

BAB II

TINJAUAN PUSTAKA

Bab ini terdiri dari penelusuran literatur, pencapaian terdahulu, dan tinjauan teoritis. Isi bab ini untuk memperkuat landasan dari penelitian Peneliti.

2.1. Pencapaian Terdahulu

Penelitian ini berfokus dalam pengembangan model prediksi harga emas dengan pendekatan *time series forecasting*. Penelusuran literatur ini menggunakan beberapa kata kunci untuk membantu penulis dalam mencari literatur. Beberapa di antaranya adalah :

1. “Gold price prediction with time series method”
2. “Gold price prediction with technical analysis comparison”
3. “Systematic review time series forecasting”

Penelusuran literatur ini memiliki tujuan untuk menjawab pertanyaan penelitian di antaranya adalah “ Apa saja metode atau pendekatan time series untuk memprediksi harga?”, “ Apa saja variabel sebagai parameter yang relevan untuk memprediksi harga emas? “.

Penelusuran literatur ini dilakukan dengan menelusuri beberapa database literatur yaitu Google Scholar. Penulis menggunakan mesin penelusuran yaitu Google dan sebuah software bernama Harzing Publish and Perish untuk mencari literatur.

Tabel 2. 1 Hasil penelitian terdahulu

No	Nama (Tahun)	Judul	Hasil
1	Ioannis E. Livieris, Emmanuel Pintelas, Panagiotis Pintelas (2020)	<i>A CNN-LSTM model for gold price time- series forecasting</i>	Penelitian ini mengembangkan sebuah model dengan metode hibrida yaitu <i>CNN-LSTM</i> yang menerapkan lapisan konvolusi dan lapisan pooling sebagai ekstraksi fitur serta <i>LSTM</i> unit untuk menganalisa data harga emas sehingga dapat diprediksi. Model ini dievaluasi dengan metrik <i>MAE</i> dan <i>RMSE</i> yang

menunjukkan bahwa model ini menghasilkan *MAE* dan *RMSE* terkecil. Hasil prediksi harga akan naik dan turun juga mendapatkan akurasi sebesar 55,53% (Livieris et al., 2020).

2	Andrés Vidal, Werner Kristjanpoller (2019)	<i>Gold volatility prediction using a CNN-LSTM approach</i>	Penelitian ini mengembangkan sebuah model dengan metode <i>CNN-LSTM</i> untuk memprediksi volatilitas harga emas dengan mengubah data deretan waktu menjadi citra lalu diekstraksi datanya sehingga dapat dianalisa oleh <i>LSTM</i>. Model <i>CNN-LSTM</i> menghasilkan <i>error</i> atau selisih paling kecil dibandingkan pengujian dengan model lainnya. Perbedaan antara model <i>LSTM</i> dengan hibrida <i>CNN-LSTM</i> sebesar -18,1% atau model <i>CNN-LSTM</i> lebih unggul dalam memprediksi (Vidal & Kristjanpoller, 2020).
3	Junling Luo, Zhongliang Zhang, Yao Fu, Feng Rao (2021)	<i>Time series prediction of COVID-19 transmission in America using LSTM and XGBoost algorithms</i>	Sebuah penelitian mengkaji penerapan metode <i>LSTM</i> dan <i>XGBoost</i> untuk memprediksi kasus harian terkonfirmasi COVID-19 di Amerika. Studi ini menggunakan data serial waktu dari 1 April hingga 30 September 2020, yang dibagi menjadi 90% data latih dan 10% data uji. Fitur masukan untuk model mencakup riwayat kasus harian dari 14 hari sebelumnya, serta nilai rata-rata dan standar deviasi dari dua minggu terakhir. Hasil pengujian menunjukkan bahwa model <i>LSTM</i> memiliki kinerja prediksi yang lebih superior, mencapai <i>MAPE</i> sebesar 2,32%. Sementara itu, model <i>XGBoost</i> mencatatkan <i>MAPE</i> 7,21%, namun unggul dalam mengidentifikasi fitur paling berpengaruh, yaitu rata-rata

kasus dan hari dalam seminggu (Luo et al., 2021).

