Evaluasi Pengaruh Pemilihan *Optimizer* Terhadap Performansi Model *Long Short- Term Memory* (LSTM) untuk Prediksi Harga Saham ANTM

[1st] Intan Puspita Pratidina
Fakultas Teknik Telekomunikasi dan Elektro
Telkom University Purwokerto
Purwokerto, Indonesia
intanpuspitap@student.telkomuniversity.ac.id

[2nd] Mas Aly Afandi
Fakultas Teknik Telekomunikasi dan Elektro
Telkom University Purwokerto
Purwokerto, Indonesia
alyafandi@telkomuniversity.ac.id

[3rd] Muhammad Panji Kusuma
Fakultas Teknik Telekomunikasi dan Elektro
Telkom University Purwokerto
Purwokerto, Indonesia
panjipraja@telkomuniversity.ac.id

Abstrak — Pertumbuhan investasi pasar modal mendorong kebutuhan akan metode yang tepat untuk memprediksi harga saham. Studi ini menggunakan model Long Short-Term Memory (LSTM) untuk memprediksi harga pembukaan saham PT Aneka Tambang Tbk (ANTM), membandingkan kinerja tiga optimizer—Adam, RMSprop, dan SGD—pada 25, 50, 75, dan 100 epoch. Data yang digunakan terdiri dari 2.622 titik data historis dari Januari 2015 hingga November 2025, dengan 70% digunakan untuk pelatihan dan 30% untuk pengujian. Evaluasi model dilakukan menggunakan MAE, MSE, RMSE, MAPE, dan R^2. Hasil penelitian menunjukkan bahwa optimizer RMSprop memberikan performa terbaik pada 50 epoch, dengan akurasi 98,12%, MAE 39,16, MSE 3756,60, RMSE 61,29, MAPE 1,88%, dan R^2 0,9883. Hasil ini menunjukkan bahwa model LSTM efektif dalam memprediksi harga saham ANTM dan bahwa pilihan optimizer serta jumlah epoch memengaruhi performa model.

Kata Kunci — ANTM, Epoch, LSTM, Optimizer, Prediksi Saham

I. PENDAHULUAN

Dalam mendorong pertumbuhan ekonomi nasional, pasar modal memainkan peran strategis. Pasar modal berfungsi sebagai tempat investasi jangka panjang dan memberikan kesempatan kepada perusahaan dan masyarakat untuk menginvestasikan uang mereka secara produktif [1]. Karena potensi pengembaliannya yang menarik, sebagian besar investor memilih saham sebagai instrumen pertama yang diperdagangkan. PT Aneka Tambang Tbk (ANTM), yang bekerja di bidang pertambangan seperti emas dan nikel, adalah salah satu sahamnya. Pergerakan harga saham bersifat dinamis dan sangat dipengaruhi oleh berbagai variabel, mulai dari mekanisme permintaan dan penawaran di pasar, kondisi Harga saham dipengaruhi oleh banyak variabel, termasuk kebijakan fiskal dan moneter, makroekonomi, dan bahkan psikologi dan sentimen investor[2] . Faktor-faktor ini saling berhubungan sehingga sulit untuk memprediksi harga saham dengan metode konvensional. Ketika dihadapkan pada data yang sangat fluktuatif, seperti harga saham harian, metode statistik tradisional seperti ARIMA seringkali mencapai batasnya [3].

Perkembangan kecerdasan buatan, khususnya dalam bidang *deep learning*, menawarkan pendekatan yang lebih adaptif. Arsitektur *Long Short-Term Memory* (LSTM), sebagai varian dari *Recurrent Neural Network* (RNN), dirancang khusus untuk menangani data sekuensial berjenis *time series*. Kemampuannya dalam menyimpan dependensi jangka panjang melalui mekanisme *gate* (*input, forget*, dan *output gate*) menjadikan LSTM unggul dalam memahami pola tersembunyi pada data historis harga saham [4].

Dalam melatih model *deep learning*, pemilihan algoritma optimasi merupakan aspek penting yang dapat memengaruhi kualitas proses pembelajaran. Optimizer berfungsi untuk memperbarui parameter model dan dengan demikian memengaruhi tingkat konvergensi dan stabilitas selama pelatihan. Beberapa algoritma yang umum digunakan, seperti Adam, RMSprop, dan *Stochastic Gradient Descent* (SGD), memiliki mekanisme optimasi yang berbeda, yang dapat menyebabkan kinerja model yang bervariasi [5]. Meskipun penerapan *optimizer* yang berbeda pada model LSTM telah banyak dipelajari, terdapat relatif sedikit penelitian yang secara sistematis membandingkan kinerja *optimizer* di berbagai jumlah *epoch*, khususnya terkait dengan prediksi harga saham di Indonesia.

Tujuan penelitian ini adalah untuk menganalisis pengaruh pilihan optimizer (Adam, RMSprop, dan SGD) dan jumlah epoch terhadap performa model LSTM dalam memprediksi harga saham ANTM. Hasil penelitian ini diharapkan dapat menjadi dasar untuk menentukan konfigurasi pelatihan optimal dalam pengembangan model peramalan saham berbasis deep learning di Indonesia.

