \quad (9)$$

Di mana:

- h_t adalah *hidden state* pada waktu t .
- z_t adalah nilai aktivasi dari *update gate*.
- h_{t-1} adalah *hidden state* pada waktu sebelumnya.
- $\tanh(h_t)$ adalah kandidat *hidden state* (yang telah dihitung pada langkah sebelumnya).
- $\tanh$ adalah fungsi aktivasi *hyperbolic tangent*.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pra-proses Data (*Data Preprocessing Results*)

Tahapan pra-proses data merupakan landasan krusial sebelum melakukan pemodelan *Deep Learning*. Keberhasilan model dalam mengenali pola sangat bergantung pada kualitas dan struktur data yang diumpangkan. Pada penelitian ini, data historis pergerakan saham PT Bank Central Asia Tbk (BBCA.JK) berhasil diekstraksi secara utuh dari server Yahoo Finance melalui pustaka antarmuka pemrograman aplikasi (API) *yfinance*. Rentang waktu observasi yang diambil adalah dari 1 Januari 2020 hingga akhir tahun 2025. Setelah proses penarikan data selesai dan sistem secara otomatis mengeliminasi hari-hari libur bursa (*non-trading days*), diperoleh representasi data mentah awal yang memuat fitur-fitur perdagangan utama. Cuplikan lima baris pertama dari kumpulan data mentah tersebut disajikan pada Tabel 2.

Tabel 2. Cuplikan Data Mentah Historis Saham BBCA.JK

Date	Open (IDR)	High (IDR)	Low (IDR)	Close (IDR)	Volume (Lembar)
2020-01-02	5544.31	5614.70	5531.89	5540.17	49.445.000
2020-01-03	5589.85	5631.26	5569.15	5631.26	47.755.500
2020-01-06	5565.01	5589.85	5540.17	5577.43	27.300.000
2020-01-07	5577.43	5606.42	5573.29	5581.57	45.022.500
2020-01-08	5523.60	5585.71	5523.60	5531.89	53.692.500

Berdasarkan struktur data pada Tabel 1, penelitian ini kemudian mengisolasi fitur harga penutupan (*Close Price*) sebagai variabel fokus tunggal (univariat). Data harga penutupan tersebut kemudian ditransformasikan menggunakan metode *MinMaxScaler* untuk menekan rentang magnitudo harga ribuan Rupiah menjadi skala rasio antara 0 hingga 1. Transformasi ini berhasil dieksekusi tanpa mengubah distribusi intrinsik dan pola fluktuasi dari data aslinya.

Langkah selanjutnya adalah merestrukturisasi array data deret waktu yang bersifat sekuensial menjadi format *supervised learning* menggunakan algoritma *sliding window*. Dengan menetapkan parameter *window size* sebesar 60 hari ($t=60$), sistem berhasil memecah data tunggal menjadi pasangan variabel independen (X) yang berisi sekuens harga 60 hari ke belakang, dan variabel dependen (y) yang berisi target harga 1 hari ke depan. Tahap pra-proses diakhiri dengan melakukan pemisahan (*data splitting*) secara kronologis untuk menghindari kebocoran memori masa depan (*data leakage*). Berdasarkan skema rasio 80:20, himpunan data terbagi menjadi dua bagian operasional yang independen:

- Data Pelatihan (*Training Data*): Mengambil 80% porsi awal dari total himpunan data. Data ini ditransformasikan ke dalam struktur tensor tiga dimensi, menghasilkan bentuk matriks akhir untuk X_{train} yang siap diproses oleh lapisan GRU. Matriks ini mewakili pola pergerakan harga dari awal tahun 2020 hingga pertengahan siklus observasi.
- Data Pengujian (*Testing Data*): Mengambil 20% porsi akhir dari total himpunan data. Data ini disimpan secara terisolasi untuk digunakan secara eksklusif pada tahap akhir guna menguji ketahanan dan performa generalisasi model GRU pada fase pasar terbaru di tahun 2025.

