

BAB II

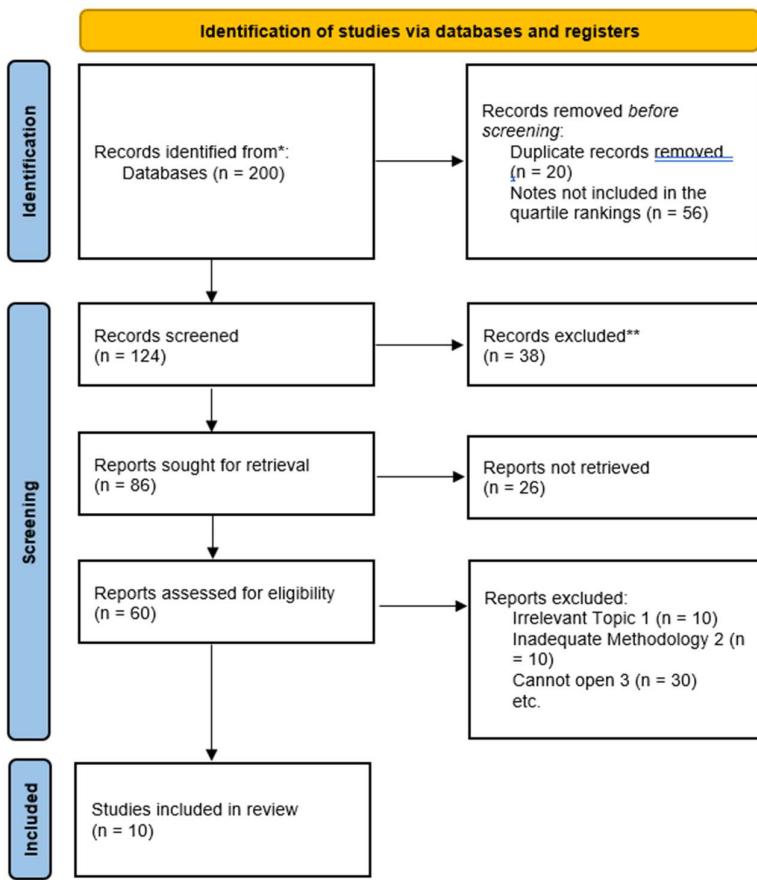
LANDASAN TEORI

2.1 Penelitian Terdahulu

Dalam upaya mengidentifikasi evaluasi dan interpretasi penelitian yang relevan dengan rumusan masalah serta topik penelitian, metode *Systematic Literature Review (SLR)* merupakan pendekatan yang sangat tepat untuk digunakan [16], [17]. SLR memungkinkan peneliti untuk melakukan tinjauan literatur secara terstruktur dan sistematis, sehingga hasil yang diperoleh dapat memberikan wawasan yang komprehensif dan mendalam terkait penelitian sebelumnya. Dalam melaksanakan proses *Systematic Literature Review (SLR)*, metode PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta Analyses*) merupakan pendekatan yang sangat tepat dan direkomendasikan untuk memastikan bahwa seluruh tahap tinjauan literatur dilakukan secara sistematis dan transparan [17], [18].

Pencarian literatur dilakukan melalui beberapa *database* bereputasi, seperti Google Scholar, Scopus, dan IEEE Xplore, dengan menggunakan kata kunci di antaranya “*stock price prediction*”, “*stock prediction*”, “LSTM”, “*Hybrid model*”, dan “*EMD optimization*”. Kombinasi kata kunci tersebut digunakan untuk memastikan cakupan pencarian yang luas, sekaligus menghindari literatur yang tidak relevan dengan ruang lingkup penelitian. Tahapan seleksi meliputi penghapusan duplikasi, pemeriksaan kesesuaian judul dan abstrak, hingga peninjauan isi jurnal berdasarkan kriteria inklusi dan eksklusi.

Gambar 2.1 menunjukkan alur kerja (*workflow*) metode PRISMA, yang menggambarkan tahapan utama dalam proses SLR, mulai dari identifikasi literatur melalui pencarian kata kunci, penyaringan data untuk menghilangkan duplikasi atau jurnal yang tidak relevan, hingga seleksi akhir berdasarkan kriteria inklusi dan eksklusi. *Workflow* ini membantu peneliti untuk memvisualisasikan proses SLR secara menyeluruh, memastikan bahwa setiap tahap dilakukan dengan cermat dan sistematis untuk mendapatkan hasil yang valid dan dapat diandalkan.