4	Sami Ben Jabeur, Salma Mefteh-Wali, Jean-Laurent Viviani (2021)	<i>Forecasting gold price with the XGBoost algorithm and SHAP interaction values</i>	Penelitian ini menerapkan algoritma <i>XGBoost</i> dan menerapkan pendekatan <i>SHapley Additive exPlanation (SHAP)</i> untuk menerjemahkan hasil dari model <i>ML</i> . Nilai dari <i>SHAP</i> dapat membantu dalam memahami berbagai model termasuk kepentingan dari fitur, ketergantungan fitur, kesimpulan lokal maupun plot kesimpulan. Penelitian ini menggunakan <i>dataset</i> dari berbagai harga yang dapat mempengaruhi harga emas, dalam harga Dolar AS, dari tahun 1986 sampai 2019. Berdasarkan uji dengan 5 model selain <i>XGBoost</i> , <i>XGBoost</i> mendapatkan <i>RMSE</i> terendah dengan nilai 34.92 (Jabeur et al., 2024).
5	Manjula, K. A., Karthikeyan, P.	<i>Gold Price Prediction using Ensemble based Machine Learning Techniques</i>	Penelitian ini menerapkan teknik <i>ensemble</i> yang menggabungkan beberapa model lalu dibentuk menjadi kesatuan model bertujuan menghasilkan performa yang lebih kuat. Penelitian ini menggunakan metode pohon keputusan yaitu <i>Random Forest Regressor</i> serta metode pohon regresi-gradien, lalu dibandingkan dengan metode regresi linear. Penelitian ini menerapkan fitur seperti harga minyak mentah, harga saham, nilai tukar rupee terhadap Dolar AS, inflasi, serta suku bunga. Hasil

yang didapatkan adalah metode dengan teknik *ensemble* lebih unggul dengan *MAE* 3007,8 dan 2804,44 dibandingkan metode Regresi Linear dengan *MAE* 4384,43 (Manjula & Karthikeyan, 2019).

6	Zakaria Alameer, Mohamed Abd Elaziz, Ahmed A. Ewees , Haiwang Ye, Zhang Jianhua (2019)	<i>Forecasting gold price fluctuations using improved multilayer perceptron neural network and whale optimization algorithm</i>	Penelitian ini menerapkan pemodelan jaringan syaraf tiruan yang melibatkan lapisan-lapisan syaraf. Penelitian ini menerapkan algoritma optimasi <i>Whale Optimization Algorithm (WOA)</i> pada model (<i>WOA-NN</i>) untuk mengatasi masalah regresi non-linear seperti peramalan fluktuasi harga emas. Penelitian ini menerapkan fitur yaitu harga komoditas, nilai tukar, dan inflasi, dengan periode bulanan, dengan kurun waktu September 2008 sampai Agustus 2017. Hasil yang didapatkan adalah model <i>WOA-NN</i> mendapatkan hasil yang lebih baik (<i>MAE</i> = 0,021) dibandingkan syaraf tiruan lainnya (<i>MAE</i> = 0,027) dan pemodelan matematika seperti ARIMA (<i>MAE</i> = 0,057) (Alameer et al., 2019).
7	Mustafa Yurtsever (2021)	<i>old Price Forecasting Using LSTM, Bi-LSTM and GRU</i>	Penelitian ini menerapkan metode <i>LSTM</i> serta <i>Bidirectional-LSTM (Bi-LSTM)</i> dan <i>Gated Recurrent Unit (GRU)</i>. Data yang digunakan selama penelitian ini melibatkan variabel yang mewakili indikator ekonomi seperti harga minyak mentah, <i>Consumer Price Index (CPI)</i>, nilai tukar efektif, suku bunga, dan indeks <i>S&P 500</i>. Hasil penelitian adalah model <i>LSTM</i> lebih unggul dibandingkan model <i>Bi-LSTM</i> dan <i>GRU</i>. Model <i>LSTM</i> menghasilkan nilai evaluasi (<i>MAE</i> = 48,85), mengalahkan model <i>Bi-LSTM</i> dengan (<i>MAE</i> = 61,53) dan <i>GRU</i> dengan

($MAE = 71,24$) (Makalesi & Yurtsever, 2021).

