

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Prediksi harga dalam *deep learning*

Prediksi harga adalah proses memperkirakan nilai suatu aset di masa depan dengan memanfaatkan pola-pola dari data historis (Ibrahim dkk., 2025). Dalam konteks pasar keuangan, pergerakan harga aset seperti saham, mata uang, dan kripto sering kali menunjukkan karakteristik non-linear dan volatil, sehingga pendekatan tradisional seperti regresi linier tidak cukup efektif dalam menangkap kompleksitas tersebut (Almadany dkk., 2024). Metode *deep learning* banyak dimanfaatkan berkat kemampuannya mengekstraksi pola tersembunyi dari data historis secara otomatis dan akurat (Mehtab & Sen, 2020). Model *deep learning* memungkinkan sistem mempelajari hubungan kompleks antar variabel serta mengelola data berskala besar dengan noise yang tinggi (Sawitri dkk., 2025).

2.1.2 *Foreign Exchange (Forex)*

Foreign Exchange (Forex) adalah pasar global tempat mata uang dari berbagai negara diperdagangkan (Lidya dkk., 2025). Pasar ini dikenal sebagai pasar keuangan terbesar di dunia dengan volume transaksi harian mencapai triliunan dolar AS. Ciri khas pasar *Forex* adalah likuiditas tinggi, volatilitas yang tajam, dan aktif selama 24 jam (Sapira, 2024). Pergerakan harga di pasar ini sangat dipengaruhi oleh faktor makroekonomi seperti suku bunga, inflasi, tingkat pengangguran, dan intervensi bank sentral. Hal ini menjadikan pasar *Forex* sangat

dinamis namun juga penuh risiko, sehingga prediksi harga memegang peranan penting dalam strategi perdagangan (Utomo & Setiawan, 2020).

Data harga *Forex* berbentuk deret waktu (*time series*) yang memiliki dependensi temporal, sehingga pemodelan pergerakan harga memerlukan pendekatan yang mampu menangani karakteristik tersebut (Ghahremani, 2025). Selain itu, karena adanya *noise*, *outlier*, dan pengaruh berita global secara tiba-tiba, diperlukan model yang adaptif dan mampu belajar dari data historis dalam jangka waktu panjang (Dey, 2025). Oleh karena itu, banyak penelitian terkini yang mengkaji penerapan model *deep learning* dalam prediksi harga *Forex* untuk meningkatkan akurasi dan mendukung sistem perdagangan otomatis (Syahkilah dkk., 2025).

2.1.3 *Exponential Moving Average (EMA)*

Moving Average (MA) merupakan indikator teknikal yang menunjukkan nilai rata-rata dari harga suatu instrumen pada periode tertentu, *MA* bertujuan untuk melihat pergerakan pasar yang lebih jelas. *Exponential Moving Average (EMA)* yaitu perhitungan pergerakan pasar yang diambil dari persentase perubahan harga terakhir. Dengan menggunakan *EMA*, harga terakhir akan lebih berpengaruh dan diharapkan dapat mengatasi keterlambatan perhitungan jenis *Simple moving Average (SMA)*. Dimana *SMA* menggunakan nilai rata-rata selama beberapa periode terakhir (Latif dkk., 2023).

$$EMA = P_1 \times K + EMA_0 \times (1 - K)$$

Persamaan (1)

$$K = 2/(N+1)$$

N = periode yang digunakan pada *EMA*

P_1 = Harga hari ini

EMA_0 = nilai *EMA* pada hari kemarin

2.1.4 *StandardScaler*

Standard Scaler merupakan salah satu teknik praproses data yang umum digunakan dalam analisis data dan pembelajaran mesin untuk melakukan standarisasi fitur. Teknik ini bertujuan untuk menyelaraskan skala antar variabel dengan cara mengurangi nilai rata-rata (mean) dan membagi data berdasarkan simpangan baku (standard deviation). Melalui proses ini, data yang telah distandarisasi akan memiliki nilai rata-rata yang mendekati nol dan varians sebesar satu atau yang dikenal sebagai unit variance (Priambodo dkk., 2023). Proses standarisasi tersebut secara matematis dinyatakan pada Persamaan (3), di mana setiap nilai data asli ditransformasikan menjadi nilai baru yang telah distandarkan dengan mengurangi rata-rata dataset dan membaginya dengan deviasi standar.

$$z = \frac{(x - \mu)}{\sigma}$$

Persamaan (3)

z = nilai baru yang sudah distandarkan


x = nilai asli dari data yang distandarkan

μ = rata-rata (mean) dari dataset

σ =deviasi standar dari dataset

2.1.5 *Informer*

Informer adalah varian dari arsitektur *Transformer* yang dirancang khusus untuk peramalan deret waktu skala panjang. Model ini dikembangkan oleh (Zhou dkk., 2021) dengan memperkenalkan mekanisme *ProbSparse self-attention* yang mengurangi kompleksitas perhitungan dari $O(L^2)$ menjadi hampir linear, sehingga lebih efisien dibandingkan *transformer* standar. Selain itu, *Informer* menggunakan teknik distillation untuk menyaring informasi penting dari data input, memungkinkan prediksi yang lebih akurat dengan sumber daya komputasi yang lebih rendah. *Informer* menjadi relevan karena karakteristik data pasar seperti *forex* sering kali terdiri atas jutaan data historis. Kemampuan *informer* untuk menangani *long-sequence time series* membuatnya ideal untuk digunakan dalam prediksi harga *forex*. Namun, penelitian yang secara khusus menerapkan *informer* dalam konteks *forex* masih sangat terbatas. Sebagian besar implementasi *informer* saat ini masih terfokus pada peramalan energi, cuaca, atau saham (J. Zhang & Duan, 2023), menunjukkan adanya peluang eksplorasi lebih lanjut di domain *forex*.



Gambar 2. 1 Arsitektur *Informer* (Lu dkk., 2023).

