

Peramalan Harga Emas 2015-2019 Menggunakan LSTM Berbasis Harga Penutupan Harian

Erwin Setiawan¹, Resty Wulaningrum²

¹⁻³Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: *¹erwinsetyawan37@gmail.com, ²restyw@unpkdr.ac.id,

Abstrak – Sebagai aset safe haven, emas memegang peran krusial dalam strategi investasi dan manajemen risiko, sehingga akurasi peramalan harganya menjadi sangat penting. Penelitian ini menerapkan algoritma Long Short-Term Memory (LSTM) untuk memproyeksikan harga emas harian menggunakan data historis penutupan (closing price) periode 2015 hingga 2019. Melalui pendekatan univariat, data diproses dengan teknik normalisasi dan windowing sebelum tahap pelatihan model. Berdasarkan evaluasi kinerja, model menunjukkan akurasi tinggi dalam mengestimasi nominal harga, tercermin dari nilai Mean Squared Error (MSE) sebesar 0,00108 dan Mean Absolute Percentage Error (MAPE) 3,54%. Namun, terdapat kesenjangan menarik pada prediksi arah tren, di mana Directional Statistic (DS) hanya mencapai 46,33%. Hal ini mengindikasikan bahwa meskipun LSTM univariat sangat andal memprediksi besaran angka, model ini masih kesulitan menangkap momentum naik-turunnya pasar secara presisi. Oleh karena itu, penelitian selanjutnya disarankan mengintegrasikan variabel eksternal agar model lebih sensitif terhadap dinamika arah pergerakan harga.

Kata Kunci — Directional Statistic, Forecasting, Harga Emas, LSTM

1. PENDAHULUAN


Emas merupakan instrumen investasi yang banyak dipilih masyarakat karena sifatnya yang stabil, tahan terhadap inflasi, serta berperan sebagai safe haven di tengah ketidakpastian ekonomi global [1]. Pergerakan harga emas dipengaruhi berbagai faktor seperti nilai tukar, suku bunga, inflasi, kondisi geopolitik, dan dinamika pasar internasional. Dalam lima tahun terakhir, harga emas mengalami volatilitas yang cukup tinggi, terutama akibat pandemi, kebijakan moneter, serta ketegangan geopolitik. *World Gold Council* (2023) melaporkan bahwa harga emas meningkat lebih dari 50% pada periode 2019–2023, menunjukkan sensitivitas pasar terhadap kondisi global. Fluktuasi ini menegaskan pentingnya prediksi harga emas sebagai dasar pengambilan keputusan investasi yang lebih terukur, terutama menggunakan model komputasi yang mampu menangkap dinamika pasar yang kompleks ini menegaskan pentingnya prediksi harga emas sebagai dasar pengambilan keputusan investasi yang lebih terukur[2].

Emas Metode prediksi tradisional seperti regresi linier dan ARIMA kurang mampu menangkap pola non-linear dan dinamika kompleks pada data deret waktu keuangan [3]. Karena itu, deep learning, khususnya Long Short-Term Memory (LSTM), menjadi pendekatan yang semakin banyak digunakan dalam prediksi harga komoditas. LSTM memiliki kemampuan dalam mempelajari ketergantungan jangka panjang dan mengatasi masalah vanishing gradient, sehingga lebih unggul dibandingkan model time series konvensional [4]. Berbagai penelitian telah menunjukkan bahwa LSTM mampu memberikan performa prediksi yang lebih akurat dan stabil, termasuk dalam analisis harga emas dan komoditas lain [5][6]

Penelitian ini menggunakan data harga penutupan harian (closing price) emas internasional dari yahoo finance, yang sering dijadikan rujukan dalam studi keuangan global karena kelengkapan dan konsistensinya[7]. Data historis periode 2015–2019 digunakan untuk membangun model prediksi harga emas jangka pendek berbasis LSTM. Selain menggunakan metrik kesalahan seperti MSE dan MAPE, untuk menilai apakah estimasi arah tersebut dapat dipakai dalam pengambilan keputusan trading, digunakan Dstat (*Directional Statistic*) sebuah metrik prosentase yang mengukur persentase prediksi arah yang sesuai dengan arah aktual pada periode berikutnya [8]. Dengan pendekatan tersebut, model diharapkan mampu memberikan prediksi yang akurat dan bermanfaat sebagai dasar strategi investasi emas.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode time series forecasting untuk memprediksi harga emas harian berdasarkan data harga penutupan (closing price). Model utama yang digunakan adalah *Long Short-Term Memory* (LSTM) karena kemampuannya menangkap pola data berurutan dan relasi temporal yang tidak dapat ditangani secara optimal oleh metode statistik tradisional [7]. Berikut adalah tahapan yang dilakukan dalam penelitian ini :



