

Evaluasi Kinerja Model LSTM dalam Memprediksi Nilai Penutupan IHSG Berdasarkan Variasi *Optimizer Adam-based*

Valensia Natalia¹, I Nyoman Saputra Wahyu Wijaya^{*2}

Luh Joni Erawati Dewi³, Ni Putu Novita Puspa Dewi⁴

Universitas Pendidikan Ganesha, Singaraja, Indonesia^{1,2,3,4}

valensia@student.undiksha.ac.id¹, wahyu.wijaya@undiksha.ac.id², joni.erawati@undiksha.ac.id³,

novita.puspa.dewi@undiksha.ac.id⁴

*Corresponding author : valensia@student.undiksha.ac.id¹

Abstrak— Prediksi Indeks Harga Saham Gabungan (IHSG) merupakan tantangan tersendiri karena pergerakannya yang bersifat non-linier dan dipengaruhi berbagai faktor eksternal. Penelitian ini mengevaluasi kinerja model *Long Short-Term Memory* (LSTM) dalam memprediksi nilai penutupan IHSG menggunakan tiga variasi algoritma optimasi berbasis Adam, yaitu Adam, AdamW, dan Nadam. Data yang digunakan adalah data historis IHSG dari *Yahoo Finance* periode 2015–2025 sebanyak 2.413 data harian. Model dibangun dengan teknik *sliding window* berukuran 60 dan dilatih menggunakan *hyperparameter* yang identik pada ketiga skenario untuk memastikan objektivitas perbandingan. Evaluasi dilakukan menggunakan metrik MAE, RMSE, dan MAPE. Hasil menunjukkan bahwa *optimizer Adam* menghasilkan performa terbaik dengan MAE sebesar 115,0, RMSE sebesar 144,4, dan MAPE sebesar 1,63%, unggul dibandingkan Nadam (MAPE 2,71%) dan AdamW (MAPE 3,18%). Keunggulan Adam berasal dari proses konvergensi yang lebih stabil sehingga model mampu mempelajari pola historis data secara lebih optimal.

Abstract— Predicting the Composite Stock Price Index (CSPI) is a challenging task due to its nonlinear behavior and the influence of various external factors. This study evaluates the performance of the Long Short-Term Memory (LSTM) model in predicting CSPI closing prices using three Adam-based optimization algorithms: Adam, AdamW, and Nadam. The dataset consists of 2,413 daily CSPI records from 2015 to 2025 obtained from Yahoo Finance. The model was developed using a sliding window technique with a window size of 60 and trained with identical hyperparameters across all experimental scenarios to ensure an objective comparison. Performance was evaluated using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), and Mean Absolute Percentage Error (MAPE). The results show that the Adam optimizer achieved the best performance, with an MAE of 115.0, RMSE of 144.4, and MAPE of 1.63%, outperforming Nadam (MAPE 2.71%) and AdamW (MAPE 3.18%). Adam's superior performance is attributed to its more stable convergence process, enabling the model to learn historical data patterns more effectively.

Keywords—IHSG, LSTM, Adam, AdamW, Nadam

This is an open access article under the [CC BY-SA](#) license.



1. Pendahuluan

Pasar modal memiliki peran yang penting dalam perekonomian Indonesia karena perkembangan zaman mendorong sistem ekonomi menjadi semakin modern. Pasar modal berfungsi sebagai salah satu pusat kegiatan keuangan yang mendukung berbagai aktivitas ekonomi [1]. Sebagai salah satu indikator utama kondisi perekonomian nasional, Indeks Harga Saham Gabungan (IHSG) mencerminkan pergerakan harga seluruh saham yang tercatat di Bursa Efek Indonesia (BEI). Pemantauan terhadap pergerakan IHSG menjadi hal yang penting bagi pelaku pasar, regulator, dan analis ekonomi karena dapat membantu dalam memahami, mengantisipasi, serta merespons berbagai perubahan dan dinamika ekonomi yang memengaruhi pasar modal di Indonesia [2]. Penurunan IHSG mendorong investor untuk lebih berhati-hati dalam mengambil keputusan investasi serta memberikan perhatian yang lebih besar terhadap risiko makroekonomi [3]. Nilai penutupan IHSG kerap dijadikan dasar analisis untuk memahami dinamika pasar dan memperkirakan kondisi pasar pada masa yang akan datang [4]. Oleh karena itu, kemampuan untuk memprediksi pergerakan IHSG secara akurat menjadi sangat penting dalam mengambil keputusan yang tepat.