Gambar 2.1 menunjukkan bagaimana arsitektur *informer* secara umum tetap mengikuti pola *encoder-decoder* sebagaimana *transformer* standar, namun dengan sejumlah modifikasi penting yang membuatnya lebih efisien dalam menangani data deret waktu panjang. Pada bagian *encoder*, input deret waktu X_{en} terlebih dahulu diproses melalui lapisan *multi-head ProbSparse self-attention*. Mekanisme ini berfungsi untuk menangkap hubungan jangka panjang antar data historis sekaligus menyaring hanya atensi dominan yang paling berpengaruh. Setelah itu, hasil representasi melewati proses *self-attention distilling* yang bertujuan mereduksi dimensi masukan dengan tetap mempertahankan informasi utama. Proses ini dilakukan secara bertingkat, membentuk struktur menyerupai piramida yang menghasilkan *concatenated feature map* sebagai keluaran *encoder*.

Selanjutnya, pada bagian *decoder*, input terdiri atas gabungan *start* token dan *placeholder* deret target $X_{de} = \{X_{token}, X_0\}$, di mana bagian X_0 diinisialisasi dengan nol. *Decoder* memanfaatkan dua mekanisme atensi, yaitu *multi-head attention* untuk menghubungkan keluaran *encoder* dengan input *decoder*, serta *masked multi-head probSparse self-attention* untuk memastikan prediksi dilakukan secara autoregresif tanpa melihat informasi masa depan. Keluaran akhir dari *decoder* kemudian diproyeksikan melalui sebuah *fully connected layer* untuk menghasilkan deret waktu keluaran sesuai horizon prediksi yang diinginkan. Dengan rancangan ini, *informer* mampu menggabungkan efisiensi komputasi dari *probSparse self-attention*, kekuatan representasi dari *encoder* yang terdistilasi, serta kecepatan inferensi dari *generative-style decoding*. Struktur tersebut menjadikan *Informer*

unggul dalam memproses data dengan panjang urutan yang sangat besar tanpa mengorbankan ketepatan hasil prediksi.

2.1.6 *Mean Absolute Error*

Mean Absolute Error (MAE) mengevaluasi tingkat akurasi model peramalan dengan cara menghitung rata-rata selisih absolut antara nilai prediksi dan nilai aktual. Semakin kecil nilai *MAE*, semakin baik kualitas prediksi yang dihasilkan. Menurut (Suryanto, 2020), *MAE* memberikan gambaran tentang rata-rata kesalahan absolut antara data hasil peramalan dan data sebenarnya. Setiap data diberi bobot yang sama dalam perhitungan *error* sehingga *MAE* dianggap lebih intuitif untuk menggambarkan rata-rata tingkat kesalahan secara keseluruhan. Oleh karena itu, ukuran ini sering dipilih dalam evaluasi model yang membutuhkan metode sederhana namun tetap informatif.

$$MAE = \frac{1}{2} \sum_{i=1}^n |f_i - y_i|$$

Persamaan (4)

f_i = nilai hasil peramalan

y_i = nilai sebenarnya, dan

n = jumlah data

2.17 *Mean Square Error*

Mean Square Error (MSE) mengatur kesalahan peramalan yang besar karena kesalahan-kesalahan itu dikuadratkan. Metode itu menghasilkan kesalahan-kesalahan sedang yang memungkinkan lebih baik untuk kesalahan kecil, tetapi kadang menghasilkan perbedaan yang besar. *MSE* merupakan cara kedua

untuk mengukur kesalahan peramalan keseluruhan. *MSE* merupakan rata-rata selisih kuadrat antara nilai yang diramalkan dan yang diamati (Litha & Hasanuddin, 2020).

$$MSE = \sum_{t=1}^n \frac{(X_t - F_t)^2}{n}$$

Persamaan (5)

X_t = data aktual pada periode (t) tertentu

F_t = nilai peramalan pada periode (t) tertentu

t = periode peramalan

n = jumlah data

2.1.8 Mean Absolute Percentage Error

Mean Absolute Percentage Error (MAPE) merupakan salah satu metode evaluasi yang umum digunakan dalam statistik maupun machine learning untuk mengukur tingkat kesalahan prediksi (Nabillah & Ranggadara, 2020). *MAPE* menghitung rata-rata selisih absolut antara nilai prediksi dan nilai aktual, kemudian dinyatakan dalam bentuk persentase dari nilai aktual. Penggunaan *MAPE* dianggap tepat apabila yang ingin dilihat adalah seberapa besar tingkat kesalahan model dalam bentuk persentase, sehingga memudahkan untuk memahami seberapa jauh hasil prediksi menyimpang dari data sebenarnya. Dengan demikian, *MAPE* sering dipakai dalam penelitian maupun praktik yang membutuhkan ukuran akurasi sederhana namun mudah diinterpretasikan (Nuha, 2023). Semakin rendah nilai *MAPE*, kemampuan dari model peramalan yang digunakan dapat dikatakan baik, dan untuk *MAPE* terdapat *range* nilai yang dapat dijadikan bahan pengukuran

mengenai kemampuan dari suatu model peramalan (Maricar, 2021), *range* nilai tersebut dapat dilihat pada tabel 2.1.

$$MAPE = \sum_{t=1}^n \left| \frac{x_t - y_t}{y_t} \right| \times 100\%$$

Persamaan (6)

x_t = nilai aktual

y_t = nilai prediksi

n = jumlah data.