Gambar 1. Tahapan Penelitian

2.1 Data dan Sumber Data

Data penelitian berupa harga penutupan emas internasional (XAU/USD) periode 1 Januari 2015 – 31 Desember 2019. Data diunduh melalui Yahoo Finance dalam format .csv, yang mencakup atribut: *Date*, *Open*, *High*, *Low*, *Close*. Dalam penelitian ini hanya digunakan variabel *Close* sebagai input utama model karena pendekatan yang digunakan bersifat univariat, dan variabel tersebut dianggap paling merepresentasikan harga emas pada penutupan pasar[9].


2.2 Tahap Preprocessing

Tahap pra-pemrosesan dilakukan untuk memastikan data harga penutupan emas siap digunakan dalam model LSTM. Proses dimulai dengan pembersihan data, yaitu memeriksa adanya nilai hilang, duplikasi, atau ketidakselarasan format tanggal. Seluruh data yang tidak lengkap dihapus, dan kolom tanggal diubah ke format *datetime* agar dapat diperlakukan sebagai deret waktu yang berurutan[10]. Setelah data bersih, dilakukan normalisasi menggunakan skema Min–Max agar seluruh nilai harga berada dalam rentang 0 hingga 1. Normalisasi ini penting untuk menjaga stabilitas model saat proses pelatihan, karena LSTM sensitif terhadap skala nilai input[11][12]. Selain itu, normalisasi membantu mempercepat konvergensi dan mencegah nilai besar mendominasi pola pembelajaran.

Tahap selanjutnya adalah pembentukan data sekuens (*windowing*). Pada tahap ini, data historis diubah menjadi potongan-potongan berurutan berdasarkan panjang jendela waktu tertentu. Serangkaian harga pada beberapa hari sebelumnya digunakan sebagai pola masukan untuk memprediksi harga pada hari berikutnya. Setelah struktur sekuens terbentuk, dataset kemudian dibagi menjadi data pelatihan dan data pengujian. Pembagian dilakukan berdasarkan urutan waktu, sehingga model tetap belajar dengan konteks kronologis yang benar.

2.3 Long Short-Term Memory

Model prediksi yang digunakan dalam penelitian ini dibangun menggunakan arsitektur *Long Short-Term Memory* (LSTM), LSTM mampu mempelajari pola panjang pada data sekuensial dan menjaga stabilitas gradien[13], sehingga lebih efektif dalam memproses deret waktu dibandingkan RNN konvensional. Meskipun secara konsep masih mengikuti struktur dasar RNN, perbedaan utama LSTM terletak pada komponen sel internalnya yang memungkinkan model mempertahankan atau melupakan informasi tertentu sesuai kebutuhan[14]. Pada tahap awal, model menerima masukan berupa sekuens harga penutupan hasil proses *windowing*. Setiap sekuens mewakili deret perubahan harga dalam beberapa hari sebelumnya yang akan digunakan sebagai dasar untuk memprediksi harga pada hari berikutnya.



Gambar 2. Arsitektur LSTM [15]

Pertama, forget gate menentukan informasi mana yang perlu dibuang dari memori karena dianggap tidak relevan bagi proses prediksi. Berikutnya, input gate memilih dan memasukkan informasi baru yang penting untuk diperbarui ke dalam cell state. Pada tahap cell state, memori lama akan diperbarui dengan menggabungkan informasi yang dipertahankan dan informasi baru yang telah dipilih sebelumnya. Terakhir, output gate mengatur informasi mana yang akan dikeluarkan sebagai hidden state untuk digunakan pada langkah prediksi berikutnya. Melalui mekanisme gerbang-gerbang ini, LSTM mampu mempertahankan informasi penting dan mengabaikan informasi yang kurang relevan sehingga lebih efektif dalam mempelajari pola jangka panjang pada data deret waktu [14].