Prediksi harga saham merupakan permasalahan yang cukup kompleks karena pergerakan harga saham cenderung bersifat non-linier, tidak stasioner, serta dipengaruhi oleh berbagai faktor eksternal yang sulit diprediksi dan dikendalikan. Kemajuan teknologi kecerdasan buatan telah mendorong pemanfaatan metode *deep learning* dalam analisis pasar keuangan [5]. Salah satu arsitektur *deep learning* yang terbukti efektif

dalam menangani data temporal dan *time series* adalah *Long Short-Term Memory* (LSTM). LSTM merupakan pengembangan dari *Recurrent Neural Network* (RNN) yang mampu mempertahankan informasi dalam jangka waktu lebih panjang melalui mekanisme memori, sehingga dapat mengatasi masalah *vanishing gradient* yang sering muncul pada RNN konvensional [6]. LSTM menawarkan potensi yang besar dalam analisis data *time series* karena kemampuan dalam memahami pola nonlinear dan hubungan jangka panjang antar data. [7].

Meskipun LSTM memiliki peran penting dalam menentukan kualitas prediksi, pemilihan algoritma optimasi juga merupakan faktor krusial yang memengaruhi konvergensi dan performa. *Optimizer* berfungsi untuk memperbarui parameter model, seperti bobot dan *learning rate* selama proses pelatihan agar nilai fungsi kehilangan (*loss function*) dapat diminimalkan [8]. Penelitian ini menggunakan tiga algoritma optimasi berbasis Adam, yaitu Adam, AdamW, dan Nadam. Ketiga *optimizer* ini dipilih karena memiliki kemampuan *adaptive learning rate* yang telah banyak digunakan pada model *deep learning* untuk prediksi data deret waktu. Meskipun berasal dari keluarga *optimizer* yang sama, masing-masing *optimizer* menerapkan mekanisme pembaruan parameter yang berbeda sehingga berpotensi menghasilkan performa prediksi yang berbeda. Urgensi dalam pemilihan *optimizer* terletak pada perbedaan mekanisme pembaruan parameter yang digunakan oleh masing-masing algoritma. Pemilihan *optimizer* secara langsung memengaruhi kecepatan konvergensi, kestabilan pelatihan, dan kemampuan generalisasi model. *Optimizer* Adam memperbaharui parameter berdasarkan estimasi momentum orde pertama, yaitu rata-rata bergerak dari gradien m_t dan orde kedua, yaitu rata-rata bergerak dari kuadrat gradien v_t . *Optimizer* Adam dituliskan pada persamaan (1).

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t, \quad v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (1)$$

AdamW memodifikasi Adam dengan memisahkan (*decoupling*) mekanisme *weight decay* dari perhitungan gradien adaptif, sehingga regularisasi diterapkan langsung pada bobot. AdamW dituliskan sesuai pada persamaan (2).

$$\theta_t = \theta_{t-1} - \eta \left(\frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} + \lambda \theta_{t-1} \right) \quad (2)$$

Sementara itu, Nadam mengintegrasikan momentum Nesterov ke dalam pembaruan Adam, sehingga estimasi gradien yang digunakan bersifat *lookahead*, yaitu mengantisipasi arah pergerakan berikutnya. Nadam dituliskan sesuai pada persamaan (3).

$$\theta_t = \theta_{t-1} - \frac{\eta}{\sqrt{\hat{v}_t} + \epsilon} \left(\beta_1 \hat{m}_t + \frac{(1 - \beta_1) g_t}{1 - \beta_1^t} \right) \quad (3)$$

Perbedaan mekanisme tersebut menunjukkan bahwa meskipun tiga *optimizer* berasal dari keluarga yang sama, masing-masing memiliki cara mengatur *learning rate* efektif dan momentum yang berbeda. AdamW cenderung membuat pembelajaran lebih konservatif karena adanya penalti bobot langsung. Nadam cenderung mempercepat konvergensi karena estimasi gradien yang bersifat antisipatif. Pada data IHSG yang bersifat non-stasioner, memiliki tren jangka panjang, dan volatilitas jangka pendek, perbedaan mekanisme ini berpotensi menghasilkan perbedaan performa prediksi yang cukup besar. Oleh karena itu, pemilihan *optimizer* yang tepat menjadi aspek penting yang perlu dievaluasi.

Beberapa penelitian mengenai prediksi harga saham telah banyak dilakukan dengan memanfaatkan model LSTM. Penelitian sebelumnya menerapkan model LSTM dengan *optimizer* Adam untuk memprediksi harga saham Bank Central Asia (BCA). Hasil penelitian menunjukkan bahwa model yang diusulkan mampu menghasilkan performa prediksi yang baik dengan nilai RMSE sebesar 40,85, MSE sebesar 6662,76, dan MAPE sebesar 0,71% [9]. Penelitian lain yang juga memanfaatkan kombinasi LSTM dan *optimizer* Adam untuk prediksi harga saham BBNI menunjukkan bahwa penggunaan *optimizer* Adam mampu meningkatkan kinerja model dengan tingkat akurasi prediksi mencapai 98,46% pada konfigurasi *batch size* 64 dan *epoch* 100. Hasil penelitian tersebut mengindikasikan bahwa *optimizer* Adam memiliki kemampuan yang baik dalam mempercepat dan menstabilkan proses konvergensi model LSTM ketika diterapkan pada data *time series* [10]. Temuan-temuan tersebut menunjukkan bahwa *optimizer* Adam memiliki kemampuan yang baik dalam membantu proses konvergensi model LSTM pada data *time series*. Selain pada bidang keuangan, kombinasi LSTM dan *optimizer* Adam-based juga telah diterapkan pada prediksi kualitas udara kota DKI Jakarta. Hasil penelitian menunjukkan bahwa penggunaan Adam

