

Peningkatan akurasi prediksi saham BBCA menggunakan arsitektur hybrid LSTM-GRU berbasis optimasi algoritma genetika

Mordekhai Gerine Lumangkun*, Made Hanindia Prami Swari, Andreas Nugroho Sihananto

Program Studi Informatika, Fakultas Ilmu Komputer, Universitas Pembangunan Nasional "Veteran" Jawa Timur
*Email: 20081010041@student.upnjatim.ac.id

Abstrak

Prediksi harga saham di sektor perbankan, khususnya pada saham berkapitalisasi besar seperti Bank Central Asia (BBCA), memiliki tantangan tersendiri akibat volatilitas pasar yang dinamis. Model *Hybrid LSTM-GRU* diketahui efektif dalam menangkap pola data *time-series*, namun performanya sangat bergantung pada pemilihan *hyperparameter* yang optimal. Penelitian ini bertujuan untuk mengimplementasikan Algoritma Genetika (GA) guna mengoptimasi *hyperparameter* model *Hybrid LSTM-GRU* secara otomatis demi meningkatkan akurasi prediksi harga penutupan saham BBCA. Metode yang digunakan meliputi pengumpulan data historis BBCA, *preprocessing*, dan pencarian *hyperparameter* terbaik (mencakup *learning rate*, *batch size*, *hidden units*, dan *dropout*) menggunakan GA dengan populasi 20 dan 80 generasi. Hasil penelitian menunjukkan bahwa GA berhasil mengidentifikasi konfigurasi optimal dengan *learning rate* 0.004 dan *batch size* 16. Model yang dioptimasi menghasilkan RMSE sebesar 149.77 dan MAPE 1.29%, mengungguli model *baseline* yang memiliki RMSE 180.38 dan MAPE 1.61%. Optimasi ini berhasil menurunkan tingkat kesalahan prediksi secara signifikan, membuktikan bahwa integrasi Algoritma Genetika mampu menghasilkan model peramalan saham yang lebih akurat dan *robust*.

Kata Kunci: algoritma genetika; BBCA; hybrid LSTM-GRU; optimasi hyperparameter; prediksi saham

The enhancing BBCA stock prediction accuracy using genetic algorithm-optimized hybrid LSTM-GRU architecture

Abstract

Predicting stock prices in the banking sector, particularly for high-capitalization stocks such as Bank Central Asia (BBCA), presents challenges due to dynamic market volatility. While Hybrid LSTM-GRU models are effective in capturing time-series data patterns, their performance relies heavily on optimal hyperparameter selection. This study aims to implement a Genetic Algorithm (GA) to automatically optimize the hyperparameters of a Hybrid LSTM-GRU model to enhance the prediction accuracy of BBCA stock closing prices. The method involved collecting BBCA historical data, preprocessing, and searching for the best hyperparameters (including learning rate, batch size, hidden units, and dropout) using GA with a population of 20 and 80 generations. The results showed that GA successfully identified the optimal configuration with a learning rate of 0.004 and a batch size of 16. The optimized model achieved an RMSE of 149.77 and a MAPE of 1.29%, significantly outperforming the baseline model, which yielded an RMSE of 180.38 and a MAPE of 1.61%. This optimization effectively reduced prediction errors, demonstrating that integrating the Genetic Algorithm yields a more accurate and robust stock forecasting model.

Keywords: BBCA; genetic algorithm; Hybrid LSTM-GRU; hyperparameter optimization; stock prediction

1. Pendahuluan

Pasar modal memegang peranan vital dalam arsitektur ekonomi modern sebagai mesin penggerak pertumbuhan nasional, memfasilitasi alokasi modal yang efisien serta menjadi sarana investasi strategis. Di Indonesia, lanskap investasi mengalami transformasi signifikan dalam beberapa tahun terakhir, ditandai dengan lonjakan partisipasi investor ritel dan mahasiswa. Fenomena ini didorong oleh peningkatan literasi keuangan yang masif serta proliferasi platform investasi digital yang mendemokratisasi akses terhadap berbagai instrumen keuangan (Ghojogh & Ghodsi, 2023), (Gusnindar & Syafri, 2023). Di tengah ragam pilihan investasi, sektor perbankan tetap menjadi primadona karena likuiditasnya yang tinggi dan kapitalisasi pasar yang substansial. Secara khusus, PT Bank Central Asia

Tbk (BBCA) menempati posisi sentral sebagai salah satu emiten terbesar dalam indeks LQ45, sering kali dianggap sebagai barometer stabilitas ekonomi nasional. Pergerakan harga saham BBCA sangat dinamis, dipengaruhi oleh interaksi kompleks antara kondisi makroekonomi global, kebijakan moneter domestik, dan kinerja fundamental perusahaan (Sadikin & Agustina, 2023).

