

PENERAPAN MODEL LSTM DAN ANALISIS SENTIMEN UNTUK PREDIKSI HARGA PENUTUPAN SAHAM PT BANK MANDIRI (PERSERO) TBK

Imelda Agustin, Ulfa Khaira, Mutia Fadhila Putri

Sistem Informasi, Universitas Jambi

Jl. Jambi-Muara Bulian KM. 15, Mendalo Indah, Kecamatan Jambi Luar Kota, Kabupaten Muaro Jambi, Jambi

Imeldaagustin092@gmail.com

ABSTRAK

Penelitian ini dilakukan untuk menganalisis pengaruh penambahan variabel sentimen publik terhadap akurasi prediksi harga penutupan saham PT Bank Mandiri (Persero) Tbk (BMRI). Data yang digunakan berupa data historis saham BMRI yang terdiri dari *close price* dan *volume* dari Yahoo Finance serta data *headline* berita dari Bisnis.com periode November 2024 hingga Januari 2026. Analisis sentimen dilakukan menggunakan model FinBERT untuk menghasilkan skor sentimen harian yang kemudian diintegrasikan ke dalam model Long Short-Term Memory (LSTM). Penelitian menggunakan dua skenario, yaitu model LSTM tanpa sentimen dan model LSTM dengan variabel sentimen. Evaluasi model dilakukan menggunakan RMSE, MAE, dan MAPE. Hasil penelitian menunjukkan bahwa model tanpa sentimen memperoleh performa lebih baik dengan nilai RMSE 83,76, MAE 62,34, dan MAPE 1,28%, sedangkan model dengan sentimen menghasilkan RMSE 97,59, MAE 68,55, dan MAPE 1,41%. Berdasarkan hasil tersebut, penambahan variabel sentimen pada penelitian ini belum mampu meningkatkan akurasi prediksi harga saham BMRI.

Kata kunci: LSTM, FinBERT, Prediksi, Saham, Sentimen

1. PENDAHULUAN

Pasar modal merupakan salah satu pilar penting dalam sistem keuangan modern karena menyediakan sarana distribusi dana dari pihak yang memiliki *surplus* kepada pihak yang membutuhkan modal untuk ekspansi bisnis. Bentuk efek dari pasar modal, salah satunya adalah perdagangan saham, yaitu tanda atau kepemilikan seseorang atau badan dalam suatu perusahaan atau perseroan terbatas [1].

Menurut data PT Bursa Efek Indonesia (BEI), jumlah investor saham pada Desember 2025 mencapai 8 juta single investor identification (SID) atau lebih tepatnya 8.461.938 SID, meningkat 32,6% dibandingkan data pada akhir tahun 2024 yaitu sebanyak 6.381.444 SID.

Di antara berbagai saham yang diperdagangkan, PT Bank Mandiri Tbk (BMRI) menjadi salah satu emiten yang paling menarik perhatian karena stabilitas kinerja dan posisinya sebagai bank terbesar di Indonesia. Fauzi (2025), menjelaskan bahwa Bank Mandiri mencatatkan total aset konsolidasi mencapai Rp 2.427 triliun dengan pertumbuhan 11,6% YoY (*year on year*) dan didorong oleh ekspansi kredit yang merata serta transformasi digital. Berdasarkan laporan keuangan September 2025, BMRI mencatatkan laba bersih naik 1,84 persen secara bulanan atau *month on month* (MoM) menjadi Rp 4,14 triliun [3].

Pergerakan harga saham dipengaruhi oleh berbagai faktor, baik internal maupun eksternal. Untuk memahami pola pergerakan harga saham, dapat dilakukan analisis untuk pengambilan keputusan investasi saham. Salah satu pendekatan yang banyak digunakan adalah analisis teknikal, karena menekankan pada pola pergerakan harga dan volume secara historis. Pola dan tren yang terbentuk dari data

historis dapat memberikan dasar pemahaman yang lebih objektif terhadap dinamika pergerakan pasar.

Pola dan tren yang terbentuk dari data historis tidak hanya membantu memahami dinamika pasar, tetapi juga menjadi dasar dalam melakukan prediksi pergerakan harga saham. Salah satu metode yang dapat digunakan dalam analisis prediksi adalah metode *Long Short-Term Memory* (LSTM). LSTM merupakan pengembangan dari RNN (*Reccurent Neural Network*) yang mampu mengekstraksi informasi pada data jangka panjang, khususnya data yang bersifat *time series* atau sekuensial [4].

LSTM memiliki kemampuan untuk mengingat informasi jangka panjang dari data historis dan dapat digunakan untuk membuat prediksi berdasarkan urutan waktu [5].

Penelitian Julian & Pribadi (2021), menunjukkan bahwa metode Long Short-Term Memory (LSTM) mampu meningkatkan akurasi prediksi, yang ditunjukkan melalui penurunan nilai RMSE pada saham ANTM dari 54,84 menjadi 40,14, TINS dari 40,73 menjadi 31,76, serta INCO dari 139,67 menjadi 111,47 seiring bertambahnya *epoch* pelatihan. Selain itu, studi oleh Pratama & Zahara (2024), menemukan bahwa LSTM menghasilkan akurasi tinggi pada saham BBNI dan BBRI dengan nilai MAE masing-masing sebesar 0,014984 dan 0,014066. Penelitian oleh Lestari et al., (2025) juga menunjukkan bahwa LSTM lebih unggul dibandingkan GRU dalam memprediksi saham TLKM, dengan tingkat akurasi 95% dibandingkan 92%. Dengan kemampuan tersebut, LSTM menjadi salah satu model yang paling banyak diadopsi dalam prediksi harga saham karena mampu mengatasi keterbatasan metode tradisional dan memberikan hasil yang lebih stabil.

