



BAB II

TINJAUAN PUSTAKA

BAB II

TINJAUAN PUSTAKA

II.1 Penelitian Terkait

Penelitian terkait dalam pengembangan model prediksi harga emas melibatkan berbagai pendekatan yang telah dilakukan sebelumnya, baik dalam konteks prediksi harga emas secara umum, penerapan model Long Short-Term Memory (LSTM) dan Gradient Boosting, maupun pengembangan model hybrid untuk mengoptimalkan hasil prediksi. Beberapa studi sebelumnya menjadi rujukan penting untuk mendukung penelitian ini dalam mengkombinasikan keunggulan masing-masing metode guna meningkatkan akurasi prediksi harga emas batangan (ANTAM).

II.1.1 Penelitian Prediksi Harga Emas

Prediksi harga emas menjadi salah satu kajian penting di bidang ekonomi dan teknologi informasi, khususnya dalam mendukung pengambilan keputusan investasi yang lebih terukur. Berbagai pendekatan telah diusulkan dalam penelitian sebelumnya untuk memperoleh hasil prediksi yang lebih akurat.

Dalam penelitian (Hidayat et al., 2024) menerapkan metode Long Short-Term Memory (LSTM) untuk memprediksi harga emas dengan menambahkan beberapa skema optimasi, yaitu ADAM, NADAM, dan ADAMAX. Hasil penelitian tersebut menunjukkan bahwa penggunaan optimasi NADAM dengan proporsi data latih sebesar 80% dan data uji sebesar 20% memberikan hasil terbaik, ditunjukkan dengan nilai Root Mean Square Error (RMSE) sebesar 0,0199 pada data latih dan 0,0260 pada data uji.

Studi (Agusmawati et al., 2020) juga serupa dengan membandingkan performa model LSTM dan Gated Recurrent Unit (GRU) untuk prediksi harga emas. Meskipun LSTM menunjukkan tingkat kesalahan yang lebih rendah berdasarkan beberapa metrik evaluasi, hasil penelitian tersebut menyimpulkan bahwa model GRU mampu memberikan performa yang lebih baik secara keseluruhan dalam menangkap pola pergerakan harga emas.

Sementara itu, (Aulia et al., 2022) mengusulkan penggunaan algoritma Support Vector Regression (SVR) dan Linear Regression (LR) dalam memprediksi harga emas. Berdasarkan hasil pengujian, Linear Regression menunjukkan performa yang lebih baik dibandingkan SVR, dengan nilai Mean Squared Error (MSE) sebesar 4,04 untuk LR dan 7,52 untuk SVR. Hasil ini menunjukkan bahwa metode yang lebih sederhana pun dapat memberikan hasil yang kompetitif, meskipun masih terdapat keterbatasan dalam menangkap dinamika kompleks harga emas.

Penelitian lainnya dilakukan oleh (Handhayani et al., 2023) yang mengembangkan sistem prediksi harga emas di Indonesia menggunakan model GRU dengan mempertimbangkan variabel eksternal seperti harga saham PT. Aneka Tambang dan nilai tukar dolar. Penelitian ini berhasil menghasilkan model dengan tingkat akurasi yang cukup tinggi, yaitu R-Squared sebesar 0,97, yang menunjukkan bahwa integrasi berbagai faktor ekonomi dapat meningkatkan ketepatan hasil prediksi.

Berdasarkan hasil studi-studi tersebut, dapat disimpulkan bahwa upaya peningkatan akurasi prediksi harga emas masih terus berkembang dengan berbagai pendekatan model. Namun, sebagian besar penelitian sebelumnya masih berfokus pada penggunaan model tunggal. Oleh karena itu, penelitian ini mengusulkan pengembangan model kombinasi antara LSTM dan Gradient Boosting guna mengoptimalkan kemampuan model dalam memproses data deret waktu sekaligus meningkatkan akurasi prediksi. Pendekatan ini diharapkan dapat memberikan kontribusi nyata dalam menyediakan informasi prediktif yang lebih akurat dan bermanfaat bagi para investor dan pihak terkait lainnya.

II.1.2 Penelitian Model Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan salah satu pengembangan dari arsitektur Recurrent Neural Network (RNN) yang dirancang untuk mengatasi keterbatasan dalam mempelajari pola jangka panjang pada data deret waktu. Keunggulan utama LSTM terletak pada kemampuannya mempertahankan informasi yang relevan melalui mekanisme *memory cell* dan *gating system*,

sehingga model ini dinilai efektif dalam menangani data yang memiliki ketergantungan antar waktu.