Kendati menawarkan potensi imbal hasil yang menarik, investasi saham secara inheren mengandung risiko tinggi akibat volatilitas harga yang dipengaruhi oleh faktor stokastik dan non-linear. Oleh karena itu, kemampuan untuk memprediksi pergerakan harga saham secara akurat menjadi kebutuhan mendesak bagi investor guna memitigasi risiko dan merumuskan strategi perdagangan yang efektif (Sarah & Dasman, 2023). Dalam upaya peramalan finansial, metode statistik konvensional seperti *Autoregressive Integrated Moving Average* (ARIMA) telah lama digunakan. Namun, metode ini sering kali memiliki keterbatasan dalam menangkap pola non-linear yang kompleks dan fluktuasi dinamis yang melekat pada data pasar saham (Laksma Pradana, 2025). Keterbatasan ini memicu pergeseran paradigma menuju pendekatan *Deep Learning*, khususnya *Recurrent Neural Networks* (RNN) yang dirancang untuk memproses data sekuensial. Sayangnya, RNN standar menghadapi kendala teknis berupa masalah *vanishing gradient*, yang menghambat kemampuannya dalam mempelajari ketergantungan jangka panjang dari data historis (Fadziso, 2020).

Untuk mengatasi kelemahan tersebut, dikembangkan varian arsitektur yang lebih canggih, yakni *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). LSTM menggunakan mekanisme gerbang memori (*memory cells*) untuk mempertahankan informasi dalam jangka waktu lama, sementara GRU menawarkan struktur yang lebih efisien secara komputasi (Ghojogh & Ghodsi, 2023). Perkembangan literatur terkini menyoroti bahwa penggabungan kedua arsitektur ini menjadi model Hybrid LSTM-GRU dapat menghasilkan performa yang superior. Yunita et al. (2025) melakukan evaluasi komprehensif terhadap sembilan arsitektur jaringan saraf termasuk RNN, LSTM, GRU, dan enam konfigurasi hybrid pada berbagai dataset seperti data bintang matahari dan kasus Covid-19. Hasil studi tersebut menyimpulkan bahwa arsitektur hybrid, khususnya Hybrid LSTM-GRU, secara konsisten mengungguli model tunggal karena sinergi antara kapasitas memori jangka panjang LSTM dan efisiensi *gating* GRU. Hal ini menegaskan bahwa arsitektur hybrid merupakan solusi yang tangguh untuk menangkap pola dinamis pada data finansial yang fluktuatif (Farhadi et al., 2025).

Meskipun model *Deep Learning* seperti Hybrid LSTM-GRU menawarkan potensi akurasi yang tinggi, efektivitasnya sangat sensitif terhadap konfigurasi *hyperparameter* (seperti *learning rate*, *batch size*, *number of hidden units*, dan *dropout rate*). Pemilihan parameter yang tidak tepat dapat menyebabkan model mengalami *overfitting* atau *underfitting*, sehingga gagal melakukan generalisasi pada data baru. Urgensi optimasi ini ditunjukkan oleh Utami & Iqbal (2024) dalam studi prediksi harga saham BBCA. Penelitian mereka membuktikan bahwa model Hybrid LSTM-GRU yang dioptimasi menggunakan metode *Bayesian Optimization* mampu mencapai tingkat kesalahan yang sangat rendah, dengan *Root Mean Square Error* (RMSE) sebesar 0.013685 dan skor R2 mencapai 0.972467. Temuan ini menggarisbawahi bahwa potensi penuh dari arsitektur *deep learning* pada saham *blue chip* hanya dapat dicapai melalui metode penalaan parameter yang ketat dan sistematis (Franceschi et al., 2024). Pentingnya optimasi juga dikonfirmasi di sektor lain; (Sezgin et al., 2025) menunjukkan bahwa model GRU yang dioptimasi pada saham penerbangan mampu menekan *Mean Absolute Percentage Error* (MAPE) hingga 3.05%.

Sebagai solusi untuk tantangan optimasi *hyperparameter* yang kompleks dan berdimensi tinggi, Algoritma Genetika (GA) telah muncul sebagai pendekatan metaheuristik yang andal. Terinspirasi oleh prinsip evolusi biologis, GA mampu menavigasi ruang pencarian solusi secara efektif untuk menemukan konfigurasi global optimum. Penerapan GA untuk mengoptimasi model berbasis RNN telah terbukti secara konsisten meningkatkan performa prediksi. Sha (2024) menerapkan GA untuk mengoptimasi model LSTM dalam peramalan finansial, yang menghasilkan model dengan generalisasi kuat serta nilai *Mean Absolute Error* (MAE) sebesar 2.41 dan RMSE 3.13. Senada dengan itu, Al Haromainy et al. (2023) menemukan bahwa integrasi GA pada model berbasis RNN berhasil menurunkan RMSE menjadi 0.106 dibandingkan model *baseline* (0.108) menggunakan data historis sepuluh tahun. Fakta-fakta empiris ini mengindikasikan bahwa GA tidak hanya mereduksi *error*, tetapi juga memastikan model mampu menangkap tren dasar harga saham dengan lebih presisi (Rajwar et al., 2023).