Selain data historis, sentimen publik juga menjadi faktor penting yang memengaruhi pergerakan harga saham dalam jangka pendek. Informasi dari berita dan media sosial dapat membentuk persepsi investor terhadap kondisi pasar. Salah satu pendekatan yang dapat digunakan dalam menganalisis sentimen ini ialah FinBert (*Financial Bidirectional Encoder Representations from Transformers*), yakni pengembangan dari model BERT yang dilatih secara khusus pada korpus teks finansial yang relevan dengan sentimen publik dari berita maupun media sosial [8].

FinBert digunakan untuk mengekstrak fitur sentimen dari berita utama keuangan, yang kemudian digabungkan ke dalam skor sentimen harian (positif, netral, negatif) [9]. Huang et al., (2023) menemukan bahwa FinBERT mencapai akurasi yang jauh lebih tinggi yaitu 88.2% daripada pendekatan lain yang populer dalam penelitian keuangan, termasuk LM dictionary, NB, SVM, RF, CNN, dan LSTM. Temuan ini memperkuat dasar penggunaan FinBert sebagai metode analisis sentimen yang efisien, terutama ketika diintegrasikan dengan LSTM untuk meningkatkan akurasi prediksi.

Integrasi model LSTM dengan fitur sentimen telah menjadi tren riset yang menunjukkan performa prediksi lebih unggul. Studi oleh Nkongolo et al (2025), menunjukkan bahwa model LSTM berbasis sentimen mencapai akurasi 89,6% pada pasar saham India dan lebih unggul dibanding model tanpa sentimen. Temuan serupa ditunjukkan pada aset Bitcoin, di mana performa LSTM meningkat setelah mengintegrasikan sentimen media social [12].

Integrasi model LSTM dan sentimen juga lebih unggul dengan nilai MAE 17,7 dibandingkan dengan model GRU dan sentimen yang memiliki nilai MAE 24,5 pada prediksi harga saham ADBL di Nepal [13].

Meskipun berbagai penelitian sebelumnya menunjukkan bahwa integrasi analisis sentimen mampu meningkatkan performa prediksi harga saham, hasil yang diperoleh masih bervariasi tergantung pada objek penelitian, jenis data sentimen, dan metode yang digunakan. Selain itu, sebagian besar penelitian terdahulu lebih banyak memanfaatkan data sentimen dari media sosial seperti Twitter dan forum daring, sedangkan penggunaan *headline* berita nasional sebagai sumber sentimen pada saham sektor perbankan masih relatif terbatas. Oleh karena itu, diperlukan penelitian lebih lanjut untuk mengetahui apakah integrasi sentimen berbasis *headline* berita nasional dapat memberikan peningkatan akurasi pada prediksi harga saham BMRI menggunakan metode LSTM.

Berdasarkan uraian tersebut, penelitian ini berfokus pada analisis pengaruh sentimen publik terhadap tingkat akurasi prediksi harga penutupan saham BMRI menggunakan metode *Long Short-Term Memory* (LSTM). Penelitian dilakukan dengan mengintegrasikan analisis sentimen berbasis FinBERT terhadap *headline* berita nasional dengan data historis saham BMRI. Selanjutnya, dibangun dua skenario

model, yaitu model LSTM tanpa sentimen dan model LSTM dengan penambahan variabel sentimen untuk membandingkan performa prediksi yang dihasilkan. Pendekatan ini diharapkan mampu memberikan pemahaman yang lebih komprehensif mengenai keterkaitan antara sentimen publik dan pergerakan harga saham BMRI.

2. TINJAUAN PUSTAKA

2.1. Pasar Modal dan Saham

Pasar modal (*Capital market*) adalah pasar keuangan yang mempertemukan pemilik dana dengan pengguna dana untuk tujuan investasi jangka menengah (*middle-term investment*) dan jangka panjang (*long-term investment*) [14].

Di antara berbagai instrumen keuangan yang diperdagangkan di pasar modal, saham menjadi instrumen yang cukup diminati karena memberikan hak kepemilikan suatu perusahaan sekaligus peluang memperoleh keuntungan melalui dividen maupun *capital gain*.

2.2. PT. Bank Mandiri Tbk


PT Bank Mandiri (Persero) Tbk didirikan pada 2 Oktober 1998 sebagai bagian dari program restrukturisasi perbankan nasional pasca krisis moneter 1998. Pada Juli 1999, pemerintah menggabungkan empat bank milik negara, Bank Bumi Daya, Bank Dagang Negara, Bank Ekspor Impor Indonesia, dan Bank Pembangunan Indonesia ke dalam satu entitas bernama Bank Mandiri. Bank Mandiri menunjukkan pertumbuhan yang konsisten. Menurut berita dari Kontan 2025, pada kuartal I tahun 2025, Bank Mandiri mencatat laba bersih sebesar Rp13,2 triliun, meningkat 3,9% dibandingkan periode yang sama pada tahun sebelumnya. Dihimpun dari TradingView 2025, total pendapatan Bank Mandiri pada kuartal III tahun 2025 mencapai Rp50,21 triliun, dan total aset tumbuh menjadi Rp2.563,74 triliun secara *year-on-year*, meningkat 10,30% dari periode sebelumnya.

2.3. Long Short-Term Memory (LSTM)

Algoritma LSTM ditemukan oleh Hochreiter dan Schmidhuber pada tahun 1997 [15]. LSTM merupakan pengembangan dari model RNN, perkembangan ini bertujuan untuk memecahkan masalah utama yang dihadapi oleh jaringan saraf rekurensi RNN konvensional, khususnya menangani informasi jangka panjang dalam data urutan [16].