II. KAJIAN TEORI

A. Penelitian Terdahulu

Dalam penelitian ini [6], peramalan harga saham JPFA dilakukan menggunakan LSTM, dan ditemukan bahwa konfigurasi optimizer memiliki dampak signifikan pada tingkat peluruhan fungsi kerugian. Penelitian serupa [7] pada saham BCA menunjukkan bahwa optimizer RMSprop

cenderung mencapai konvergensi yang lebih stabil daripada optimizer lain ketika berurusan dengan data harga saham yang berfluktuasi. Penelitian [8] secara khusus membandingkan tiga optimizer (Adam, SGD, RMSprop) dan menyimpulkan bahwa pilihan optimizer secara signifikan memengaruhi akurasi model. Penelitian lain [9] menggunakan pendekatan hybrid CNN-LSTM untuk memprediksi saham Telkom dan melaporkan bahwa penggabungan arsitektur dapat meningkatkan akurasi ekstraksi fitur lokal. Sementara itu, sebuah penelitian [10] dalam investigasi berbasis data internasional menegaskan bahwa LSTM memiliki kemampuan superior dalam memproses data deret waktu keuangan dibandingkan dengan metode konvensional, meskipun kinerja sangat bergantung pada hyperparameter yang digunakan.

B. *Long Short Term Memory* (LSTM)

Long Short-Term Memory (LSTM) adalah perkembangan dari *Recurrent Neural Network* (RNN). LSTM bertujuan untuk menyelesaikan masalah vanishing gradient yang sering terjadi pada RNN konvensional. Ini adalah masalah yang muncul ketika nilai gradien menurun seiring dengan panjang urutan data. Ini membatasi kemampuan model untuk mengamati hubungan jangka panjang. Peramalan harga saham membutuhkan kemampuan untuk mengidentifikasi pola dalam jangka waktu yang lama karena kondisi saat ini dan siklus dan tren pasar yang berubah dari waktu ke waktu memengaruhi pergerakan harga [11].

Arsitektur LSTM bekerja dengan memanfaatkan dua komponen utama, yaitu *cell state* yang berfungsi menyimpan informasi jangka panjang dan *hidden state* yang merepresentasikan keluaran pada setiap tahap pemrosesan. Aliran informasi dalam kedua komponen tersebut diatur oleh tiga mekanisme gerbang, yaitu *forget gate, input gate, dan output gate. Forget gate* berperan dalam menentukan informasi dari tahap sebelumnya yang masih relevan untuk dipertahankan atau perlu dihilangkan. Selanjutnya, *input gate* mengontrol informasi baru yang akan ditambahkan ke memori. Sementara itu, *output gate* bertugas memilih informasi yang akan diteruskan sebagai keluaran ke proses berikutnya. Melalui kerja sama ketiga gerbang tersebut, LSTM mampu mengelola, memperbarui, dan mempertahankan informasi penting secara efektif sehingga cocok digunakan untuk memproses data sekuensial dan deret waktu.

Karakteristik LSTM yang mampu memodelkan dependensi nonlinier jangka panjang menjadikannya sangat sesuai untuk data *time series* harga saham yang bersifat fluktuatif. Teori penelitian [11] membuktikan bahwa LSTM secara konsisten mengungguli metode *machine learning* klasik dalam prediksi pergerakan harga saham. Dalam penelitian ini, model dibangun menggunakan dua lapisan LSTM tersusun (*stacked LSTM*) masing-masing 50 unit sel, diikuti satu lapisan *Dense* sebagai keluaran prediksi. Lapisan pertama mengekstrak pola temporal tingkat dasar, sementara lapisan kedua mengabstraksi representasi yang lebih kompleks dan abstrak dari pola temporal dalam data historis harga saham.

C. *Optimizer*

Optimizer merupakan algoritma yang mengatur cara bobot jaringan saraf diperbarui selama proses pelatihan berdasarkan nilai gradien dari fungsi *loss.* Pemilihan optimizer secara langsung memengaruhi kecepatan konvergensi, stabilitas pelatihan, dan kemampuan generalisasi model. Dalam penelitian ini digunakan tiga optimizer dengan karakteristik yang berbeda secara fundamental, yaitu Adam, RMSprop, dan SGD .

Adaptive Moment Estimation (Adam) adalah algoritma optimasi adaptif yang menggabungkan keunggulan metode AdaGrad dan RMSprop. Adam menggunakan informasi gradien rata-rata dan akar kuadrat rata-rata gradien untuk menyesuaikan proses pembaruan parameter model selama pelatihan. Selain itu, mekanisme koreksi biasnya membantu meningkatkan efektivitas pembelajaran, terutama pada tahap awal pelatihan. Kemampuan Adam untuk secara otomatis menyesuaikan laju pembelajaran untuk setiap parameter menyebabkan penggunaannya dalam banyak model pembelajaran mendalam, bahkan untuk data dengan pola yang kompleks dan berfluktuasi seperti harga saham [12].

Root Mean Square Propagation (RMSprop) adalah algoritma optimasi yang dirancang untuk mengatasi kelemahan AdaGrad: penurunan laju pembelajaran yang terlalu cepat selama proses pelatihan. RMSprop menggunakan rata-rata bergerak dari kuadrat gradien untuk menyesuaikan laju pembelajaran secara adaptif untuk setiap parameter. Pendekatan ini memungkinkan proses pembelajaran yang lebih stabil, karena parameter dengan gradien besar dan kecil dapat diperbarui secara lebih merata. Oleh karena itu, RMSprop sering digunakan dengan data deret waktu yang menunjukkan volatilitas tinggi, seperti data harga saham, karena memfasilitasi proses konvergensi yang lebih efektif [13].