3.2. Hasil Pelatihan Model (*Model Training Results*)

Setelah data berhasil diproses dan direstrukturisasi ke dalam format *supervised learning*, tahapan selanjutnya adalah melakukan inisiasi proses pembelajaran (pelatihan) pada arsitektur *Gated Recurrent Unit* (GRU). Model dilatih menggunakan *optimizer* Adam dengan fungsi objektif *Mean Squared Error* (MSE) untuk meminimalkan

selisih antara nilai prediksi dan target aktual. Eksperimen komputasi dijalankan sebanyak 20 siklus iterasi penuh (*epochs*) dengan parameter ukuran *batch* (*batch size*) sebesar 32 sampel per iterasi. Selama fase pelatihan berlangsung, model secara dinamis memperbarui bobot pada *Update Gate* dan *Reset Gate* untuk menyesuaikan diri dengan pola volatilitas data *training*. Tingkat keberhasilan proses pembelajaran ini diukur melalui metrik nilai kerugian (*loss value*) pada setiap akhir *epoch*. Ringkasan historis penurunan nilai *loss* dari proses pelatihan tersebut disajikan pada Tabel 3 berikut:

Tabel 3. Log Konvergensi Nilai *Loss* (MSE) selama Fase Pelatihan

Iterasi (Epoch)	Ukuran Batch	Nilai Loss (MSE)	Keterangan
Epoch 1	35/35	0.0436	Fase inisiasi, <i>error</i> masih tergolong tinggi.
Epoch 2	35/35	0.0057	Penurunan <i>error</i> terjadi secara drastis (konvergensi cepat).
Epoch 5	35/35	0.0035	Model mulai menstabilkan pembaruan bobot internal.
Epoch 10	35/35	0.0026	Pembelajaran pola volatilitas memori jangka pendek semakin presisi.
Epoch 15	35/35	0.0022	Nilai kerugian mencapai ekuilibrium (titik jenuh minimal).
Epoch 20	35/35	0.0022	Titik akhir konvergensi lokal optimal tanpa indikasi <i>overfitting</i> .

Berdasarkan data pada Tabel 2, dapat diobservasi bahwa model GRU menunjukkan performa konvergensi yang sangat sangat impresif dan efisien. Pada *Epoch* pertama, jaringan memulai pembelajaran dengan tingkat kesalahan awal sebesar 0.0436. Namun, berkat efisiensi mekanisme perhitungan gradien pada struktur dua gerbang GRU, nilai *loss* tersebut berhasil ditekan secara drastis menjadi 0.0057 hanya pada iterasi kedua. Seiring bertambahnya jumlah *epoch*, nilai *loss* terus mengalami penyusutan secara landai dan konsisten hingga akhirnya mencapai stabilitas minimum di angka 0.0022 pada *Epoch* ke-20. Fakta bahwa nilai *loss* mampu turun secara konstan tanpa mengalami lonjakan fluktuasi yang liar membuktikan dua hal krusial: pertama, konfigurasi lapisan tersembunyi (*hidden layers*) dan parameter *Dropout* sebesar 20% yang diterapkan berhasil mencegah model dari menghafal data secara buta (*overfitting*); kedua, arsitektur model terbukti sangat kapabel dalam mengekstrak fitur dan memori historis jangka panjang dari tren pergerakan saham BBKA. Keberhasilan pada fase pelatihan ini menjadi fondasi yang valid sebelum model diuji menggunakan sekumpulan data pengujian (*unseen data*).