Hal yang membedakan LSTM dengan RNN biasa adalah LSTM mampu mempelajari informasi mana yang harus dibuang dan informasi mana yang harus tetap disimpan dalam *memory cell* [17].

Kemampuan ini didapat dari struktur *neuron* LSTM yang berbeda dengan *neuron* RNN biasa, yang mana setiap *neuron* LSTM memiliki *memory cell* dan *gate units*.



Gambar 1. Neuron pada LSTM [17]

Struktur LSTM terdiri dari tiga gerbang: gerbang masukan (*input gate*), gerbang lupakan (*forget gate*), dan gerbang keluaran (*output gate*). Gerbang masukan mengontrol jumlah informasi yang disimpan dalam memori jangka panjang, gerbang lupakan menentukan seberapa banyak informasi yang dihapus, dan gerbang keluaran mengatur berapa banyak informasi yang dikeluarkan dari memori jangka panjang [15].

2.4. Natural Language Processing (NLP)

Natural Language Processing (NLP) adalah teknologi yang memungkinkan komputer untuk memahami dan menganalisis bahasa manusia [18].

Menurut Tarumangkeng, (2024) NLP mencakup berbagai komponen, diantaranya adalah pemahaman sintaksis, pemahaman semantik, *contextual understanding*, *Name Entity Recognition* (NER), *sentiment analysis*, dan *text generation*. Terdapat tiga pendekatan yang populer dalam NLP modern, yaitu *Transfer Learning*, *Transformers* dan *Attention Mechanism*, serta *Fine-tuning* [19].

2.5. Analisis Sentimen

Analisis sentimen sering juga disebut dengan *opinion mining* atau *content analysis* adalah proses pengelompokan teks/serangkaian kata yang mengandung nada emosi yang diterapkan untuk memperoleh pemahaman tentang sikap, opini, pendapat, dan emosi yang diungkapkan dalam percakapan *online* [20].

Secara umum sentimen yang terkumpul dikategorikan menjadi 3, yaitu sentimen positif, sentimen negatif, dan sentimen netral. Sentimen dapat berasal dari berita, media sosial, *e-commerce*, dan aplikasi publik.

2.6. Arsitektur Transformer & BERT

Transformer pertama kali dikenalkan oleh Vaswani dan rekan-rekannya pada tahun 2017 dalam penelitiannya yang berjudul *Attention is All You Need* [21].

Dalam penelitiannya, Vaswani et al., (2017) menggunakan mekanisme *self-attention* sebagai komponen utama dalam pemrosesan data sekuensial. Arsitektur ini terdiri atas dua komponen utama, yaitu *encoder* dan *decoder* di mana *Transformer* bekerja dengan cara mengubah teks menjadi *embedding*, memahami hubungan kata melalui *self-attention* di *encoder*, lalu menghasilkan *output* melalui *decoder* menggunakan *attention* terhadap konteks *input*.

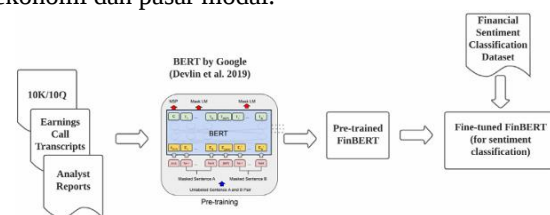
Keunggulan *Transformer* dalam memahami konteks bahasa kemudian menjadi dasar pengembangan berbagai model bahasa modern, salah satunya adalah BERT (*Bidirectional Encoder Representations from Transformers*) yang diperkenalkan oleh Devlin dan rekan-rekannya pada tahun 2018. BERT dirancang untuk melakukan *pre-training* representasi bahasa secara *bidirectional*, yaitu memahami kata dengan mempertimbangkan konteks sebelum dan sesudah kata secara simultan pada seluruh lapisan model. Pada model BERT, setiap teks input diubah menjadi representasi numerik melalui proses *embedding* yang merupakan penjumlahan dari tiga komponen, yaitu *token embedding*, *segment embedding*, dan *position embedding*. *Token embedding* merepresentasikan setiap kata dalam bentuk vektor numerik, *segment embedding* membedakan pasangan kalimat, dan *position embedding* memberikan informasi urutan kata karena arsitektur *Transformer* tidak bersifat sekuensial. Selain itu, BERT menggunakan token khusus [CLS] di awal kalimat sebagai representasi keseluruhan teks dan [SEP] sebagai pemisah antar kalimat.

2.7. FinBERT

FinBERT merupakan *large language model* berbasis arsitektur BERT yang dikembangkan secara khusus untuk mengekstraksi informasi dari teks dalam domain keuangan [10].

FinBERT dikembangkan oleh Araci untuk melakukan tugas *Natural Language Processing* (NLP) pada domain keuangan, khususnya analisis sentimen teks finansial [23].

Model ini dibangun dengan pendekatan *transfer learning*, yaitu memanfaatkan model bahasa umum BERT kemudian menyesuaikannya menggunakan korpus teks finansial agar mampu memahami karakteristik bahasa yang digunakan dalam konteks ekonomi dan pasar modal.