Tabel 2. 1 *Range* nilai *MAPE*

<i>Range MAPE</i>	Arti
<10%	Kemampuan Model Peramalan Sangat Baik
10-20%	Kemampuan Model Peramalan Baik
20-50%	Kemampuan Model Peramalan Layak
>50%	Kemampuan Model Peramalan Buruk

2.2 State-of-the-Art

Terdapat beberapa penelitian yang menggunakan berbagai pendekatan dalam melakukan prediksi harga di pasar keuangan, seperti saham, indeks pasar, dan mata uang kripto. Kontribusi penting dari penelitian-penelitian tersebut terletak pada pemahaman terhadap faktor-faktor yang memengaruhi akurasi prediksi harga serta eksplorasi model-model *deep learning*, seperti *LSTM*, *Transformer*, dan *BERT*. Penelitian-penelitian terdahulu memiliki potensi besar untuk menjadi dasar penting dalam pengembangan metode prediksi yang lebih akurat dan efisien. Berikut Tabel 2.2 yang merangkum penelitian terkait yang menjadi landasan dalam pengembangan dan implementasi model *Informer* pada prediksi harga *forex* dalam penelitian ini.

Tabel 2. 2 *State-of-the-Art*

No	Nama Peneliti/Journal		Hasil Penelitian
1	Peneliti (tahun)	(Ren dkk., 2023)	Penelitian ini menggunakan model hybrid berbasis algoritma Wavelet Transform, Informer, dan Encoder Forest untuk memprediksi harga saham berdasarkan data saham dari pasar A-share Tiongkok. Data yang digunakan mencakup harga penutupan harian dan 244 indikator teknikal dari berbagai sektor industri. Model ini mengimplementasikan pendekatan dekomposisi-rekonstruksi, di mana komponen sinyal frekuensi tinggi diprediksi
	Judul	<i>A novel hybrid model for stock price forecasting integrating Encoder Forest and Informer</i>	
	Algoritma/Metode	<i>Wavelet Transform (WT), Informer, Encoder Forest (EF)</i>	

			menggunakan Informer dan komponen frekuensi rendah menggunakan Encoder Forest. Hasil eksperimen menunjukkan bahwa model hybrid Informer + Encoder Forest menghasilkan performa prediksi terbaik dibandingkan model lain. Pada contoh data saham dengan ID 000552, model ini mencapai nilai MAE sebesar 0,246, RMSE sebesar 0,298, dan R^2 sebesar 0,9978. Dibandingkan model hybrid LSTM + Random Forest (R^2 sebesar 0,9188) dan RNN + Decision Tree (R^2 sebesar 0,8872), model ini menunjukkan peningkatan akurasi signifikan dalam memprediksi harga saham jangka panjang.
2	Peneliti (tahun)	(Wu, 2023)	Penelitian ini menggunakan berbagai model deep learning berbasis Transformer, yaitu Transformer, Informer, Autoformer, dan Non-Stationary Transformer, untuk memprediksi indeks harga saham, termasuk CSI 300 (China Securities Index), Hang Seng Index (HSI), dan S&P 500 (SPX). Variabel dependen adalah harga penutupan indeks saham, sedangkan variabel independen terdiri dari harga pembukaan, harga tertinggi, harga terendah, harga penutupan, dan volume transaksi selama lima hari sebelumnya. Hasil evaluasi menggunakan metrik Mean Absolute Error (MAE)
	Judul	<i>Comparison between transformer, informer, autoformer and non-stationary transformer in financial market</i>	
	Algoritma/Metode	<i>Transformer, Informer, Autoformer, Non-Stationary Transformer (NSTransformer)</i>	

			dan Root Mean Square Error (RMSE) menunjukkan bahwa model Non-Stationary Transformer memiliki akurasi terbaik, dengan nilai MAE sebesar 0,04304 dan RMSE sebesar 0,05891 pada indeks CSI 300. Sebagai pembanding, model Autoformer menghasilkan MAE sebesar 0,04956 dan RMSE sebesar 0,06693, sementara Transformer dan Informer memiliki nilai MAE masing-masing sebesar 0,10135 dan 0,11287. Dengan demikian, model Non-Stationary Transformer menunjukkan peningkatan akurasi sebesar 57,53% dibandingkan Transformer dalam prediksi harga saham indeks CSI.
3	Peneliti (tahun)	(Gothai dkk., 2024)	Penelitian ini menggunakan algoritma Transformer untuk memprediksi indeks harga saham global dari tujuh negara, yaitu China, Kanada, India, Jepang, Rusia, Inggris, dan Amerika Serikat. Model ini menggunakan struktur encoder-decoder dengan multi-head attention mechanism, serta dilakukan pre-processing menggunakan Exponential Moving Average (EMA) dan normalisasi MinMaxScaler. Variabel dependen adalah harga penutupan indeks saham, sedangkan variabel independen mencakup harga pembukaan, harga tertinggi, harga terendah,
	Judul	<i>GLOBAL STOCK MARKET PREDICTION USING TRANSFORMER BASED DEEP LEARNING TECHNIQUES</i>	
	Algoritma/Metode	<i>Transformer, Recurrent Neural Network (RNN), Convolutional Neural Network (CNN)</i>	

			volume perdagangan, dan harga penutupan sebelumnya. Model Transformer dibandingkan dengan Recurrent Neural Network (RNN) dan Convolutional Neural Network (CNN). Hasil evaluasi menunjukkan bahwa Transformer memiliki performa terbaik, dengan nilai Mean Absolute Error (MAE) sebesar 0,0106, Mean Squared Error (MSE) sebesar 0,0003, dan Root Mean Squared Error (RMSE) sebesar 0,0180. Angka ini menunjukkan tingkat kesalahan prediksi yang sangat rendah dibandingkan dengan RNN (MAE = 0,0208) dan CNN (MAE = 0,0984), sehingga model Transformer lebih akurat hingga 49,04% lebih rendah dalam MAE dibandingkan RNN dan 89,22% dibandingkan CNN.
4	Peneliti (tahun)	(Zhou dkk., 2021)	Penelitian ini menggunakan algoritma Informer, sebuah model berbasis Transformer yang dioptimalkan untuk memprediksi data deret waktu jangka panjang (Long Sequence Time-Series Forecasting). Variabel dependen adalah nilai target dari deret waktu (seperti suhu transformator listrik), sementara variabel independen meliputi berbagai fitur terkait seperti beban daya, waktu, dan parameter iklim lainnya. Hasil eksperimen pada empat dataset (ETTh1, ETTh2, ETTm1, dan Weather) menunjukkan bahwa model
	Judul	<i>Beyond Efficient Transformer for Long Sequence Time-Series Forecasting-</i>	
	Algoritma/Metode	<i>Informer, LSTM, Reformer</i>	