Gambar 2. 1 Workflow Prisma

Berdasarkan gambar 2.1 menjelaskan bahwa penelitian ilmiah yang terkumpul sekitar 10 yang sesuai dengan rumusan masalah dan topic pada penelitian ini. Tahapan melakukan proses screening pada mencari penelitian ilmiah yang terkait adalah menentukan keyword untuk melihat isi penelitian ilmiah yang berada pada database. Setelah itu melakukan tahapan penyesuaian dengan melihat abstract dan juga membuka journal agar dapat di akses. Tabel 2.1 merupakan hasil dari summary result paper yang telah terkumpul

Tabel 2. 1 Perbandingan Penelitian Terdahulu

Referensi	Judul	Metode	Jenis Pendekatan	Hasil
[15]	Stock Price Forecasting with Optimized Long Short-Term Memory Network	LSTM, EMD-LSTM EMD-MRFO-LSTM	Hybrid	R ² 0.99 %, RMSE 91.99, MAE 71,54 dan MAPE 0.57

Referensi	Judul	Metode	Jenis Pendekatan	Hasil
	with Manta Ray Foraging Optimization			
[19]	Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm	LSTM	<i>Non-Hybrid</i>	MAE 0.738, MAPE 0.024, dan R^2 0.907
[20]	A Multi Parameter Forecasting for Stock <i>Time series</i> Data Using LSTM and <i>Deep learning</i> Model	LSTM	<i>Non-Hybrid</i>	MAE 28.712, RMSE 41.003, dan R^2 0.962
[12]	Forecasting Stock Market Indices Using the Recurrent Neural Network Based <i>Hybrid</i> Models: CNN-LSTM, GRU-CNN, and Ensemble Models	CNN-LSTM dan GRU-CNN	<i>Hybrid</i>	MSE 0.0017 dan MAE 0.0345
[9]	Prediction of Complex Stock Market Data Using an Improved <i>Hybrid</i> EMD-LSTM Model	EMD-LSTM	<i>Hybrid</i>	RMSE 490.664, MAE 383.899 dan MAPE 0.941
[13]	Stock Price Prediction System LSTM Based on <i>Deep learning</i>	LSTM	<i>Non-Hybrid</i>	MSE 2.201569
[21]	Comparison of Random Forest and LSTM in Stock Prediction	LSTM	<i>Non-Hybrid</i>	RMSE 2.0830
[10]	Stock Price Prediction using Multi-Layered Sequential LSTM	LSTM	<i>Non-Hybrid</i>	Accuracy 99,42%
[11]	Predicting LQ45 financial sector indices using RNN-LSTM	RNN-LSTM	<i>Hybrid</i>	RMSE 2878.4668 MAPE 19.1020
[14]	PREDIKSI HARGA DAN VALUASI SAHAM BBCA, BBRI, DAN	LSTM	<i>Non-Hybrid</i>	MSE 0.0005701339687, MAE 0.01803036525, MAPE

Referensi	Judul	Metode	Jenis Pendekatan	Hasil
	BMRI MELALUI RELATIVE VALUATION METHOD DI INDONESIA SKRIPSI			2.212988043, RMSE 0.02387747922, P-Value 0.9820368713, dan R ² 0.9566722014

Berdasarkan hasil peninjauan literatur, dapat disimpulkan bahwa pendekatan *Hybrid* berbasis EMD–MRFO–LSTM terbukti mampu meningkatkan akurasi prediksi dibandingkan penggunaan model LSTM tunggal. Namun, temuan tersebut masih terbatas pada studi internasional dan belum diimplementasikan dalam konteks pasar modal Indonesia. Hingga saat ini, tidak ditemukan penelitian terdahulu yang menerapkan model *Hybrid* EMD–MRFO–LSTM pada saham sektor perbankan yang tergabung dalam indeks LQ45, khususnya BBCA, BBRI, dan BMRI, padahal ketiga saham tersebut memiliki peran strategis terhadap pergerakan indeks dan menjadi perhatian investor. Berdasarkan celah penelitian tersebut, penelitian ini mengusulkan penerapan model *Hybrid* EMD–MRFO–LSTM untuk memprediksi harga saham BBCA, BBRI, dan BMRI sebagai upaya untuk meningkatkan akurasi prediksi serta memberikan kontribusi metodologis pada studi prediksi harga saham di Indonesia.

