

BAB 2

LANDASAN TEORI

2.1 Pasar Modal

Pasar modal memiliki peran penting dalam perekonomian karena menyediakan likuiditas, mendukung diversifikasi investasi, membantu alokasi sumber daya secara efisien, serta mengurangi biaya informasi dan transaksi [1]. Berbeda dengan pasar uang yang berfokus pada instrumen jangka pendek, pasar modal berperan sebagai sarana penghimpunan modal bagi perusahaan sekaligus wahana investasi bagi masyarakat [27]. Di Indonesia, kegiatan pasar modal diawasi oleh Otoritas Jasa Keuangan (OJK) dan kegiatan perdaganganannya diselenggarakan oleh Bursa Efek Indonesia (BEI) [28, 29].

Salah satu instrumen utama yang diperdagangkan di pasar modal adalah saham, yang merepresentasikan kepemilikan atas suatu perusahaan [30]. Harga saham di pasar modal cenderung berfluktuasi dan dipengaruhi oleh berbagai faktor, baik yang berasal dari kondisi internal perusahaan, seperti kinerja keuangan dan prospek usaha, maupun faktor eksternal, seperti kondisi makroekonomi, sentimen investor, dan kebijakan pemerintah [9]. Dinamika pergerakan harga saham ini menjadikan prediksi harga saham sebagai topik yang relevan dalam riset keuangan kuantitatif.

2.2 Indeks IDX30

Dalam dinamika pasar modal Indonesia, terdapat berbagai macam indeks saham yang dibentuk untuk mengelompokkan perusahaan-perusahaan berdasarkan kriteria spesifik tertentu. Indeks IDX30 digunakan untuk menggambarkan kinerja harga dari 30 saham pilihan di Bursa Efek Indonesia (BEI) yang memiliki tingkat likuiditas tinggi, kapitalisasi pasar besar, serta kondisi fundamental perusahaan yang relatif baik [2]. Adapun daftar emiten yang tergabung dalam indeks IDX30 periode Februari - April 2026 dapat dilihat pada Gambar 2.1

Lampiran 1 Pengumuman BEI No. Peng-00014/BEI.POP/01-2026 tanggal 26 Januari 2026

Nama Indeks : **IDX30**
Evaluasi : **Mayor**
Periode Efektif Konstituen : **02 Februari 2026 s.d. 30 April 2026**
Periode Efektif Jumlah Saham Penghitungan Indeks : **02 Februari 2026 s.d. 30 April 2026**