			Informer menghasilkan akurasi prediksi terbaik. Sebagai contoh, pada dataset ETTh1 dengan panjang prediksi 168, Informer mencapai nilai MSE sebesar 0,183 dan MAE sebesar 0,346, mengungguli metode lainnya seperti LSTM (MSE = 0,236, MAE = 0,392) dan Reformer (MSE = 1,522, MAE = 1,191). Ini menunjukkan bahwa Informer meningkatkan akurasi hingga 22,03% dibandingkan LSTM dan 88,0% dibandingkan Reformer dalam hal MSE.
5	Peneliti (tahun)	(Bhogade & Nithya, 2024)	Penelitian ini menggunakan model Informer-Based Time Series Forecasting (IBTSF), yang merupakan arsitektur transformer, untuk memprediksi data deret waktu (time series) pada tiga jenis dataset: lalu lintas, harga saham, dan cuaca. IBTSF dibandingkan dengan model lain seperti LSTM, GRU, TCN, dan ARIMA. Hasil evaluasi menunjukkan bahwa model IBTSF memiliki performa terbaik dalam hal akurasi prediksi. Pada dataset lalu lintas, IBTSF memperoleh nilai Mean Squared Error (MSE) sebesar 10,1, sedangkan untuk data harga saham IBM diperoleh MSE sebesar 8,04, dan untuk data cuaca sebesar 86,12. Selain itu, IBTSF juga menunjukkan nilai Mean Absolute Scaled Error (MASE) terendah,
	Judul	<i>Time series forecasting using transformer neural network</i>	
	Algoritma/Metode	<i>Informer, LSTM, GRU, ARIMA, TCN</i>	

			yaitu 1,69 (lalu lintas), 1,53 (saham), dan 0,7 (cuaca), membuktikan ketangguhan model ini dalam menangkap pola jangka panjang dan kompleks pada data deret waktu.
6	Peneliti (tahun)	(Mozaffari & Zhang, 2024)	Penelitian ini menggunakan model Transformer, khususnya BERT dan FinBERT, untuk memprediksi harga saham berdasarkan data historis dan analisis sentimen dari berita keuangan. Dataset yang digunakan mencakup data harga saham dan berita keuangan selama periode tertentu. Metode yang diterapkan adalah kombinasi dari time series forecasting dengan pendekatan deep learning dan pemrosesan bahasa alami (NLP) untuk ekstraksi sentimen. Model yang menggabungkan FinBERT dengan Transformer menghasilkan performa terbaik, dengan nilai akurasi tertinggi mencapai 93,8% pada prediksi arah pergerakan harga saham (up/down) dan nilai RMSE sebesar 0.023 untuk prediksi harga numerik. Hasil ini menunjukkan bahwa integrasi informasi sentimen ke dalam model prediksi berbasis Transformer mampu meningkatkan akurasi secara signifikan dibandingkan model baseline tradisional seperti LSTM atau ARIMA.
	Judul	<i>Predictive Modeling of Stock Prices Using Transformer Model</i>	
	Algoritma/Metode	<i>Long Short-Term Memory (LSTM), Transformer</i>	

7	Peneliti (tahun)	(Cahyani & Mahyuni, 2020)	Penelitian ini memberikan bukti empiris mengenai keakuratan metode <i>Moving Average (MA)</i> dalam memprediksi arah pergerakan harga saham LQ45 di Bursa Efek Indonesia. Hasilnya menunjukkan tidak ada perbedaan signifikan antara prediksi yang dihasilkan sinyal <i>Golden Cross</i> dan <i>Death Cross</i> dengan kenyataannya, sehingga memvalidasi <i>MA</i> sebagai indikator analisis teknikal yang andal dan relevan untuk digunakan dalam pengambilan keputusan investasi jangka pendek.
	Judul	<i>AKURASI MOVING AVERAGE DALAM PREDIKSI SAHAM LQ45 DI BURSA EFEK INDONESIA</i>	
	Algoritma/Metode	<i>Moving Average (MA)</i>	
8	Peneliti (tahun)	(Rosita dkk., 2024)	Studi ini secara langsung membandingkan tiga varian <i>Moving Average</i> dan menemukan bahwa metode <i>EMA</i> memberikan hasil prediksi terbaik dengan nilai error (MAD, MSE, MAPE) terkecil. <i>EMA</i> menunjukkan hasil lebih akurat karena memberikan bobot eksponensial pada data terbaru, membuatnya lebih cepat mendeteksi perubahan tren. Temuan ini memberikan justifikasi kuat untuk memilih <i>EMA</i> sebagai indikator yang akan diintegrasikan dengan model <i>Informer</i>.
	Judul	<i>Perbandingan Prediksi Pergerakan Harga Saham Menggunakan Metode SMA, WMA, dan EMA di PT Bank Central Asia (BCA)</i>	
	Algoritma/Metode	<i>Simple Moving Average (SMA), Weighted Moving Average (WMA), Exponential Moving Average (EMA)</i>	