2.1.1 *Research gap* dan Kebaruan Penelitian

Penelitian ini memiliki perbedaan yang jelas dibandingkan dengan sejumlah penelitian terdahulu yang paling relevan. Studi oleh Ali et al. (2023), serta penelitian pada referensi [15] dan [9], telah menerapkan model *Hybrid* berbasis EMD–LSTM maupun EMD–MRFO–LSTM dalam konteks prediksi harga saham. Namun, seluruh penelitian tersebut dilakukan pada konteks pasar modal internasional dan belum secara spesifik mengkaji pasar modal Indonesia. Selain itu, sebagian besar penelitian terdahulu masih berfokus pada penggunaan data saham tunggal atau indeks saham secara umum, tanpa memberikan perhatian khusus pada saham sektor perbankan yang tergabung dalam indeks LQ45, yang memiliki karakteristik volatilitas dan pola pergerakan harga yang berbeda dibandingkan sektor lainnya.

Berdasarkan hasil peninjauan literatur, dapat diidentifikasi beberapa celah penelitian (*research gap*) yang belum banyak dieksplorasi. Pertama, dari sisi konteks data, penerapan model *Hybrid EMD–MRFO–LSTM* pada pasar modal Indonesia, khususnya pada saham sektor perbankan LQ45 seperti BCA, BBRI, dan BMRI, masih sangat terbatas. Padahal, saham perbankan memiliki peran strategis dalam pergerakan indeks serta menunjukkan dinamika harga yang khas, sehingga memerlukan pendekatan pemodelan yang mampu menangkap pola non-linear dan volatilitas secara lebih adaptif.

Kedua, dari sisi metodologi, belum ditemukan penelitian yang secara terpadu mengintegrasikan *Empirical Mode Decomposition* (EMD) sebagai metode dekomposisi sinyal, *Manta Ray Foraging Optimization* (MRFO) sebagai algoritma optimasi *hyperparameter*, dan *Long Short-Term Memory* (LSTM) sebagai model prediksi utama dalam satu *pipeline* terstruktur untuk saham perbankan Indonesia. Penelitian terdahulu umumnya hanya mengombinasikan dua komponen, seperti EMD–LSTM atau LSTM dengan algoritma optimasi tertentu, tanpa melibatkan MRFO sebagai *optimizer* dalam proses penyesuaian parameter model.

Ketiga, dari sisi evaluasi model, sebagian besar penelitian sebelumnya masih mengandalkan perbandingan performa berdasarkan metrik kesalahan prediksi secara deskriptif. Penelitian ini menawarkan pendekatan evaluasi yang lebih komprehensif dengan menambahkan pengujian *multi-epoch* untuk mengamati kestabilan performa model, serta analisis statistik menggunakan uji normalitas *Shapiro–Wilk* dan *paired t-test* guna menilai perbedaan performa antar model secara lebih sistematis dan terukur.

Dengan demikian, kebaruan (*novelty*) penelitian ini terletak pada penerapan model *Hybrid EMD–MRFO–LSTM* pada saham sektor perbankan LQ45 di pasar modal Indonesia, integrasi algoritma MRFO dalam proses optimasi *hyperparameter* LSTM, serta penggunaan pendekatan evaluasi yang mengombinasikan analisis deskriptif dan inferensial untuk memperoleh gambaran kinerja model yang lebih komprehensif dan objektif.

2.2 Teori yang berkaitan

2.2.1 Pasar Modal

Pasar modal merupakan mekanisme yang mempertemukan investor dan emiten melalui perdagangan instrumen jangka panjang seperti saham, obligasi, dan reksa dana [2]. Di Indonesia, kegiatan ini difasilitasi oleh Bursa Efek Indonesia (BEI). Saham LQ45 menjadi salah satu acuan utama karena terdiri dari 45 saham dengan likuiditas tinggi dan kapitalisasi pasar besar [6]. Pada sektor perbankan, saham BCA, BBRI, dan BMRI termasuk saham berkapitalisasi besar dan aktif diperdagangkan sehingga sering digunakan sebagai representasi stabilitas sektor perbankan dalam indeks LQ45.