menghasilkan nilai RMSE sebesar 11,09, MAE sebesar 8,54, dan koefisien determinasi (R^2) sebesar 0,44. Penelitian yang sama juga membandingkan Adam dengan AdamW dan Nadam. AdamW memperoleh nilai RMSE sebesar 11,15, MAE sebesar 8,53, dan R^2 sebesar 0,44, sedangkan Nadam menghasilkan nilai RMSE sebesar 11,09, MAE sebesar 8,54, dan R^2 sebesar 0,44 [11]. Hasil tersebut menunjukkan bahwa variasi algoritma optimasi berbasis Adam dapat memberikan perbedaan performa meskipun menggunakan arsitektur model yang sama.

Berdasarkan penelitian-penelitian terdahulu, diketahui bahwa model LSTM yang dikombinasikan dengan algoritma optimasi berbasis Adam telah banyak digunakan untuk menyelesaikan permasalahan prediksi deret waktu dan menunjukkan kinerja yang baik. Namun, penelitian yang secara khusus membandingkan kinerja *optimizer* Adam, AdamW, dan Nadam pada prediksi harga Indeks Harga Saham Gabungan (IHSG) masih terbatas. Oleh karena itu, penelitian ini dilakukan untuk mengevaluasi pengaruh penggunaan ketiga *optimizer* tersebut terhadap performa model dalam memprediksi harga IHSG. Evaluasi dilakukan berdasarkan metrik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE) guna menentukan *optimizer* yang paling optimal untuk kasus prediksi data *time series* IHSG.

2. Metodologi Penelitian


Indeks Harga Saham Gabungan merupakan indikator yang digunakan untuk menggambarkan pergerakan harga saham di Bursa Efek Indonesia [12]. Data yang digunakan dalam penelitian ini adalah data historis IHSG periode 25 Juni 2015 hingga 25 Juni 2025 yang diperoleh dari *Yahoo Finance*. Dataset terdiri dari 2.413 data harian dengan lima variabel, yaitu *Open*, *High*, *Low*, *Close*, dan *Volume*. Nilai *Close* digunakan sebagai variabel target dalam proses prediksi karena merepresentasikan harga penutupan indeks pada setiap periode perdagangan.

Tahap prapemrosesan data memastikan tidak terdapat nilai yang hilang (*missing value*) atau data yang tidak valid. Data kemudian dinormalisasi dengan metode *Min-Max Scalling* sehingga nilai setiap fitur berada dalam rentang 0 hingga 1 [13]. Secara matematis, *Min-Max Scalling* dituliskan pada persamaan (4).

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (4)$$

Di mana x adalah nilai asli, x_{min} adalah nilai minimum, dan x_{max} adalah nilai maksimum. Metode ini menjaga pola dari distribusi data tetap sama, namun diubah ke dalam rentang nilai yang lebih kecil dan seragam. Setelahnya, data dibagi menjadi data pelatihan dan data pengujian.

Model LSTM dirancang untuk memprediksi nilai IHSG berdasarkan data historis yang telah melalui tahap prapemrosesan. LSTM mampu memodelkan pola data berdasarkan urutan waktu dan mengidentifikasi dependensi jangka panjang yang terdapat dalam suatu rangkaian data [14]. Model terdiri dari dua lapisan LSTM yang berfungsi untuk mempelajari pola dan ketergantungan jangka panjang pada data *time series*, lapisan *dropout* untuk mencegah *overfitting*, serta dua lapisan *dense* pada bagian akhir untuk menghasilkan nilai prediksi.



Gambar 1. Arsitektur model LSTM untuk prediksi harga penutupan IHSG

Proses diawali dengan pembentukan *input sequence* menggunakan teknik *sliding window* dengan ukuran *window size* sebesar 60 untuk menghasilkan data *time series* yang dapat diproses oleh model. Selanjutnya, data dinormalisasi menggunakan *Min-Max Scaling* agar proses pelatihan model lebih stabil. Data hasil *sliding window* kemudian di-*reshape* menjadi tensor berdimensi tiga dengan format $(n, 60, 1)$, n menyatakan jumlah sampel, 60 sebagai *sequence length*, dan 1 merupakan jumlah fitur yang digunakan. Representasi ini memungkinkan model LSTM mempelajari hubungan temporal dari 60 hari perdagangan sebelumnya untuk memprediksi nilai penutupan pada periode berikutnya.