9	Peneliti (tahun)	(Abid Shabrina & Hasnawati, 2022)	Penelitian ini juga memperkuat keunggulan EMA. Hasil studi menunjukkan bahwa EMA dengan periode 30 hari menjadi analisis estimasi harga saham yang paling efisien dibandingkan SMA pada saham sektor pertambangan di BEI. Semakin panjang periode analisis yang digunakan pada EMA, semakin baik hasil prediksinya. Ini memberikan landasan empiris yang solid untuk penerapan EMA dalam model prediksi.
	Judul	<i>PERBANDINGAN EFISIENSI ANALISIS TEKNIKAL, SMA DAN EMA DALAM MENGESTIMASI HARGA SAHAM</i>	
	Algoritma/Metode	<i>Simple Moving Average (SMA), Exponential Moving Average (EMA)</i>	
10	Peneliti (tahun)	(Rifai dkk., 2024)	Penelitian ini membandingkan implementasi EMA, WMA, dan SMA untuk memprediksi Indeks Harga Saham Gabungan (IHSG). Hasilnya konsisten menunjukkan bahwa EMA secara konsisten mengungguli WMA dan SMA dengan akurasi yang lebih tinggi. EMA berdasarkan hasil evaluasi lebih responsif terhadap perubahan tren pasar saham karena fokusnya pada data terbaru, menjadikannya pilihan superior untuk prediksi pasar yang dinamis.
	Judul	<i>COMPARISON OF IMPLEMENTATION BETWEEN EMA, WMA, SMA IN PREDICTING IHSG</i>	
	Algoritma/Metode	<i>EMA, WMA, SMA</i>	
	Peneliti (tahun)	(Panchal & Gor, 2022)	

11	Judul	<i>COMPARATIVE STUDY OF HYBRID STRATEGIES WITH MOVING AVERAGE CROSSOVER</i>	Studi ini membandingkan berbagai strategi hybrid dengan strategi dasar Moving Average Crossover. Meskipun strategi hybrid (seperti Parabolic SAR + EMA) menunjukkan kinerja yang baik untuk skenario tertentu (misalnya intraday trading), keberadaan MA Crossover sebagai benchmark menunjukkan statusnya sebagai salah satu strategi paling fundamental dan banyak digunakan, memperkuat relevansinya dalam analisis teknikal.
	Algoritma/Metode	<i>DCRSI, PSAREMA, Moving Fibonacci, Moving Average Crossover</i>	
12	Peneliti (tahun)	(Xiao dkk., 2025)	Penelitian ini menggunakan algoritma TimeFound, yaitu model foundation berbasis Transformer dengan arsitektur encoder-decoder untuk melakukan prediksi deret waktu secara zero-shot tanpa pelatihan tambahan. Model TimeFound dilatih menggunakan dataset besar dari berbagai domain seperti keuangan, energi, ritel, dan cuaca, dengan pendekatan multi-resolution patching yang memungkinkan penangkapan pola temporal pada berbagai skala waktu. Variabel dependen dalam eksperimen adalah nilai prediksi pada beragam dataset deret waktu (misalnya nilai tukar, permintaan energi, data kesehatan), sementara variabel input berupa urutan data historis dari masing-masing domain. TimeFound dievaluasi pada 24 dataset berbeda menggunakan metrik MASE (Mean Absolute
	Judul	<i>TimeFound: A Foundation Model for Time Series Forecasting</i>	
	Algoritma/Metode	<i>TimeFound, TimesFM</i>	

			Scaled Error) dan sMAPE (Symmetric Mean Absolute Percentage Error), dan dibandingkan dengan dua model foundation terkini: TimesFM dan Chronos. Hasil evaluasi menunjukkan bahwa TimeFound-Large mencapai performa terbaik dengan MASE geometrik rata-rata sebesar 0.842, mengungguli TimesFM (0.869) dan Chronos (0.857). Dalam uji rolling forecast jangka panjang, TimeFound juga menunjukkan keunggulan dengan nilai sMAPE rata-rata 0.486 pada dataset ETTm2, lebih baik dibandingkan TimesFM (0.517) dan Chronos (0.520). Hal ini membuktikan bahwa TimeFound memiliki generalisasi tinggi dan efektif untuk prediksi deret waktu lintas domain secara efisien.
13	Peneliti (tahun)	(J. Zhang & Duan, 2023)	Penelitian ini menggunakan model Enhanced LFTSformer, sebuah algoritma hybrid berbasis arsitektur Informer yang telah ditingkatkan untuk melakukan prediksi deret waktu keuangan jangka panjang. Dataset yang digunakan mencakup data saham 22 perusahaan besar dari Bursa Saham Shanghai dan Shenzhen, dengan interval waktu 30 menit sejak tahun 1999 hingga 2023. Model ini menggabungkan teknik Variational Mode Decomposition (VMD), Maximal Information Coefficient (MIC), dan Fuzzy
	Judul	<i>Adaptive Hybrid Model for Enhanced Stock Market Predictions Using Improved VMD and Stacked Informer</i>	
	Algoritma/Metode	<i>Informer, LSTM, CNN, Autoformer, Pyraformer</i>	

			Entropy dalam tahap rekayasa fitur, serta mengadopsi Stacked Distributed Informer Encoder, GC-enhanced Adam Optimizer, dan Dynamic Loss Function. Hasil eksperimen menunjukkan bahwa model Enhanced LFTSformer menghasilkan akurasi prediksi lebih dari 90%, berdasarkan evaluasi dengan metrik R^2 , serta menunjukkan nilai kesalahan yang rendah, yaitu MAE sebesar 0,0174, MSE sebesar 0,0013, dan RMSE sebesar 0,0361 pada dataset saham Bank Pembangunan Pudong (SHA: 600000). Model ini juga menunjukkan performa unggul dibandingkan model CNN, LSTM, Informer, Autoformer, dan Pyraformer, baik dari sisi akurasi maupun efisiensi komputasi.
14	Peneliti (tahun)	(Abdullah & Salah, 2023)	Penelitian ini bertujuan untuk membandingkan kinerja berbagai model prediktif dalam analisis deret waktu keuangan untuk memprediksi harga instrumen. Metode yang digunakan adalah model ARIMA sebagai model statistik, regresi linier (LR) sebagai model machine learning (ML), dan dua model deep learning (DL) yaitu LSTM dan CNN-LSTM. Data yang digunakan berasal dari tiga kategori dataset yang berbeda: peramalan mata uang, peramalan pasar saham, dan peramalan harga cryptocurrency. Hasil
	Judul	<i>A novel hybrid deep learning model for price prediction</i>	
	Algoritma/Metode	<i>ARIMA, Regresi Linier, LSTM, CNN-LSTM</i>	