Harga saham pada dasarnya membentuk deret waktu finansial yang sangat dipengaruhi faktor ekonomi, sentimen pasar, dan dinamika mikro perusahaan. Akibatnya, data harga saham memiliki sifat non-stasioner, non-linier, volatilitas tinggi, serta mengandung *noise*, sehingga memerlukan pendekatan analisis yang mampu menangani kompleksitas tersebut [9], [22]. Kondisi inilah yang menjadi dasar pemilihan metode EMD–LSTM pada penelitian ini, di mana EMD dapat memecah sinyal non-stasioner menjadi komponen yang lebih stabil, sedangkan LSTM mampu mempelajari pola non-linier jangka pendek maupun jangka panjang.

2.3 Framework/Algoritma yang digunakan

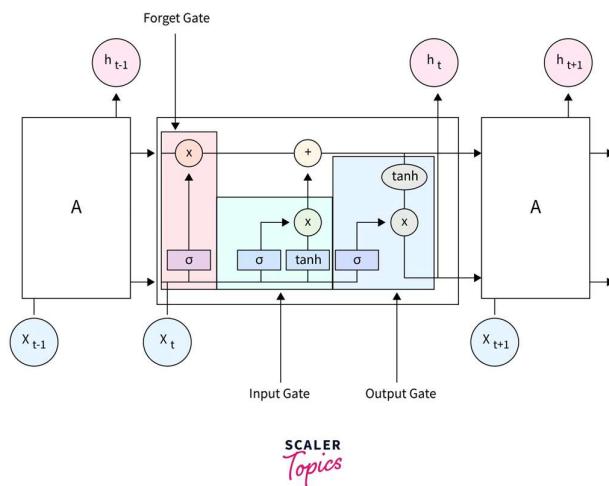
2.3.1. Framework SEMMA

SEMMA merupakan suatu proses pemodelan dalam *data mining* yang terdiri dari lima tahapan utama, yaitu *sample*, *explore*, *modify*, *model*, dan *assess* [23]. Kelima tahap tersebut dirancang untuk memfokuskan seluruh aktivitas analisis pada proses pemodelan, mulai dari pengambilan sampel data, eksplorasi karakteristik data, melakukan modifikasi atau transformasi terhadap data, membangun model prediktif, hingga melakukan evaluasi untuk menilai kinerja model yang telah dihasilkan. Dengan adanya tahapan ini, SEMMA berperan sebagai kerangka kerja yang sistematis dalam

pengembangan model data mining agar hasil analisis yang diperoleh lebih akurat, terarah, dan dapat digunakan secara optimal untuk mendukung proses pengambilan keputusan.

2.3.2. Long-Short Term Memory (LSTM)

(*Recurrent Neural Network* atau *RNN*) yang dirancang untuk mempelajari pola dalam data urutan waktu (*sequential data*) [24], [25], [26]. LSTM mengatasi kelemahan *RNN* tradisional, seperti masalah *vanishing gradient*, yang menghambat pembelajaran pola jangka Panjang [24]. LSTM menggunakan struktur sel khusus dengan tiga control yaitu *input control*, *output control*, dan *forget control* [24]. Struktur ini memungkinkan LSTM untuk menyimpan, menghapus, atau memperbarui informasi berdasarkan relevansi dengan tugas yang sedang dipelajari. Gambar 2.1 menunjukkan arsitektur *Long Short-Term Memory* (LSTM).



Gambar 2. 2 Arsitektur Long-Short Term Memory [27]

a) Input Gate

Gerbang input (*Input Gate*) berfungsi untuk memproses data masukan pada waktu tertentu bersama dengan *hidden state* dari langkah sebelumnya, kemudian memperbarui nilai *cell state*. Gerbang ini terdiri dari dua komponen utama [24]. Pertama, fungsi aktivasi sigmoid yang berperan dalam menentukan

proporsi informasi yang akan dipertahankan. Kedua, fungsi aktivasi tanh yang memetakan data ke dalam rentang nilai antara -1 hingga 1. Hasil keluaran dari fungsi tanh kemudian dikalikan dengan output dari fungsi sigmoid, sehingga hanya informasi relevan yang diteruskan untuk memperbarui *cell state* [27].