Kendati efektivitas GA pada model tunggal dan keberhasilan optimasi Bayesian pada model hybrid telah terdokumentasi dengan baik, masih terdapat kesenjangan penelitian (*research gap*) yang signifikan. Hingga saat ini, belum banyak literatur yang secara spesifik mengintegrasikan Algoritma Genetika untuk mengoptimasi arsitektur Hybrid LSTM-GRU dalam konteks prediksi saham perbankan di pasar negara berkembang seperti Indonesia, khususnya pada saham BBCA. Penelitian ini bertujuan untuk mengisi celah tersebut dengan mengusulkan pendekatan baru: optimasi *hyperparameter* model Hybrid LSTM-GRU menggunakan Algoritma Genetika untuk memprediksi harga penutupan saham BBCA. Hipotesis penelitian ini adalah bahwa pendekatan evolusioner GA mampu mengidentifikasi kombinasi parameter yang lebih optimal dibandingkan model *baseline*, sehingga menghasilkan peningkatan akurasi prediksi yang signifikan serta model yang lebih *robust* terhadap volatilitas pasar.

2. Metode

Metodologi yang diterapkan dalam penelitian ini mengikuti kerangka kerja sistematis untuk mengoptimalkan model *Hybrid LSTM-GRU* menggunakan Algoritma Genetika (GA). Pendekatan ini dirancang untuk memastikan integrasi yang kohesif antara pemrosesan data *time-series* dan optimasi parameter evolusioner guna mencapai akurasi prediksi tertinggi pada saham PT Bank Central Asia Tbk (BBCA). Seluruh tahapan penelitian, mulai dari pengumpulan data hingga evaluasi, dijalankan secara terstruktur untuk menjamin validitas hasil eksperimen.

2.1. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini terdiri dari dua komponen utama, yaitu data harga saham dan rasio fundamental perusahaan. Komponen pertama mencakup data historis harian saham BBCA dari periode November 2020 hingga Juni 2025 yang diperoleh melalui teknik *web scraping* dari Yahoo Finance. Fitur utama yang diambil dari data ini meliputi *Open*, *High*, *Low*, *Close*, dan *Volume* yang merepresentasikan aktivitas perdagangan harian. Selain itu, komponen kedua melibatkan data rasio keuangan, khususnya *Return on Assets* (ROA) dan *Return on Equity* (ROE), yang bersumber dari publikasi Otoritas Jasa Keuangan (OJK) untuk melengkapi data teknikal dengan indikator kinerja internal emiten.

2.2. Pra-pemrosesan Data

Tahapan pra-pemrosesan data dilakukan melalui serangkaian langkah yang berkesinambungan untuk memastikan kualitas input bagi model *Deep Learning*. Proses ini diawali dengan penggabungan data (*Data Merging*) untuk mengintegrasikan data harga saham harian dengan data ROA dan ROE periodik agar indikator teknikal dan fundamental selaras dalam satu *timeline*. Selanjutnya, dilakukan penanganan *missing values* dengan mengimputasi nilai kosong yang disebabkan oleh hari libur bursa, yang bertujuan menjaga kontinuitas urutan waktu dalam analisis *time-series*. Setelah data utuh, dataset dibagi (*Data Splitting*) menjadi tiga subset dengan rasio 80:10:10, di mana 80% data dialokasikan untuk pelatihan (*training*), 10% untuk validasi (*validation*), dan 10% sisanya sebagai data uji (*testing*) (Sezgin et al., 2025). Langkah berikutnya adalah normalisasi fitur menggunakan *Min-Max Scaler* untuk memetakan seluruh nilai ke dalam rentang [0, 1] guna meminimalisir bias skala dan mempercepat konvergensi gradien selama pelatihan. Terakhir, dilakukan perurutan data (*Sequencing*) dengan mentransformasi data kontinu menjadi format *supervised learning* menggunakan teknik *sliding window* untuk memprediksi harga pada satu langkah waktu ke depan.