			penelitian menunjukkan bahwa model CNN-LSTM memiliki kinerja yang lebih baik dibandingkan model LSTM dan model statistik seperti ARIMA, dengan peningkatan akurasi prediksi sebesar 15% dibandingkan model ARIMA dan 10% dibandingkan model LSTM.
15	Peneliti (tahun)	(Stefaniuk & Ślepaczuk, 2025)	Penelitian ini menggunakan algoritma Informer, sebuah arsitektur Transformer yang dioptimalkan untuk prediksi deret waktu panjang, guna membangun strategi perdagangan otomatis berdasarkan data harga Bitcoin berfrekuensi tinggi. Dataset yang digunakan adalah pasangan BTC/USDT dari bursa Binance, dengan interval waktu 5 menit, 15 menit, dan 30 menit, dalam rentang waktu dari 21 Agustus 2019 hingga 24 Juli 2024. Model Informer dilatih dengan tiga fungsi loss berbeda, yaitu Root Mean Squared Error (RMSE), Quantile Loss, dan Generalized Mean Absolute Directional Loss (GMADL). Hasil eksperimen menunjukkan bahwa strategi berbasis Informer dengan fungsi loss GMADL memberikan performa terbaik, menghasilkan nilai Information Ratio (IR) tertinggi sebesar 1,71, dan Annualized Return Compounded (ARC) sebesar 19,25%, mengungguli strategi Buy-
	Judul	<i>Informer in Algorithmic Investment Strategies on High Frequency Bitcoin Data</i>	
	Algoritma/Metode	<i>Transformer, Informer</i>	

			and-Hold serta dua strategi berbasis indikator teknikal (MACD dan RSI). Strategi ini juga memiliki jumlah transaksi yang optimal dan mampu mengambil keuntungan dari volatilitas harga pada interval data 5 menit.
16	Peneliti (tahun)	(L. Zhao & Yan, 2024)	Penelitian ini menggunakan tiga algoritma deep learning berbasis Transformer, yaitu Transformer, Informer, dan Temporal Fusion Transformer (TFT) untuk memprediksi nilai tukar mata uang NZD terhadap USD, CNY, GBP, dan AUD berdasarkan data historis dari Yahoo Finance dan Investing.com. Variabel dependen adalah nilai tukar NZD, sedangkan variabel independen terdiri atas harga pembukaan, penutupan, tertinggi, terendah, dan harga mengambang harian dari tahun 2005 hingga 2024 dengan total 4980 data harian per pasangan mata uang. Hasil evaluasi menunjukkan bahwa model TFT menghasilkan performa terbaik, dengan rata-rata nilai R^2 sebesar 94,99%, MAPE sebesar 0,55%, dan RMSE sebesar 0,0111, mengungguli Informer ($R^2 = 88,93\%$, MAPE = 0,95%) dan Transformer ($R^2 = 89,22\%$, MAPE = 0,97%). Secara spesifik, TFT menunjukkan hasil prediksi paling akurat untuk pasangan NZD/USD ($R^2 = 98,92\%$, MAE = 0,0035). Sementara itu, model
	Judul	<i>Prediction of Currency Exchange Rate Based on Transformers</i>	
	Algoritma/Metode	<i>Transformer, Informer, TFT (Temporal Fusion Transformer)</i>	

			Informer menunjukkan efisiensi pelatihan terbaik karena mampu menghasilkan prediksi stabil hanya dalam 60 epoch.
17	Peneliti (tahun)	(Lu dkk., 2023)	Penelitian ini menggunakan algoritma Informer untuk memprediksi harga saham dan indeks pasar berdasarkan data frekuensi 1-menit dan 5-menit dari empat entitas: HSI, IXIC, Tencent, dan Apple. Variabel target adalah harga penutupan, sementara fitur input meliputi harga pembukaan, tertinggi, terendah, volume, rasio perputaran, dan stempel waktu global. Model Informer dievaluasi dengan tiga metrik: MAE, RMSE, dan MAPE. Pada prediksi harga saham Apple frekuensi 1-menit, model Informer mencapai hasil terbaik dengan MAE sebesar 0.0134, RMSE 0.0218, dan MAPE 16.69%. Dibandingkan dengan LSTM, Transformer, dan BERT, Informer menunjukkan kinerja paling akurat dan stabil terutama dalam kondisi volatilitas tinggi.
	Judul	<i>Stock and market index prediction using Informer network</i>	
	Algoritma/Metode	<i>Informer, Long Short-Term Memory (LSTM), Transformer, BERT</i>	
18	Peneliti (tahun)	(Yulistiani & Kurniadi, 2024)	Penelitian ini menggunakan algoritma Informer untuk memprediksi harga penutupan saham berdasarkan data historis saham perbankan di Indonesia, yaitu BBKA, BBNI, dan BBRI, yang diperoleh dari GitHub Anderies/CS-IDX30. Variabel dependen adalah harga penutupan harian, sedangkan variabel independen meliputi harga
	Judul	<i>Stock Price Prediction with the Informer Model</i>	
	Algoritma/Metode	<i>Informer, LSTM, GRU, RNN</i>	