3.3. Evaluasi Performa Model (*Model Performance Evaluation*)

Setelah model *Gated Recurrent Unit* (GRU) terbukti mampu mencapai titik konvergensi yang optimal pada fase pelatihan, tahap pengujian sesungguhnya dilakukan menggunakan 20% data sisa (*testing data*). Himpunan data pengujian ini sengaja diisolasi sejak awal eksperimen sehingga bertindak sebagai data yang sepenuhnya baru dan belum pernah dipelajari (*unseen data*) oleh jaringan saraf. Sebelum proses komputasi metrik evaluasi dilakukan, *output* prediksi dari model yang masih berada dalam rentang rasio 0 hingga 1 dikembalikan ke dalam skala nominal mata uang asli (Rupiah) melalui proses denormalisasi (*inverse transform*).

Kinerja arsitektur GRU dalam memproyeksikan harga penutupan saham BBKA.JK diukur secara objektif menggunakan tiga metrik statistik standar, yaitu *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE). Hasil kalkulasi dari ketiga instrumen evaluasi tersebut dirangkum pada Tabel 4 berikut

Tabel 4. Hasil Evaluasi Performa Model GRU pada Data Pengujian

Metrik Evaluasi	Nilai Perolehan	Satuan Ukur	Interpretasi Skala Kesalahan
<i>Root Mean Squared Error</i> (RMSE)	213.39	Rupiah (IDR)	Tingkat deviasi kuadratik minimum.
<i>Mean Absolute Error</i> (MAE)	162.22	Rupiah (IDR)	Rata-rata selisih harga absolut sangat kecil.
<i>Mean Absolute Percentage Error</i> (MAPE)	1.93%	Persentase (%)	Kategori peramalan sangat akurat.

Berdasarkan perolehan angka pada Tabel 3, model GRU menunjukkan keandalan prediktif yang sangat superior dalam meramalkan pergerakan saham perbankan. Secara nominal, nilai MAE sebesar 162.22 mengindikasikan bahwa rata-rata selisih antara harga prediksi sistem dengan harga penutupan aktual di pasar bursa hanya berkisar di angka Rp162 per lembar saham. Mengingat harga saham *blue-chip* BBKA berada pada rentang valuasi yang tinggi (berkisar antara Rp8.000 hingga Rp10.000-an pada periode pengujian), margin kesalahan absolut tersebut tergolong sangat marjinal dan tidak berdampak signifikan secara finansial. Di sisi lain, perolehan nilai RMSE sebesar 213.39 yang tidak terpaut terlalu jauh dari nilai MAE membuktikan bahwa model ini memiliki ketahanan (*robustness*) yang baik dan tidak menghasilkan prediksi pencilan (*outliers*) dengan nilai *error* yang ekstrem.

Lebih lanjut, pencapaian yang paling menonjol dari implementasi arsitektur ini dibuktikan oleh metrik MAPE. Hasil pengujian menunjukkan bahwa nilai MAPE yang dihasilkan hanyalah sebesar 1.93%. Merujuk pada literatur standar evaluasi peramalan statistik, nilai MAPE yang berada di bawah ambang batas 10% diklasifikasikan secara mutlak ke dalam kategori peramalan yang sangat akurat (*highly accurate forecasting*). Pencapaian kesalahan relatif di bawah 2% ini memberikan validasi empiris bahwa modifikasi dua gerbang informasi (*Update Gate* dan *Reset Gate*) pada struktur GRU terbukti sangat tangkas dan presisi dalam menangkap memori volatilitas, kelengkungan tren linier, maupun fluktuasi harian pada data saham sektor perbankan di Indonesia.