Stochastic gradient descent (SGD) adalah salah satu algoritma optimasi paling sederhana dan paling banyak digunakan untuk melatih model pembelajaran mesin. Dalam metode ini, parameter model diperbarui pada setiap iterasi berdasarkan gradien yang diperoleh dari satu sampel atau mini-batch. Tidak seperti Adam dan RMSprop, yang memiliki mekanisme untuk secara otomatis menyesuaikan laju pembelajaran, SGD menggunakan laju pembelajaran tetap untuk semua parameter sepanjang proses pelatihan. Ini berarti bahwa SGD biasanya membutuhkan lebih banyak epoch untuk mencapai konvergensi optimal. Namun, kesederhanaan mekanisme tersebut dapat menghasilkan proses pembelajaran yang lebih konsisten dan lebih mudah dikendalikan. Dalam penelitian ini, Adam, RMSprop, dan SGD dipilih karena mewakili pendekatan optimasi yang berbeda, mulai dari metode konvensional hingga adaptif. Membandingkan ketiga pengoptimal ini bertujuan untuk memberikan perspektif yang lebih luas tentang dampak strategi optimasi terhadap kinerja model LSTM dalam memprediksi harga saham ANTM [5].

Evaluasi model dilakukan dengan menggunakan angka-angka kunci MAE, MSE, RMSE, MAPE, dan nilai R^2 untuk mengukur tingkat kesalahan prediksi serta kemampuan model dalam menjelaskan variasi pada data aktual [14].

III. METODE

A. Alur Penelitian

Penelitian ini dimulai dengan tinjauan pustaka untuk membangun landasan teoritis yang relevan. Data harga saham historis PT Aneka Tambang Tbk (ANTM) dari Januari 2015 hingga November 2025 kemudian dikumpulkan dan diproses terlebih dahulu, termasuk normalisasi data dan pemisahan menjadi data pelatihan dan data uji. Model LSTM kemudian dibangun dan dilatih menggunakan tiga optimizer—Adam, RMSprop, dan SGD—dengan epoch masing-masing 25, 50, 75, dan 100. Kinerja model dinilai menggunakan MAE, MSE, RMSE, MAPE, dan skor R^2. Hasil penilaian ini kemudian dianalisis untuk menyelidiki dampak pilihan optimizer terhadap kinerja model LSTM dalam memprediksi harga saham ANTM. Proses penelitian diilustrasikan pada Gambar 1.

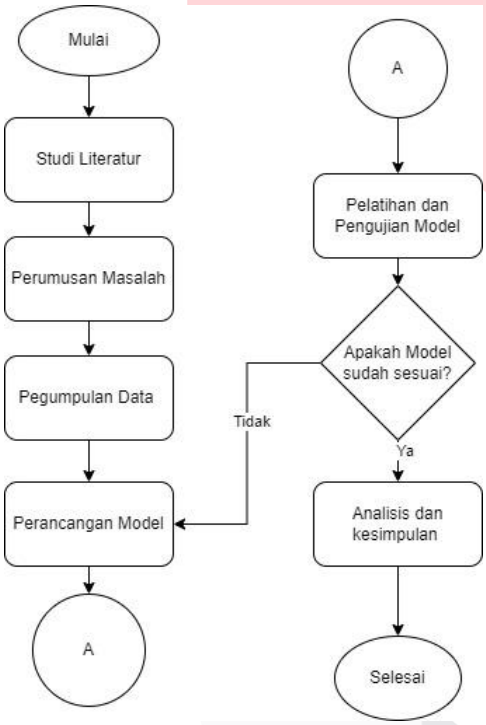

GAMBAR 1
(Flowchart Penelitian)

B. Proses Pemodelan LSTM

Proses penelitian dimulai dari pengumpulan data historis saham ANTM, dilanjutkan dengan tahap preprocessing, pembangunan model LSTM, proses pelatihan menggunakan berbagai optimizer dan epoch, serta evaluasi performa model menggunakan beberapa metrik evaluasi. Hasil evaluasi menunjukkan bahwa pemilihan parameter pelatihan yang sesuai berperan penting dalam meningkatkan kualitas hasil estimasi. Perbedaan konfigurasi yang diterapkan menghasilkan tingkat kinerja yang bervariasi, sehingga diperlukan proses pengujian untuk menentukan kombinasi yang paling efektif. Temuan penelitian ini menunjukkan bahwa metode LSTM memiliki kemampuan yang baik dalam mengenali karakteristik data historis dan merepresentasikan pola pergerakan harga saham secara memadai.