No.	Kode	Rasio Free Float	Jumlah Saham untuk Indeks (lembar)			Bobot pada Indeks		
			Pra Evaluasi	Pasca Evaluasi * (15% Cap)	Keterangan Tetap/ Naik/ Turun/ Baru	Pra Evaluasi	Pasca Evaluasi	Keterangan Tetap/ Naik/ Turun/ Baru
1	AADI	18.81%	1,464,714,340	1,464,714,340	Tetap	0.77%	0.72%	Turun
2	ADRO	28.67%	8,426,023,951	8,426,023,951	Tetap	1.30%	1.22%	Turun
3	AMRT	41.72%	17,610,541,171	17,324,022,109	Turun	2.26%	2.09%	Turun
4	ANTM	34.84%	8,372,318,430	8,372,318,430	Tetap	2.32%	2.18%	Turun
5	ASII	44.30%	18,205,453,847	17,934,214,041	Turun	8.11%	7.50%	Turun
6	BBCA	42.74%	26,465,303,450	31,757,820,395	Naik	13.32%	15.00%	Naik
7	BBNI	39.27%	14,548,189,876	14,500,188,234	Turun	4.39%	4.11%	Turun
8	BBRI	46.04%	57,676,348,487	63,765,702,369	Naik	14.46%	15.00%	Naik
9	BMRI	37.47%	35,426,159,998	34,622,279,999	Turun	11.61%	10.65%	Turun
10	BRPT	27.20%	25,499,243,308	25,499,243,308	Tetap	4.61%	4.33%	Turun
11	BUMI	32.53%	-	120,795,403,040	Baru	-	2.60%	Baru
12	CPIN	34.14%	5,598,277,200	5,598,277,200	Tetap	1.66%	1.56%	Turun
13	EMTK	26.96%	-	16,560,571,320	Baru	-	1.07%	Baru
14	GOTO	76.92%	878,355,473,086	877,328,957,146	Turun	3.58%	3.36%	Turun
15	ICBP	19.47%	2,270,573,488	2,270,573,488	Tetap	1.24%	1.17%	Turun
16	INCO	20.40%	2,150,116,045	2,150,116,045	Tetap	0.92%	0.87%	Turun
17	INDF	48.24%	4,235,677,744	4,235,677,744	Tetap	1.88%	1.77%	Turun
18	INKP	39.65%	2,094,839,368	2,169,244,736	Naik	1.46%	1.42%	Turun
19	ISAT	16.33%	5,269,782,510	5,266,557,429	Turun	0.84%	0.79%	Turun
20	JPFA	41.03%	4,811,413,805	4,811,413,805	Tetap	0.91%	0.86%	Turun
21	KLBF	38.39%	18,004,430,386	17,971,661,012	Turun	1.45%	1.36%	Turun
22	MBMA	26.77%	29,201,961,541	28,910,373,907	Turun	1.52%	1.41%	Turun
23	MDKA	47.78%	11,612,430,799	11,693,191,646	Naik	2.48%	2.34%	Turun
24	MEDC	23.44%	5,912,041,590	5,891,932,605	Turun	0.59%	0.55%	Turun
25	PGAS	43.03%	10,431,120,977	10,431,120,977	Tetap	1.48%	1.39%	Turun
26	PGeo	10.91%	4,553,736,634	4,562,099,787	Naik	0.37%	0.35%	Turun
27	PTBA	32.76%	3,774,167,970	3,774,167,970	Tetap	0.63%	0.59%	Turun
28	TLKM	47.21%	46,767,272,457	46,767,272,457	Tetap	11.51%	10.80%	Turun
29	UNTR	35.15%	1,311,515,514	1,311,142,500	Turun	2.37%	2.22%	Turun
30	UNVR	14.05%	5,360,075,000	5,360,075,000	Tetap	0.80%	0.75%	Turun

*Jumlah saham untuk perhitungan indeks akan disesuaikan pada tanggal efektif apabila terjadi aksi korporasi seperti stock split, reverse stock, right issue, saham bonus dan atau dividen saham yang terjadi pada saat sebelum tanggal efektif.

Gambar 2.1 Daftar Konstituen IDX30 Periode 2 Februari - 30 April 2026 [31]

2.3 Indikator Teknikal

Indikator teknikal adalah instrumen dalam analisis teknikal yang berfungsi untuk mengevaluasi pergerakan harga dengan memanfaatkan data historis, seperti harga dan volume perdagangan [2]. Indikator ini umumnya berbasis perhitungan matematis sehingga menghasilkan sinyal yang relatif objektif. Beberapa indikator teknikal digunakan untuk mengidentifikasi kondisi pasar, arah tren, kekuatan momentum, tingkat volatilitas, serta memberikan sinyal potensi perubahan pergerakan harga.

2.3.1 Simple Moving Average (SMA)

Simple Moving Average (SMA) merupakan indikator teknikal yang digunakan untuk menghitung rata-rata harga penutupan suatu aset dalam periode tertentu, dengan setiap data harga memiliki bobot yang sama [13]. Indikator ini digunakan untuk memperhalus fluktuasi harga jangka pendek sehingga arah tren jangka panjang dapat diidentifikasi dengan lebih jelas [13]. Oleh karena itu, SMA sering digunakan sebagai acuan dasar untuk menilai apakah harga berada di atas atau di bawah rata-rata historisnya.

Nilai SMA untuk periode n pada waktu t dihitung menggunakan Rumus 2.1 [13].

$$SMA_t = \frac{1}{n} \sum_{i=0}^{n-1} P_{t-i} \quad (2.1)$$

Keterangan:

SMA_t : nilai *Simple Moving Average* pada waktu t

P_{t-i} : harga penutupan pada periode $t - i$

n : jumlah periode yang digunakan

2.3.2 Exponential Moving Average (EMA)

Exponential Moving Average (EMA) merupakan pengembangan dari *Simple Moving Average* (SMA) yang menerapkan pembobotan eksponensial dengan memberikan bobot lebih besar pada data harga terbaru [13]. Karakteristik ini membuat EMA lebih sensitif terhadap perubahan harga jangka pendek, sehingga

berguna dalam menganalisis pergerakan pasar yang memiliki volatilitas jangka pendek relatif tinggi.