2.3. Arsitektur Model Hybrid LSTM-GRU

Inti dari sistem prediksi ini adalah arsitektur *Hybrid LSTM-GRU* yang secara sekuensial mengintegrasikan lapisan LSTM dan GRU. Lapisan LSTM ditempatkan pada tahap awal untuk memproses urutan input dan menangkap dependensi jangka panjang (*long-term dependencies*) menggunakan mekanisme sel memori. Secara matematis, operasi di dalam unit LSTM didefinisikan oleh persamaan (1) hingga (6) berikut (Sezgin et al., 2025):

$$i_t = \sigma(W_i [h_{t-1}, x_t] + b_i) \quad (1)$$

$$f_t = \sigma(W_f [h_{t-1}, x_t] + b_f) \quad (2)$$

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (3)$$

$$\tilde{c}_t = \tanh(W_c [h_{t-1}, x_t] + b_c) \quad (4)$$

$$c_t = (f_t * c_{t-1}) + (i_t * \tilde{c}_t) \quad (5)$$

$$h_t = o_t * \tanh(c_t) \quad (6)$$

Di mana i_t , f_t , dan o_t masing-masing merepresentasikan gerbang input, gerbang *forget*, dan gerbang output. Variabel adalah status sel (*cell state*) dan adalah status tersembunyi (*hidden state*) pada waktu . Setelah lapisan LSTM, diterapkan lapisan *Dropout* untuk mencegah *overfitting*. Fitur yang diekstraksi kemudian diteruskan ke lapisan GRU. Berbeda dengan LSTM, GRU memiliki arsitektur yang lebih ramping tanpa sel memori terpisah, hanya menggunakan gerbang *update* (z_t) dan gerbang *reset* (r_t) untuk menangkap fluktuasi jangka pendek secara efisien. Operasi GRU dinyatakan dalam persamaan (7) hingga (10) berikut (Sezgin et al., 2025):

$$r_t = \sigma(W_r h_{t-1} + U_r x_t + b_r) \quad (7)$$

$$z_t = \sigma(W_z h_{t-1} + U_z x_t + b_z) \quad (8)$$

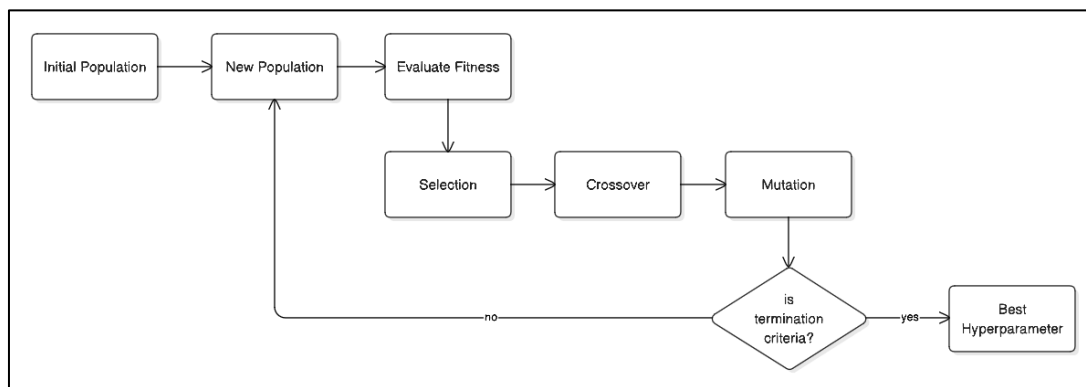
$$\tilde{h}_t = \tanh(W_c (r_t * h_{t-1}) + U_c x_t + b_c) \quad (9)$$

$$h_t = ((1 - z_t) * h_{t-1}) + (z_t * \tilde{h}_t) \quad (10)$$

Dengan menempatkan lapisan GRU setelah lapisan LSTM, model ini secara efektif menggabungkan konteks historis yang luas dengan dinamika pasar yang segera, sebuah sinergi yang telah ditemukan oleh studi sebelumnya sebagai metode yang efisien secara komputasi dan sangat akurat (Farhadi et al., 2025), (Yunita et al., 2025). Lapisan Dropout kedua diterapkan setelah pemrosesan GRU sebagai langkah regularisasi akhir sebelum data dimasukkan ke dalam lapisan Dense. Lapisan output yang sepenuhnya terhubung ini menggabungkan semua fitur yang dipelajari untuk menghasilkan nilai kontinu tunggal, yang mewakili harga penutupan saham yang diprediksi.

2.4. Optimasi Hyperparameter

Kinerja model *Hybrid LSTM-GRU* sangat sensitif terhadap *hyperparameter*-nya (misalnya, *learning rate* dan jumlah neuron). Penyetelan manual parameter ini seringkali tidak efisien dan rentan terhadap hasil sub-optimal (Franceschi et al., 2024). Untuk mengatasi hal ini, Algoritma Genetika (GA) digunakan untuk mencari konfigurasi *hyperparameter* optimal secara otomatis. Alur kerja lengkap dari proses optimasi ini digambarkan dalam Gambar 1.