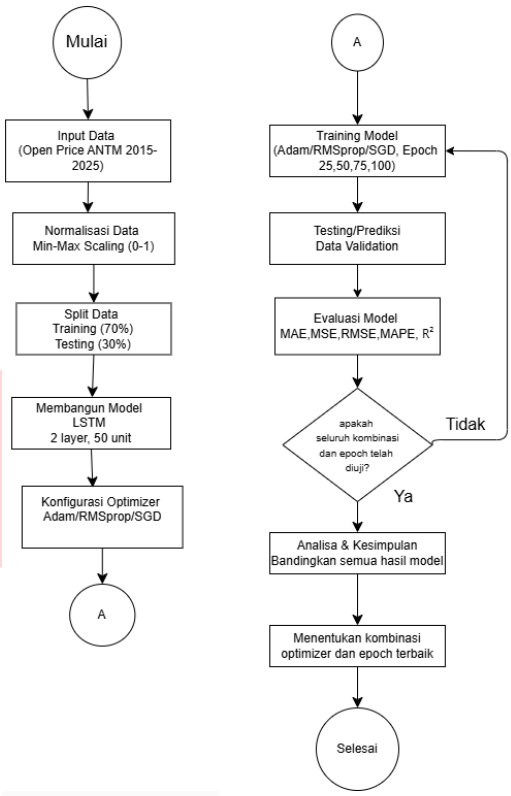

GAMBAR 2
(Alur proses prediksi LSTM)

Data penelitian berupa data historis harga pembukaan (open price) saham PT Aneka Tambang Tbk (ANTM) yang diperoleh dari Yahoo Finance. Data yang digunakan mencakup periode Januari 2015 hingga November 2025 dengan frekuensi harian. Setelah melalui proses pembersihan data untuk menghilangkan nilai duplikat, data kosong, dan data tidak valid, diperoleh sebanyak 2.622 data yang siap digunakan. Selanjutnya, data dibagi menjadi data pelatihan dan data pengujian dengan rasio 70:30 menggunakan metode time series split. Pendekatan ini mempertahankan urutan waktu sehingga model dapat mempelajari pola historis dan dievaluasi menggunakan data yang lebih baru.

TABEL 1
(Pembagian Dataset Penelitian)

Keterangan	Jumlah Data	Persentase
Data Training	1.835	70%
Data Testing/Validasi	787	30%
Total Dataset	2.622	100%

C. *Pre-processing Data*

Sebelum dimasukkan ke dalam model LSTM, seluruh data harga pembukaan menjalani proses normalisasi menggunakan metode *Min-Max Scaling*. Metode ini mengubah nilai fitur data ke dalam rentang standar antara 0 dan 1 melalui transformasi linear, sehingga mengeliminasi

pengaruh perbedaan skala yang dapat memperlambat atau mendestabilisasi proses pelatihan jaringan saraf. Setelah proses prediksi selesai, nilai keluaran model dikembalikan ke skala aslinya melalui proses invers normalisasi (*inverse scaling*) sebelum dibandingkan dengan nilai aktual harga saham. Pembentukan sequence data dilakukan menggunakan window size sebesar 60 langkah waktu. Artinya, model menggunakan data harga dari 60 hari perdagangan sebelumnya sebagai input untuk memprediksi harga pada hari berikutnya. Pendekatan ini memungkinkan LSTM menangkap pola dependensi temporal jangka menengah yang terdapat dalam data historis harga saham.

D. Arsitektur Model LSTM

Model LSTM dibangun menggunakan arsitektur sekuensial, yang terdiri dari dua lapisan LSTM dan lapisan keluaran padat. Arsitektur sekuensial dipilih karena lapisannya disusun dalam urutan yang teratur, menyederhanakan manajemen aliran data dan membuatnya sangat cocok untuk memproses data harga saham deret waktu. Lapisan LSTM pertama terdiri dari 50 unit dan dikonfigurasi dengan `return_sequences=True`dan `input_shape=(60, 1)`. Ini berarti model menerima 60 langkah waktu sebelumnya (ukuran jendela) sebagai input, dengan satu fitur yang mewakili harga pembukaan. Pengaturan `return_sequences=True` memastikan bahwa output tetap sekuensial sehingga dapat diteruskan ke lapisan LSTM berikutnya. Lapisan LSTM kedua juga memiliki 50 unit dengan nilai default `return_sequences=False`, yang meringkas informasi dari urutan data ke dalam vektor representasi sebelum diteruskan ke lapisan keluaran. Penggunaan dua lapisan LSTM bertujuan untuk memungkinkan model menangkap representasi fitur secara lebih mendalam: Lapisan pertama mengekstrak fitur dasar dari data masukan, sementara lapisan kedua memproses fitur-fitur ini untuk mendapatkan representasi yang lebih kompleks dan abstrak. Setelah kedua lapisan LSTM ini, ditambahkan lapisan dense dengan sebuah neuron, yang mengubah informasi yang telah diproses menjadi nilai prediktif, yaitu harga pembukaan saham ANTM untuk hari berikutnya. Semua pengaturan hyperparameter yang digunakan disajikan dalam Tabel 1

TABEL 2
(Konfigurasi Hyperparameter Model LSTM)

Parameter	Nilai
Jumlah layer, unit LSTM, lapisan output	2, unit= 50 , output= Dense (1 neuron)
Window size, batch size	60, batch size = 1
Batch size	1
Variasi epoch	25, 50, 75, 100
Learning rate (Adam)	0,001
Learning rate (RMSprop)	0,001
Learning rate (SGD)	0,01
Fungsi loss	MSE
Normalisasi	Min-Max Scaling
Rasio split data	70% training / 30% validasi

E. Skenario Pengujian

Kombinasi tiga optimizer (Adam, RMSprop, SGD) dan empat variasi epoch (25, 50, 75, 100) menghasilkan total 12 skenario percobaan yang masing-masing dilatih dan diuji secara independen. Setiap skenario dilatih menggunakan data training yang sama, kemudian digunakan untuk melakukan prediksi pada data testing, dan hasilnya dievaluasi secara komprehensif menggunakan kelima metrik yang telah ditetapkan. Pendekatan ini memungkinkan perbandingan yang adil dan terstruktur antara setiap kombinasi konfigurasi. Tiga optimizer diuji: Adam, RMSprop, dan SGD, masing-masing pada variasi epoch 25, 50, 75, dan 100. Persamaan matematis gerbang utama LSTM: [15] [16].