Nilai EMA dihitung secara rekursif dengan menggunakan faktor penghalusan α sebagaimana ditunjukkan pada Rumus 2.2 [13].

$$EMA_t = \alpha \cdot P_t + (1 - \alpha) \cdot EMA_{t-1} \quad (2.2)$$

keterangan:

EMA_t : nilai *Exponential Moving Average* pada waktu t

P_t : harga penutupan pada waktu t

α : *smoothing factor*

EMA_{t-1} : nilai EMA pada periode sebelumnya

2.3.3 Bollinger Bands

Bollinger Bands (BB) adalah indikator teknikal berbasis volatilitas yang terdiri atas tiga garis, yaitu *middle band* berupa *Simple Moving Average* (SMA), serta *upper band* dan *lower band* yang masing-masing dibentuk pada jarak tertentu di atas dan di bawah rata-rata bergerak pusat berdasarkan simpangan baku harga [13]. Indikator ini digunakan untuk mengamati perubahan volatilitas pasar, sehingga dapat membantu dalam mengidentifikasi potensi pembalikan arah maupun *breakout* harga [13].

Bollinger Bands dengan periode n dan faktor pengali simpangan baku k dihitung menggunakan Rumus 2.3[13].

$$\begin{aligned} MB_t &= SMA_t(n) \\ UB_t &= MB_t + k \cdot \sigma_t \\ LB_t &= MB_t - k \cdot \sigma_t \end{aligned} \quad (2.3)$$

Keterangan:

MB_t : *middle band* pada waktu t

UB_t : *upper band* pada waktu t

LB_t : *lower band* pada waktu t

σ_t : simpangan baku harga pada waktu t

k : faktor pengali simpangan baku

2.3.4 Relative Strength Index (RSI)

Relative Strength Index (RSI) merupakan indikator momentum yang digunakan untuk menilai tingkat kecepatan serta besarnya perubahan harga pada suatu aset [13]. Indikator ini membantu mengidentifikasi kondisi pasar yang mendekati jenuh beli (*overbought*) atau jenuh jual (*oversold*), sehingga dapat memberikan gambaran mengenai potensi pembalikan harga serta kekuatan tren yang sedang berlangsung [13].

Perhitungan RSI dihitung menggunakan Rumus 2.4 didasarkan pada rasio rata-rata kenaikan harga terhadap rata-rata penurunan harga dalam periode tertentu [13].

$$RS = \frac{\text{Average Gain}}{\text{Average Loss}}$$
$$RSI = 100 - \frac{100}{1+RS} \quad (2.4)$$

Keterangan:

RS : rasio rata-rata kenaikan harga terhadap rata-rata penurunan harga

RSI : nilai *Relative Strength Index*

Average Gain: rata-rata kenaikan harga dalam periode pengamatan

Average Loss: rata-rata penurunan harga dalam periode pengamatan

2.3.5 Moving Average Convergence Divergence (MACD)

Moving Average Convergence Divergence (MACD) adalah indikator momentum berbasis tren yang diperoleh dari selisih antara dua *Exponential Moving Average* (EMA) yang dihitung pada periode jangka pendek dan jangka panjang [13]. Untuk meningkatkan kemudahan interpretasi, MACD umumnya dilengkapi dengan *Signal Line*, yaitu EMA dari nilai MACD, yang digunakan untuk membantu mendeteksi potensi pembalikan tren dan mengonfirmasi perubahan momentum pasar [13].

Nilai MACD dihitung menggunakan Rumus 2.5 [13].

$$MACD_t = EMA_{short,t} - EMA_{long,t} \quad (2.5)$$

Keterangan:

$MACD_t$: nilai MACD pada waktu t

$EMA_{short,t}$: nilai EMA periode jangka waktu pendek pada waktu t

$EMA_{long,t}$: nilai EMA periode jangka waktu panjang pada waktu t

2.3.6 MACD Signal Line

MACD Signal Line adalah garis sinyal yang diperoleh dari *Exponential Moving Average* (EMA) atas nilai MACD [32]. Garis ini digunakan untuk membantu interpretasi momentum pasar. Ketika garis MACD memotong *Signal Line* dari bawah ke atas, kondisi tersebut dapat diinterpretasikan sebagai potensi sinyal beli, sedangkan perpotongan dari atas ke bawah dapat diinterpretasikan sebagai potensi sinyal jual [32].