			pembukaan, harga tertinggi, harga terendah, dan stempel waktu. Model Informer dibandingkan dengan LSTM, RNN, dan GRU menggunakan metrik MSE, RMSE, dan R^2. Hasil terbaik dicapai oleh model Informer pada dataset BNI, dengan R^2 sebesar 89,6%, MSE sebesar 0,001, dan RMSE sebesar 0,032, menunjukkan bahwa Informer dapat memberikan akurasi tinggi jika diterapkan pada dataset yang sesuai. Namun, pada dataset BCA dan BRI, performa Informer menurun dengan R^2 masing-masing hanya 57,3% dan 15,5%, menandakan bahwa efektivitas model bergantung pada karakteristik data yang digunakan.
19	Peneliti (tahun)	(Ding dkk., 2023)	Penelitian ini menggunakan algoritma Informer untuk memprediksi harga penutupan intraday saham berdasarkan data K-line per menit dari Indeks Komposit Shanghai (XSHG000001). Variabel dependen adalah harga penutupan, sedangkan variabel independen meliputi harga pembukaan, harga tertinggi, harga terendah, volume transaksi, dan nilai transaksi. Model Informer dibandingkan dengan LSTM pada lima jenis dataset dengan frekuensi pengambilan data berbeda (1–5 menit), dan dievaluasi menggunakan metrik MSE, MAE, RMSE, dan MAPE. Hasil terbaik diperoleh pada frekuensi 5
	Judul	<i>An Informer Based Method for Stock Intraday Price Prediction</i>	
	Algoritma/Metode	<i>Informer, LSTM</i>	

			menit, di mana Informer menghasilkan MSE sebesar 0.001593, MAE sebesar 0.26739, RMSE sebesar 0.39924, dan MAPE sebesar 6.84%, sementara LSTM pada konfigurasi yang sama menghasilkan MAPE sebesar 16.88%. Hal ini menunjukkan bahwa Informer memiliki performa prediksi yang lebih baik dibandingkan LSTM, dengan peningkatan akurasi sekitar 10% dalam memprediksi harga saham intraday.
20	Peneliti (tahun)	(Duan & Ke, 2024)	Penelitian ini menggunakan algoritma LSTM dan Informer untuk memprediksi harga saham berdasarkan data historis dari www.quote.eastmoney.com yang mencakup atribut seperti harga pembukaan, harga penutupan, harga tertinggi, harga terendah, dan volume perdagangan. Variabel dependen adalah harga penutupan saham harian, sementara variabel independen terdiri dari fitur-fitur teknikal dan sentimen berita. Penelitian membandingkan tiga model: Informer, LSTM, dan gabungan Informer+LSTM, dengan evaluasi menggunakan metrik MAE, RMSE, dan R^2. Hasil terbaik dicapai oleh model gabungan Informer+LSTM, yang menghasilkan MAE sebesar 17,689, RMSE sebesar 23,071, dan akurasi prediksi (R^2) sebesar 97,9%, lebih tinggi dibandingkan model LSTM (R^2 =
	Judul	<i>Advanced Stock Price Prediction Using LSTM and Informer Models</i>	
	Algoritma/Metode	<i>LSTM, Informer</i>	

			87,9%) dan Informer ($R^2 = 86,7\%$). Hal ini menunjukkan bahwa kombinasi kedua model mampu meningkatkan akurasi prediksi secara signifikan dibandingkan penggunaan model tunggal.
--	--	--	--

Pada Tabel 2.1, Model *Transformer* dan variannya memiliki potensi besar dalam prediksi harga di sektor keuangan. Salah satu model yang paling menonjol adalah *Informer*, yang diperkenalkan oleh (Zhou dkk., 2021) dan unggul dalam berbagai studi lanjutan. Penelitian oleh (Bhogade & Nithya, 2024) dan (Lu dkk., 2023) mengonfirmasi keunggulan *Informer* di berbagai domain data deret waktu, termasuk pada data saham frekuensi tinggi, yang membuktikan kapabilitasnya untuk diterapkan pada pasar dinamis seperti harga emas (*XAU/USD*). Seiring berkembangnya teknologi, penelitian terus mengarah pada model yang lebih canggih dan pendekatan *hybrid* untuk meningkatkan akurasi. Model-model baru seperti *Non-Stationary Transformer* yang dievaluasi oleh (Wu, 2023) dan model fondasi seperti *TimeFound* dari (Xiao dkk., 2025) menunjukkan evolusi berkelanjutan dalam arsitektur ini. Lebih penting lagi, pendekatan *hybrid* secara konsisten menemukan hasil yang superior. Sebagai contoh, penggabungan *Informer* dengan *Encoder Forest* oleh (Ren dkk., 2023) serta integrasi dengan *LSTM* yang dilakukan oleh (Duan & Ke, 2024) memberikan peningkatan pada tingkat akurasi prediksi. Tren ini menegaskan bahwa mengintegrasikan kekuatan dari beberapa metode adalah strategi yang efektif untuk mengatasi kompleksitas data pasar keuangan.

Meskipun model-model canggih ini menunjukkan performa luar biasa, penelitian secara konsisten juga membuktikan bahwa indikator analisis teknikal klasik tetap sangat relevan dan efektif. Penelitian oleh (Cahyani & Mahyuni, 2020) membuktikan keakuratan metode *Moving Average (MA)* secara umum dalam memprediksi arah pergerakan harga saham di pasar Indonesia. Secara spesifik, beberapa studi komparatif menyimpulkan bahwa *Exponential Moving Average (EMA)* secara konsisten lebih unggul dibandingkan varian lain. Penelitian oleh (Rosita dkk., 2024) menemukan bahwa *EMA* memberikan hasil prediksi dengan tingkat *error (MAD, MSE, MAPE)* terkecil. Hal ini didukung oleh (Abid Shabrina & Hasnawati, 2022) yang mengidentifikasi *EMA* sebagai metode estimasi paling efisien, serta (Rifai dkk., 2024) yang menyatakan *EMA* lebih responsif terhadap perubahan tren pasar. Bahkan, (Gothai dkk., 2024) telah menggunakan *EMA* sebagai langkah *pre-processing* data yang efektif sebelum diolah oleh model *Transformer*.