1. *Forget Gate*

$$ft = \sigma\left(W_f X_t + U_f h_{t^{-1}} + bf\right) \quad (1)$$

2. *Input gate*

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (2)$$

$$\tilde{C}_t = tanh(W_c x_t + U_c h_{t^{-1}} + b_c) \quad (3)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4)$$

3. *Cell state*

$$Ct = i_t \tilde{C}t + f_t C_{t^{-1}} \quad (5)$$

4. *Output gate*

$$o_t = \sigma(W_o x_t + U_o h_{t^{-1}} + bo) \quad (6)$$

$$h_t = o_t \times \tanh(C_t) \quad (7)$$

IV. HASIL DAN PEMBAHASAN

A. Hasil Prediksi Model LSTM Optimizer Adam

Model LSTM dengan optimizer Adam menunjukkan performa yang baik dalam memprediksi pergerakan harga saham ANTM di semua epoch. Pada epoch ke-25, model sudah mampu mendeteksi tren data, meskipun prediksinya masih relatif halus dan kurang responsif terhadap perubahan harga yang cepat. Seiring bertambahnya jumlah epoch menjadi 50, kemampuan model untuk melacak pergerakan harga meningkat; namun, nilai MSE juga naik dari 10.437,11 menjadi 20.486,70, menunjukkan ketidakstabilan sementara selama proses pelatihan. Selanjutnya, pada epoch ke-75 dan 100, performa model kembali meningkat, dibuktikan dengan penurunan nilai MSE menjadi 12.557,72 dan penurunan MAPE menjadi 2,62%.

Secara keseluruhan, peningkatan jumlah epoch memberikan efek positif pada akurasi model, yang meningkat dari 96,58% pada epoch ke-25 menjadi 97,38% pada epoch ke-100. Berdasarkan hasil evaluasi, konfigurasi dengan 75 epoch dipilih sebagai yang optimal, karena mencapai keseimbangan terbaik antara tingkat kesalahan prediksi dan akurasi model.

TABEL 3
(Rekapitulasi Metrik Evaluasi Model LSTM OptimizerAdam)

Epoch	Akurasi (%)	MAE	MSE	RMSE	MAPE (%)	R^2
25	96,58	71,90	10.437,11	102,16	3,42	0,9675
50	97,04	71,75	20.486,70	143,13	2,96	0,9362
75	97,35	62,73	12.557,72	112,06	2,65	0,9609
100	97,38	62,19	16.255,65	127,50	2,62	0,9494

B. Hasil Prediksi Model LSTM dengan Optimizer RMSprop

Optimizer RMSprop memberikan hasil yang paling menonjol di antara ketiga optimizer yang diuji. Bahkan pada epoch paling awal (epoch 25), model dengan RMSprop sudah mampu mengikuti pola pergerakan harga saham dengan cukup baik, mencapai akurasi 97,93%. Kemampuan adaptif RMSprop dalam menyesuaikan learning rate berdasarkan riwayat gradien membuatnya lebih cepat beradaptasi terhadap karakteristik data dibandingkan Adam pada jumlah

epoch yang sama. Konfigurasi terbaik dicapai pada epoch ke-50, dengan performa puncak pada semua metrik: akurasi 98,12%, MAE 39,17, MSE 3.756,60, RMSE 61,29, MAPE 1,88%, dan R^2 0,9883. Nilai MAPE sebesar 1,88% ini termasuk dalam kategori "sangat akurat" berdasarkan kriteria evaluasi yang menetapkan batas di bawah 10%. Nilai R^2 sebesar 0,9883 mengindikasikan bahwa model mampu menjelaskan lebih dari 98% variabilitas harga saham aktual — sebuah tingkat kecocokan yang sangat tinggi. Menariknya, penambahan epoch di atas 50 justru menunjukkan degradasi performa RMSprop. Pada epoch 75 dan 100, nilai MSE meningkat menjadi 7.012,28 dan 8.150,77 secara berturut-turut, sementara MAPE kembali naik menjadi 2,22% dan 2,64%. Pola ini mengisyaratkan bahwa RMSprop memiliki titik saturasi pembelajaran yang lebih cepat, di mana penambahan iterasi setelah titik optimal tidak hanya tidak memberikan manfaat, tetapi bahkan menurunkan kemampuan generalisasi model terhadap data baru. Fenomena ini sejalan dengan kajian terdahulu yang menyatakan bahwa optimizer adaptif seperti RMSprop mencapai konvergensi stabil pada jumlah epoch tertentu, dan penambahan epoch berlebihan dapat berdampak negatif.