Nilai *MACD Signal Line* dihitung menggunakan Rumus 2.6 [32]:

$$Signal_t = EMA_9(MACD_t) \quad (2.6)$$

Keterangan:

$Signal_t$: nilai *MACD Signal Line* pada waktu t

$EMA_9(MACD_t)$: *Exponential Moving Average* periode 9 dari nilai MACD

2.4 Deep Learning

Deep learning merupakan bagian dari machine learning yang memanfaatkan jaringan saraf tiruan dengan banyak lapisan untuk mempelajari pola dan representasi fitur dari data secara bertingkat [33]. Kemampuan *deep learning* dalam menangkap pola kompleks dan non-linear dalam data berdimensi tinggi menjadikannya sangat relevan untuk permasalahan prediksi deret waktu (*time series*) seperti prediksi harga saham [34].

Recurrent Neural Network (RNN) merupakan salah satu arsitektur deep learning yang dirancang untuk mengolah data sekuensial dengan mempertahankan


hidden state, sehingga informasi dari langkah waktu sebelumnya dapat digunakan dalam proses pembelajaran [33]. Berbeda dengan jaringan saraf *feedforward* konvensional, RNN memiliki koneksi berulang yang memungkinkan informasi kontekstual dari urutan sebelumnya dipertimbangkan dalam komputasi berikutnya [33]. Namun, RNN standar mengalami keterbatasan dalam mempelajari dependensi jangka panjang akibat masalah *vanishing gradient*, sehingga mendorong pengembangan variannya. Penelitian ini menggunakan varian lanjutan dari arsitektur tersebut, yaitu *Gated Recurrent Unit* (GRU), sebagai model utama dan *Long Short-Term Memory* (LSTM) sebagai model pembandingan.

2.4.1 Long Short-Term Memory

Long Short-Term Memory (LSTM) merupakan pengembangan lebih lanjut dari arsitektur RNN, yang didesain untuk mengatasi keterbatasan dalam mempelajari dependensi jangka panjang akibat *vanishing gradient* [1]. LSTM memperkenalkan *cell state* sebagai memori internal yang dikelola oleh tiga gerbang utama, *forget gate* untuk menentukan informasi mana yang dibuang, *input gate* untuk mengontrol informasi baru yang masuk, dan *output gate* untuk menentukan informasi yang diteruskan ke langkah berikutnya [1]. Ketiga gerbang ini menggunakan fungsi aktivasi *sigmoid* dan *tanh* untuk menyaring dan mempertahankan informasi yang relevan [1].

2.4.2 Gated Recurrent Unit

Gated Recurrent Unit (GRU) merupakan varian arsitektur RNN yang mengatasi masalah memori jangka pendek (*short-term memory*) dan menawarkan struktur yang lebih sederhana dibandingkan LSTM, sehingga mampu menangkap dependensi jangka panjang dalam data sekuensial [22]. GRU menggabungkan *input gate* dan *forget gate* LSTM ke dalam sebuah *update gate* tunggal, sehingga hanya menggunakan dua gerbang utama, yaitu *reset gate* dan *update gate*, serta tidak memiliki *cell state* terpisah seperti pada LSTM [22]. Penyederhanaan ini mengurangi jumlah parameter dan operasi tensor, sehingga pelatihan dan komputasi menjadi lebih efisien, terutama pada data sekuensial dengan kompleksitas yang tidak terlalu tinggi [22].



Gambar 2.2 Arsitektur *Gated Recurrent Unit* (GRU)

Operasi matematis pada setiap unit GRU dirumuskan sebagai berikut [35].