Gambar 2. Tahapan Pre-training dan Fine-tuning pada FinBERT [10]

Huang et al., (2023) menjelaskan bahwa teks keuangan memiliki perbedaan kosakata, gaya penulisan, dan makna kontekstual dibandingkan bahasa umum, sehingga model BERT standar sering kali kurang optimal dalam memahami informasi finansial. Oleh karena itu, FinBERT dirancang sebagai model bahasa yang telah beradaptasi secara khusus pada domain keuangan. Selain itu, sebagai model berbasis *Transformer*, FinBERT umumnya tidak memerlukan tahapan *preprocessing* tradisional seperti penghapusan *stopword*, *lowercasing*, *stemming*,

lemmatization, maupun penghilangan tanda baca, karena BERT dan turunannya dilatih menggunakan teks alami (*raw text*) [10].

2.8. Metrik Performa

Mengevaluasi performa dari model *deep learning* merupakan salah satu langkah penting dalam pembuatan model yang efektif. Beberapa metrik yang berbeda dapat digunakan untuk menilai kinerja dan kualitas dari model *deep learning*. Metrik ini biasa dikenal metrik performa atau *performance metrics*. Beberapa metrik performa yang umum digunakan adalah *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), dan *Mean Absolute Percentage Error* (MAPE).

2.9. Penelitian Terdahulu

Beberapa penelitian terdahulu telah mengkaji prediksi harga saham menggunakan metode Long Short-Term Memory (LSTM) dan analisis sentimen. Gupta), Chou, Heiden & Parpinelli, serta Yan menunjukkan bahwa penambahan fitur sentimen mampu meningkatkan performa prediksi saham dengan menurunkan nilai error dan meningkatkan akurasi model. Penelitian Ouf, Jothimani & Afnan, serta Aslim juga menunjukkan bahwa kombinasi data historis dan sentimen memberikan hasil prediksi yang lebih baik dibandingkan hanya menggunakan data historis.

Namun, beberapa penelitian lain menunjukkan hasil yang berbeda. Thormann, Urlam, dan Pradiptyo menemukan bahwa penambahan variabel sentimen tidak selalu meningkatkan performa model LSTM, bahkan pada beberapa kasus model tanpa sentimen memberikan hasil yang lebih baik. Berdasarkan perbedaan hasil penelitian tersebut, penelitian ini dilakukan untuk menganalisis pengaruh integrasi sentimen berbasis *headline* berita nasional menggunakan FinBERT terhadap akurasi prediksi harga saham BMRI menggunakan metode LSTM.


3. METODE PENELITIAN

Penelitian ini dilaksanakan di Program Studi Sistem Informasi, Jurusan Teknik Elektro dan Informatika, Fakultas Sains dan Teknologi, Universitas Jambi, Jl. Jambi-Muara Bulian No. KM. 15, Mendalo Darat, Kec. Jambi Luar Kota, Kabupaten Muaro Jambi.

3.1. Prosedur Penelitian

- Mulai
- Mengumpulkan data harga saham dan data *headline*.
- Preprocessing* data saham
 - Data saham dibersihkan dan di cek apakah antar variabel memiliki korelasi.
- Preprocessing* data *headline*
 - Data sentimen (*headline*) yang telah dikumpulkan, disesuaikan tanggal berita dengan hari perdagangan saham.

- Menterjemahkan *headline* ke Bahasa Inggris agar kompatibel dengan mode FinBERT.
 - Input* data ke FinBERT
 - Output* data sentimen menjadi skor sentimen
- Menyatukan data historis dan data sentimen
 - Split* data menjadi *data training* dan *data testing*
 - Normalisasi data
 - Membangun model LSTM
 - Mengembalikan hasil prediksi ke skala asli (*denormalisasi*)
 - Melakukan evaluasi untuk mengukur performa model
 - Selesai



Gambar 2. Flowchart prosedur penelitian

3.2. Pengumpulan Data

Sumber data saham yang digunakan dalam penelitian ini berasal dari Yahoo Finance dengan objeknya adalah saham BMRI, sedangkan data sentimen (*headline*) berasal dari Bisnis.com yang difilter berdasarkan kata kunci “BMRI” dan “BANK MANDIRI”. Data saham dan *headline* dikumpulkan dalam periode November 2024 – Januari 2026.

3.3. Preprocessing Data

Preprocessing data dilakukan pada kedua dataset, yaitu data historis harga saham dan data *headline* berita. *Preprocessing* data merupakan tahapan mengolah data mentah menjadi format yang siap digunakan untuk pemodelan. *Preprocessing* data historis dimulai dari *data cleaning* yang dilakukan untuk mengidentifikasi *missing value*, menghapus atau

mengisi *missing value* dan mengidentifikasi duplikat data. Selanjutnya dilakukan uji korelasi untuk melihat hubungan antar variabel yaitu, *close price*, *high price*, *low price*, *open price*, dan *volume*. Uji korelasi bertujuan untuk menghindari informasi yang *redundan*, dimana secara alami antar variabel harga saham memiliki kaitan yang sangat kuat.

Preprocessing data sentimen dimulai dengan data *headline* berita dengan data historis harga saham BMRI berdasarkan tanggal dan waktu perdagangan saham. Data *headline* dibatasi pada berita yang dipublikasikan pada pukul 00.01 hingga 15.59 WIB pada hari perdagangan untuk memastikan bahwa sentimen yang dianalisis berpotensi memengaruhi harga penutupan saham pada hari yang sama. Tahap selanjutnya adalah menerjemahkan *headline* dari Bahasa Indonesia ke Bahasa Inggris. *Headline* berita yang telah diterjemahkan ke dalam Bahasa Inggris selanjutnya digunakan sebagai input untuk proses analisis sentimen menggunakan model FinBERT ProsusAI. *Output* dari model ini adalah skor sentimen yang kemudian diakumulasi untuk mendapatkan skor sentimen harian. Nilai inilah yang selanjutnya akan digabungkan ke dalam model LSTM.