TABEL 4
(Rekapitulasi Metrik Evaluasi Model LSTM Optimizer RMSpro)

Epoch	Akurasi (%)	MAE	MSE	RMSE	MAPE (%)	R^2
25	97,93	44,53	4.837,70	69,55	2,07	0,9849
50	98,12	39,16	3.756,60	61,29	1,88	0,9883
75	97,78	49,92	7.012,28	83,74	2,22	0,9782
100	97,36	57,84	8.150,77	90,28	2,64	0,9746

C. Hasil Prediksi Model LSTM dengan Optimizer SGD

Model LSTM dengan optimizer SGD menunjukkan performa yang paling rendah di antara ketiga optimizer yang diuji, sekaligus memperlihatkan pola peningkatan yang lebih lambat namun lebih konsisten seiring bertambahnya epoch. Pada epoch ke-25, model SGD menghasilkan nilai error tertinggi: MAE 111,15, MAPE 5,90%, dan R^2 hanya 0,9441. Hal ini berkaitan erat dengan karakteristik SGD yang melakukan pembaruan bobot secara seragam tanpa mekanisme adaptasi terhadap perubahan gradien, sehingga proses konvergensi berlangsung lebih lambat, terutama pada data time series dengan tingkat fluktuasi yang tinggi. Namun demikian, SGD menunjukkan perbaikan yang cukup signifikan dari epoch 25 menuju epoch 50 dengan MAE turun dari 111,15 menjadi 75,97 dan MAPE turun dari 5,90% menjadi 3,62% mengindikasikan bahwa mekanisme gradient descent sederhana pada SGD memerlukan lebih banyak iterasi untuk membangun representasi yang memadai dari pola data. Perbaikan tersebut terus berlanjut secara bertahap hingga epoch ke-100, di mana SGD mencapai akurasi terbaiknya sebesar 96,57% dengan MAE 69,20 dan RMSE 99,88. Berbeda dengan RMSprop yang mengalami degradasi di atas epoch optimal, SGD memperlihatkan tren perbaikan monoton, mencerminkan konvergensi yang lebih lambat namun lebih stabil dalam jangka panjang.

Karakteristik ini konsisten dengan pemahaman teoritis bahwa SGD, meskipun lebih lambat, dapat menghasilkan generalisasi yang lebih baik pada beberapa kasus tertentu. Namun pada konteks data time series keuangan yang sangat dinamis seperti harga saham ANTM, keunggulan generalisasi SGD tidak mampu mengompensasi keterlambatan konvergensinya dibandingkan optimizer adaptif.

TABEL 5
(Rekapitulasi Metrik Evaluasi Model LSTM Optimizer SGD)

Epoch	Akurasi (%)	MAE	MSE	RMSE	MAPE (%)	R^2
25	94,10	111,15	17.951,76	133,98	5,90	0,9441
50	96,38	75,97	13.194,37	114,87	3,62	0,9589
75	96,37	72,77	10.765,09	103,76	3,63	0,9665
100	96,57	69,20	9.975,25	99,88	3,43	0,9690

D. Perbandingan Komprehensif Seluruh Optimizer

Perbandingan menyeluruh antara ketiga optimizer memperlihatkan perbedaan yang jelas dalam hal akurasi, tingkat kesalahan, dan stabilitas pembelajaran. RMSprop secara konsisten unggul dalam menghasilkan akurasi tertinggi di semua variasi epoch yang diuji. Hal ini tecermin dalam nilai akurasi yang berkisar antara 97,36% hingga 98,12%, dengan puncak terbaik pada epoch ke-50. Adam memperlihatkan tren akurasi yang terus meningkat seiring penambahan epoch, dari 96,58% hingga 97,38%, menunjukkan karakteristik optimizer yang memerlukan lebih banyak iterasi untuk mencapai potensi penuhnya. SGD, sebaliknya, berada di posisi terendah dengan akurasi berkisar antara 94,10% hingga 96,57%.

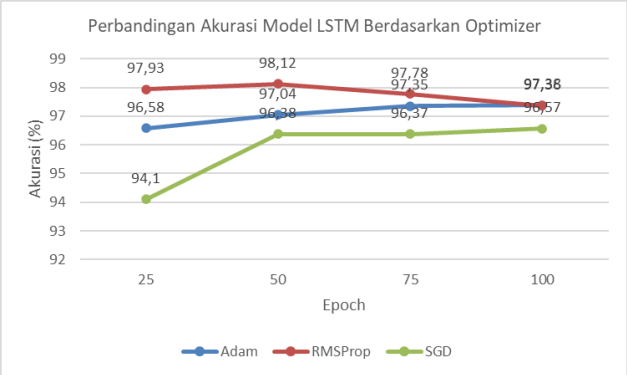

GAMBAR 3
(Perbandingan akurasi pada model LSTM)

Dari Gambar 3 terlihat bahwa RMSprop secara konsisten menghasilkan akurasi tertinggi pada sebagian besar variasi *epoch*. Puncak performa dicapai pada *epoch* ke-50 dengan akurasi 98,12%, menjadikannya konfigurasi terbaik secara keseluruhan. Optimizer Adam menunjukkan tren peningkatan bertahap dari 96,58% (*epoch* 25) hingga 97,38% (*epoch* 100), mencerminkan kestabilan proses adaptasi gradien yang dimilikinya. SGD mencatat akurasi terendah pada seluruh variasi *epoch*, dengan nilai minimum 94,10% pada *epoch* 25, yang mengindikasikan lambatnya konvergensi akibat mekanisme pembaruan bobot yang tidak adaptif.