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (2.7)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (2.8)$$

$$\tilde{h}_t = \tanh(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h) \quad (2.9)$$

$$h_t = (1 - z_t) \odot h_{t-1} + z_t \odot \tilde{h}_t \quad (2.10)$$

Keterangan:

z_t : *Update gate* mengontrol seberapa besar informasi dari *hidden state* sebelumnya (h_{t-1}) dipertahankan.

r_t : *Reset gate* mengontrol seberapa banyak informasi dari *hidden state* sebelumnya (h_{t-1}) dilupakan.

$\tilde{h}_t$: kandidat *hidden state*.

h_t : *hidden state* akhir pada waktu t

W_*, U_* : matriks bobot; b_* : vektor bias.

σ : fungsi sigmoid; $\tanh$: fungsi aktivasi tangen hiperbolik

⊙: perkalian elemen per elemen

2.5 SHAP Feature Importance

SHAP (*SHapley Additive exPlanations*) adalah metode yang digunakan untuk menginterpretasikan hasil prediksi suatu model dengan mengukur seberapa besar kontribusi setiap fitur input terhadap output yang dihasilkan [36]. Metode ini berlandaskan pada teori permainan kooperatif, di mana setiap fitur diberikan nilai kontribusi yang disebut *Shapley value*. Nilai tersebut dihitung berdasarkan seluruh kemungkinan kombinasi fitur, sehingga kontribusi setiap fitur dapat diukur secara adil. Dalam penerapannya pada model deep learning, nilai kontribusi tersebut dapat diestimasi menggunakan *GradientExplainer*, yaitu varian SHAP berbasis gradien [37].

2.6 Time Series Cross Validation (TSCV)

Time Series Split Cross-Validation (TSCV) merupakan teknik validasi yang dirancang untuk mempertahankan dependensi sekuensial dalam data deret waktu, khususnya pada data pasar finansial [13]. Berbeda dengan *k-fold cross-validation* konvensional yang membagi data secara acak, TSCV menjaga urutan kronologis dengan mempartisi data secara temporal [13]. Dengan cara ini, data pelatihan selalu diambil dari periode yang lebih awal dan data validasi dari periode yang lebih akhir, sehingga tidak terjadi kebocoran informasi masa depan (*data leakage*). Pendekatan ini memastikan bahwa pelatihan dilakukan pada segmen awal deret waktu dan validasi pada segmen setelahnya, sehingga memperkuat kemampuan model dalam mempelajari dependensi temporal serta menghasilkan evaluasi performa yang lebih realistis dan sesuai dengan karakteristik data deret waktu. [13].

2.7 Early Stopping

EarlyStopping merupakan salah satu teknik regularisasi yang digunakan untuk mengurangi risiko *overfitting* pada proses pelatihan model *deep learning*. Teknik ini bekerja dengan memantau performa model pada data validasi selama proses *training* berlangsung. Apabila nilai *validation loss* tidak mengalami perbaikan

dalam sejumlah *epoch* tertentu sesuai nilai *patience* yang ditentukan, maka proses pelatihan akan dihentikan secara otomatis [38].

Dengan demikian, model tidak terus dilatih secara berlebihan pada data *training* ketika performanya pada data validasi sudah tidak meningkat. Selain itu, *EarlyStopping* sering dikombinasikan dengan *ModelCheckpoint* untuk menyimpan model dengan nilai *validation loss* terbaik selama proses pelatihan [38].

Penggunaan *EarlyStopping* terbukti dapat menghasilkan nilai *loss* yang lebih rendah dibandingkan pelatihan tanpa *EarlyStopping*, sehingga teknik ini dapat membantu meningkatkan efektivitas pelatihan model sekaligus menghemat waktu komputasi [38].

2.8 Volatilitas dan Pemilihan Aset Representatif

Volatilitas merupakan ukuran yang menggambarkan tingkat fluktuasi return suatu aset [39]. Dalam konteks saham, volatilitas dapat digunakan sebagai ukuran risiko historis yang direpresentasikan melalui standar deviasi return saham dalam periode tertentu [39]. Return harian dapat dihitung berdasarkan perubahan harga penutupan dari satu periode ke periode berikutnya, sebagaimana ditunjukkan pada Rumus 2.11 [36].

$$R = \frac{P_f - P_i}{P_i} \quad (2.11)$$

di mana R merupakan return, P_f merupakan harga akhir periode, dan P_i merupakan harga awal periode. Dalam penelitian ini, harga yang digunakan adalah harga penutupan harian. Oleh karena itu, P_f merepresentasikan harga penutupan pada hari perdagangan saat ini, sedangkan P_i merepresentasikan harga penutupan pada hari perdagangan sebelumnya.