2.4 Evaluasi *Dstat Metric*

Selain mengevaluasi kesalahan prediksi menggunakan MSE dan MAPE, penelitian ini juga memakai Directional Statistic (*Dstat*) untuk menilai kemampuan model dalam memprediksi arah pergerakan harga. Metrik ini sangat penting pada konteks trading, karena keputusan buy atau sell lebih bergantung pada arah pasar dibandingkan besaran harga. *Dstat* dihitung menggunakan rumus berikut :

$$Dstat = \frac{1}{N} \sum_{i=0}^N a_t x 100 \dots\dots\dots(1)$$

Persamaan 1 membandingkan apakah arah prediksi (naik/turun) sesuai dengan arah aktual. Jika prediksi dan aktual bergerak pada arah yang sama, maka dihitung sebagai benar (1); jika tidak, dihitung salah (0). Nilai akhir berupa persentase antara 0 hingga 100. Menurut [8], model dapat dianggap layak secara industri jika nilai $Dstat \geq 60\%$, karena menunjukkan prediksi arah yang lebih banyak benar daripada salah. Dengan demikian, metrik ini digunakan untuk melihat apakah model LSTM tidak hanya akurat secara nominal, tetapi juga bermanfaat dalam pengambilan keputusan arah pasar.

3. HASIL DAN PEMBAHASAN

Pada bagian ini dipaparkan seluruh temuan penelitian mulai dari hasil pengumpulan data, proses prapemrosesan, pelatihan model LSTM, hingga evaluasi performa prediksi harga emas. Seluruh tahapan dilakukan secara sistematis untuk memastikan bahwa data yang digunakan bersih, representatif, serta sesuai dengan karakteristik deret waktu. Analisis visual juga ditampilkan untuk menunjukkan pola tren harga emas serta performa model dalam memprediksi nilai maupun arah pergerakan harga. Hasil evaluasi akan dibandingkan dengan indikator kesalahan serta metrik *Directional Statistic* (DS) untuk menilai apakah model tidak hanya akurat dalam angka nominal, tetapi juga mampu menangkap arah tren pasar secara konsisten. Dengan pendekatan ini, bagian hasil dan pembahasan memberikan gambaran komprehensif mengenai kualitas model LSTM dalam memprediksi harga emas periode 2015–2019.

3.1. Pengumpulan Data


Data penelitian terdiri dari harga penutupan emas internasional (XAU/USD) periode 2015–2019 yang diperoleh melalui platform Yahoo Finance. Dataset berisi atribut *Date*, *Open*, *High*, *Low*, dan *Close*, namun hanya variabel *Close* yang digunakan karena model dirancang dengan pendekatan univariat. Data awal menunjukkan pola fluktuasi yang konsisten sepanjang periode observasi, dengan pergerakan harga yang relatif stabil namun tetap menunjukkan dinamika sesuai kondisi ekonomi global.

Tabel 1. *Processed Data*

Date	Price	Open	High	Low
2013-01-02	1689.9	1675.8	1695.0	1672.1
2013-01-03	1675.6	1688.0	1689.3	1664.3
2013-01-04	1649.9	1664.4	1664.4	1630.0
2013-01-07	1647.2	1657.3	1663.8	1645.3
2013-01-08	1663.2	1651.5	1662.6	1648.8


3.2. Preprocessing

Setelah pengumpulan, data melalui tahap pembersihan untuk memastikan tidak ada nilai kosong (*missing value*) maupun data duplikat. Seluruh baris data yang tidak lengkap dihapus, dan kolom *Date* dikonversi ke format *datetime* sehingga dapat diperlakukan sebagai deret waktu yang berurutan. Selanjutnya dilakukan normalisasi menggunakan metode *MinMaxScaler* sehingga seluruh nilai harga berada pada rentang 0–1. Tahap ini sangat penting karena LSTM sensitif terhadap skala data dan membutuhkan input yang terstandarisasi agar proses pembelajaran lebih stabil.