8	Pinyi Zhang, Bicong Ci (2020)	<i>Deep belief network for gold price forecasting</i>	Penelitian ini menerapkan metode Deep Belief Network (<i>DBN</i>) yang merupakan penerapan RBM dan model <i>Backpropagation Neural Network</i> (<i>BPNN</i>) untuk mempelajari data dari menerapkan bobot dan bias lalu dikoreksi dan diubah agar lebih menyesuaikan dengan target. Penelitian ini menggunakan fitur CPI, minyak mentah, suku bunga, indeks saham <i>Dow Jones</i> , dan nilai tukar Dolar AS. Hasil dari penelitian ini bahwa model dengan sepuluh neuron menghasilkan performa terbaik dengan nilai evaluasi ($MAE = 0,04$) dan waktu yang diperlukan untuk melatih selama 179,4 detik (Zhang & Ci, 2020).
9	Zhanhong He, Junhao Zhou, Hong-Ning Dai, Hao Wang (2019)	<i>Gold Price Forecast based on LSTM-CNN Model</i>	Penelitian ini menggunakan metode hibrida yaitu <i>LSTM-CNN</i> serta menerapkan teknik <i>Attention Mechanism</i> untuk memberikan bobot yang lebih penting pada data yang lebih berharga dan mengurangi bobot pada data yang kurang relevan. Penelitian ini menerapkan fitur harga seperti harga emas harian dalam harga Dolar AS, mata uang euro, RMB, Dolar Hongkong, per ounce. Berdasarkan hasil penelitian, model <i>LSTM-Attention-CNN</i> ($MAE = 21,71$) lebih baik dibandingkan model <i>LSTM</i> ($MAE = 60,40$) dan <i>LSTM-CNN</i> ($MAE = 42,50$) (He et al., 2019).

10	Xuanyi Song, Yuetian Liu, Liang Xue, Jun Wang, Jingzhe Zhang, Junqiang Wang, Long Jiang, Ziyang Cheng (2020)	<i>Time-series well performance prediction based on Long Short-Term Memory (LSTM) neural network model</i>	Penelitian ini menerapkan metode <i>LSTM</i> untuk memprediksi serta menguji performa dari <i>LSTM</i> dibandingkan dengan model <i>RNN</i> maupun <i>ANN</i> . Penelitian ini menggunakan teknik optimisasi seperti <i>Particle Swarm Optimization</i> (PSO). Penelitian ini menerapkan model untuk memprediksi laju produksi minyak harian dari reservoir vulkanik. Penelitian ini menghasilkan penemuan bahwa model <i>LSTM</i> ($MAE = 1.60$) mendapatkan performa lebih baik dibandingkan model pengujian lainnya seperti <i>RNN</i> (3,18) (Song et al., 2020).
----	--	--	---

Penelitian-penelitian sebelumnya menunjukkan bahwa metode hybrid deep learning dan ensemble sangat efektif untuk peramalan data deret waktu, khususnya harga emas. Beberapa penelitian menyoroti keunggulan model hibrida CNN-LSTM. Model ini terbukti menghasilkan error prediksi yang lebih kecil dibandingkan model tunggal. Sebagai contoh, sebuah studi mengembangkan model CNN-LSTM untuk prediksi harga emas dan menemukan bahwa model ini menghasilkan nilai Mean Absolute Error (MAE) dan Root Mean Square Error (RMSE) yang paling kecil (Livieris et al., 2020). Penelitian lain juga mengonfirmasi bahwa model CNN-LSTM 18,1% lebih unggul dalam memprediksi volatilitas harga emas dibandingkan model LSTM saja (Vidal & Kristjanpoller, 2019). Keunggulan model hibrida juga terlihat pada penelitian yang menggabungkan LSTM-CNN dengan Attention Mechanism, yang menghasilkan MAE jauh lebih rendah ($MAE=21,71$) dibandingkan dengan model LSTM standar ($MAE=60,40$) atau LSTM-CNN ($MAE=42,50$) (He et al., 2019).

Metode LSTM secara konsisten menunjukkan kinerja yang superior dalam berbagai aplikasi peramalan. Dalam prediksi penularan COVID-19, LSTM (MAPE 2,32%) terbukti lebih akurat daripada XGBoost (MAPE 7,21%) (Luo et al., 2021). Dalam peramalan harga emas, model LSTM ($MAE=48,85$) juga mengungguli model lain seperti Bi-LSTM ($MAE=61,53$) dan GRU ($MAE=71,24$) (Yurtsever,

2021). Selain itu, pada prediksi performa sumur minyak, LSTM (MAE=1.60) juga lebih baik daripada model RNN konvensional (Song et al., 2020).