Setelah nilai return harian diperoleh, volatilitas saham dihitung menggunakan standar deviasi dari return selama periode pengamatan [40]. Standar deviasi digunakan karena dapat menunjukkan seberapa besar penyimpangan return terhadap rata-rata return [39]. Secara matematis, volatilitas dapat dihitung menggunakan Rumus 2.12 [40].

$$Volatilitas = \sqrt{\frac{\sum_{t=1}^n (R_t - \bar{R})^2}{n-1}} \quad (2.12)$$

di mana R_t merupakan return saham pada periode ke- i , $\bar{R}$ merupakan rata-rata return saham selama periode pengamatan, dan n merupakan jumlah data return yang digunakan. Rumus tersebut menunjukkan bahwa volatilitas dihitung menggunakan standar deviasi return, yaitu akar dari jumlah kuadrat selisih antara setiap nilai return dengan rata-rata return yang dibagi dengan $n - 1$. Dengan demikian, semakin besar nilai volatilitas, semakin tinggi tingkat fluktuasi return saham tersebut.

Penggunaan volatilitas sebagai dasar pengelompokan saham sejalan dengan pendekatan *low-volatility investing*, yaitu saham dapat disortir atau dipilih berdasarkan ukuran risiko historis seperti standar deviasi return [39]. Pengelompokan saham ke dalam kategori risiko rendah, sedang, dan tinggi berdasarkan standar deviasi juga digunakan dalam studi terdahulu untuk membentuk portofolio berdasarkan tingkat risiko saham [41].

Pengelompokan berdasarkan volatilitas dapat digunakan sebagai dasar untuk memilih aset representatif dari masing-masing kategori risiko. Pemilihan aset representatif memungkinkan proses analisis atau pemodelan dilakukan pada aset yang mewakili karakteristik kelompok tertentu, sehingga kompleksitas komputasi dapat dikurangi tanpa mengabaikan perbedaan karakteristik antar kelompok aset. Pendekatan ini sejalan dengan gagasan pengelompokan deret waktu finansial pada data berdimensi tinggi, di mana aset dapat dikelompokkan berdasarkan kemiripan atau karakteristik tertentu untuk mengurangi kompleksitas analisis [42].

2.9 Hyperparameter Tuning

Hyperparameter tuning merupakan proses pencarian kombinasi hyperparameter yang bertujuan untuk memperoleh konfigurasi model dengan performa terbaik. Hyperparameter memiliki pengaruh yang besar terhadap performa model, sehingga pemilihannya perlu dilakukan secara sistematis. Pemilihan hyperparameter secara manual melalui proses *trial-and-error* dapat memakan waktu, rentan terhadap kesalahan, dan sulit direproduksi [43]. Beberapa

metode yang umum digunakan dalam proses *hyperparameter optimization* seperti *Grid Search*, *Random Search*, dan metode optimasi lainnya [43].

2.9.1 Random Search

Random Search merupakan metode pencarian hyperparameter yang memilih kombinasi nilai secara acak dari ruang pencarian yang telah ditentukan [43]. Berbeda dengan *Grid Search* yang mengevaluasi seluruh kombinasi hyperparameter, *Random Search* hanya mengevaluasi sejumlah kombinasi tertentu sehingga lebih efisien ketika ruang pencarian hyperparameter cukup besar [43].

2.10 Metrik Evaluasi

Metrik evaluasi digunakan untuk mengukur tingkat akurasi dan kesalahan prediksi model secara kuantitatif [44]. Dalam konteks prediksi harga saham yang merupakan permasalahan regresi, metrik yang umum digunakan adalah *Mean Absolute Percentage Error* (MAPE) dan R^2 [13, 35]. Kedua metrik ini memberikan perspektif yang saling melengkapi dalam mengevaluasi performa model prediksi.