Beberapa penelitian sebelumnya telah memanfaatkan LSTM dalam upaya memprediksi pergerakan harga emas. (Agusmawati¹ et al., 2020), dalam studinya yang membandingkan performa LSTM dan Gated Recurrent Unit (GRU), menunjukkan bahwa meskipun GRU memberikan hasil yang lebih stabil dan akurat, LSTM tetap mampu menghasilkan prediksi yang cukup baik dengan nilai Mean Absolute Error (MAE) sebesar 0,0389 dan Root Mean Squared Error (RMSE) sebesar 0,0475. Hasil ini mengindikasikan bahwa LSTM memiliki potensi yang baik dalam menangani prediksi harga emas, terutama pada data dengan karakteristik deret waktu yang kompleks.

Dalam penelitian (Hidayat et al., 2024) mengusulkan penerapan LSTM dengan penambahan teknik optimasi ADAM, NADAM, dan ADAMAX. Penelitian ini berhasil menunjukkan bahwa penggunaan optimasi NADAM menghasilkan performa terbaik dengan nilai RMSE sebesar 0,0199 pada data latih dan 0,0260 pada data uji. Temuan ini memperkuat bukti bahwa LSTM yang dioptimalkan dengan pemilihan algoritma dan parameter yang tepat dapat meningkatkan ketepatan prediksi.

Selain itu, studi oleh (Seabe et al., 2023) yang mengkaji prediksi harga cryptocurrency menggunakan LSTM, GRU, dan Bi-Directional LSTM, menemukan bahwa meskipun Bi-Directional LSTM memberikan performa tertinggi, LSTM tetap menunjukkan hasil yang kompetitif. Studi ini memberikan gambaran bahwa LSTM masih relevan diterapkan pada berbagai jenis data keuangan yang bersifat fluktuatif dan nonlinier.

Berdasarkan berbagai studi tersebut, dapat disimpulkan bahwa LSTM merupakan salah satu model yang layak untuk diterapkan dalam prediksi harga emas. Keberhasilan penerapan model ini sangat dipengaruhi oleh kualitas data, pemilihan parameter, dan metode optimasi yang digunakan. Oleh karena itu, penelitian ini memanfaatkan keunggulan LSTM yang dipadukan dengan metode Gradient Boosting guna memperoleh hasil prediksi yang lebih optimal dan akurat.

II.1.3 Penelitian Model Gradient Boosting

Gradient Boosting merupakan salah satu metode *ensemble learning* yang banyak dimanfaatkan untuk meningkatkan akurasi prediksi pada berbagai bidang, termasuk prediksi harga komoditas. Metode ini bekerja dengan membangun model secara bertahap, di mana setiap model baru ditujukan untuk memperbaiki kesalahan dari model sebelumnya. Pendekatan ini memungkinkan model untuk menangkap pola yang kompleks dan hubungan non-linier dalam data.

Dalam penelitian (Simamora et al., 2024) mengembangkan model kombinasi antara Random Forest dan Gradient Boosting untuk prediksi harga emas. Hasil studi menunjukkan bahwa meskipun Gradient Boosting secara mandiri menghasilkan nilai Mean Squared Error (MSE) sebesar 0,008353, performa model meningkat ketika dikombinasikan dengan Random Forest, dengan MSE sebesar 0,006826. Penelitian ini menegaskan bahwa Gradient Boosting mampu memberikan kontribusi signifikan dalam meningkatkan stabilitas dan akurasi model prediksi harga emas, serta mengurangi risiko *overfitting* yang kerap menjadi tantangan dalam pemodelan prediktif.

Di bidang lain, (Fitri, 2023) melakukan studi komparasi antara Linear Regression, Random Forest, dan Gradient Boosted Trees dalam prediksi harga rumah. Hasil penelitian menunjukkan bahwa Gradient Boosted Trees menghasilkan nilai RMSE sebesar 0,508, yang lebih baik dibandingkan Linear Regression (RMSE 0,515) namun masih sedikit di bawah Random Forest (RMSE 0,440). Studi ini memperlihatkan bahwa Gradient Boosting dapat menjadi alternatif yang baik dalam konteks prediksi harga, meskipun performanya perlu disesuaikan dengan karakteristik data yang digunakan.