Gambar 1. Flowchart Proses Algoritma Genetika

Proses optimasi mengikuti siklus sistematis. Dimulai dengan *Initial Population*, di mana algoritma menghasilkan populasi individu (kromosom). Setiap kromosom adalah vektor yang mewakili kombinasi spesifik dari *hyperparameter* yang diambil secara acak dari ruang pencarian yang ditentukan dalam Tabel 2. Selanjutnya, proses mengevaluasi *fitness* untuk menentukan kualitas setiap kromosom. Dalam penelitian ini, *fitness* didefinisikan sebagai akurasi prediksi model *Hybrid* pada Set Validasi. Secara khusus, algoritma berusaha meminimalkan *Root Mean Square Error* (RMSE), dengan RMSE yang lebih rendah menunjukkan individu yang "lebih bugar".

Setelah penilaian, evolusi berlanjut ke Seleksi untuk menentukan induk bagi generasi berikutnya. Strategi seleksi *hybrid* yang menggabungkan *Elitism* dan *Tournament Selection* diterapkan. *Elitism* memprioritaskan pelestarian solusi berkualitas tinggi, menyalin kromosom dengan kinerja terbaik (didefinisikan oleh *Elite Size*) langsung ke generasi berikutnya tanpa modifikasi, memastikan bahwa sifat genetik terbaik yang ditemukan sejauh ini tidak pernah hilang (Pahlawan, 2022). Untuk slot populasi yang tersisa, *Tournament Selection* digunakan: subset acak dari kromosom (didefinisikan oleh *Tournament Size*) dipilih, dan individu dengan *fitness* terbaik dalam kelompok itu dipilih sebagai induk. Kombinasi ini menjaga keragaman populasi sambil menjamin stabilitas konvergensi (Sha, 2024).

Untuk memastikan proses optimasi secara efektif menyeimbangkan eksplorasi dan eksploitasi, parameter Algoritma Genetika (GA) tertentu ditetapkan berdasarkan eksperimen pendahuluan. Parameter ini dirancang untuk memandu proses evolusi dan memastikan pencarian sistematis untuk solusi optimal. Konfigurasi lengkap GA yang digunakan dalam penelitian ini, termasuk ukuran populasi dan tingkat evolusi, dirinci dalam Tabel 1, yang menguraikan pengaturan utama yang mengatur perilaku algoritma selama proses optimasi.

Tabel 1. Parameter Algoritma Genetika

Parameter	Nilai
Population size	20
Generation size	80
Crossover rate	0.8
Mutation rate	0.2
Elite size	2
Tournament size	2

Selanjutnya, GA mengeksplorasi ruang *hyperparameter* yang telah ditentukan sebelumnya untuk mengidentifikasi konfigurasi optimal bagi model *Hybrid*. Ruang pencarian ini mencakup parameter kritis, termasuk *learning rate*, *batch size*, dan jumlah neuron di setiap lapisan. Dengan memvariasikan *hyperparameter* ini secara sistematis dalam batas-batas yang ditentukan, GA dapat mengevaluasi beberapa konfigurasi dan menentukan kombinasi yang menghasilkan kinerja terbaik untuk model *Hybrid LSTM-GRU*, sebagaimana diilustrasikan dalam Tabel 2.

Tabel 2. Ruang Pencarian Hyperparameter

Hyperparameter	Nilai
LSTM units	[32, 64, 128]
GRU units	[16, 32, 64]
Dropout rate	[0.1, 0.2, 0.3, 0.4, 0.5]
Learning rate	[0.001, 0.002, 0.003, 0.004, 0.005]
Batch size	[16, 24, 32]

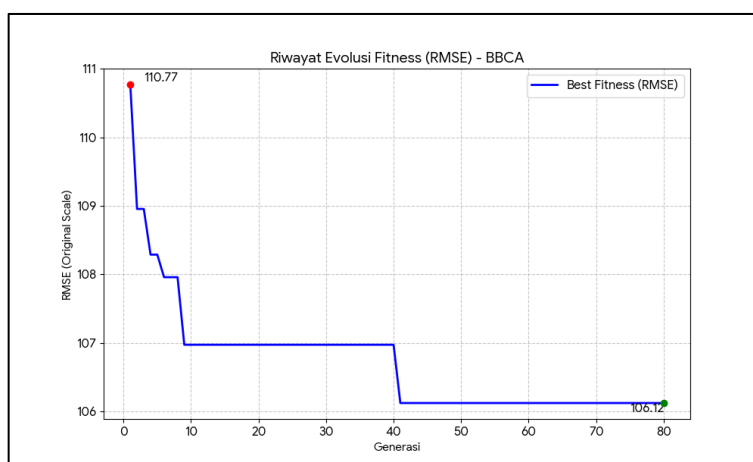
2.5. Metrik Evaluasi

Evaluasi performa model dilakukan secara komprehensif menggunakan dua metrik statistik standar. *Root Mean Square Error* (RMSE) digunakan untuk mengukur deviasi standar dari kesalahan prediksi, memberikan bobot lebih pada kesalahan besar yang krusial dalam risiko finansial. Selain itu, *Mean Absolute Percentage Error* (MAPE) digunakan untuk mengukur rata-rata kesalahan persentase absolut terhadap nilai aktual, memberikan gambaran intuitif tentang akurasi model yang independen terhadap skala data. Secara matematis, metrik ini menghitung selisih antara nilai aktual dan nilai prediksi untuk memastikan penilaian yang objektif (Chicco et al., 2021).