3.4. Combine Data

Data historis harga saham BMRI digabungkan dengan data sentimen yang telah diperoleh dari *headline* berita. Proses ini menghasilkan satu dataset terpadu yang berisi *Close Price*, *Volume*, dan nilai *Sentimen*. Pemilihan variabel tersebut mempertimbangkan hasil uji korelasi antar variabel harga saham yang menunjukkan adanya hubungan yang sangat kuat antara *open price*, *high price*, *low price*, dan *close price*. Oleh karena itu, untuk menghindari redundansi informasi dan potensi multikolinearitas, digunakan *close price* sebagai representasi pergerakan harga saham. Variabel *volume* tetap digunakan karena memiliki karakteristik informasi yang berbeda dari variabel harga.

3.5. Data Training dan Data Testing

Proses pembagian data atau data *split* merupakan langkah untuk memisahkan dataset menjadi beberapa subset yang saling terpisah, yang digunakan untuk keperluan pelatihan (*training*) dan pengujian (*testing*) model. Tujuan utama dari proses ini adalah memperoleh gambaran yang lebih jelas mengenai seberapa baik model mampu bekerja ketika dihadapkan pada data baru. Pada penelitian ini, pembagian data dilakukan dengan rasio 80:20, di mana 80% data digunakan sebagai *training set*, sedangkan 20% sisanya menjadi *testing set*.

3.6. Normalisasi Data

Setelah proses menyatukan data selesai, selanjutnya melakukan normalisasi data menggunakan metode *Min-Max Scalling* untuk mengubah rentang nilai menjadi sama antara 0 dan 1. Hal ini bertujuan untuk menghasilkan skala nilai yang konsisten antar

data, baik sebelum maupun sesudah proses. Persamaan metode ini adalah sebagai berikut:

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

Keterangan:

X' = Hasil Normalisasi Data

X_{min} = Data minimum dari data X

X_{max} = Data maksimum dari data X

3.7. Membuat Model LSTM

Pada tahap ini, model *Long Short-Term Memory* (LSTM) dibangun untuk melakukan pemodelan dan prediksi harga saham berdasarkan dataset yang telah melalui seluruh proses pra-pemrosesan. Pembangunan model dilakukan dalam dua skenario, yaitu model *baseline* tanpa variabel sentimen dan model LSTM yang mengintegrasikan informasi sentimen dari *headline* berita. Pemisahan kedua model ini bertujuan untuk membandingkan pengaruh penambahan variabel sentimen terhadap peningkatan akurasi prediksi.

Proses pemodelan mencakup pengaturan awal bobot untuk *forget gate*, *input gate*, *cell gate*, dan *output gate*, serta pengaturan awal nilai bias untuk masing-masing gerbang (W_f , W_i , W_{ct} , W_o dan bias b_f , b_i , b_{ct} , b_o).

$$W = \left(-\frac{1}{\sqrt{d}}, \frac{1}{\sqrt{d}} \right) \quad (2)$$

Keterangan:

W = *Weight*

d = Jumlah variabel

Terdapat sejumlah *gates* yang dimiliki LSTM, terdiri dari lapisan *sigmoid* dan operasi *pointwise*. *Gates* ini berfungsi untuk menambahkan atau menghapus informasi yang akan diteruskan atau dihentikan. Rentang [0,1] merupakan batas dari output lapisan *sigmoid*, dimana nilai 0 merupakan informasi tidak akan diteruskan, sedangkan nilai 1 berarti informasi akan dilanjutkan. Persamaan *sigmoid* dapat dilihat pada persamaan berikut:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

Forget Gate merupakan gerbang pertama tempat informasi masuk dan diproses pada LSTM. Gerbang ini memiliki fungsi untuk menentukan informasi mana yang akan dihapus dari cell state. Persamaan *forget gate* adalah sebagai berikut:

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$

Keterangan:

f_t = *Forget gate*

σ = Fungsi *Sigmoid*

w_f = Nilai *weight* untuk *forget gate*

h_{t-1} = Nilai *output* sebelum orde ke t

x_t = Nilai *input* pada orde ke t

b_f = Nilai bias pada *forget gate*

Input gate berperan mengambil *output* sebelumnya, *input* baru, dan melewatkan mereka melalui lapisan *sigmoid*. Nilai 0 atau 1 dikembalikan melalui *gate* ini.

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (5)$$

Keterangan:

i_t = input gate

σ = Fungsi Sigmoid

w_t = Nilai weight untuk input gate

h_{t-1} = Nilai output sebelum orde ke t

x_t = Nilai input pada orde ke t

b_i = Nilai bias pada input gate

Cell state berperan mengangkut informasi melalui seluruh rantai sel dan memungkinkan jaringan untuk menyimpan informasi untuk periode waktu yang panjang. Persamaan cell state sebagai berikut:

$$c_t^- = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (6)$$

Keterangan:

c_t^- = Nilai baru yang dapat ditambahkan ke cell state

$\tanh$ = Fungsi Tangen Hiperbolik

w_c = Nilai weight untuk cell state

h_{t-1} = Nilai output sebelum orde ke t

x_t = Nilai input pada orde ke t

b_c = Nilai bias pada cell gate

Output gate berperan untuk mengontrol berapa banyak state yang lewat ke output dan bekerja dengan cara yang sama dengan gate lainnya. Dan terakhir menghasilkan cell state yang baru (h_t).