Selain itu, (Putra Nasyuli Leriensyah et al., 2023) menerapkan Gradient Boosting untuk memprediksi harga kendaraan bekas. Penelitian ini menunjukkan bahwa algoritma Gradient Boosting mampu memberikan hasil prediksi yang cukup baik dan memiliki tingkat kesalahan yang relatif rendah dibandingkan dengan metode Linear Regression. Studi ini kembali menegaskan fleksibilitas dan efektivitas Gradient Boosting dalam berbagai skenario prediktif, termasuk di sektor otomotif.

Berdasarkan uraian tersebut, dapat disimpulkan bahwa Gradient Boosting memiliki keunggulan dalam membangun model yang kuat dan akurat, terutama dalam menghadapi data yang kompleks dan dinamis. Oleh karena itu, penelitian ini mengadopsi metode Gradient Boosting sebagai salah satu komponen dalam pengembangan model kombinasi bersama Long Short-Term Memory (LSTM), dengan tujuan untuk mengoptimalkan akurasi prediksi harga emas batangan (ANTAM).

II.1.4 Penelitian Model Ensemble Learning

Model ensemble learning merupakan pendekatan yang dirancang untuk mengatasi keterbatasan model tunggal dalam melakukan prediksi, khususnya pada data deret waktu yang kompleks dan mengandung unsur linear sekaligus non-linear. Penggunaan model kombinasi memungkinkan integrasi kekuatan dari dua atau lebih metode yang berbeda, sehingga diharapkan mampu meningkatkan ketepatan hasil prediksi.

Mengkaji penerapan model kombinasi ARIMA-SVR dalam peramalan harga emas di masa pandemi Covid-19 yang dilakukan oleh (Purnama, 2021). Kombinasi antara ARIMA sebagai model yang unggul dalam menangani pola linear dan SVR yang mampu mengakomodasi pola non-linear menunjukkan hasil yang lebih baik dibandingkan dengan model ARIMA tunggal. Hal ini dibuktikan dengan nilai Mean Absolute Percentage Error (MAPE) yang lebih rendah pada model kombinasi, baik pada data pelatihan maupun data pengujian, sehingga memperkuat keunggulan pendekatan ensemble learning dalam meningkatkan akurasi prediksi harga emas.

Oleh (Yeng & Siahaan, 2024) dalam penelitiannya mengembangkan sistem prediksi harga saham berbasis web menggunakan model kombinasi ARIMA-LSTM. Model ini memanfaatkan keunggulan ARIMA dalam mengolah komponen linear serta kemampuan LSTM dalam menangkap pola non-linear yang bersifat dinamis. Evaluasi yang dilakukan menunjukkan bahwa model ini mampu memberikan prediksi yang mendekati data aktual, dengan tingkat kesalahan yang rendah, sebagaimana ditunjukkan oleh nilai Mean Squared Error (MSE) dan MAPE yang

relatif baik. Temuan ini menegaskan efektivitas model ensemble learning dalam konteks prediksi data keuangan yang fluktuatif.

Mengusulkan pengembangan model ensemble learning dengan mengombinasikan algoritma Random Forest dan Gradient Boosting untuk meningkatkan akurasi prediksi harga emas. Penelitian ini menunjukkan bahwa model gabungan memberikan hasil yang lebih stabil dan akurat dibandingkan penggunaan algoritma tunggal, dengan penurunan nilai MSE yang signifikan. Hasil ini memberikan gambaran bahwa pendekatan kombinasi antar algoritma pembelajaran mesin dapat mengatasi permasalahan overfitting sekaligus meningkatkan ketahanan model dalam menghadapi data yang bervariasi dan dinamis (Simamora et al., 2024).

Berdasarkan hasil-hasil tersebut, pendekatan ensemble learning terbukti memberikan kontribusi yang signifikan dalam meningkatkan kualitas prediksi, terutama pada permasalahan yang melibatkan data deret waktu dengan karakteristik yang kompleks. Oleh karena itu, penelitian ini mengembangkan model kombinasi LSTM dan Gradient Boosting sebagai upaya untuk memperoleh prediksi harga emas batangan (ANTAM) yang lebih akurat dan dapat diandalkan sebagai dasar pengambilan keputusan bagi berbagai pihak yang berkepentingan.