Meskipun demikian, sebagian besar studi yang berfokus pada *Informer* belum secara eksplisit mengeksplorasi integrasi langsung dengan sinyal dari indikator *EMA* sebagai fitur input. Padahal, berbagai temuan empiris menunjukkan bahwa *EMA* memiliki keunggulan sebagai indikator tren, serta bahwa pendekatan hybrid mampu memberikan performa model yang lebih baik. Oleh karena itu, penelitian ini berfokus untuk menjembatani celah tersebut dengan menerapkan model *Informer* yang diintegrasikan dengan indikator *EMA* untuk memprediksi harga emas (*XAU/USD*). Selanjutnya, penelitian ini akan mengevaluasi apakah integrasi ini mampu

memberikan peningkatan kinerja dibandingkan dengan model *Informer standar*. Dengan pendekatan ini, diharapkan dapat diperoleh sistem prediksi yang tidak hanya akurat dan efisien, tetapi juga lebih kaya fitur dan adaptif terhadap dinamika pasar yang volatil.

2.3 Matrix Penelitian

Tabel 2. 3 Matrix Penelitian

No	Penelitian	Algoritma	Tujuan Penelitian			
			Perbandingan Algoritma	Pengujian Variabel	Optimalisasi Algoritma	Analisis Teknikal
1	(Ren dkk., 2023)	<i>Wavelet Transform, Informer, Encoder Forest</i>	✓	-	✓	-
2	(Wu, 2023)	<i>Transformer, Informer, Autoformer, NSTransformer</i>	✓	-	✓	-
3	(Gothai dkk., 2024)	<i>Transformer, Recurrent Neural Network (RNN), Convolutional Neural Network (CNN)</i>	✓	✓	✓	-
4	(Zhou dkk., 2021)	<i>Informer, LSTM, Reformer</i>	✓	✓	✓	-
5	(Bhogade & Nithya, 2024)	<i>Informer, LSTM, GRU, ARIMA, TCN</i>	✓	-	-	-

6	(Mozaffari & Zhang, 2024)	<i>Long Short-Term Memory (LSTM), Transformer</i>	✓	-	-	-
7	(Cahyani & Mahyuni, 2020)	<i>Moving Average (MA)</i>	-	-	-	✓
8	(Rosita dkk., 2024)	<i>Simple Moving Average (SMA), EMA (Exponential Moving Average), Weighted Moving Average (WMA)</i>	-	-	-	✓
9	(Abid Shabrina & Hasnawati, 2022)	<i>Simple Moving Average (SMA), EMA (Exponential Moving Average)</i>	-	-	-	✓
10	(Rifai dkk., 2024)	<i>MA, WMA, SMA</i>	-	-	-	✓
11	(J. Zhang & Duan, 2023)	<i>Informer, LSTM, CNN, Autoformer, Pyraformer</i>	✓	-	-	-
12	(Abdullah & Salah, 2023)	<i>ARIMA, Regresi Linier, LSTM, CNN-LSTM</i>	✓	-	-	-
13	(Stefaniuk & Ślepaczuk, 2025)	<i>Transformer, Informer</i>	-	-	-	-

14	(Kartono dkk., 2021)	<i>Nonlinear Schrodinger Equation (NLSE)</i>	-	-	-	-
15	(L. Zhao & Yan, 2024)	<i>Transformer, Informer, TFT (Temporal Fusion Transformer)</i>	-	✓	-	-
16	(Lu dkk., 2023)	<i>Informer, Long Short-Term Memory (LSTM), Transformer, BERT</i>	-	-	-	-
17	(Yulistiani & Kurniadi, 2024)	<i>Informer, LSTM, GRU, RNN</i>	-	✓	-	-
18	(Ding dkk., 2023)	<i>Informer, LSTM</i>	-	✓	-	-
19	(Duan & Ke, 2024)	<i>LSTM, Informer</i>	✓	✓	✓	-
20	(Xiao dkk., 2025)	<i>TimeFound, TimesFM</i>	✓	✓	-	-

Tabel 2.3 matriks penelitian menunjukkan bahwa berbagai penelitian sebelumnya telah mengeksplorasi beragam algoritma untuk memprediksi data deret waktu keuangan. Sebagian besar berfokus pada perbandingan algoritma *deep learning* seperti *Transformer* dan variannya (*Informer, Autoformer*), serta model klasik seperti *LSTM* dan *ARIMA* (Gothai dkk., 2024; Ren dkk., 2023; Wu, 2023; Zhou dkk., 2021). Beberapa penelitian lain memiliki fokus yang lebih spesifik pada pengujian variabel atau optimalisasi

algoritma untuk meningkatkan performa model-model tersebut (Duan & Ke, 2024; Xiao dkk., 2025). Matriks tersebut juga menyoroti adanya dikotomi yang jelas, satu kelompok penelitian terkonsentrasi pada evaluasi model *deep learning* canggih, sementara kelompok penelitian lain secara terpisah berfokus pada analisis teknikal untuk memvalidasi dan membandingkan indikator klasik seperti *MA*, *SMA*, *WMA*, dan *EMA* (Abid Shabrina & Hasnawati, 2022; Cahyani & Mahyuni, 2020; Rifai dkk., 2024; Rosita dkk., 2024). Terlihat jelas adanya celah di mana belum ada penelitian dalam matriks ini yang secara spesifik menjembatani kedua domain tersebut, yaitu mengintegrasikan indikator teknikal seperti *Exponential Moving Average (EMA)* ke dalam arsitektur model *Transformer* canggih seperti *Informer*.

Penelitian ini bertujuan untuk menjawab celah tersebut dengan menerapkan model *Informer* yang diintegrasikan dengan indikator *EMA* dalam memprediksi harga emas (*XAU/USD*) berbasis data historis pasar *forex*. Selanjutnya, penelitian ini juga membandingkan performa model *Informer-EMA* dengan model *Informer* standar untuk mengetahui peningkatan akurasi prediksi yang dihasilkan dari integrasi tersebut. Dengan pendekatan ini, diharapkan hasil penelitian dapat memberikan kontribusi empiris yang kuat dalam pengembangan metode *hybrid* antara *deep learning* dan analisis teknikal untuk prediksi pasar keuangan.