3.4. Analisis Visualisasi Prediksi Harga (*Prediction Visualization Analysis*)

Selain melalui metrik evaluasi kuantitatif, performa model *Gated Recurrent Unit* (GRU) dievaluasi secara kualitatif melalui representasi grafis untuk melihat bagaimana kurva hasil prediksi berinteraksi dengan data aktual. Visualisasi ini memetakan tiga komponen utama: data pelatihan (*training data*), data pengujian aktual (*actual testing data*), dan kurva hasil ramalan model (*GRU predicted data*). Grafik ini memberikan pemahaman intuitif mengenai sensitivitas model terhadap pola volatilitas saham BBKA.JK pada rentang waktu testing. Berdasarkan grafik hasil prediksi, dapat diamati bahwa kurva hasil prediksi model GRU (garis hijau putus-putus) menunjukkan tingkat keselarasan (*alignment*) yang sangat tinggi dengan kurva harga penutupan aktual (garis oranye). Beberapa poin analisis kritis dari hasil visualisasi tersebut adalah:

- Adaptabilitas Tren: Model GRU terbukti mampu mereplikasi pergerakan harga saham dengan sangat presisi, baik pada saat kondisi pasar sedang mengalami tren naik (*uptrend*) maupun saat terjadi koreksi tajam (*downtrend*). Hal ini menunjukkan bahwa memori jangka pendek dan menengah yang disimpan oleh *Update Gate* berhasil mengakomodasi perubahan arah tren pasar secara real-time.
- Sensitivitas terhadap Volatilitas: Meskipun terdapat *noise* pasar yang tinggi pada data pengujian, hasil prediksi model GRU tidak terlihat mengalami *lagging* (keterlambatan) yang signifikan dibandingkan harga aktual. Kurva prediksi tampak mampu mengikuti titik-titik balik (*turning points*) harga dengan cukup responsif, yang merupakan tantangan utama dalam peramalan data keuangan non-linear.
- Stabilitas Model: Tidak adanya celah (*gap*) yang lebar secara konsisten antara garis oranye dan garis hijau di sepanjang periode testing menegaskan bahwa model tidak terjebak dalam *overfitting*. Sebaliknya, model telah berhasil melakukan generalisasi terhadap pola-pola musiman dan volatilitas yang terkandung di dalam data historis, sehingga performanya tetap konsisten saat diaplikasikan pada fase pasar tahun 2025 yang relatif dinamis.

Visualisasi ini secara empiris mendukung hasil metrik MAPE (1.93%) yang telah dipaparkan sebelumnya. Keberhasilan model dalam membentuk kurva yang hampir berimpit dengan data aktual menegaskan bahwa arsitektur *Gated Recurrent Unit* merupakan solusi komputasi yang tepat untuk memodelkan aset finansial dengan volatilitas tinggi. Analisis ini memberikan keyakinan bahwa sistem prediksi yang dikembangkan tidak hanya sekadar menghitung angka statistik secara kaku, tetapi benar-benar mampu memahami "dinamika perilaku" saham BBKA.JK di pasar modal.

3.5. Implikasi Praktis bagi Investor (*Practical Implications*)

Temuan empiris dalam penelitian ini, khususnya akurasi prediksi model GRU yang mencapai nilai MAPE sebesar 1.93%, memberikan kontribusi signifikan tidak hanya dalam aspek teoretis informatika, melainkan juga dalam aspek praktis pengambilan keputusan di pasar modal. Bagi para pelaku pasar, mulai dari investor ritel hingga manajer investasi institusi, hasil penelitian ini membawa implikasi strategis sebagai berikut:

- Mitigasi Risiko melalui Sistem Pendukung Keputusan (*Decision Support System*), volatilitas yang melekat pada saham sektor perbankan seperti BBKA.JK sering kali memicu bias psikologis dalam pengambilan keputusan jual atau beli. Model GRU yang diusulkan dalam riset ini dapat diintegrasikan sebagai *Decision Support System* (DSS) untuk memberikan sinyal objektif berdasarkan data historis. Dengan tingkat kesalahan yang minimal, investor dapat menggunakan hasil ramalan satu hari ke depan sebagai referensi utama untuk menentukan *entry point* (saat harga diprediksi turun) atau *exit point* (saat harga diprediksi mencapai puncak), sehingga meminimalisasi potensi kerugian modal akibat spekulasi yang tidak berdasar.
- Optimalisasi Algoritma *Trading* Otomatis (*Algorithmic Trading*), dalam era perdagangan berbasis frekuensi tinggi (*high-frequency trading*), kecepatan dan akurasi adalah kunci utama. Arsitektur GRU yang efisien secara komputasi dengan waktu pelatihan yang jauh lebih singkat dibandingkan LSTM memungkinkan model ini untuk dilatih ulang (*retraining*) secara berkala dengan data yang paling baru. Implikasinya, sistem ini dapat diimplementasikan ke dalam *platform trading* otomatis untuk melakukan eksekusi order secara *real-time* dengan akurasi arah tren yang telah tervalidasi, sehingga meningkatkan efisiensi eksekusi portofolio secara keseluruhan.
- Alat Bantu Analisis untuk Regulator dan Analis Keuangan, bagi analis keuangan dan pihak regulator bursa, kemampuan model GRU dalam mengikuti tren penurunan (*downtrend*) yang ekstrem pada tahun 2025 menjadi indikator yang berguna untuk pemantauan stabilitas pasar. Hasil prediksi yang presisi dapat digunakan untuk

menyusun skenario *stress test* pada portofolio perbankan, membantu memetakan respons pasar terhadap kebijakan makroekonomi, serta memantau anomali pergerakan harga yang mungkin mengindikasikan adanya manipulasi pasar atau kepanikan massal (*panic selling*).

- d. Penyelarasan Strategi Investasi dengan Data Kuantitatif, penelitian ini membuktikan bahwa integrasi teknologi *Deep Learning* mampu menangkap pola non-linear yang tidak terlihat oleh indikator analisis teknikal konvensional (seperti *Moving Average* atau *RSI*). Oleh karena itu, para investor disarankan untuk mengadopsi pendekatan hibrida, di mana analisis fundamental tetap menjadi dasar pemilihan aset (*asset picking*), namun keputusan waktu eksekusi (*market timing*) diserahkan pada model prediktif berbasis *Artificial Intelligence*. Pendekatan ini diharapkan dapat memberikan keunggulan kompetitif (*competitive advantage*) yang lebih baik dibandingkan dengan strategi *buy-and-hold* tradisional, terutama di tengah kondisi pasar yang sedang fluktuatif.

4.KESIMPULAN

Penelitian ini berhasil membuktikan bahwa arsitektur *Gated Recurrent Unit* (GRU) merupakan solusi komputasi yang sangat efektif dan tangguh dalam memprediksi volatilitas harga saham PT Bank Central Asia Tbk (BBCA.JK) pada periode 2020–2025. Melalui penerapan *sliding window* 60 hari dan optimalisasi struktur dua lapisan *hidden units* dengan *dropout* 20%, model yang dikembangkan menunjukkan performa generalisasi yang superior dengan nilai MAPE mencapai 1.93%, yang mengklasifikasikan sistem ini ke dalam kategori peramalan sangat akurat (*highly accurate forecasting*). Hasil evaluasi kuantitatif dan analisis visual secara konsisten menunjukkan bahwa mekanisme *Update Gate* dan *Reset Gate* pada GRU mampu menangkap dinamika tren pasar serta fluktuasi non-linear secara presisi, bahkan dalam kondisi koreksi harga yang ekstrem di tahun 2025. Secara praktis, tingkat akurasi yang tinggi ini memberikan implikasi strategis bagi investor sebagai sistem pendukung keputusan yang objektif dalam menentukan waktu eksekusi transaksi yang lebih terukur, sekaligus memitigasi risiko akibat bias spekulatif. Temuan ini menegaskan bahwa integrasi teknologi *Deep Learning* mampu memberikan keunggulan kompetitif yang signifikan dibandingkan metode analisis teknikal konvensional, sehingga sangat potensial untuk diimplementasikan dalam sistem perdagangan otomatis maupun analisis pasar modal yang lebih efisien di Indonesia.