$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

Keterangan:

o_t = Output gate

σ = Fungsi Sigmoid

w_o = Nilai weight untuk input gate

h_{t-1} = Nilai output sebelum orde ke t

x_t = Nilai input pada orde ke t

b_o = Nilai bias pada output gate

Hidden state merupakan hasil akhir ataupun prediksi yang telah diproses di setiap gerbang LSTM. Hasil hidden state merupakan nilai prediksi. Berikut adalah persamaan untuk hidden state:

$$h_t = o_t * \tanh(c_t) \quad (8)$$

Keterangan:

h_t = Nilai output orde t

o_t = Output gate

Tanh = Fungsi tangen hiperbolik

c_t = Cell state

3.8. Denormalisasi

Denormalisasi merupakan proses mengembalikan data hasil prediksi ke dalam skala aslinya. Tahap ini penting dilakukan karena data yang digunakan untuk training model telah melalui proses normalisasi sebelumnya. Berikut adalah persamaan untuk denormalisasi.

$$d = d'(\max - \min) + \min \quad (9)$$

Keterangan:

d = Nilai hasil denormalisasi

d' = Nilai data normalisasi

$\max$ = Nilai maksimum dari data aktual

$\min$ = Nilai minimum dari data aktual

3.9. Evaluasi

Evaluasi dilakukan dengan menggunakan tiga metrik utama, yaitu Root Mean Square Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute

Percentage Error (MAPE). Ketiga metrik ini mengukur kesalahan prediksi secara menyeluruh untuk menilai akurasi dan performa model secara komprehensif.

a. Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) merupakan metrik yang digunakan untuk menilai tingkat akurasi suatu algoritma berdasarkan besarnya kesalahan prediksi. Persamaan RMSE dapat dilihat sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (10)$$

Keterangan:

Y_i = Data aktual pada periode i

$\hat{Y}_i$ = Data prediksi pada periode i

n = Jumlah periode prediksi yang terlibat

b. Mean Absolute Error (MAE)

Mean Absolute Error (MAE) merupakan ukuran yang menghitung rata-rata selisih absolut antara nilai aktual dan nilai hasil prediksi. Persamaan untuk MAE dilihat melalui persamaan berikut:

$$MAE = \frac{1}{n} \sum_{t=1}^n |f_t - y_t| \quad (11)$$

Keterangan:

f_t : nilai hasil perkiraan (prediksi) ke-t ($t=1, \dots, n$),

y_t : nilai sebenarnya (aktual) ke-t ($t=1, \dots, n$),

n : banyaknya data yang diuji

$|f_t - y_t|$: nilai kesalahan atau perbedaan nilai aktual dengan nilai prediksi

c. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan metode evaluasi yang digunakan dalam peramalan untuk mengukur persentase rata-rata kesalahan absolut antara nilai aktual dan nilai prediksi. Persamaan MAPE dapat dilihat sebagai berikut:

$$MAE = \frac{1}{n} \sum_{t=1}^n |f_t - y_t| \quad (11)$$

Keterangan:

Y_t : nilai sebenarnya (aktual) ke-t ($t=1, \dots, n$),

Y'_t : nilai hasil perkiraan (prediksi) ke-t ($t=1, \dots, n$),

n : banyaknya data yang diuji

4. HASIL DAN PEMBAHASAN

Dalam penelitian ini terdapat dua skenario yang berbeda, yaitu:

- Skenario 1: model prediksi harga saham tanpa menggunakan variabel sentimen.
- Skenario 2: model prediksi harga saham dengan menambahkan variabel sentimen berita.

Pembagian skenario ini bertujuan untuk menganalisis pengaruh penambahan variabel sentimen terhadap kinerja model dalam memprediksi harga saham. Model yang digunakan adalah Long Short-Term Memory (LSTM) dengan pendekatan data deret waktu (time series). Data dibentuk menggunakan time-steps sebanyak 10, yang berarti model memanfaatkan

10 periode sebelumnya untuk memprediksi nilai pada periode ke-11. Proses ini diterapkan baik pada data pelatihan maupun data pengujian agar struktur input tetap konsisten. Pada skenario tanpa sentimen, model menggunakan dua fitur, yaitu harga penutupan dan volume, sedangkan pada skenario dengan sentimen digunakan tiga fitur dengan penambahan skor sentimen.


Arsitektur model yang dibangun terdiri dari satu *input layer*, dua lapisan LSTM, dua *dropout layer* dengan nilai 0,2, serta satu dense layer sebagai *output*. Lapisan LSTM berfungsi untuk menangkap pola temporal dalam data, sedangkan *dropout* digunakan untuk mengurangi risiko *overfitting*. Untuk memperoleh model terbaik, dilakukan proses *hyperparameter tuning* menggunakan metode *grid search* dengan variasi jumlah *neuron* (10, 20, 30, 40, 50, dan 100), *epoch* (25, 50, 75, 100, dan 200), serta *batch size* (32 dan 64). Hasil tuning menunjukkan bahwa kombinasi parameter terbaik pada kedua skenario diperoleh pada *epoch* 200, *batch size* 32, dan jumlah *neuron* 100. Model kemudian dilatih menggunakan data pelatihan dan diuji menggunakan data pengujian untuk mengevaluasi kemampuan generalisasi model.

Tabel 1. Hasil evaluasi model

Model	RMSE	MAE	MAPE
Tanpa Sentimen	83.76	62.34	1.28
Dengan Sentimen	97.59	68.55	1.41

Evaluasi model dilakukan setelah proses denormalisasi menggunakan tiga metrik, yaitu Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), dan Mean Absolute Percentage Error (MAPE). Hasil pengujian menunjukkan bahwa model tanpa sentimen menghasilkan nilai RMSE sebesar 83,76, MAE sebesar 62,34, dan MAPE sebesar 1,28%. Sementara itu, model dengan sentimen menghasilkan nilai RMSE sebesar 97,59, MAE sebesar 68,55, dan MAPE sebesar 1,41%. Berdasarkan hasil tersebut, model tanpa sentimen menunjukkan performa yang lebih baik dibandingkan model dengan sentimen pada seluruh metrik evaluasi.