Seluruh model LSTM pada penelitian ini menggunakan konfigurasi *hyperparameter* yang sama. Penggunaan *hyperparameter* yang konsisten bertujuan untuk memastikan bahwa perbedaan kinerja model yang dihasilkan berasal dari perbedaan algoritma optimasi yang digunakan.

Tabel 1. Hyperparameter yang digunakan

Parameter	Nilai
Window Size (Sequence Length)	60
Rasio Data Pengujian	20%
LSTM Layer 1	64 unit
LSTM Layer 2	32 unit
Dense Layer 1	16 unit
Fungsi Aktivasi Dense Layer	ReLU
Dropout Rate	0.2
Jumlah Penerapan Dropout	2
Epoch	100
Batch Size	32
Learning Rate	0.001
Loss Function	Mean Squared Error (MSE)
Early Stopping Patience	10
ReduceLROnPlateau Patience	5
ReduceLROnPlateau Factor	0.5
Minimum Learning Rate (min_lr)	1×10^{-6}

Proses pelatihan dilakukan dengan jumlah *epoch* maksimum sebesar 100, ukuran *batch* sebesar 32, dan *learning rate* awal sebesar 0.001. Selain itu, diterapkan *callback* berupa *EarlyStopping* dengan *patience* 10 *epoch* untuk menghentikan pelatihan secara otomatis apabila tidak terdapat peningkatan pada *validation*

loss, serta *ReduceLROnPlateau* untuk menurunkan *learning rate* secara adaptif apabila model mengalami stagnasi. Evaluasi kinerja model dilakukan untuk mengukur akurasi prediksi yang dihasilkan oleh LSTM dengan variasi algoritma optimasi. Pengukuran *error* dilakukan dengan membandingkan nilai hasil prediksi yang telah di-*inverse transform* ke skala harga asli dengan nilai aktual pada data pengujian sebesar 20% dari keseluruhan data. Metrik evaluasi yang digunakan terdiri dari *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE). MAE digunakan untuk mengukur rata-rata nilai absolut dari selisih antara nilai aktual dan nilai hasil prediksi [15]. Secara matematis, MAE dituliskan pada persamaan (5).

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

RMSE mengukur akar dari rata-rata kuadrat selisih antara nilai prediksi dan nilai aktual, sehingga memberikan penalti lebih besar terhadap kesalahan yang ekstrem. Semakin rendah nilai RMSE, semakin tinggi tingkat ketepatan dan akurasi model dalam menghasilkan prediksi [16]. Secara matematis, RMSE dituliskan pada persamaan (6).

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


Sementara itu, MAPE mengukur rata-rata persentase kesalahan prediksi terhadap nilai aktual sehingga hasil evaluasi lebih mudah diinterpretasikan secara relatif. Semakin rendah nilai MAPE, semakin akurat hasil peramalan yang dihasilkan oleh model [17]. MAPE secara matematis diformulasikan pada persamaan (7).

$$MAPE = \frac{1}{n} \sum_{n=1}^n \left| \frac{y_n - \hat{y}_n}{y_n} \right| \quad (7)$$

di mana y_i adalah nilai aktual harga IHSG, $\hat{y}_i$ adalah nilai prediksi model, dan n adalah jumlah data pengujian. Ketiga metrik ini digunakan secara bersamaan untuk memberikan gambaran menyeluruh mengenai tingkat kesalahan prediksi dari berbagai sudut pandang. Hasil evaluasi dari masing-masing optimizer kemudian dibandingkan, dan berdasarkan nilai RMSE terkecil,

3. Hasil dan Pembahasan

Pelatihan model LSTM dilakukan dengan menggunakan tiga variasi algoritma optimasi berbasis Adam, yaitu Adam, AdamW, dan Nadam. Setiap model dilatih dengan *hyperparameter* pada Tabel 1 untuk memastikan perbandingan yang objektif.



Gambar 2. Grafik loss Adam vs AdamW vs Nadam


Pada model LSTM dengan *optimizer* Adam, proses konvergensi berlangsung relatif paling stabil di antara ketiga *optimizer* yang diuji. *Loss training* mengalami penurunan tajam pada epoch-epoch awal dan mencapai titik terbaik pada *epoch* 7, kemudian nilai *loss* cenderung stabil hingga *early stopping* terpicu pada *epoch* 17. Pada model dengan *optimizer* AdamW, konvergensi terjadi sangat cepat dengan titik terbaik tercapai pada *epoch* 2, dan *early stopping* terpicu pada *epoch* 10. Sementara itu, model LSTM dengan *optimizer* Nadam menunjukkan konvergensi paling cepat dengan titik terbaik tercapai pada *epoch* 1 dan *early stopping* terpicu pada *epoch* 10. Untuk memberikan gambaran kuantitatif mengenai performa prediksi masing-masing model, dilakukan evaluasi menggunakan metrik MAE, RMSE, dan MAPE. Hasil evaluasi ketiga model disajikan pada Tabel 2.