II.1.5 Tabulasi Referensi Penelitian

Berdasarkan hasil – hasil penelitian yang digunakan sebagai referensi dalam penelitian ini. Berikut tabulasi dari penelitian - penelitian tersebut pada Tabel II.1

Tabel II. 1 Tabulasi Referensi Penelitian

Penulis (Tahun)	Judul Penelitian	Metode	Hasil Evaluasi	Keterangan
Aulia, Anisa (2022)	Prediksi Harga Emas Menggunakan Support Vector Regression (SVR) dan	SVR, Linear Regression	MSE SVR: 7.52, MSE LR: 4.04	MSE (Mean Squared Error) menunjukkan tingkat kesalahan prediksi. Nilai lebih kecil berarti

	Linear Regression (LR)			model lebih akurat. Dalam kasus ini, LR memiliki MSE lebih kecil dari SVR, yang berarti LR lebih akurat dalam prediksi.
Handhayani, Teny (2023)	Prediksi Harga Emas di Indonesia Menggunakan Gated Recurrent Unit (GRU)	GRU	R2: 0.97, MAE: 300.17, RMSE: 17.33	R ² mendekati 1 menunjukkan model sangat baik. MAE dan RMSE menunjukkan tingkat kesalahan; semakin kecil nilainya, semakin baik akurasi model.
Hidayat, Wahyutama Fitri (2024)	Prediksi Harga Komoditi Emas Menggunakan Long Short-Term Memory (LSTM) dengan Optimalisasi	LSTM + ADAM, NADAM, ADAMAX	RMSETrain:0.0199 RMSE Test: 0.0260	RMSE menunjukkan seberapa jauh hasil prediksi dari nilai aktual. Nilai rendah di Train dan Test menunjukkan model cukup stabil dan akurat.
Purnama, Drajat Indra (2021)	Peramalan Harga Emas Saat Pandemi Covid-19 Menggunakan	Hybrid ARIMA-SVR	MAPETrain: 0.355, MAPE Test: 4.001	MAPE menunjukkan kesalahan dalam bentuk persentase. Nilai 4.001% tergolong rendah, menunjukkan model

	Model Hybrid ARIMA-SVR			memiliki tingkat kesalahan yang kecil.
Simamora, Purwanto (2024)	Peningkatan dan Optimalisasi Prediksi Harga Emas dengan Combine Machine Learning Random Forest dan Gradient Boosting	Random Forest, Gradient Boosting	MSE RF: 0.0053, GB: 0.00835, Combined:0.00683	MSE menunjukkan kesalahan kuadrat rata-rata. Nilai kecil pada semua model menandakan akurasi baik. Model gabungan (Combined) memiliki keseimbangan terbaik.
Suwandi, Andri (2023)	Prediksi Harga Emas Menggunakan Metode LSTM dan GRU	LSTM, GRU	LSTM:0.0475 GRURMSE:0.0545	RMSE keduanya relatif kecil, menunjukkan performa prediksi yang baik. LSTM lebih akurat daripada GRU berdasarkan nilai RMSE yang lebih rendah.
Budiharto, Widodo (2021)	Data Science Approach to Stock Prices Forecasting in Indonesia during Covid-19 using LSTM	LSTM	Akurasi 94.57% untuk data 1 tahun	Akurasi tinggi (>90%) menunjukkan bahwa model sangat baik dalam mengenali pola historis harga saham selama periode pandemi.
Yeng, Handyca (2024)	Perancangan Sistem Prediksi Harga Saham	ARIMA-LSTM	MSE: 0.0078, MAE: 0.556, MAPE: 41.89%	MSE dan MAE tergolong rendah, namun MAPE 41.89%

	Berbasis Website Menggunakan Algoritma Hybrid (ARIMA-LSTM)			tergolong tinggi, menandakan ketidakakuratan model dalam konteks persentase kesalahan prediksi.
Rizkilloh, Moch Farryz (2022)	Prediksi Harga Cryptocurrency Menggunakan Algoritma Long Short Term Memory (LSTM)	LSTM + Nadam Optimizer	RMSE: 0.0630(DOGE Coin)	RMSE tergolong rendah, menandakan model memiliki kesalahan prediksi yang kecil. Penggunaan optimizer Nadam membantu konvergensi yang efisien dalam pelatihan model.
Andriyani, Mayrisa (2024)	Prediksi Harga Beras Premium Tahun 2024 Menggunakan Metode Gradient Boosted Trees Regression	Gradient Boosted Trees	R ² : 0.9047, RMSE: 0.0473	R ² mendekati 1 menunjukkan model sangat baik. RMSE rendah mengindikasikan tingkat kesalahan prediksi kecil. Model ini efisien untuk data regresi seperti harga beras.