Metode berbasis pohon keputusan seperti XGBoost dan ensemble learning juga menunjukkan hasil yang kuat. Sebuah studi yang menggunakan XGBoost untuk peramalan harga emas dari tahun 1986 hingga 2019 menemukan bahwa model ini memiliki RMSE terendah (34.92) dibandingkan lima model lainnya (Jabeur et al., 2024). Sementara itu, penelitian lain yang menerapkan teknik ensemble seperti Random Forest dan gradient-boosted trees juga membuktikan bahwa teknik ini lebih unggul (MAE 2804,44) dibandingkan regresi linear (MAE 4384,43) dalam memprediksi harga emas (Manjula & Karthikeyan, 2019). Penelitian lain mengeksplorasi berbagai arsitektur jaringan saraf dan algoritma optimisasi. Misalnya, model Deep Belief Network (DBN) menunjukkan performa yang sangat baik untuk peramalan harga emas dengan nilai MAE serendah 0.04 (Zhang & Ci, 2020). Selain itu, penggunaan Whale Optimization Algorithm (WOA) untuk mengoptimalkan jaringan saraf tiruan (WOA-NN) juga terbukti lebih efektif (MAE=0.021) untuk memprediksi fluktuasi harga emas dibandingkan dengan model jaringan saraf lainnya (Alameer et al., 2019).

2.2. Tinjauan Teoritis

Tinjauan Teoritis adalah subbab dari bab 2. Subbab ini adalah landasan dari teori-teori yang digunakan peneliti untuk memperkuat penyelesaian masalah dalam penelitian. Teori-teori ini secara detail akan dijelaskan sebagai berikut.

2.2.1 Prediksi Harga Emas

Harga emas merupakan salah satu topik atau objek penelitian yang relevan karena harganya yang dapat dikatakan cenderung naik dalam jangka panjang. Penelitian mengenai harga emas cukup beragam, baik dari analisa faktor yang mempengaruhi harga emas (Qian et al., 2019), dinamika harga emas dalam perannya di tengah ketidakpastian (Beckmann et al., 2019), maupun penelitian mengenai prediksi harga emas dengan berbagai metode *Machine Learning* seperti *XGBoost* (Jabeur et al., 2024), jaringan syaraf tiruan (Alameer et al., 2019), hingga

pemodelan hibrida atau gabungan dua metode seperti *CNN-LSTM* (Livieris et al., 2020; Vidal & Kristjanpoller, 2020) maupun *LSTM-CNN* (He et al., 2019).

Harga emas sendiri terbilang kompleks karena emas sendiri memiliki hubungan dengan variabel finansial maupun makroekonomi (Qian et al., 2019). Berdasarkan studi dari Qian et al., (2019) mengenai analisa yang mempengaruhi harga emas, penelitian ini menunjukkan dalam kurun waktu Januari 2020 hingga Desember 2018 bahwa *CPI* atau tingkat inflasi konsumen berkorelasi positif dengan harga emas, sedangkan indeks Dolar AS, suku bunga, nilai tukar, harga minyak, dan *S&P 500* memiliki korelasi negatif dengan harga emas.

Penelitian lainnya yang dilakukan oleh Alameer et al., (2019) mengenai peramalan harga emas dengan model jaringan syaraf tiruan, menguji variabel-variabel seperti harga komoditas, nilai tukar, dan inflasi dari harga dolar AS maupun inflasi mata uang RMB terhadap harga emas, dalam kurun waktu September 1987 hingga Agustus 2017. Hasil dari pengujian dengan uji korelasi bahwa harga komoditas khususnya harga perak, merupakan nilai korelasi yang tinggi sebesar 0,956 terhadap harga emas. Ini menandakan bahwa harga perak naik memiliki kecenderungan yang tinggi bahwa harga emas akan naik. Variabel lainnya seperti nilai tukar mata uang cina memiliki korelasi negatif terhadap harga emas sebesar -0,23. Meskipun demikian, nilai tukar mata uang india dan nilai tukar mata uang afrika selatan memiliki korelasi positif terhadap harga emas sebesar 0,619 dan 0,605. Variabel lainnya yaitu tingkat inflasi mata uang memiliki korelasi negatif terhadap harga emas. Ini menandakan bahwa harga emas memiliki kecenderungan naik jika tingkat inflasi mengecil, meskipun nilai korelasinya tidak begitu kuat.

2.2.2 Machine Learning (*ML*)

ML merupakan sebuah terminologi bahwa sebuah mesin dapat mempelajari berbagai hal sehingga dapat melakukan berbagai tugas berdasarkan parameter yang telah ditentukan. *ML* ini dikembangkan untuk menghasilkan nilai aproksimasi berdasarkan pola-pola dalam data yang berguna dalam melaksanakan tugasnya. Pola-pola ini dapat membantu mesin untuk memahami proses, seperti berdasarkan pola-pola dapat meramal atau memprediksi maupun berasumsi dalam masa depan.