Tabel 2. Hasil evaluasi model

Optimizer	MAE	RMSE	MAPE (%)
Adam	115.0	144.4	1.63
AdamW	228.6	262.1	3.18
Nadam	193.2	233.2	2.71

Berdasarkan Tabel 2, *optimizer* Adam menghasilkan nilai MAE, RMSE, dan MAPE terendah dibandingkan AdamW dan Nadam. Hasil tersebut menunjukkan bahwa Adam memiliki kemampuan yang lebih baik dalam meminimalkan kesalahan prediksi dan menghasilkan akurasi yang lebih tinggi pada data IHSG. Meskipun AdamW dan Nadam mampu mencapai konvergensi lebih cepat, kedua *optimizer* tersebut menghasilkan nilai *error* yang lebih besar. Temuan ini mengindikasikan bahwa konvergensi yang terlalu dini dapat menyebabkan model belum sepenuhnya mempelajari pola historis data, sehingga berdampak pada penurunan performa prediksi.

Setelah proses training selesai, masing-masing model digunakan untuk memprediksi harga penutupan IHSG pada data uji yang mencakup periode 2023 hingga pertengahan 2025. Hasil prediksi kemudian dibandingkan secara visual terhadap nilai aktual untuk menilai kemampuan setiap model dalam menangkap pola pergerakan harga.




Gambar 3. Grafik prediksi vs aktual optimizer Adam vs AdamW vs Nadam

Optimizer Adam menghasilkan prediksi yang paling mendekati nilai aktual secara keseluruhan. Kurva prediksi mampu mengikuti tren naik dan turun harga IHSG dengan cukup baik, meskipun pada 60 hari

terakhir terdapat lag di mana prediksi belum sepenuhnya merespons penurunan harga yang terjadi secara tajam. Selanjutnya, *optimizer* AdamW menghasilkan kurva prediksi yang cenderung lebih halus dan kurang responsif terhadap fluktuasi harga. Pada periode 60 hari terakhir, gap antara prediksi dan nilai aktual terlihat cukup lebar, mengindikasikan keterbatasan model dalam menangkap pergerakan harga jangka pendek. Sementara itu, Nadam memiliki kurva prediksi yang sedikit lebih responsif dibandingkan AdamW, terutama dalam mengikuti arah tren secara umum meskipun belum mampu menangkap fluktuasi harga secara presisi. Secara keseluruhan, Adam menghasilkan prediksi yang paling representatif terhadap pergerakan harga aktual IHSG, sementara AdamW dan Nadam cenderung menghasilkan prediksi yang underestimate dan kurang mampu mengikuti volatilitas pasar secara detail.

Perbandingan rata-rata distribusi *error* disajikan untuk memperlihatkan perbedaan performa masing-masing *optimizer* dalam menghasilkan tingkat kesalahan prediksi.



Gambar 4. Distribusi error optimizer Adam vs AdamW vs Nadam

Berdasarkan distribusi error, seluruh *optimizer* menunjukkan nilai *mean error* negatif yang mengindikasikan adanya kecenderungan *underestimate* dalam prediksi. *Optimizer* Adam menghasilkan distribusi *error* yang paling simetris dan terpusat di sekitar nilai 0 dengan *mean error* sebesar -53, yang menunjukkan bahwa rata-rata prediksi model hanya meleset sekitar 53 poin di bawah harga aktual. Kurva *Kernel Density Estimation* (KDE) Adam paling mendekati distribusi normal, menandakan bahwa *error* tersebar secara merata tanpa bias signifikan ke suatu arah tertentu. Sementara itu, AdamW memiliki *mean error* sebesar -206 dengan distribusi yang bergeser ke kiri, menunjukkan kecenderungan *underestimate* yang lebih kuat dan konsisten. Kondisi ini disebabkan oleh mekanisme *weight decay* yang membuat model menjadi lebih konservatif sehingga menghasilkan prediksi yang lebih rendah dari harga sebenarnya. Di sisi lain, Nadam menghasilkan *mean error* sebesar -148 dengan pola distribusi yang juga condong ke kiri, meskipun tingkat *underestimate* tidak sebesar AdamW. Distribusi *error* Nadam menunjukkan bahwa model sesekali masih menghasilkan prediksi yang lebih tinggi daripada nilai aktual (*overestimate*). Kecenderungan *underestimate* pada ketiga *optimizer* merupakan fenomena yang umum terjadi pada prediksi harga saham yang sedang mengalami tren kenaikan, karena model mempelajari pola dari data historis yang memiliki nilai lebih rendah dibandingkan harga saat ini. Namun demikian, Adam menunjukkan bias yang paling kecil karena nilai *mean error*-nya paling mendekati nol, sehingga dapat dianggap sebagai *optimizer* dengan performa prediksi terbaik di antara ketiganya.