2.10.1 Mean Squared Error (MSE)

Mean Squared Error (MSE) adalah metrik evaluasi regresi yang digunakan untuk mengukur rata-rata dari kuadrat perbedaan antara nilai aktual dan nilai prediksi [13]. MSE memberikan penalti yang lebih besar terhadap kesalahan prediksi yang besar karena setiap selisih dikuadratkan. Oleh karena itu, MSE sensitif terhadap outlier atau deviasi prediksi yang besar. Nilai MSE yang lebih kecil menunjukkan bahwa model memiliki tingkat kesalahan prediksi yang lebih rendah, sedangkan nilai nol menandakan bahwa hasil prediksi sama persis dengan nilai aktual [13].

Nilai MSE dihitung menggunakan Rumus 2.13 [13].

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.13)$$

Keterangan:

y_i : nilai aktual pada observasi ke- i

$\hat{y}_i$: nilai prediksi pada observasi ke- i

n : jumlah total observasi

2.10.2 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan metrik yang mengevaluasi rata-rata persentase perbedaan antara nilai prediksi dan nilai aktual, sehingga mencerminkan tingkat akurasi prediksi relatif terhadap nilai sebenarnya [45]. Keunggulan MAPE terletak pada kemampuannya menyajikan kesalahan dalam bentuk persentase relatif, sehingga memudahkan interpretasi serta memungkinkan perbandingan kinerja pada data dengan rentang nilai yang berbeda [44]. Namun, metrik ini memiliki keterbatasan ketika nilai aktual mendekati nol karena dapat menghasilkan nilai yang sangat besar atau bahkan tidak terdefinisi.

Nilai MAPE dihitung menggunakan Rumus 2.14 [44]:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (2.14)$$

Keterangan:

y_i : nilai aktual pada observasi ke- i

$\hat{y}_i$: nilai prediksi pada observasi ke- i

n : jumlah total observasi

2.10.3 Coefficient of Determination (R^2)

Coefficient of Determination atau R^2 merupakan metrik evaluasi yang digunakan untuk mengukur seberapa besar variasi pada nilai aktual dapat dijelaskan oleh model prediksi [13]. Nilai R^2 yang semakin mendekati 1 menunjukkan bahwa model mampu menjelaskan variasi data dengan baik dan hasil prediksi memiliki kesesuaian yang tinggi terhadap nilai aktual. Sebaliknya, nilai R^2 yang rendah menunjukkan bahwa model kurang mampu menangkap pola atau hubungan pada data. Dalam konteks prediksi harga saham, R^2 digunakan untuk menilai kemampuan model dalam merepresentasikan pergerakan harga aktual berdasarkan hasil prediksi yang dihasilkan.

Nilai R^2 dihitung menggunakan Rumus 2.15 [13].

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.15)$$

Keterangan:

y_i : nilai aktual pada observasi ke- i

$\hat{y}_i$: nilai prediksi pada observasi ke- i

$\bar{y}$: rata-rata nilai aktual

n : jumlah total observasi

2.11 Penelitian Terkait

Tabel 2.1 merangkum beberapa penelitian terdahulu yang relevan dengan topik prediksi harga saham menggunakan pendekatan *deep learning*, indikator teknikal, dan validasi deret waktu.

Tabel 2.1 Penelitian Terkait

Referensi	Dataset	Metode dan Hyperparameter	Hasil dan relevansi
[13]	Saham perbankan Indonesia: BBKA, BBRI, BMRI, BBNI, dan BBTN periode Januari 2020–September 2025. Data menggunakan OHLCV dan indikator teknikal.	LSTM dengan 5-fold TSCV, lookback window 90 hari, 13 fitur input, dan Random Search. Unit LSTM terbaik yang digunakan adalah [50, 100, 150].	Model menghasilkan MAPE pada seluruh saham, yaitu 2,34%–3,88%. Relevan sebagai dasar penggunaan TSCV, indikator teknikal, sliding window, dan tuning hyperparameter.
[12]	Data saham dari Kaggle yang mencakup beberapa pasar saham, dengan	Model LSTM dengan indikator MA, EMA, MACD, dan RSI. Hyperparameter yang	Model LSTM mampu memprediksi tren saham dan menghasilkan

Tabel 2.1 Penelitian Terkait (Lanjutan)