3. Hasil dan Pembahasan

Analisis komprehensif mengenai hasil eksperimen yang dilakukan untuk memvalidasi efektivitas model *Hybrid LSTM-GRU* yang dioptimasi menggunakan Algoritma Genetika (GA). Pembahasan dibagi menjadi tiga segmen utama, yaitu dinamika optimasi *hyperparameter*, evaluasi metrik kinerja statistik, serta analisis visual terhadap kemampuan prediksi model pada data uji. Setiap segmen dirancang untuk memberikan bukti empiris yang kuat mengenai keunggulan metode yang diusulkan, dengan seluruh eksperimen dijalankan menggunakan *optimizer* Adam dan fungsi aktivasi Tanh selama 100 *epoch*.

Proses pencarian parameter optimal dilakukan dengan menjalankan Algoritma Genetika selama 80 generasi dengan populasi 20 individu per generasi. Tujuannya adalah meminimalkan nilai RMSE pada set validasi, yang berfungsi sebagai fungsi tujuan (*fitness function*) untuk mengukur kualitas setiap individu dalam populasi. Dinamika proses evolusi ini divisualisasikan dalam Gambar 2, yang menunjukkan pergerakan nilai *fitness* terbaik dari generasi ke generasi.



Gambar 2. Grafik Fitness Algoritma Genetika

Berdasarkan Gambar 2, terlihat adanya penurunan tajam pada nilai RMSE di fase awal evolusi, khususnya antara generasi ke-1 hingga ke-20. Penurunan drastis ini mengindikasikan fase eksplorasi yang efektif, di mana algoritma berhasil mengeliminasi konfigurasi parameter yang buruk dan mulai memusatkan pencarian pada area solusi yang menjanjikan. Memasuki generasi ke-40 dan seterusnya,

kurva mulai melandai (*plateau*), yang menandakan bahwa algoritma telah beralih ke fase eksploitasi untuk memperhalus solusi terbaik menuju konvergensi global. Stabilitas kurva di akhir generasi menegaskan bahwa GA telah berhasil menemukan konfigurasi yang konsisten dan *robust* (Sha, 2024).

Hasil akhir dari proses optimasi ini menghasilkan satu set *hyperparameter* terbaik yang kemudian dibandingkan dengan konfigurasi *baseline*. Perbandingan rinci antara kedua konfigurasi tersebut disajikan dalam Tabel 3 di bawah ini.

Tabel 3. Parameter Algoritma Genetika

Parameter	Baseline	Algoritma Genetika
LSTM units	64	64
GRU units	64	64
Dropout rate	0.1	0.2
Learning rate	0.001	0.004
Batch size	32	16

Analisis terhadap Tabel 3 mengungkap temuan menarik terkait preferensi algoritma terhadap *Learning Rate* dan *Batch Size*. Meskipun kedua model menggunakan *optimizer* Adam dan aktivasi Tanh yang sama selama 100 *epoch*, GA memilih *Learning Rate* sebesar 0.004, yang empat kali lebih besar dibandingkan nilai *baseline* (0.001), serta *Batch Size* yang lebih kecil yaitu 16 dibandingkan 32. Secara teoritis, *Learning Rate* yang lebih besar memungkinkan *optimizer* Adam untuk melakukan penyesuaian bobot yang lebih agresif, membantu menghindari jebakan *local minima* yang dangkal. Di sisi lain, penggunaan *Batch Size* kecil (16) memberikan efek regularisasi implisit melalui *noise* pada estimasi gradien, yang terbukti membantu model mencapai kemampuan generalisasi yang lebih baik pada data *time-series* yang volatil (Franceschi et al., 2025). Kombinasi parameter ini menunjukkan bahwa untuk kasus saham BBKA, model membutuhkan fleksibilitas adaptasi yang tinggi daripada konvergensi yang lambat.


Setelah mendapatkan parameter optimal, model dilatih ulang dan dievaluasi kinerjanya menggunakan data uji (*testing set*) yang belum pernah dilihat sebelumnya. Evaluasi ini menggunakan dua metrik standar industri, yaitu RMSE untuk mengukur besaran kesalahan dan MAPE untuk mengukur persentase kesalahan relatif. Ringkasan perbandingan kinerja antara model *baseline* dan model hasil optimasi GA disajikan dalam Tabel 4.