Adapun persamaan ditunjukkan pada Rumus 2.1 berikut:

$$\begin{aligned} i_t &= \sigma(W_i \times [h_{t-1}, x_t] + b_i \\ C_t &= \tanh(W_c \times [h_{t-1}, x_t] + b_f \end{aligned} \quad (2.1)$$

b) *Output Gate*

Gerbang keluaran (Output Gate) berfungsi menghasilkan *hidden state* yang akan digunakan pada langkah waktu berikutnya. Mekanisme gerbang ini terdiri dari dua tahap utama. Pertama, fungsi aktivasi sigmoid digunakan untuk menentukan proporsi informasi relevan yang akan diteruskan, sebagaimana fungsinya pada gerbang lainnya. Kedua, *cell state* yang telah diperbarui diproses menggunakan fungsi aktivasi tanh, kemudian hasilnya dikalikan dengan keluaran dari fungsi sigmoid. Proses ini menghasilkan *hidden state* baru yang akan digunakan pada langkah berikutnya [27]. Adapun persamaannya ditunjukkan pada Rumus 2.2 berikut:

$$\begin{aligned} \sigma_t &= \sigma(W_o \times [h_{t-1}, x_t] + b_o \\ h_t &= o_t \times \tanh c_t \end{aligned} \quad (2.2)$$

c) *Forget Gate*

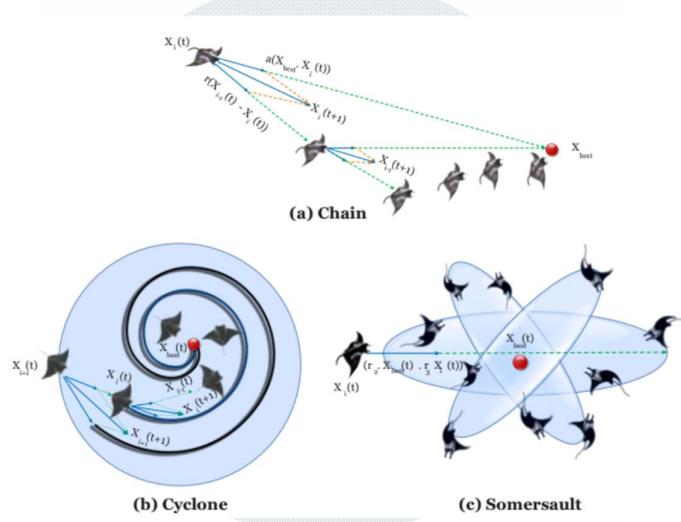
Gerbang lupa (Forget Gate) berperan dalam menentukan informasi mana yang perlu dipertahankan dan mana yang harus dihapus dari *cell state*. Pada tahap ini, gerbang menerima *hidden state* dari langkah waktu sebelumnya bersama dengan input saat ini, kemudian memproses keduanya melalui fungsi aktivasi sigmoid. Fungsi ini menghasilkan keluaran dengan rentang nilai antara 0 hingga 1, di mana nilai 0 menunjukkan bahwa informasi akan dihapus, sedangkan nilai 1 menunjukkan bahwa informasi

tersebut tetap dipertahankan [28]. Adapun persamaan ditunjukkan pada Rumus 2.3 berikut:

$$f_t = \sigma(W_f \times [h_{t-1}, x_t] + b_f) \quad (2.3)$$

2.3.3. Manta Ray Foraging Optimization (MRFO)

Manta Ray Foraging Optimization (MRFO) adalah algoritma optimasi metaheuristik berbasis *swarm* yang terinspirasi oleh perilaku ikan pari manta dalam proses pencarian makanan [29].



Gambar 2. 3 Ilustrasi dari MRFO [15]

MRFO memiliki tiga jenis pendekatan dalam proses pencaharian, yaitu:

a) Chain Food

Pada tahap *chain foraging*, setiap ikan pari manta memperbarui posisinya dengan mengacu pada solusi terbaik yang telah diperoleh sejauh ini serta posisi ikan pari yang berada di depannya. Pengecualian diberikan pada ikan pari pertama, yang memperbarui posisinya hanya berdasarkan solusi terbaik global yang telah dicapai hingga iterasi tersebut [29], [30].