Referensi	Dataset	Metode dan Hyperparameter	Hasil dan relevansi
	pengujian pada Public Bank, Tenaga, dan Apex Healthcare. Data menggunakan harga saham harian dan indikator teknikal.	digunakan meliputi pembagian data 80:20, normalisasi 0–1, jumlah node 32, 64, atau 128, epoch 25, batch size 15, 3 LSTM layer, dan 2 fully connected layer.	pergerakan prediksi yang mendekati pergerakan aktual. Relevan sebagai dasar penggunaan indikator teknikal dan penentuan jumlah node, epoch, batch size, serta struktur layer pada model LSTM/GRU.
[14]	Data historis saham Tesla (TSLA). Data menggunakan fitur open, high, low, close, volume, serta indikator teknikal RSI, MACD, dan Bollinger Bands.	Model Hybrid CNN-LSTM with Attention (HCLA) menggunakan <i>sequence length</i> 30, CNN 64 filter (kernel 3), LSTM 128 unit, <i>scaled dot-product attention</i> , optimizer Adam (<i>learning rate</i> 0,001), <i>loss</i> MSE, serta indikator RSI, MACD, dan Bollinger Bands.	Model HCLA mengungguli model pembanding dengan penurunan MSE, RMSE, dan MAE masing-masing sebesar 12,4%, 10,7%, dan 11,3%. Penelitian ini menjadi acuan penggunaan indikator teknikal, <i>sequence length</i> , optimizer Adam, <i>learning rate</i> , dan <i>loss function</i> MSE.

Tabel 2.1 Penelitian Terkait (Lanjutan)

Referensi	Dataset	Metode dan Hyperparameter	Hasil dan relevansi
[20]	Saham blue chip IDX: BBKA, BBRI, BMRI, BBNI, TLKM, dan ASII periode 2005–2022. Data menggunakan OHLC, volume, serta indikator teknikal MA, SMA, dan EMA.	Hybrid RNN-GRU. GRU digunakan untuk data historis, sedangkan RNN untuk indikator teknikal. Hyperparameter yang digunakan meliputi batch size 64, epoch 400, early stopping patience 80, learning rate 0,001, optimizer Adam, loss MSE, serta variasi time step 15–50.	Model hybrid menghasilkan performa lebih baik dibanding GRU, LSTM, dan RNN tunggal. R^2 tertinggi diperoleh pada BBNI sebesar 0,9886, BMRI 0,9854, dan BBKA 0,9806. Relevan sebagai dasar penggunaan indikator teknikal dan tuning time step pada prediksi saham.
[25]	Data saham AMZN, GOOGL, BLL, dan QCOM dari Yahoo Finance periode 2010–2022. Data difokuskan pada harga penutupan dan dinormalisasi menggunakan Min-Max.	Menggunakan model LSTM dan GRU pada data time series berkelompok. Hyperparameter utama meliputi timestep 40 data historis untuk memprediksi data ke-41, pembagian data 80:20, serta empat arsitektur model: direct, downsizing, tuned downsizing, dan stabilized downsizing.	GRU menunjukkan performa lebih baik dibanding LSTM pada data uji, dengan akurasi tertinggi 97,37% berdasarkan MAPE dan 96,60% berdasarkan RMSPE. Relevan sebagai dasar pemilihan GRU dan penggunaan timestep/lookback window pada prediksi harga saham.

Tabel 2.1 Penelitian Terkait (Lanjutan)

Referensi	Dataset	Metode dan Hyperparameter	Hasil dan relevansi
[35]	Data harian HDFC Bank, TCS, TSLA, Nifty 50, dan S&P 500 periode 2015–2025. Data menggunakan 36 fitur awal, termasuk OHLCV, indikator teknikal, dan fitur turunan	Model TCN-GRU-MHA untuk prediksi horizon 1, 3, dan 7 hari. Hyperparameter utama meliputi timestep 20, split data 70:30, batch size 32, epoch 100, dropout 0,2, learning rate 0,005, optimizer Adam, loss MSE, GRU 128 dan 64 unit, serta early stopping patience 10.	Model TCN-GRU-MHA menghasilkan error lebih rendah dan akurasi lebih tinggi dibanding TCN, LSTM, GRU, BiGRU, dan TCN-GRU. Relevan sebagai dasar penggunaan data historis panjang, variasi horizon prediksi, dan tuning timestep pada prediksi harga saham.