Nilai RMSE yang lebih rendah pada model tanpa sentimen menunjukkan bahwa model tersebut lebih stabil dalam meminimalkan kesalahan prediksi, terutama terhadap deviasi yang besar. Selain itu, nilai MAE dan MAPE yang lebih kecil juga mengindikasikan bahwa model tanpa sentimen memiliki tingkat kesalahan rata-rata yang lebih rendah dan akurasi yang lebih tinggi dalam memprediksi harga saham BMRI. Sebaliknya, penambahan variabel sentimen dalam penelitian ini belum mampu meningkatkan performa model, bahkan cenderung menurunkan akurasi prediksi. Oleh karena itu, dalam konteks penelitian ini, penggunaan model LSTM tanpa variabel sentimen terbukti lebih efektif dalam memprediksi harga saham BMRI.



Gambar 3. Perbandingan prediksi skenario 1, 2 dan nilai aktual

Gambar 3 menunjukkan perbandingan antara harga saham aktual PT Bank Mandiri (Persero) Tbk dengan hasil prediksi menggunakan model LSTM tanpa sentimen dan dengan sentimen. Secara visual, kedua model prediksi mampu mengikuti arah tren harga aktual dengan cukup baik, namun terdapat fenomena *time lag* atau keterlambatan di mana garis prediksi cenderung mengikuti pergerakan harga aktual satu langkah di belakang. Meskipun model tanpa sentimen terlihat sedikit lebih stabil dalam mengikuti fluktuasi data historis pada beberapa titik, kedua model tetap menunjukkan akurasi yang tinggi karena margin kesalahan yang relatif kecil, sebagaimana dibuktikan oleh nilai MAPE yang sebelumnya berada di kisaran 1%.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, model Long Short-Term Memory (LSTM) mampu memprediksi harga saham BMRI dengan baik, namun performanya dipengaruhi oleh penggunaan variabel input. Model tanpa sentimen menunjukkan kinerja yang lebih unggul dengan nilai RMSE sebesar 83,76, MAE sebesar 62,34, dan MAPE sebesar 1,28%, dibandingkan model dengan sentimen yang menghasilkan RMSE sebesar 97,59, MAE sebesar 68,55, dan MAPE sebesar 1,41%. Hasil ini menunjukkan bahwa penambahan variabel sentimen dalam penelitian ini belum mampu meningkatkan akurasi model, sehingga model berbasis data historis saja lebih efektif dalam memprediksi harga saham BMRI.

Untuk penelitian selanjutnya, disarankan untuk mengembangkan skenario pemodelan yang lebih beragam, seperti menambahkan variabel eksternal lain yang berpotensi memengaruhi harga saham, misalnya indikator makroekonomi (inflasi, suku bunga, nilai tukar) atau variabel pasar global. Selain itu, eksplorasi skenario lain seperti penggunaan kombinasi fitur yang berbeda, penambahan *lag variable*, maupun integrasi dengan model lain dapat dilakukan untuk melihat apakah terdapat konfigurasi yang mampu meningkatkan performa prediksi secara signifikan. Pendekatan ini diharapkan dapat memberikan pemahaman yang lebih komprehensif terhadap faktor-faktor yang memengaruhi pergerakan harga saham.