Berikut adalah persamaan yang ditunjukkan pada rumus (2.4)

$$x_k^{t+1} = \begin{cases} x_i^t + rn \times (Gbest^t - x_k^t) + 2 \times rn \times \sqrt{|\log(r)|} \times (Gbest^t - x_k^t), & k = 1 \\ x_i^t + rn \times (Gbest^t - x_k^t) + 2 \times rn \times \sqrt{|\log(r)|} \times (Gbest^t - x_k^t), & k = 2, \dots, N \end{cases}$$

b) *Cyclone Food*

Pada tahap *cyclone food*, ikan pari manta melakukan pergerakan dalam ruang pencarian secara melingkar (*cyclic way*) untuk mengeksplorasi area solusi secara lebih luas dan meningkatkan peluang menemukan posisi yang lebih optimal [29], [30]. Berikut adalah persamaan yang ditunjukkan pada rumus (2.5)

$$x_k^{t+1} = \begin{cases} Gbest + rn \times (Gbest^t - x_k^t) + 2 \\ \times e^{rn \times \frac{\text{Max } t-t+1}{\text{Max } t}} \times \sin(2 \times \pi \times rn) \times (Gbest^t - x_k^t), & k = 1 \\ Gbest + rn \times (Gbest^t - x_k^t) + 2 \\ \times e^{rn \times \frac{\text{Max } t-t+1}{\text{Max } t}} \times \sin(2 \times \pi \times rn) \times (Gbest^t - x_k^t), & k = 2, \dots, N \end{cases}$$

c) *Somersault Food*

Pada tahap *somersault foraging*, setiap ikan pari manta menyesuaikan posisinya dengan melakukan gerakan jungkir balik (*somersault walk*) menuju lokasi terbaik yang telah ditemukan sejauh ini. Pendekatan ini bertujuan untuk memperkuat proses eksplorasi dan memperbaiki posisi individu agar lebih dekat dengan solusi optimal [29], [30]. Berikut adalah persamaan yang ditunjukkan pada rumus (2.6)

$$x_k^{t+1} = x_k^t + \text{Somersault factor} \times (rn_1 \times Gbest - rn_2 \times x_k^{t+1}), i = 1, \dots, n$$

2.3.4. Empirical Mode Decomposition (EMD)

Empirical Mode Decomposition atau EMD merupakan algoritma yang berperan untuk memproses sinyal yang berfungsi untuk menganalisis data yang bersifat non-linear dan non-stationer [31]. EMD bertujuan untuk melakukan dekomposisi data *time series* menjadi *intrinsic mode function* (IMFs) dan satu residual [32]. Adapun persamaan yang ditunjukkan pada rumus (2.7) berikut:

$$x(t) = \sum_{i=1}^n a_i + y_n$$

2.3.5. Hybrid Model EMD–MRFO–LSTM

Model *Hybrid EMD-MRFO-LSTM* merupakan arsitektur prediksi *time series* berbasis *deep learning* yang menggabungkan teknik dekomposisi sinyal (EMD), algoritma optimasi meta-heuristik (MRFO), dan jaringan *Long Short-Term Memory* (LSTM). EMD berfungsi memecah sinyal harga saham yang bersifat non-linear dan non-stationer ke dalam beberapa *Intrinsic Mode Functions* (IMFs) untuk mengurangi *noise* [15]. Selanjutnya, MRFO diimplementasikan untuk mengoptimalkan hyperparameter LSTM seperti jumlah neuron, jumlah *layer*, *learning rate*, dan dropout sehingga meningkatkan efektivitas proses pembelajaran [15], [30]. Setelah *hyperparameter* optimal diperoleh, setiap IMF dilatih menggunakan LSTM guna mempelajari dinamika temporalnya. Hasil prediksi dari seluruh IMF digabungkan kembali (*reconstruction*) untuk menghasilkan nilai prediksi harga saham akhir.