II.2 Data Mining

Data mining merupakan proses mengekstraksi pengetahuan atau informasi bermakna dari sejumlah besar data yang tersimpan dalam basis data, data warehouse, atau sumber informasi lainnya. Dalam konteks prediksi harga emas, data mining berperan penting untuk mengidentifikasi pola tersembunyi dalam data historis dan merumuskan model prediktif yang akurat. Teknik ini melibatkan

beberapa tahap, termasuk pengumpulan data, praproses data, pemilihan fitur, pemodelan, evaluasi, dan interpretasi hasil.

Penerapan data mining dalam prediksi harga emas telah menunjukkan efektivitas yang signifikan dalam berbagai studi. (Wahyuningsih et al.,2023) menyebutkan bahwa teknik data mining digunakan untuk mengolah data historis harga emas dengan mempertimbangkan berbagai variabel seperti kurs dolar, inflasi, harga minyak dunia, dan indeks saham. Beberapa metode populer yang dikaji dalam studi tersebut antara lain Artificial Neural Network (ANN), Support Vector Machine (SVM), dan Naïve Bayes. ANN menjadi metode yang paling sering digunakan karena kemampuannya dalam menangkap pola kompleks pada data time series harga emas.

Studi lain yang dilakukan oleh (Tyas dan Fajriyah.,2022) menunjukkan bahwa dalam lima tahun terakhir, metode prediksi harga emas mengalami pergeseran ke arah penggunaan teknik deep learning seperti Long Short-Term Memory (LSTM) dan model hybrid seperti CNN-LSTM. Metode berbasis deep learning dinilai mampu mengakomodasi karakteristik non-linear dan kompleksitas data harga emas yang fluktuatif. Selain itu, pendekatan ensemble seperti Gradient Boosting Regression juga diadopsi untuk meningkatkan akurasi prediksi melalui proses agregasi dari beberapa model lemah.

Dalam Kutipan (Muharrom.,2023) juga menyoroti pentingnya pemanfaatan tools data mining seperti Orange dalam eksperimen prediksi harga emas. Dalam penelitiannya, metode Regresi Linier, K-Nearest Neighbor (K-NN), dan SVM dibandingkan dari segi akurasi prediksi menggunakan metrik RMSE dan MAE. Hasilnya menunjukkan bahwa Regresi Linier memberikan performa terbaik dalam konteks data yang digunakan, namun tetap direkomendasikan untuk mengeksplorasi pendekatan lain yang lebih kompleks pada dataset yang bersifat non-linear.

Dalam penelitian ini, teknik data mining menjadi landasan utama dalam membangun model prediksi harga emas yang optimal. Kombinasi model LSTM sebagai representasi dari pendekatan deep learning dan Gradient Boosting sebagai representasi dari pendekatan ensemble machine learning dipilih untuk menggali

kelebihan masing-masing metode. LSTM dipilih karena kemampuannya dalam mengelola data time-series yang memiliki ketergantungan jangka panjang, sedangkan Gradient Boosting dipilih karena kekuatannya dalam mengurangi bias dan meningkatkan akurasi prediksi melalui teknik boosting.

II.3 Harga Emas Batangan (ANTAM)

Emas batangan ANTAM merupakan produk logam mulia yang diproduksi oleh PT Aneka Tambang Tbk (ANTAM), salah satu Badan Usaha Milik Negara (BUMN) yang memiliki legalitas dan reputasi terpercaya di Indonesia. Emas ini dihasilkan melalui proses pertambangan dan pemurnian dengan kadar kemurnian tinggi, yaitu 99,99% atau 24 karat, serta dilengkapi dengan sertifikat resmi yang menjamin keaslian dan beratnya (Mutia Evi Kristhy et al., 2022). Emas batangan ANTAM tersedia dalam berbagai ukuran, mulai dari 0,5 gram hingga 100 gram, yang mudah diperdagangkan karena diterima secara luas di pasar domestik maupun internasional (Achmad & Kalbarini, n.d.).