Tabel 4. Parameter Algoritma Genetika

Metrik Evaluasi	Baseline	Algoritma Genetika
RMSE	180.38	1.61%
MAPE%	149.77	1.29%

Data pada Tabel 4 memperlihatkan peningkatan performa yang sangat signifikan akibat penerapan optimasi GA. Model optimal mencatat penurunan RMSE sebesar 16.97%, turun dari 180.38 menjadi 149.77, yang berarti variasi kesalahan prediksi berhasil diredam secara substansial. Lebih impresif lagi, nilai MAPE mengalami perbaikan sebesar 19.88%, mencapai angka 1.29%. Dalam konteks harga saham BBKA yang berada di kisaran ribuan rupiah, tingkat kesalahan 1.29% ini tergolong sangat kecil dan sangat presisi untuk dijadikan acuan keputusan investasi. Penurunan error ini mengkonfirmasi hipotesis bahwa konfigurasi parameter *default* atau manual sering kali gagal mengeksplorasi potensi penuh dari arsitektur *Deep Learning*, dan optimasi otomatis adalah kunci untuk membuka potensi tersebut.

Untuk memvalidasi keunggulan model optimal secara kualitatif, dilakukan analisis visual dengan membandingkan plot prediksi kedua model terhadap harga aktual saham. Visualisasi ini ditampilkan dalam Gambar 3, yang memisahkan performa model *baseline* (atas) dan model optimal (bawah) dalam satu kerangka perbandingan.



Gambar 3. Grafik Fitness Algoritma Genetika

Pada grafik bagian atas (Baseline Model), terlihat jelas bahwa garis prediksi (oranye) sering kali mengalami keterlambatan (*lag*) dalam merespons perubahan harga aktual (biru). Selain itu, pada titik-titik ekstrim atau puncak fluktuasi, prediksi model cenderung *underestimate* atau tidak mencapai level harga yang sesungguhnya, yang menunjukkan kekakuan model dalam menangkap volatilitas tinggi. Fenomena ini menjelaskan mengapa nilai RMSE model *baseline* masih cukup tinggi, karena model gagal memetakan perubahan arah tren secara *real-time*.

Sebaliknya, pada grafik bagian bawah (GA-Optimized Model), garis prediksi menunjukkan keselarasan yang luar biasa dengan harga aktual. Model optimal mampu menempel ketat pada pergerakan harga, bahkan saat terjadi lonjakan atau penurunan tajam dalam jangka pendek. Responsivitas ini membuktikan bahwa kombinasi parameter hasil GA (LR 0.004 dan Batch 16) memberikan model kapasitas dinamis untuk menangkap pola non-linear yang kompleks. Akurasi visual ini selaras dengan rendahnya nilai MAPE yang diperoleh, menegaskan bahwa model ini dapat diandalkan untuk peramalan harga saham BCCA.

4. Kesimpulan

Penelitian ini berhasil menjembatani kesenjangan literatur yang teridentifikasi dengan mengimplementasikan Algoritma Genetika (GA) untuk mengoptimasi arsitektur *Hybrid LSTM-GRU* dalam konteks prediksi saham perbankan di Indonesia, khususnya pada saham BCCA. Sejalan dengan hipotesis yang diajukan, pendekatan evolusioner ini terbukti mampu menavigasi kompleksitas ruang pencarian *hyperparameter* secara efektif, mengidentifikasi kombinasi parameter optimal yang meliputi *Learning Rate* 0.004 dan *Batch Size* 16 dengan *optimizer* Adam dan fungsi aktivasi Tanh. Penemuan konfigurasi ini menegaskan bahwa penerapan metode adaptif sangat krusial untuk menangkap karakteristik volatilitas unik pada pasar negara berkembang, yang sering kali luput dari jangkauan model dengan parameter *baseline* atau standar.

Keunggulan pendekatan yang diusulkan tervalidasi secara empiris melalui peningkatan akurasi prediksi yang signifikan dan kekokohan (*robustness*) model terhadap fluktuasi pasar. Secara kuantitatif, model hasil optimasi mencatat penurunan *Root Mean Square Error* (RMSE) sebesar 16.97% dan perbaikan *Mean Absolute Percentage Error* (MAPE) sebesar 19.88% hingga mencapai angka 1.29%. Hasil ini membuktikan bahwa integrasi GA tidak hanya sekadar mengurangi kesalahan statistik, tetapi juga menghasilkan model yang mampu memetakan dinamika harga saham BCCA dengan presisi tinggi, mengikuti tren non-linear secara rapat, dan meminimalkan keterlambatan respons terhadap perubahan harga yang mendadak.

Implikasi dari temuan ini mengonfirmasi bahwa *Hybrid LSTM-GRU* yang dioptimasi secara genetik merupakan instrumen yang andal dan superior dibandingkan metode konvensional untuk pengambilan keputusan investasi di sektor perbankan. Sebagai rekomendasi untuk pengembangan selanjutnya, penelitian dapat diperluas dengan mengintegrasikan faktor eksternal seperti sentimen pasar atau indikator makroekonomi guna memperkuat daya prediksi model. Selain itu, komparasi dengan algoritma metaheuristik modern lainnya dapat dilakukan untuk mengeksplorasi efisiensi komputasi yang lebih baik dalam menangani dataset finansial yang semakin kompleks.