Berdasarkan hasil evaluasi, *optimizer* Adam menghasilkan performa terbaik dalam prediksi harga penutupan IHSG menggunakan model LSTM dengan nilai MAE sebesar 115,0, RMSE sebesar 144,4, dan MAPE sebesar 1,63%. Keunggulan Adam berasal dari kemampuannya dalam menyesuaikan *learning rate* secara adaptif untuk setiap parameter melalui kombinasi momentum orde pertama dan orde kedua. Karakteristik tersebut memungkinkan proses pembelajaran berlangsung lebih stabil pada data finansial yang bersifat non-stasioner, seperti IHSG yang memiliki fluktuasi harga, tren jangka panjang, dan volatilitas jangka pendek. Hal ini juga terlihat dari proses konvergensi yang berlangsung secara bertahap hingga *epoch* ke-17 sebelum *early stopping* terpicu, sehingga model memiliki waktu yang cukup untuk mempelajari pola historis data secara lebih optimal. Sebaliknya, AdamW menghasilkan performa terendah dengan nilai *error* yang lebih besar dibandingkan *optimizer* lainnya. Meskipun secara teoritis mekanisme *weight decay* pada AdamW bertujuan meningkatkan kemampuan generalisasi model, pada penelitian ini mekanisme tersebut menyebabkan proses pembelajaran menjadi terlalu konservatif sehingga model mencapai titik konvergensi terbaik hanya pada *epoch* ke-2. Akibatnya, model cenderung menghasilkan

prediksi yang lebih rendah dari nilai aktual, yang ditunjukkan oleh rata-rata residual sebesar -206. Sementara itu, Nadam menunjukkan performa yang lebih baik dibandingkan AdamW tetapi masih berada di bawah Adam, dengan nilai MAPE sebesar 2,71%. Konvergensi yang sangat cepat, yaitu pada epoch pertama, mengindikasikan bahwa penambahan momentum Nesterov belum memberikan keuntungan yang signifikan pada dataset yang digunakan. Hal ini juga tercermin dari rata-rata residual sebesar -148 yang menunjukkan adanya kecenderungan *underestimate*. Perbedaan kinerja ketiga *optimizer* juga dipengaruhi oleh mekanisme *early stopping*. Adam yang berkonvergensi secara lebih bertahap memperoleh kesempatan lebih untuk mengeksplorasi ruang parameter sebelum proses pelatihan dihentikan, sedangkan AdamW dan Nadam cenderung berhenti terlalu cepat sehingga model belum sepenuhnya menangkap pola data yang kompleks.

Keunggulan Adam dapat dijelaskan lebih lanjut dari sisi mekanisme kerja dan karakteristik data yang digunakan. Data IHSG memiliki tren kenaikan jangka panjang yang diselingi koreksi tajam dalam jangka pendek, sehingga bobot model perlu disesuaikan secara adaptif tanpa dibatasi terlalu ketat. Mekanisme *bias correction* pada estimasi momentum orde pertama dan kedua di Adam memungkinkan *learning rate* efektif tetap proporsional terhadap besar-kecilnya gradien pada setiap parameter, tanpa memberikan penalti tambahan terhadap besar bobot itu sendiri. Kondisi ini membuat Adam lebih leluasa dalam mempelajari pola tren jangka panjang sekaligus fluktuasi jangka pendek pada data *sliding window* 60 hari. Sebaliknya, mekanisme *decoupled weight decay* pada AdamW menarik nilai bobot mendekati nol pada setiap langkah pembaruan, terlepas dari besar gradien yang dihasilkan. Pada data dengan tren naik yang kuat seperti IHSG, mekanisme ini menghambat model untuk membentuk bobot yang cukup besar guna merepresentasikan pertumbuhan harga secara akurat, sehingga model berhenti belajar terlalu dini, yaitu terjadi konvergensi pada epoch ke-2 dan menghasilkan prediksi yang secara konsisten lebih rendah dari nilai aktual dengan *mean error* sebesar -206. Sehingga, regularisasi yang seharusnya meningkatkan generalisasi justru menjadi terlalu agresif untuk karakteristik data yang didominasi tren. Pada Nadam, penambahan komponen momentum Nesterov membuat model menggunakan estimasi gradien yang bersifat antisipatif (*lookahead*), yaitu memperkirakan posisi parameter satu langkah ke depan sebelum melakukan pembaruan. Mekanisme ini efektif mempercepat konvergensi pada data yang relatif stabil, namun pada data IHSG yang non-stasioner dan memiliki *noise* jangka pendek, estimasi antisipatif tersebut menyebabkan model mencapai titik optimal lokal terlalu cepat, yaitu pada epoch ke-1 sebelum sempat mempelajari variasi pola yang lebih kompleks. Hal ini tercermin dari nilai *error* yang lebih besar dibandingkan Adam meskipun konvergensinya paling cepat di antara ketiga *optimizer*.