Beberapa faktor yang mempengaruhi fluktuasi harga emas ANTAM (Mutia Evi Kristhy et al., 2022), antara lain:

1. Inflasi dan Daya Beli Mata Uang.

Harga emas cenderung naik saat inflasi meningkat karena emas dipandang sebagai aset lindung nilai terhadap penurunan daya beli mata uang.

2. Kondisi Ekonomi Global dan Domestik.

Ketidakpastian ekonomi, termasuk krisis keuangan atau pandemi seperti Covid-19, meningkatkan permintaan emas sebagai aset aman, yang berdampak pada kenaikan harga.

3. Nilai Tukar Rupiah terhadap Dolar AS.

Karena harga emas dunia ditransaksikan dalam dolar AS, pelemahan rupiah terhadap dolar turut menaikkan harga emas dalam rupiah.

4. Permintaan dan Penawaran di Pasar.

Kenaikan permintaan emas untuk investasi, industri, atau perhiasan, serta keterbatasan pasokan dari produsen, dapat mendorong naiknya harga.

5. Kebijakan Suku Bunga.

Suku bunga yang rendah mendorong investor untuk mengalihkan dana dari instrumen berbunga rendah ke emas yang tidak menghasilkan bunga, sehingga meningkatkan harga.

Pola pergerakan harga emas biasanya memperlihatkan:

1. Kenaikan saat krisis atau ketidakpastian ekonomi. Emas menjadi pilihan utama saat investor menghindari risiko pada instrumen lain.
2. Kestabilan dalam jangka Panjang. Emas memiliki karakteristik sebagai aset yang nilainya stabil dan cenderung meningkat seiring waktu, sehingga diminati untuk investasi jangka panjang.

Pola ini menunjukkan bahwa emas batangan ANTAM bukan hanya sekadar komoditas, tetapi juga instrumen investasi yang relatif aman dan likuid, cocok digunakan untuk melindungi nilai kekayaan dari risiko inflasi dan ketidakpastian ekonomi (Achmad & Kalbarini, n.d.).

II.4 Long Short-Term Memory (LSTM)

Long Short-Term Memory (LSTM) merupakan salah satu jenis arsitektur jaringan saraf tiruan yang dikembangkan dari Recurrent Neural Network (RNN) untuk mengatasi permasalahan dalam memproses data deret waktu yang memiliki ketergantungan jangka panjang. LSTM pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997 dengan tujuan utama mengatasi masalah *vanishing gradient* yang sering dialami oleh RNN konvensional saat mempelajari hubungan jangka panjang pada data sekuensial (Lindemann et al., 2021).

LSTM dirancang dengan kemampuan untuk menyimpan, memperbarui, dan menghapus informasi yang relevan melalui mekanisme *gating*, sehingga memungkinkan model untuk mempertahankan informasi penting dalam periode waktu yang panjang maupun pendek. Oleh karena itu, LSTM banyak digunakan dalam berbagai bidang seperti prediksi harga komoditas, analisis keuangan, pengolahan bahasa alami, dan pengenalan pola pada data sekuensial (Budiharto, 2021).

LSTM memiliki arsitektur khusus yang terdiri dari tiga gerbang utama, yaitu *input gate*, *forget gate*, dan *output gate*, yang berperan dalam mengatur aliran informasi dalam jaringan (Lindemann et al., 2021). Adapun penjelasan dari ketiga komponen tersebut adalah sebagai berikut :

- *Input Gate*: Berfungsi untuk menentukan informasi baru yang relevan dan perlu disimpan ke dalam *cell state*.
- *Forget Gate*: Mengatur informasi dari *cell state* sebelumnya yang perlu dilupakan atau dipertahankan.
- *Output Gate*: Mengontrol informasi yang akan dikeluarkan sebagai output pada setiap langkah waktu.