REFERENCES

- [1] A. Roosmawarni, D. Fatihudin, and N. Mauliddah, "Market Capitalisation and Financial Performance: Evidence from Banking Listed Company in Indonesia," *J. Anal. Bisnis Ekon.*, vol. 20, no. 2, pp. 124–136, Jan. 2023, doi: 10.31603/bisnisekonomi.v20i2.7835.
- [2] M. K. Dandi and R. Kurniawan, "Sistem Rekomendasi Pemilihan Saham Blue-Chip di Bursa Efek Indonesia Menggunakan Fuzzy Mamdani," *TIN Terap. Inform. Nusantara*, vol. 6, no. 5, pp. 472–482, Oct. 2025, doi: 10.47065/tin.v6i5.8465.
- [3] M. P.-J. Ekonomi, B. dan Pendidikan, and U. 2025, "Indeks Harga Saham Sub-Sektor Perbankan Dan Indikator Ekonomi Makro Di Tengah Optimisme Pertumbuhan Ekonomi Indonesia," 2025. [Online]. Available: <https://journal3.um.ac.id/index.php/fe/article/view/7363>
- [4] F. Hanggoro, D. Aryanto, R. Hajar, P. Sejati, and I. Sanjaya, "Pengembangan Sistem Prediksi Saham Menggunakan Model Hybrid Gated Recurrent Unit–Long Short-Term Memory Berbasis Integrasi Indikator Teknikal Konvensional," *TIN Terap. Inform. Nusantara*, vol. 6, no. 8, pp. 1296–1307, Jan. 2026, doi: 10.47065/TIN.V6I8.8988.
- [5] M. Arya, A. Yoga, and A. Perdana, "Optimasi Hyperparameter Bi-Directional Long Short Term Memory Menggunakan Particle Swarm Optimization Untuk Prediksi Saham BBRI," *Sienna*, vol. 7, no. 1, pp. 21–36, Jun. 2026, doi: 10.47637/SIENNA.V7I1.2320.
- [6] M. A. Kusuma and Y. Fatma, "Literature Review: Metode Machine Learning dan Deep Learning dalam Prediksi Indeks Harga Saham Gabungan (IHSG)," *J. Tek. Inform. dan Teknol. Inf.*, vol. 6, no. 2, pp. 82–99, Jun. 2026, doi: 10.55606/JUTITI.V6I2.7331.
- [7] C. T. Utari, M. T. A. P. Sembiring, and M. H. R. Z. Siregar, "Analisis Komparasi Algoritma ARIMA dan LSTM pada Prediksi Harga Cabai Merah Keriting Harian," *Build. Informatics, Technol. Sci.*, vol. 7, no. 3, pp. 1932–1942, Dec. 2025, doi: 10.47065/BITS.V7I3.8784.
- [8] S. Rikukawa, H. Mori, and T. Harada, "Recurrent neural network based stock price prediction using multiple stock brands," *Int. J. Innov. Comput. Inf. Control*, vol. 16, no. 3, pp. 1093–1099, 2020, doi: 10.24507/IJICIC.16.03.1093.
- [9] N. A. Fitriani and I. Sultan Agung, "Perbandingan Metode Recurrent Neural Network dan Long Short Term Memory Untuk Prediksi Harga Saham Bank Mandiri," *Nusant. Eng.*, vol. 8, no. 02, pp. 465–671, Oct. 2025, doi: 10.29407/NOE.V8I02.24661.
- [10] Hermansah, M. Muhajir, and P. C. Rodrigues, "Indonesian Inflation Forecasting with Recurrent Neural Network Long Short-Term Memory (RNN-LSTM)," *Enthusiastic Int. J. Appl. Stat. Data Sci.*, pp. 132–142, Oct. 2024, doi: 10.20885/ENTHUSIASTIC.VOL4.ISS2.ART5.
- [11] D. P. A. Remetwa, L. Cahyadi, F. V. Ferdinand, K. V. I. Saputra, and K. Teja, "Analysis Of Long Short – Term Memory (Lstm) Parameters In Predicting Ihsg," *JOHME J. Holist. Math. Educ.*, vol. 9, no. 2, pp. 213–224, Dec. 2025, doi: 10.19166/JOHME.V9I2.10220.
- [12] M. A. R. Aziis, Wiranto, and Arif Rohmadi, "A model for determining stock purchase decisions based on gated recurrent units and decision tree C4.5," *J. Soft Comput. Explor.*, vol. 7, no. 2, pp. 391–401, Jun. 2026, doi: 10.52465/JOSCEX.V7I2.133.
- [13] A. Prasetya Wibawa *et al.*, "Gated Recurrent Unit (GRU) for Forecasting Hourly Energy Fluctuations," *Front. Energy Syst.*