2.3.6. Min-Max Scaling

Min-Max Scaling merupakan salah satu metode normalisasi data yang digunakan untuk mengubah nilai fitur ke dalam rentang tertentu, umumnya antara 0 hingga 1 [33]. Dalam konteks prediksi harga saham, teknik ini berperan penting untuk memastikan bahwa seluruh data historis saham, seperti harga pembukaan (open), harga penutupan (close), volume transaksi, dan indikator teknikal lainnya memiliki skala yang seragam sebelum digunakan dalam proses pelatihan model *Long Short-Term Memory* (LSTM). Perbedaan skala antar fitur dapat menyebabkan model sulit beradaptasi dan memperlambat proses konvergensi selama pelatihan, karena LSTM sensitif terhadap besaran nilai input [13], [34].

Normalisasi menggunakan Min-Max Scaling dilakukan dengan mentransformasikan setiap nilai data berdasarkan nilai minimum dan maksimum dari fitur tersebut sehingga seluruh nilai berada dalam rentang yang sama tanpa mengubah distribusi relatif antar data. Proses normalisasi

ini membantu model mengenali pola pergerakan harga saham secara lebih efisien dan stabil [13]. Adapun rumus dari Min-Max Scaling dapat ditunjukkan pada rumus 2.8 berikut [13], [33], [34]:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}$$

2.3.7. Root Mean Square Error (RMSE)

Root Mean Square Error (RMSE) adalah ukuran kesalahan yang dihitung dengan cara mengambil akar kuadrat dari rata-rata kuadrat selisih antara nilai aktual dan nilai prediksi [33]. RMSE sensitif terhadap kesalahan yang besar karena selisihnya dikuadratkan terlebih dahulu. Berikut adalah persamaan rumus 2.9 sebagai berikut [15], [33]:

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

2.3.8. Mean Absolute Error (MAE)

Mean Absolute Error (MAE) adalah ukuran kesalahan yang dihitung dengan cara mengambil rata-rata nilai absolut dari selisih antara nilai aktual dan prediksi [12], [15]. Berbeda dengan RMSE, MAE tidak mengkuadratkan selisih, sehingga tidak terlalu sensitif terhadap *outlier*.

Berikut adalah persamaan rumus 2.10 [12], [15]:

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

2.3.9. Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah ukuran kesalahan relatif yang dinyatakan dalam bentuk persentase [26]. MAPE menghitung rata-rata kesalahan absolut yang dibagi dengan nilai aktual, kemudian dikalikan 100%. Berikut adalah persamaan rumus 2.11 [11], [15]:

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

2.4 Tools/software yang digunakan

2.4.1. Python

Python merupakan bahasa pemrograman serbaguna yang banyak digunakan dalam penelitian berbasis data, termasuk analisis deret waktu (*time series*) dan *deep learning*. Python dipilih dalam penelitian ini karena memiliki sintaks yang sederhana, fleksibel, serta didukung oleh ekosistem pustaka yang luas untuk pengolahan data, pemodelan, dan visualisasi. [35].

Dalam implementasi *model Hybrid EMD–MRFO–LSTM*, Python menyediakan beragam pustaka yang diperlukan pada setiap tahap pemodelan. Pustaka NumPy digunakan untuk komputasi numerik dan manipulasi *array*, sedangkan Pandas digunakan untuk membaca dataset harga saham, pembersihan data, penyusunan fitur, dan pembentukan data *training–testing*. Untuk proses dekomposisi sinyal menggunakan *Empirical Mode Decomposition* (EMD), penelitian ini memanfaatkan pustaka PyEMD. Selanjutnya, algoritma optimasi Manta Ray Foraging Optimization (MRFO) diimplementasikan menggunakan pustaka metaheuristic berbasis Python *library* yang mendukung pencarian hyperparameter optimal. [36].

Untuk pengembangan dan pelatihan model *deep learning*, penelitian ini memanfaatkan TensorFlow dan Keras, yang menyediakan arsitektur LSTM dan mendukung pemrosesan model secara efisien menggunakan GPU. Sementara itu, proses visualisasi data dan evaluasi model dilakukan menggunakan Matplotlib dan Seaborn, yang memungkinkan penyajian grafik seperti tren harga saham, *learning curve*, serta hasil perbandingan antara nilai aktual dan hasil prediksi. [37].

Dengan dukungan pustaka-pustaka tersebut, Python menjadi perangkat yang sangat sesuai untuk membangun model prediksi saham berbasis *deep learning* yang kompleks dan komputasional, seperti EMD–MRFO–LSTM.