Secara matematis, mekanisme kerja LSTM dapat dijelaskan melalui persamaan berikut : (Moch Farryz Rizkilloh & Sri Widiyanesti, 2022)

$$it = \sigma(Wixt + Uiht - 1 + bi) \dots\dots\dots (II.1)$$

$$ft = \sigma(Wfxt + Ufht - 1 + bf) \dots\dots\dots (II.2)$$

$$ot = \sigma(Woxt + Uoht - 1 + bo) \dots\dots\dots (II.3)$$

$$ct = ft * ct - 1 + it * \tan h(Wcxt + Ucht - 1 + bc) \dots\dots\dots (II.4)$$

$$ht = ot * \tan h(ct) \dots\dots\dots (II.5)$$

di mana :

x_t : vektor input pada waktu ke-t,

h_{t-1} : output tersembunyi pada waktu sebelumnya,

c_t : *cell state* saat ini,

i_t, f_t, o_t : *input gate*, *forget gate*, dan *output gate*,

W, U, b : bobot dan bias jaringan,

σ : fungsi aktivasi sigmoid,

$\tanh$: fungsi aktivasi hiperbolik.

Mekanisme ini memungkinkan LSTM untuk mengendalikan aliran informasi secara adaptif, menjaga informasi yang relevan, dan mengabaikan informasi yang tidak diperlukan, sehingga mendukung pembelajaran ketergantungan jangka panjang dan pendek secara efektif.

Adapun kelebihan dari LSTM menurut (Lindemann et al., 2021), sebagai berikut:

1. Kemampuan Menangani Ketergantungan Jangka Panjang dan Pendek
LSTM dirancang untuk mengatasi permasalahan RNN dalam mempelajari ketergantungan jangka panjang, sehingga lebih andal dalam menangani data deret waktu yang kompleks dan dinamis.
2. Ketahanan terhadap *Vanishing Gradient* Arsitektur *gating* pada LSTM memungkinkan jaringan untuk menghindari hilangnya gradien saat proses pembelajaran, yang sering terjadi pada RNN konvensional saat memproses urutan data yang panjang.
3. Akurasi Prediksi yang Lebih Tinggi LSTM telah terbukti menghasilkan tingkat akurasi yang lebih baik dibandingkan metode lain seperti Moving Average, Support Vector Machine (SVM), dan ARIMA dalam berbagai studi terkait prediksi harga saham dan kripto.
4. Kemampuan Generalisasi yang Baik pada Berbagai Domain
LSTM dapat diterapkan pada berbagai bidang aplikasi, mulai dari prediksi harga komoditas hingga pengolahan bahasa alami dan pengenalan suara.

Adapun kelemahan dari LSTM menurut (Budiharto, 2021), sebagai berikut :

1. Kompleksitas Perhitungan yang Tinggi LSTM memerlukan sumber daya komputasi yang besar dan waktu pelatihan yang relatif lama dibandingkan model lain yang lebih sederhana, seperti ARIMA atau metode statistik konvensional.
2. Potensi *Overfitting* Apabila tidak diatur dengan baik, seperti penggunaan jumlah epoch yang berlebihan atau data yang terbatas, LSTM berisiko mengalami *overfitting* yang dapat menurunkan performa model saat dihadapkan pada data baru.
3. Kinerja Tidak Konsisten pada Data yang Terlalu Panjang atau Pendek
Beberapa studi menunjukkan bahwa LSTM memberikan hasil yang optimal pada data dengan panjang moderat. Penggunaan data historis yang terlalu panjang justru dapat menurunkan akurasi prediksi.

II.5 Gradient Boosting

Gradient Boosting merupakan salah satu metode pembelajaran mesin berbasis ensemble yang efektif untuk meningkatkan akurasi model prediksi. Menurut (Andriyani et al., 2024), Gradient Boosting bekerja dengan membangun model secara bertahap untuk meminimalkan kesalahan prediksi melalui pendekatan gradient descent. Setiap model baru dalam ensemble berfokus untuk mengoreksi kesalahan dari model sebelumnya, sehingga menghasilkan model akhir yang lebih kuat dan akurat dibandingkan model tunggal.

Gradient Boosting merupakan algoritma yang bekerja dengan membangun model secara berurutan, di mana setiap model baru dibentuk untuk mengoreksi kesalahan dari model sebelumnya. Proses ini dilakukan dengan cara menyesuaikan prediksi model terhadap *pseudo-residual* yang dihitung dari turunan fungsi kerugian. Pendekatan ini memanfaatkan metode *gradient descent* untuk meminimalkan fungsi kerugian secara bertahap hingga mencapai hasil prediksi yang optimal.