ISSN 2962-7966 (media online)

Vol 4 No 1, Hal: 380-392

- Power Eng.*, vol. 5, no. 1, pp. 16–25, Jun. 2024, doi: 10.17977/UM049V5I1P16-25.
- [14] D. U. Iswavigra, V. D. Setiawan, M. Ulfa, and B. Ommr, "Sentiment Analysis Using Bidirectional Encoder Representations from Transformers for Indonesian Stock Price Prediction with Long Short-Term Memory and Gated Recurrent Unit Models," *J. Tek. Inform.*, vol. 7, no. 2, pp. 961–976, Apr. 2026, doi: 10.52436/1.JUTIF.2026.7.2.5383.
 - [15] G. B. Suhandi *et al.*, "Analisis Arima Pada Peramalan Harga Saham PT Bank Central Asia Tbk (BBCA) Ditengah Ketidakpastian Ekonomi Global Periode 2021-2026," *J. BISNIS DAN Akunt. UNSURYA*, vol. 11, no. 1, pp. 176–187, Jun. 2026, doi: 10.35968/JBAU.V11I1.2058.
 - [16] J. D. Guerrero Balaguera, J. E. Rodriguez Condia, and M. Sonza Reorda, "Effective Fault Effects Evaluation for Permanent Faults in GPUs executing DNNs," *ACM Trans. Des. Autom. Electron. Syst.*, vol. 30, no. 2, Feb. 2025, doi: 10.1145/3715327.
 - [17] I. Navila, N. Q. Nada, and R. Renaldy, "Banking Stock Price Prediction Dashboard Using Long Short-Term Memory," *J. Tek. Inform.*, vol. 7, no. 2, pp. 2008–2022, Apr. 2026, doi: 10.52436/1.JUTIF.2026.7.2.5802.
 - [18] A. M. Priyatno, L. S. Tanjung, W. F. Ramadhan, P. Cholidhazia, P. Z. Jati, and F. I. Firmananda, "Comparison Random Forest Regression and Linear Regression For Forecasting BBCA Stock Price," *J. Tek. Ind. Terintegrasi*, vol. 6, no. 3, pp. 718–732, Jul. 2023, doi: 10.31004/JUTIN.V6I3.16933.
 - [19] E. C. Wibowo and A. D. Cahyono, "Comparative Analysis of Linear Regression and Neural Network Algorithms for Stock Price Prediction," *SISTEMASI*, vol. 14, no. 4, p. 1879, Jul. 2025, doi: 10.32520/STMSI.V14I4.5325.
 - [20] B. Labibah, R. G. Guntara, and S. S. Maesaroh, "Kombinasi Inisialisasi Hyperparameter dan Algoritma Adam untuk Optimasi Model Gated Recurrent Unit dalam Meramalkan Harga Penutupan Saham Pasca Isu Boikot," *Build. Informatics, Technol. Sci.*, vol. 6, no. 3, pp. 1547–1558-1547–1558, Dec. 2024, doi: 10.47065/BITS.V6I3.6202.