ML menggunakan teori dari statistika dalam pengembangan model matematika berdasarkan sampel-sampel lalu menjadi sebuah kesimpulan (Alpaydin, 2020).

ML memiliki berbagai tugas, salah satunya adalah regresi. Tugas regresi merupakan salah satu dari *Supervised Learning* atau pembelajaran yang diawasi, yang terdapat nilai *input* sebagai *X* dan *Y* sebagai *output*, serta dapat mempelajari pemetaan dari *X* ke *Y*. Menurut dari Alpaydin (2020), pendekatan ini mengoptimalkan parameter, dengan itu *error* atau selisih aproksimasi juga diperkecil, yang membuat estimasi *output* sedekat mungkin dengan *output* yang sesuai. (*Introduction to Machine Learning, Fourth Edition - Ethem Alpaydin - Google Books*, n.d.)

2.2.2.1 Deep Learning (DL)

Metode pembelajaran mesin dengan menggunakan jaringan saraf tiruan sudah digunakan dari tahun 1957. Meskipun demikian, jaringan saraf tiruan yang lebih mendalam baru digunakan sejak 2006. Karakteristik dari berbagai variasi model *DL* merupakan banyaknya lapisan dari neuron tersembunyi. Komponen dasar dari setiap jaringan saraf merupakan sebuah neuron di mana ide dasar dari pengembangan neuron adalah sebuah *input* x , bersama dengan bias b , diberikan sebuah bobot oleh w , lalu dijumlahkan bersama. Penjumlahan ini dinyatakan sebagai, $z = w^T x + b$ menjadi sebuah argumen untuk sebuah fungsi aktivasi, menghasilkan luaran untuk sebuah neuron. Terdapat berbagai fungsi aktivasi pada neuron, salah satunya merupakan *Rectified Linear Unit (ReLU)* yang merupakan fungsi aktivasi terpopuler untuk jaringan saraf mendalam. Fungsi aktivasi lainnya yaitu fungsi *softmax* yang mengubah vektor n -dimensi x menjadi vektor n -dimensi y , di mana seluruh komponen y adalah 1, yang berarti nilai-nilai dari y mewakili probabilitas dari masing-masing elemen (Emmert-Streib et al., 2020).

Untuk mengembangkan jaringan saraf, neuron-neuron diperlukan untuk saling terhubung hingga membentuk sebuah struktur jaringan saraf. Struktur paling sederhana merupakan *Feedforward Neural Networks*, yang sering disebutkan *Multilayer Perceptron (MLP)*, dapat menggunakan fungsi aktivasi yang non-linear. Perlu diperhatikan bahwa *MLP* tidak memiliki siklus yang memungkinkan adanya umpan balik. Itu sebabnya, diperlukan sebuah metode optimal untuk dapat fungsi


error atau fungsi *loss* dengan algoritma yang optimal untuk mencari parameter dengan mengurangi *error* selama pembelajaran (Emmert-Streib et al., 2020).

2.2.2.2 Long Short Term Memory (*LSTM*)

LSTM adalah suatu versi atau varian dari Recurrent Neural Network (*RNN*). Sherstinsky (2018) membuat literatur mengenai dasar atau fundamental dari *RNN* dan *LSTM*. Penjelasan dimulai dengan menguraikan formulasi *RNN* karonik berasal dari persamaan diferensial atau turunan dan teknik dengan istilah “Unfolding” atau “Unrolling” dalam *RNN*. Pembahasan dilanjutkan dengan membahas kesulitan dalam melatih *RNN* standar dan menangani kesulitan tersebut dengan mengubah *RNN* ini menjadi istilah “*Vanilla LSTM*”. *LSTM* sebagai varian atau versi yang dikembangkan dari *RNN*, dirancang untuk mengatasi masalah dependensi jangka panjang yang sering terjadi jika menggunakan *RNN* standar.

Literatur paper ini memberikan sebuah identifikasi peluang baru untuk memperkaya sistem *LSTM* dan dipadukan eksistensi peluang tersebut ke dalam jaringan *Vanilla LSTM*. Paduan ini menghasilkan varian *LSTM* yang paling umum hingga saat ini.