Perbedaan durasi pelatihan sebelum *early stopping* terpicu juga memperkuat temuan ini. Adam memperoleh 17 epoch efektif untuk menyesuaikan bobot secara bertahap, sedangkan AdamW dan Nadam masing-masing berhenti pada epoch ke-10 setelah mencapai titik terbaik pada epoch yang jauh lebih awal, yaitu epoch 2 dan 1. Waktu eksplorasi yang lebih singkat membatasi kemampuan kedua model dalam menangkap dinamika data historis IHSG selama 10 tahun yang mencakup berbagai kondisi pasar, termasuk periode volatilitas tinggi. Dengan demikian, kombinasi antara mekanisme *adaptive learning rate* tanpa regularisasi bobot yang agresif serta proses konvergensi yang bertahap menjadi faktor utama yang menjelaskan mengapa Adam menghasilkan performa prediksi terbaik pada kasus data IHSG dalam penelitian ini. Secara keseluruhan, hasil penelitian ini menunjukkan bahwa *optimizer* dengan proses konvergensi yang lebih stabil dan tidak terlalu agresif, seperti Adam, lebih sesuai untuk prediksi harga saham IHSG menggunakan model LSTM. Temuan ini mengindikasikan bahwa karakteristik data finansial yang kompleks dan dinamis memerlukan proses pembelajaran yang cukup panjang agar model mampu menghasilkan prediksi yang lebih akurat.

4. Kesimpulan

Perbedaan *optimizer* berpengaruh terhadap kinerja model LSTM dalam prediksi harga penutupan IHSG. *Optimizer* Adam terbukti memberikan hasil prediksi terbaik dibandingkan AdamW dan Nadam karena mampu menghasilkan proses pembelajaran yang lebih stabil serta menangkap pola data historis IHSG secara lebih efektif. Temuan ini menunjukkan bahwa pada data deret waktu finansial yang bersifat kompleks, non-stasioner, dan memiliki volatilitas tinggi, *optimizer* dengan konvergensi yang lebih bertahap cenderung menghasilkan performa prediksi yang lebih baik dibandingkan *optimizer* yang

berkonvergensi sangat cepat. Dengan demikian, Adam dapat dipertimbangkan sebagai *optimizer* yang lebih sesuai untuk pengembangan model LSTM dalam prediksi pergerakan harga saham IHSG.