Secara matematis, proses Gradient Boosting dapat dijelaskan sebagai berikut. Misalkan y_i adalah nilai aktual, $F_m(x_i)$ adalah model pada iterasi ke- m , dan $L(y, F(x))$ adalah fungsi kerugian yang digunakan. Model diawali dengan prediksi awal:

$$F_0(x) = \operatorname{argmin}_\gamma = 1 \sum_{i=1}^n L(y_i, \gamma) \dots\dots\dots (II.6)$$

Kemudian, untuk setiap iterasi ke- m , dihitung *pseudo-residual*:

$$r_{im} = - \left[\frac{\partial L(y_i, F(x_i))}{\partial F(x_i)} \right]_{F(x)=F_{m-1}(x)} \dots\dots\dots (II.7)$$

Setelah residual dihitung, model baru $h_m(x)$ dilatih untuk memprediksi residual tersebut. Model diperbarui sebagai berikut:

$$F_m(x) = F_{m-1}(x) + v \cdot h_m(x) \dots\dots\dots (II.8)$$

Di mana v adalah *learning rate* yang mengontrol seberapa besar kontribusi setiap model baru dalam pembaruan. Proses ini diulang hingga jumlah iterasi M tercapai atau sampai peningkatan performa tidak lagi signifikan.

Dalam implementasi *Gradient Boosted Trees Regression*, model $h_m(x)$ yang digunakan adalah *decision tree* yang dilatih untuk meminimalkan kesalahan

prediksi residual. (Andriyani et al., 2024) juga merumuskan proses ini dalam konteks regresi dengan persamaan berikut:

$$f(x) = \sum_{i=1}^T F_i(x) \dots \dots \dots (II.13)$$

Di mana $f(x)$ adalah hasil akhir prediksi dan $F_i(x)$ adalah model pohon keputusan ke- i dalam ensemble.

Keunggulan utama Gradient Boosting terletak pada kemampuannya menangani data non-linear dan meningkatkan akurasi model melalui proses pembelajaran bertahap. Menurut (Andriyani et al., 2024), metode ini juga robust terhadap outlier dan cocok diterapkan pada data dengan pola yang tidak sederhana. Namun Gradient Boosting memerlukan proses tuning parameter yang kompleks dan memiliki risiko overfitting jika tidak diatur dengan tepat, terutama pada dataset yang kecil atau mengandung noise.

II.6 Optimalisasi Model Prediksi

Optimalisasi model prediksi merupakan proses sistematis yang bertujuan untuk meningkatkan performa suatu model dalam menghasilkan output prediktif yang lebih akurat dan efisien. Optimalisasi dapat mencakup peningkatan akurasi, efisiensi waktu komputasi, kestabilan terhadap fluktuasi data, serta generalisasi model terhadap data baru. Dalam konteks prediksi harga emas, optimalisasi sangat penting mengingat fluktuasi harga yang sensitif terhadap dinamika pasar global dan faktor-faktor ekonomi domestik. Menurut (Simamora et al., 2024), optimalisasi model prediksi tidak hanya meningkatkan akurasi prediksi, tetapi juga mengurangi risiko kesalahan prediksi yang dapat berimplikasi besar terhadap pengambilan keputusan oleh investor dan pemangku kepentingan di sektor keuangan.

Optimalisasi tidak hanya meningkatkan akurasi model, tetapi juga berperan penting dalam memperkuat stabilitas model terhadap variasi data, terutama data time series yang memiliki pola musiman atau volatilitas tinggi. Model yang dioptimalkan melalui teknik ensemble learning, seperti kombinasi Random Forest dan Gradient Boosting dalam penelitian (Simamora et al., 2024), menunjukkan performa yang lebih stabil dengan kecenderungan overfitting yang lebih rendah. Stabilitas ini sangat krusial dalam konteks prediksi harga emas, di mana kesalahan

prediksi bisa berdampak pada keputusan investasi, strategi perdagangan, dan kebijakan ekonomi. Optimalisasi memungkinkan model untuk menyesuaikan terhadap perubahan tren harga, meningkatkan generalisasi terhadap data yang belum terlihat, serta memperkuat kemampuan prediktif dalam jangka pendek maupun jangka panjang. Oleh karena itu, strategi optimalisasi menjadi fondasi penting dalam pengembangan sistem prediksi harga emas yang andal dan aplikatif.