LSTM ini merupakan salah satu Jaringan Saraf Tiruan (*JST*) yang mampu untuk mempelajari ketergantungan jangka panjang dalam data. Ini membuat model *LSTM* cocok untuk penafsiran bahasa, pengenalan bahasa, dan prediksi berderet waktu. Prediksi berderet waktu ini cocok untuk prediksi harga yang memiliki data historis. Hal ini disebabkan oleh *LSTM* memiliki tiga buah gate yaitu *Forget Gate*, *Input Gate*, dan *Output Gate*.



Gambar 2. 1. Rangkaian Kerja *LSTM*

Forget Gate menghasilkan nilai baru untuk perhitungan nilai memori jangka panjang dari perkalian antar bobot dari setiap *input* dan nilai memori jangka pendek awal lalu ditambahkan bias. Hasil pertambahan ini akan menjadi nilai sumbu x pada fungsi aktivasi yaitu persamaan logistik yang memiliki range nilai (0,1). Hasil ini akan dikalikan dengan nilai memori jangka panjang awal dan disimpan untuk menghitung nilai memori jangka panjang yang baru.

Input Gate menghasilkan nilai baru untuk menghitung nilai memori jangka panjang yang baru. *Input Gate* dibagi menjadi dua proses yaitu proses di mana proses pertama itu menggunakan fungsi aktivasi persamaan logistik sehingga menghasilkan range nilai (0,1), sedangkan proses kedua menggunakan fungsi aktivasi persamaan hiperbolik tangen atau istilah persamaan $\tanh$ sehingga menghasilkan range nilai (-1,1). Masing-masing proses ini menggunakan memori jangka pendek dan nilai *input* yang telah dikalikan dengan bobot lalu hasilnya akan ditambahkan juga dengan bias pada setiap proses. Hasil dari setiap proses akan menjadi nilai sumbu x pada fungsi aktivasi proses masing-masing lalu range nilai pada kedua proses akan dikalikan. Hasil perkalian kedua range nilai ini akan ditambahkan pada hasil perhitungan pada *Forget Gate* dan hasil pertambahan ini akan menjadi nilai memori jangka panjang yang baru.

Output Gate menghasilkan nilai baru untuk menghitung nilai memori jangka pendek yang baru. *Output Gate* memiliki dua proses berbeda yaitu salah satu prosesnya adalah menghasilkan range nilai (0,1) dengan fungsi aktivasi persamaan logistik dan proses satunya lagi menghasilkan range nilai (-1,1) dengan fungsi

aktivasi persamaan tanh. Proses pertama adalah menghitung nilai memori jangka pendek awal dikalikan bobotnya, ditambah dengan nilai *input* yang dikalikan bobotnya, lalu pertambahan ini ditambahkan lagi dengan bias. Hasil perhitungan akan menjadi nilai sumbu x pada fungsi aktivasi persamaan logistik yang menghasilkan range nilai (0,1). Proses kedua yaitu nilai memori jangka panjang baru akan menjadi nilai sumbu x pada persamaan tanh yang memiliki range nilai (-1,1) lalu hasilnya akan dikalikan dengan nilai yang didapatkan pada proses menggunakan fungsi aktivasi persamaan logistik. Hasil perkalian ini akan menjadi nilai memori jangka pendek yang baru.

Kumbure et al. (2022) memberikan kesimpulan dari pengembangan tinjauan literatur teknik mesin belajar dan data untuk harga saham bahwa penelitian berbasis Deep Learning telah menerapkan *LSTM* untuk memprediksi pasar saham. Kesimpulan dari tinjauan literatur adalah *LSTM* ini lebih efektif dibandingkan Deep Learning lainnya dengan hasil perbandingan yaitu prediksi yang lebih kuat.

2.2.2.3 Mean Absolute Error (MAE)

Mean Absolute Error adalah salah satu metrik yang digunakan untuk mengukur performa model prediktif, terutama dalam konteks regresi. *MAE* mengukur rata-rata kesalahan absolut antara nilai yang diprediksi oleh model dan nilai aktual. Kesalahan absolut adalah selisih antara nilai yang diprediksi dan nilai sebenarnya tanpa memperhitungkan arah kesalahan (positif atau negatif).

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

Keterangan :

- n adalah jumlah observasi (data points).
- y_i adalah nilai aktual untuk observasi ke-i.
- y'_i adalah nilai prediksi untuk observasi ke-i.
- $|y_i - y'_i|$ adalah nilai absolut dari selisih antara nilai aktual dan nilai prediksi untuk observasi ke-i.