DAFTAR PUSTAKA

- [1] G. Mokosolang, Y. A. R. Langi, and M. L. Mananohas, "Prediksi Harga Saham Kimia Farma dan Saham Netflix di Era New Normal Menggunakan Model Autoregressive Integrated Moving Average," *J. Mat. dan Apl.*, vol. 11, no. 1, pp. 23–31, 2022, [Online]. Available: <https://ejournal.unsrat.ac.id/index.php/decartesian>
- [2] M. P. Fauzi, "Aset Bank Mandiri Naik 11,6%, Total Mencapai Rp 2.427 Triliun," 2025, *detikfinance*, Jakarta. [Online]. Available: <https://finance.detik.com/moneter/d-7767914/aset-bank-mandiri-naik-11-6-total-mencapai-rp-2-427-triliun>
- [3] Bank Mandiri, "Bank Mandiri Pertegas Optimisme Bisnis, Buyback Saham Jadi Sinyal Kekuatan Fundamental," 2025, *Bank Mandiri*. [Online]. Available: <https://www.bankmandiri.co.id/en/press-detail?primaryKey=499487920&backUrl=/press>
- [4] R. Julian and M. R. Pribadi, "Peramalan Harga Saham Pertambangan Pada Bursa Efek Indonesia (BEI) Menggunakan Long Short Term Memory (LSTM)," *J. Tek. Inform. dan Sist. Inf.*, vol. 8, no. 3, pp. 1570–1580, 2021.
- [5] R. N. Silalahi and Muljono, "Perbandingan Kinerja Metode Linear Regression , LSTM dan GRU untuk Prediksi Harga Penutupan Saham Coca-Cola Performance Comparison Of Linear Regression , LSTM & GRU Methods For Coca-Cola Stock Closing Price Prediction," *Komputika J. Sist. Komput.*, vol. 13, no. 2, pp. 201–211, 2024, doi: 10.34010/komputika.v13i2.12265.
- [6] Y. P. L. Pratama and S. Zahara, "Prediksi Saham Bbni Dan Bbri Menggunakan Lstm (Long Short Term Memory)," *J. Ilm. Teknol. Inf. dan Sains*, vol. 2, no. 4, pp. 1–4, 2024.
- [7] S. A. Lestari, V. Atina, and H. Hasanah, "Perbandingan Model Gated Recurrent Unit dan Long Short-Term Memory Dalam Prediksi Harga Saham," *Semin. Nas. Teknol. Inf. dan Bisnis (SENATIB)2025*, pp. 393–400, 2025, doi: <https://doi.org/10.47701/9q31rx63>.
- [8] A. Kamil, M. A. Hamzah, and B. A. Umam, "Analisis Sentimen Di X Menggunakan Bert Terhadap Stabilitas Usdt Di Tengah Kompetisi Mata Uang Digital BRICS," *Semin. Nas. Hum. dan Apl. Teknol. Inf.* 2025, vol. 11, no. 1, pp. 495–504, 2025.
- [9] R. Sharma, "A Hybrid Sentiment – Technical Framework for Forecasting Dow Jones Industrial Average Movements Using FinBERT and XGBoost," *TechRxiv*, pp. 1–5, 2025, doi: 10.36227/techrxiv.175699539.94947703/v1.
- [10] A. H. Huang, H. Wang, and Y. Yang, "FinBERT: A Large Language Model for Extracting Information from Financial Text," *Contemp. Account. Res.*, vol. 40, no. 2, pp. 806–841, 2023, doi: 10.1111/1911-3846.12832.
- [11] A. N. Nkongolo, Y. O. Gaba, K. K. Pierre, B. Mbuyi, and E. M. Mabela, "Natural Language Processing-Based Financial Time Series Forecasting : Utilizing Sentiment Analysis for Improved Stock Price Prediction," *J. Innov. Inf. Technol. Appl.*, vol. 7, no. 1, pp. 19–25, 2025, doi: [doi: doi.org/10.35970/jinita.v7i1.2290](https://doi.org/10.35970/jinita.v7i1.2290).
- [12] A. F. Pratama, T. B. Kurniawan, Misinem, and D. A. Dewi, "Implementasi Analisis Sentimen dan Model Deep Learning Untuk Prediksi Harga Bitcoin," *J. Penelit. Ilmu dan Teknol. Komput.*, vol. 15, no. 1b, pp. 403–412, 2023, doi: <https://doi.org/10.5281/5522/15.jupiter.2023.04>.
- [13] T. B. Shahi, A. Shrestha, A. Neupane, and W. Guo, "Stock Price Forecasting with Deep Learning : A Comparative Study," *Mathematics*, vol. 8, no. 1441, pp. 1–15, 2020, doi: 10.3390/math8091441.
- [14] F. P. Sholikhah, W. Putri, and R. M. Djangi, "Peranan Pasar Modal Dalam Perekonomian Negara Indonesia," *Arbitr. J. Econ. Account.*, vol. 3, no. 2, pp. 341–345, 2022, doi: 10.47065/arbitrase.v3i2.496.
- [15] R. Al Kiramy, I. Permana, A. Marsal, M. R. Munzir, and Megawati, "Comparison of RNN and LSTM Algorithm Performance in Predicting the Number of Umrah Pilgrims at PT . Hajar Aswad Perbandingan Performa Algoritma RNN dan LSTM dalam Prediksi Jumlah Jamaah Umrah pada PT . Hajar Aswad," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. October, pp. 1224–1234, 2024, doi: <https://doi.org/10.57152/malcom.v4i4.1373>.
- [16] A. Sujjada, F. Sembiring, and Febriansyah, "Prediksi Harga Bitcoin Menggunakan Algoritma Long ShortTerm Memory," *J. INOVTEK Polbeng*, vol. 9, no. 1, pp. 450–459, 2024, doi: <https://doi.org/10.35314/isi.v9i1.4247>.
- [17] M. Q. Andiyantama, I. Zahira, and A. Irawan, "Prediksi Energi Listrik Kincir Angin Berdasarkan Data Kecepatan Angin Menggunakan LSTM," *JITCE (Journal Inf. Technol. Comput. Eng.*, vol. 05, no. 1, pp. 1–7, 2021, doi: <https://doi.org/10.25077/jitce.5.01.1-7.2021>.
- [18] R. C. Rivaldi and T. . Wismarini, "Analisis Sentimen Pada Ulasan Produk Dengan Metode Natural Language Processing (NLP).pdf," *J. Ilm. Elektron. DAN Komput.*, vol. 17, no. 1, pp. 120–128, 2024, doi: <https://doi.org/10.51903/elkom.v17i1.1680>.
- [19] R. C. Tarumangkeng, *Natural Language Processing (NLP)*. 2024.
- [20] A. Mahani and H. Margono, "Prediksi Sentimen Investor Pasar Modal Di Jejaring Sosial Menggunakan Text Mining," *Balanc. Econ.*

- Business, Manag. Account. J.*, vol. XVIII, no. 2, pp. 32–45, 2021.
- [21] Robet, K. L. Kohsasih, and J. Darwin, “Penerapan Algoritma Transformer Dalam Aplikasi Parafrase Teks Otomatis,” *TAMIKA J. Tugas Akhir Manaj. Inform. Komputerisasi Akunt.*, vol. 5, no. 1, pp. 103–109, 2025, doi: <https://doi.org/10.46880/tamika.Vol5No1.pp103-109>.
- [22] A. Vaswani *et al.*, “Attention Is All You Need,” *Neural Inf. Process. Syst.*, pp. 1–17, 2017.
- [23] D. T. Araci, “FinBERT : Financial Sentiment Analysis with Pre-trained Language Models,” 2019.