Daftar Pustaka

Al Haromainy, M. M., Prasetya, D. A., & Sari, A. P. (2023). Improving Performance of RNN-Based

- Models With Genetic Algorithm Optimization For Time Series Data. *TIERS Information Technology Journal*, 4(1), 16–24. <https://doi.org/10.38043/tiers.v4i1.4326>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 1–24. <https://doi.org/10.7717/peerj-cs.623>
- Fadziso, T. (2020). Overcoming the Vanishing Gradient Problem during Learning Recurrent Neural Nets (RNN). *Asian Journal of Applied Science and Engineering*, 9(1), 197–208.
- Farhadi, A., Zamanifar, A., Alipour, A., Taheri, A., & Asadolahi, M. (2025). A Hybrid LSTM-GRU Model for Stock Price Prediction. *IEEE Access*, 13, 117594–117618. <https://doi.org/10.1109/ACCESS.2025.3586558>
- Franceschi, L., Donini, M., Perrone, V., Klein, A., Franceschi, L., Klein, A., Seeger, M., & Frasconi, P. (2024). *Hyperparameter Optimization in Machine Learning*.
- Ghojogh, B., & Ghodsi, A. (2023). *Recurrent Neural Networks and Long Short-Term Memory Networks: Tutorial and Survey*. <http://arxiv.org/abs/2304.11461>
- Gusnindar, G. W., & Syafri. (2023). Faktor Pengaruh Harga Emas Dengan Metode Error Correction Model (Ecm). *Jurnal Ekonomi Trisakti*, 3(2), 2359–2366. <https://doi.org/10.25105/jet.v3i2.16556>
- Laksmad Pradana, B. (2025). Time Series Forecasting of LQ45 Stock Index Using ARIMA: Insights and Implications. *Journal of Management, Accounting and Business Research (JMABR)*, 1(1), 27–40. <https://doi.org/10.51170/jmabr.v4i.1.160>
- Pahlawan, M. R. (2022). Prediksi Indeks Harga Saham Menggunakan Model Hibrida Recurrent Neural Network dan Genetic Algorithm. *JATISI (Jurnal Teknik Informatika Dan Sistem Informasi)*, 9(4), 3619–3631. <https://doi.org/10.35957/jatisi.v9i4.3065>
- Rajwar, K., Deep, K., & Das, S. (2023). *An exhaustive review of the metaheuristic algorithms for search and optimization: taxonomy, applications, and open challenges*. 13187–13257.
- Sadikin, M., & Agustina, R. (2023). Analisis Fundamental dan Teknikal Saham BCA dan BRI (Tahun 2019-2021). *Seminar Nasional Akuntansi Dan Call for Paper (SENAPAN)*, 3(1), 57–67. <https://doi.org/10.33005/senapan.v3i1.285>
- Sarah, S., & Dasman, H. S. (2023). ANALISIS FAKTOR MAKRO EKONOMI DAN FAKTOR INTERNAL RASIO KEUANGAN TERHADAP HARGA SAHAM INDEKS LQ-45 YANG TERDAFTAR DI BURSA EFEK INDONESIA (BEI) PERIODE 2018-2022. *Journal of Economics and Business UBS*, 12(3), 1675–1694.
- Sezgin, F. H., Algorabi, Ö., Sart, G., & Güler, M. (2025). Hyperparameter-Optimized RNN, LSTM, and GRU Models for Airline Stock Price Prediction: A Comparative Study on THYAO and PGSUS. *Symmetry*, 1–19.
- Sha, X. (2024). Time Series Stock Price Forecasting Based on Genetic Algorithm (GA)-Long Short-Term Memory Network (LSTM) Optimization. *Advances in Economics, Management and Political Sciences*, 91(1), 142–149. <https://doi.org/10.54254/2754-1169/91/20241031>
- Utami, M. D., & Iqbal, K. (2024). Bayesian Optimization for Stock Price Prediction Using LSTM, GRU, and Hybrid LSTM-GRU, and Hybrid GRU-LSTM. *Ujme*, 13(2), 9–19. <http://journal.unnes.ac.id/sju/index.php/ujme>
- Yunita, A., Iqbal, M. H. D., Zaki, M., Ramadhan, H., Akashah, E., Akhir, P., Besse, A., Mansur, F., & Hoirul, A. (2025). Performance analysis of neural network architectures for time series forecasting: A comparative study of RNN, LSTM, GRU, and hybrid models. *MethodsX*, 15, 103462. <https://doi.org/10.1016/j.mex.2025.103462>