TABEL 6
(Hasil MAE dan MAPE pada Setiap Konfigurasi)

Optimizer	Epoch	MAE	MAPE (%)
Adam	25	71,90	3,42
Adam	50	71,75	2,96
Adam	75	62,73	2,65
Adam	100	62,19	2,62
RMSprop	25	44,53	2,07
RMSprop	50	39,16	1,88
RMSprop	75	49,92	2,22
RMSprop	100	57,84	2,64
SGD	25	111,15	5,90
SGD	50	75,97	3,62
SGD	75	72,77	3,63
SGD	100	69,20	3,43

Data pada Tabel 2 memperkuat temuan sebelumnya. RMSprop memperlihatkan nilai MAE terkecil (39,16) dan MAPE terendah (1,88%) pada *epoch* 50. Nilai MAPE 1,88% tersebut jauh di bawah ambang 10% yang ditetapkan Lewis [15] sebagai batas kategori sangat akurat. Sebaliknya, SGD pada *epoch* 25 menghasilkan MAE 111,15 dan MAPE 5,90%, meskipun nilai MAPE ini masih berada dalam kisaran akurat. Menariknya, Adam menunjukkan perbaikan MAPE yang konsisten seiring penambahan *epoch*, dari 3,42% (*epoch* 25) turun menjadi 2,62% (*epoch* 100), mengindikasikan bahwa penambahan iterasi memberikan manfaat yang lebih merata pada optimizer ini.

TABEL 7
(Hasil MSE, RMSE, dan R^2 Score)

Optimizer	Epoch	MSE	RMSE	R^2
Adam	25	10.437,11	102,16	0,9675
Adam	50	20.486,70	143,13	0,9362
Adam	75	12.557,72	112,06	0,9609
Adam	100	16.255,65	127,50	0,9494
RMSprop	25	4.837,70	69,55	0,9849
RMSprop	50	3.756,60	61,29	0,9883
RMSprop	75	7.012,28	83,74	0,9782
RMSprop	100	8.150,77	90,28	0,9746
SGD	25	17.951,76	133,98	0,9441
SGD	50	13.194,37	114,87	0,9589
SGD	75	10.765,09	103,76	0,9665
SGD	100	9.975,25	99,88	0,9690

Berdasarkan Tabel 6, RMSprop pada *epoch* 50 menghasilkan MSE terendah (3.756,60), RMSE terkecil (61,29), dan nilai R^2 tertinggi (0,9883). Nilai R^2 mendekati 1 mengindikasikan bahwa model mampu menjelaskan sekitar 98,83% variansi harga aktual, yang merupakan kapabilitas eksplanatori yang sangat tinggi. Sebaliknya, Adam pada *epoch* 50 mencatat MSE tertinggi (20.486,70) dan R^2 terendah (0,9362) di antara seluruh konfigurasi, yang mengindikasikan terjadinya overfitting pada fase tersebut. SGD menunjukkan tren penurunan MSE yang stabil seiring penambahan *epoch*, meskipun nilainya tetap lebih tinggi dibandingkan RMSprop.

E. Pengaruh Jumlah Epoch terhadap Performa

Analisis lintas konfigurasi menunjukkan bahwa penambahan jumlah *epoch* tidak selalu berbanding lurus dengan peningkatan performa. Pada optimizer RMSprop, kondisi optimal dicapai pada *epoch* 50; penambahan *epoch* lebih lanjut justru memperlihatkan sedikit degradasi akurasi yang mengindikasikan potensi *overfitting.* Fenomena serupa juga terlihat pada Adam di *epoch* 50. SGD, di sisi lain, cenderung mendapat manfaat dari penambahan *epoch* karena mekanismenya yang non-adaptif membutuhkan lebih banyak iterasi untuk mencapai konvergensi yang memadai. Temuan ini sejalan dengan penelitian Pipin et al. [16] dan Verianto [17] yang menekankan pentingnya pemilihan jumlah *epoch* yang tepat untuk menjaga keseimbangan antara kemampuan belajar dan generalisasi model.

V. KESIMPULAN

Berdasarkan hasil penelitian, model LSTM mampu memprediksi harga saham ANTM dengan tingkat akurasi yang tinggi pada berbagai kombinasi optimizer dan epoch. Di antara optimizer yang diuji, RMSprop memberikan performa terbaik dengan akurasi tertinggi sebesar 98,12% pada epoch 50 serta menghasilkan nilai error yang lebih rendah dibandingkan Adam dan SGD. Sementara itu, Adam menunjukkan kinerja yang stabil pada seluruh variasi epoch, sedangkan SGD menghasilkan performa yang relatif lebih rendah dibandingkan kedua optimizer adaptif tersebut. Evaluasi menggunakan metrik MAE, MSE, RMSE, MAPE, dan R^2 Score menunjukkan bahwa seluruh konfigurasi model memiliki kemampuan prediksi yang baik, dengan nilai MAPE berada pada kategori sangat akurat. Hasil penelitian juga menunjukkan bahwa pemilihan optimizer berpengaruh terhadap performa model, di mana RMSprop dan Adam lebih efektif dibandingkan SGD dalam meningkatkan akurasi dan mengurangi kesalahan prediksi pada model LSTM untuk prediksi harga saham ANTM. Epoch optimal masing-masing optimizer adalah epoch ke-75 untuk Adam, epoch ke-50 untuk RMSprop, dan epoch ke-100 untuk SGD. Penelitian ini memiliki keterbatasan pada penggunaan satu saham (ANTM), satu fitur input (open price), dan belum mempertimbangkan faktor eksternal seperti sentimen pasar, sehingga penelitian lanjutan dapat memperluas cakupan fitur dan objek saham yang diteliti.