Penilaian *MAE* ini akan diinterpretasikan dengan penilaian yang lebih kecil menandakan bahwa model memiliki performa lebih baik karena kesalahan yang lebih kecil. *MAE* yang bernilai relatif lebih besar menandakan bahwa model memiliki performa kurang baik karena kesalahan yang lebih besar. Penelitian yang dilakukan oleh Manjula & Karthikeyan, (2019) juga menerapkan *MAE* dalam mengukur kesalahan hasil prediksi terhadap harga emas.

2.2.3.4 Mean Squared Error (*MSE*)

Mean Squared Error (*MSE*) adalah metrik yang sering digunakan untuk mengukur performa model prediktif, termasuk model Long Short-Term Memory (*LSTM*). *MSE* mengukur rata-rata dari kuadrat kesalahan antara nilai yang diprediksi oleh model dan nilai aktual.

Berbeda dengan (*MAE*) yang hanya menjumlahkan kesalahan prediksi dalam bentuk absolut, *MSE* memberikan penalti yang lebih besar terhadap kesalahan besar karena kesalahan tersebut dikuadratkan. Ini berarti bahwa *MSE* lebih sensitif terhadap outlier, yang dapat menyebabkan nilai *MSE* menjadi sangat tinggi jika model tidak dapat menggeneralisasi dengan baik terhadap data yang menyimpang.

Sebagai contoh dalam Studi dari Vidal & Kristjanpoller, (2020), *MSE* divalidasi sebagai pengukuran kesalahan yang paling sesuai untuk mengukur volatilitas harga emas. Ini mengindikasikan bahwa *MSE* efektif digunakan dalam situasi di mana perbedaan besar antara nilai yang diprediksi dan nilai aktual dianggap penting.

MSE dirumuskan secara matematis sebagai berikut:

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

Di mana:

A. *n* adalah jumlah observasi (data points).

- B. y_i adalah nilai aktual untuk observasi ke- i .
- C. y'_i adalah nilai prediksi untuk observasi ke- i .
- D. $(y_i - y'_i)^2$ adalah kuadrat dari selisih antara nilai aktual dan nilai prediksi untuk observasi ke- i .

Penilaian *MSE* ini akan diinterpretasikan dengan penilaian yang lebih kecil menandakan bahwa model memiliki performa lebih baik karena rata-rata kesalahan yang lebih kecil. *MSE* yang bernilai relatif lebih besar menandakan bahwa model memiliki performa kurang baik karena rata-rata kesalahan yang lebih besar. Penelitian yang dilakukan oleh Manjula & Karthikeyan, (2019) juga menerapkan *MSE* dalam mengukur kesalahan hasil prediksi terhadap harga emas.

2.2.3.5 Root Mean Squared Error (RMSE)

RMSE adalah salah satu metrik kesalahan untuk mengevaluasi kinerja model dalam memprediksi deretan waktu. Metrik *RMSE* sering digunakan untuk mengukur kinerja model dari metode prediktif, khususnya *LSTM*. *RMSE* merupakan nilai akar kuadrat dari *MSE*, sehingga *RMSE* dapat memberikan gambaran mengenai tingkat kesalahan dalam satuan yang sama dengan data yang diprediksi.

RMSE dirumuskan secara matematis sebagai berikut :

$$RMSE = \sqrt{MSE}$$

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

Di mana:

- A. n adalah jumlah observasi (data points).
- B. y_i adalah nilai aktual untuk observasi ke- i .
- C. y'_i adalah nilai prediksi untuk observasi ke- i .

D. $(y_i - y'_i)^2$ adalah kuadrat dari selisih antara nilai aktual dan nilai prediksi untuk observasi ke- i .

Sama seperti metrik evaluasi pengukuran kinerja lainnya yaitu *MAE* dan *MSE*, semakin rendah nilai *RMSE* maka semakin akurat model dalam memprediksi data yang mengartikan bahwa hasil prediksi semakin mendekati dengan nilai asli. Kebalikannya, semakin besar nilai *RMSE* maka semakin besar selisih atau *error* yang dihasilkan model untuk memprediksi harga. Sebagai contoh, penelitian yang dilakukan oleh Nguyen & Walther, (2020) menerapkan *RMSE* sebagai salah satu metrik pengujian dalam mengukur kesalahan hasil peramalan volatilitas komoditas terhadap nilai asli. Penelitian yang dilakukan oleh Manjula & Karthikeyan, (2019) juga menerapkan *RMSE* dalam mengukur kesalahan hasil prediksi terhadap harga emas.