5. Daftar Pustaka

- [1] N. W. R. Sari and I. G. A. P. Yudiantara, "Determinan Nilai Perusahaan Pada Sektor Industri Barang Konsumsi yang Terdaftar di Bursa Efek Indonesia Tahun 2017-2020," *Bisma: Jurnal Manajemen*, vol. 8, no. 2, pp. 410–420, Aug. 2022.
- [2] J. Yandes, D. Destiana, R. Azka Raga, J. Jasrial, A. Fajar Suryo Antoro, and H. Putri Pertiwi, "Fluktuasi Nilai IHSG: Dampak Kondisi Inflasi Tahun 2023 di Indonesia," *Jurnal Ilmiah Metansi (Manajemen dan Akuntansi)*, vol. 7, no. 1, pp. 95–104, Apr. 2024, doi: 10.57093/metansi.v7i1.251.
- [3] I Gede Yoga Satya Ariarta and Ni Made Suci, "Dampak Buyback Saham terhadap Abnormal Return pada Bank Badan Usaha Milik Negara di Bursa Efek Indonesia Tahun 2025," *Sammajiva: Jurnal Penelitian Bisnis dan Manajemen*, vol. 4, no. 2, pp. 24–39, May 2026, doi: 10.47861/sammajiva.v4i2.2289.
- [4] E. Dwi, A. A. Zam, W. Ihdina Nabilla, A. S. Pohan, and R. S. Lubis, "Penerapan Model Arima Pada Nilai Penutupan Indeks Harga Saham Gabungan Untuk Data yang Hilang," *JISTech (Journal of Islamic Science and Technology) JISTech*, vol. 10, no. 2, pp. 198–207, Dec. 2025, doi: 10.30829/jistech.v10i2.28361.
- [5] I. Winarni and N. Pratiwi, "Prediksi Harga Saham Menggunakan Metode Long-Short Term Memory Studi Kasus: Saham Intel Corporation," *Decode: Jurnal Pendidikan Teknologi Informasi*, vol. 5, no. 2, pp. 380–390, Jul. 2025, doi: 10.51454/decode.v5i2.1192.
- [6] C. Alkahfi, A. Kurnia, and A. Saefuddin, "Perbandingan Kinerja Model Berbasis RNN pada Peramalan Data Ekonomi dan Keuangan Indonesia," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1235–1243, Jul. 2024, doi: 10.57152/malcom.v4i4.1415.
- [7] Y. Ashari and A. Suhendar, "Implementasi Algoritma Long Short-Term Memory (LSTM) untuk Memprediksi Harga Beras di Jawa Tengah Berdasarkan Cuaca," *Djtechno: Jurnal Teknologi Informasi*, vol. 5, no. 3, pp. 624–636, Dec. 2024, doi: 10.46576/djtechno.
- [8] S. Asy Syifa and I. Amelia Dewi, "Arsitektur Resnet-152 dengan Perbandingan Optimizer Adam dan RMSProp untuk Mendeteksi Penyakit Paru-Paru," *MIND Journal*, vol. 7, no. 2, pp. 139–150, Dec. 2022, doi: 10.26760/mindjournal.v7i2.139-150.
- [9] A. Rosyd, A. Irma Purnamasari, and I. Ali, "Penerapan Metode Long Short Term Memory (LSTM) dalam Memprediksi Harga Saham PT Bank Central Asia," *JATI: Jurnal Mahasiswa Teknik Informatika*, vol. 8, no. 1, pp. 501–506, Feb. 2024.
- [10] A. Rahman, L. Sri Istiyowati, and Z. Azis, "Implementasi Data Mining dalam Prediksi Harga Saham BBNi dengan Pemodelan Matematika Menggunakan Metode LSTM dengan Optimasi Adam," *JUTECH Journal Education and Technology*, vol. 5, no. 2, pp. 427–439, Dec. 2024.
- [11] A. Arkadia, B. Hananto, and D. S. Prasvita, "Optimasi Long Short Term Memory Dengan Adam Menggunakan Data Udara Kota DKI Jakarta," in *SENAMIKA Seminar Nasional Mahasiswa Ilmu Komputer dan Aplikasinya*, Jakarta, Aug. 2022, pp. 92–101.
- [12] N. Luh, P. Sukma, W. Sari, I. Gusti, and A. Purnamawati, "Pengaruh Kurs Rupiah, Suku Bunga, dan Harga Minyak Dunia terhadap Indeks Harga Saham (IHSG) pada Periode 2019-2023," *Jurnal Ilmiah Akuntansi dan Humanika*, vol. 14, no. 3, 2024.
- [13] I. Kadek *et al.*, "Analisis Clustering Kepribadian Mahasiswa Berdasarkan Data Kuesioner Menggunakan Self-Organizing Map," *KARMAPATI: Kumpulan Artikel Mahasiswa Pendidikan Teknik Informatika*, vol. 15, no. 2, pp. 267–279, 2026.
- [14] N. K. T. A. Saputri, I. G. A. Gunadi, and I. M. G. Sunarya, "Analisis Sentimen Pelayanan Daring di Fakultas Teknik dan Kejuruan Universitas Pendidikan Ganesha Menggunakan Algoritma Naïve

Bayes dan LSTM,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 3, pp. 1120–1129, Jul. 2024, doi: 10.57152/malcom.v4i3.1336.

- [15] K. R. Suryani, G. A. Mahayukti, I. Putu, and W. Ariawan, “Peramalan Nilai Tukar Petani Subsektor Tanaman Pangan Provinsi Bali dengan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA),” *Lebesgue: Jurnal Ilmiah Pendidikan Matematika, Matematika dan Statistika*, vol. 7, no. 1, pp. 96–108, Apr. 2026, doi: 10.46306/lb.v7i1.
- [16] M. Wahyu Aditya, I. N. Sukajaya, and I. Gede Aris Gunadi, “Forecasting Jumlah Pasien DBD di BRSUD Kabupaten Tabanan Menggunakan Metode Regresi Linier,” *Bali Medika Jurnal*, vol. 10, no. 1, pp. 1–12, Jun. 2023, doi: 10.36376/bmj.v9i3.
- [17] K. Ratna Sari, I. Made Sugiarta, and I. Wayan Puja Astawa, “Peramalan Jumlah Penerbitan Sertifikat Tanah Pada Kantor Pertanahan Kabupaten Buleleng Menggunakan Metode Double Exponential Smoothing Brown,” *Wahana Matematika dan Sains: Jurnal Matematika, Sains, dan Pembelajarannya*, vol. 18, no. 2, pp. 51–67, Aug. 2024.


6. Penulis




Valensia Natalia
Program Studi Ilmu Komputer, Fakultas Teknik dan Kejuruan,
Universitas Pendidikan Ganesha, Singaraja, Indonesia



I Nyoman Saputra Wahyu Wijaya
Dosen Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha
Singaraja



Luh Joni Erawati Dewi
Dosen Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha
Singaraja



Ni Putu Novita Puspa Dewi
Dosen Fakultas Teknik dan Kejuruan, Universitas Pendidikan Ganesha
Singaraja