REFERENSI

[1] Bursa Efek Indonesia, “Saham Indonesia,” 2025. https://www.idx.co.id (accessed Nov. 01, 2025).

[2] I. Oktavia and K. Genjar, “Faktor -Faktor yang Memperngaruhi Harga Saham,” *J. Ris. Akunt. Multiparadigma*, vol. 6, no. 1, pp. 29–39, 2019.

[3] Kontan, “Investor Asing Ramai Memburu Saham ANTM,”2025.https://insight.kontan.co.id/news/investor-asing-ramai-memburu-saham-antm-dari blackrock-hingga-russell-investments

[4] A. Khumaidi, R. Raafi’udin, and I. P. Solihin, “Pengujian Algoritma Long Short Term Memory untuk Prediksi Kualitas Udara dan Suhu Kota Bandung,” *J. Telemat.*, vol. 15, no. 1, pp. 13–18, 2020.

[5] D. Anggara, N. Suarna, and Y. Arie Wijaya, “Performance Comparison Analysis Of Optimizer Adam, SGD, and RMSPROP on The H5 Model,” *J. Ilm. NERO*, vol. 8, no. 1, p. 2023, 2023.

[6] I. K. A. Enriko, F. N. Gustiyana, and H. Krishna, “Forecasting JPFA Share Price using Long Short Term Memory Neural Network,” *Jaict*, vol. 8, no. 1,

p. 157, 2023, doi: 10.32497/jaict.v8i1.4285.

[7] V. No and M. N. Wathani, "Prediksi Tren Pergerakan Harga Saham PT Bank Central Asia Tbk , Dengan Menggunakan Algoritma Long Shot Term Memory (LSTM) Pergerakan indeks pasar saham selalu identik sebagai salah satu indikator penting dalam menilai kondisi perekonomian sebuah negara ," vol. 6, no. 2, pp. 502–513, 2023.

[8] D. Anggara, N. Suarna, and Y. Arie Wijaya, "Performance Comparison Analysis Of Optimizer Adam, SGD, And RMSPROP On The H5 Model," *J. Ilm. NERO*, vol. 8, no. 1, pp. 53–64, 2023.

[9] F. R. Pratama, B. Santoso, and S. Kacung, "Prediksi Harga Saham Pt Telkom Menggunakan Metode CNN-LSTM," *J. Inf. Syst. Manag.*, vol. 7, no. 1, pp. 66–70, 2025.

[10] A. Wahab, A. Herdian, D. Wirawan, Y. Jumaryadi, S. Alam, and A. Fiade, "Stock Prediction for Indonesia Stock Exchange with Long Short-Term Memory," *J. Ilm. FIFO*, vol. 16, no. 1, p. 96, 2024, doi: 10.22441/fifo.2024.v16i1.010.

[11] N. W. Meri Aryati, I. K. A. G. Wiguna, N. W. S. Putri, I. K. K. Widiartha, and N. L. W. S. R. Ginantra, "Komparasi Metode LSTM dan GRU dalam Memprediksi Harga Saham," *J. Media Inform. Budidarma*, vol. 8, no. 2, p. 1131, 2024, doi: 10.30865/mib.v8i2.7342.

[12] A. Makinde, "Optimizing Time Series Forecasting: A Comparative Study of Adam and Nesterov Accelerated Gradient on LSTM and GRU networks Using Stock Market data," no. 1, pp. 1–12, 2024, [Online]. Available: http://arxiv.org/abs/2410.01843

[13] S. Makamo, "A Review of Optimization Algorithms in Deep Learning Models for Improving the Forecasting Accuracy in Sequential Datasets with Application in the South African Stock Market Index," pp. 173–181, 2024, doi: 10.5121/csit.2024.141015.

[14] 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 Mhs. Tek. Inform.*, vol. 8, no. 1, pp. 501–506, 2024, doi: 10.36040/jati.v8i1.8440.

[15] D. R. Babu and B. Sathyanarayana, "Design and Implementation of Technical Analysis Based LSTM Model for Stock Price Prediction," *Int. J. Recent Innov. Trends Comput. Commun.*, vol. 11, no. December 2022, pp. 1–7, 2023, doi: 10.17762/ijritcc.v11i4s.6301.

[16] G. Van Houdt, C. Mosquera, and G. Nápoles, "A review on the long short-term memory model," *Artif. Intell. Rev.*, vol. 53, no. 8, pp. 5929–5955, 2020, doi: 10.1007/s10462-020-09838-1.