2.2.3.6 Mean Absolute Percentage (*MAPE*)

MAPE adalah salah satu metrik kesalahan yang umum digunakan untuk mengevaluasi kinerja model prediktif, terutama dalam prediksi deret waktu. Metrik ini mengukur rata-rata persentase kesalahan antara nilai yang diprediksi oleh model dan nilai aktual, memberikan gambaran tentang seberapa besar kesalahan model dalam bentuk persentase. Salah satu kelebihan *MAPE* adalah hasilnya yang lebih mudah dipahami, karena kesalahan diungkapkan dalam persentase dari nilai aktual.

Secara matematis, *MAPE* dirumuskan sebagai berikut :

$$MAPE = \frac{1}{n} \sum_{i=1}^n |y_i - y'_i| \times 100$$

Di mana:

- A. n adalah jumlah observasi (data points).
- B. y_i adalah nilai aktual untuk observasi ke- i .
- C. y'_i adalah nilai prediksi untuk observasi ke- i .

D. $(y_i - y'_i)^2$ adalah kuadrat dari selisih antara nilai aktual dan nilai prediksi untuk observasi ke- i .

Sama seperti metrik evaluasi pengukuran kinerja lainnya yaitu *MAE* dan *MSE*, semakin rendah nilai *RMSE* maka semakin akurat model dalam memprediksi data yang mengartikan bahwa hasil prediksi semakin mendekati dengan nilai asli. Kebalikannya, semakin besar nilai *RMSE* maka semakin besar selisih atau *error* yang dihasilkan model untuk memprediksi harga.

MAPE mengukur kesalahan relatif antara nilai yang diprediksi dan nilai aktual. Semakin rendah nilai *MAPE*, semakin akurat model dalam memprediksi data, yang berarti bahwa hasil prediksi semakin mendekati nilai aktual. Sebaliknya, semakin besar nilai *MAPE*, semakin besar kesalahan relatif yang dihasilkan model dalam memprediksi data (Jeong, 2024).

Namun, *MAPE* memiliki beberapa kelemahan, terutama ketika nilai aktual y_i mendekati nol, karena dapat menghasilkan kesalahan yang sangat besar atau bahkan tidak terdefinisi. Oleh karena itu, meskipun *MAPE* mudah dipahami, penggunaannya perlu hati-hati dalam situasi tertentu.

Beberapa penelitian terkini menunjukkan bahwa *MAPE* tetap menjadi metrik yang populer dan efektif untuk mengukur kinerja model prediktif dalam memprediksi deretan waktu (He et al., 2019; Luo et al., 2021; Makalesi & Yurtsever, 2021; Zhang & Ci, 2020).

2.2.3.7 Jaringan Syaraf Tiruan (JST)

Jaringan Syaraf Tiruan (JST) atau *Artificial Neural Network (ANN)* merupakan sistem komputasi yang terinspirasi cara kerja otak manusia. Secara umum, *ANN* tersusun atas lapisan input, satu atau beberapa lapisan tersembunyi, dan lapisan output. Setiap neuron melakukan kombinasi linear terhadap input yang dibobot dan diberi bias, lalu menerapkan fungsi aktivasi seperti *ReLU*, *Sigmoid*, atau *Tanh* untuk menghasilkan sinyal keluaran (Kurniasari et al., 2023).

Latihan model *ANN* umumnya menggunakan algoritma backpropagation. Prosesnya melibatkan perhitungan kesalahan (*loss*), kemudian menggunakan

derivatif kesalahan tersebut untuk memperbarui bobot secara bertahap melalui metode seperti *gradient descent*. Untuk pemodelan data berurutan (seperti *time-series*), varian *ANN* seperti *RNN* dan *LSTM* digunakan. *RNN* memiliki *hidden state* yang mempertahankan informasi dari langkah sebelumnya, memungkinkan penangkapan ketergantungan temporal. Namun, *RNN* pada dasarnya rentan terhadap permasalahan *vanishing* atau *exploding gradient* ketika menangani urutan panjang. *LSTM* dan *GRU* mengatasi hal tersebut dengan mekanisme gerbang (*gating*) untuk mengatur aliran informasi (Kim et al., 2025).

Model *ANN* dan variannya banyak digunakan dalam berbagai aplikasi, mulai dari peramalan cuaca, ekonomi, hingga konsumsi energi. *CNN* 1-D, meskipun pertama kali dikembangkan untuk data citra, juga sering diaplikasikan untuk mengekstraksi fitur dari data *time-series*.