Gambar 3. Arsitektur LSTM

Data kemudian dibagi menjadi dua bagian: sekitar 80% sebagai data pelatihan dan 20% sebagai data pengujian. Gambar 2 memperlihatkan distribusi data, di mana harga pada masa pelatihan cenderung bergerak stabil dengan fluktuasi moderat, sedangkan data uji menunjukkan tren naik tajam pada tahun 2019. Kondisi ini menantang model karena pola tren berubah lebih cepat dibanding periode sebelumnya. Namun, LSTM masih mampu mengikuti pola pergerakannya meski sifat tren pada data uji lebih tajam.




Gambar 4. Pembagian Training Set dan Test Set

3.3. Pelatihan Model

Model LSTM dibangun menggunakan arsitektur berlapis yang terdiri dari satu lapisan LSTM utama dengan kemampuan mempelajari ketergantungan jangka panjang pada data runtut waktu. Selama proses pelatihan, model dioptimalkan menggunakan algoritma Adam dan fungsi kerugian MSE. Proses pelatihan dilakukan tanpa pengacakan urutan data agar urutan waktu tetap terjaga. Hasil pelatihan memperlihatkan penurunan nilai loss secara konsisten hingga mencapai titik stabil sebelum epoch terakhir, yang mengindikasikan bahwa model telah mampu menyesuaikan parameter internalnya dengan pola historis harga emas.

3.4. Evaluasi Model

Model LSTM yang dilatih dengan pendekatan univariat menunjukkan performa yang baik pada prediksi nominal harga. Hasil evaluasi pada data uji memberikan nilai MSE 0,001086 MAPE 3,54%, Akurasi 96.45%, *Directional Statistic* 46.33%. Nilai MAPE yang rendah menunjukkan bahwa error relatif terhadap harga asli sangat kecil sehingga prediksi nominal harga model cukup akurat. Hal ini sejalan dengan temuan penelitian sebelumnya yang menyatakan bahwa LSTM unggul dalam memprediksi nilai numerik pada data deret waktu finansial. Namun, nilai Dstat sebesar 46,33% menunjukkan bahwa model belum mampu menangkap arah (*up/down*) dengan baik. Menurut [8], model dapat dianggap layak untuk strategi berbasis arah jika nilai Dstat setidaknya berada pada kisaran 60%. Dengan demikian, meskipun nominal prediksi mendekati nilai aktual, informasi arah belum dapat diandalkan dalam konteks keputusan trading.



Gambar 5. Plot Harga Actual vs Prediksi

Gambar 3.2 memperlihatkan perbandingan antara harga aktual dan prediksi model pada data uji. Secara umum, garis prediksi mengikuti pola tren harga aktual, terutama pada fase kenaikan yang dominan di akhir 2019. Namun, terdapat deviasi pada beberapa titik reversals (pembalikan arah), yang menyebabkan skor Dstat cukup rendah.

4. SIMPULAN

Penelitian ini bertujuan melakukan peramalan harga emas menggunakan model *Long Short-Term Memory* (LSTM) dengan pendekatan univariat berbasis harga penutupan harian periode 2015–2019. Berdasarkan hasil pengujian, model menunjukkan performa yang sangat baik dalam memprediksi nilai nominal harga, dibuktikan dengan nilai MSE sebesar 0,001086, MAPE 3,54%, dan akurasi numerik mencapai 96,45%. Hasil ini menunjukkan bahwa LSTM mampu menangkap pola sekuensial jangka panjang pada data harga emas dan memberikan estimasi harga yang mendekati nilai aktual. Namun, kemampuan model dalam memprediksi arah pergerakan harga masih terbatas. Nilai Directional Statistic hanya mencapai 46,33%, yang mengindikasikan bahwa model kurang efektif dalam menangkap perubahan arah (*up/down*) harga emas. Kondisi ini terjadi karena pendekatan univariat hanya mengandalkan satu variabel sehingga tidak cukup sensitif terhadap faktor eksternal yang memengaruhi arah pasar.

5. SARAN

Penelitian selanjutnya disarankan untuk menambahkan variabel eksternal seperti suku bunga, indeks dolar (DXY), inflasi, dan harga minyak dunia agar model lebih sensitif terhadap perubahan arah pasar yang dipengaruhi faktor makroekonomi. Selain itu, penggunaan data dengan rentang waktu yang lebih panjang dan diperbarui hingga periode terbaru akan memberikan pola pergerakan yang lebih beragam sehingga model dapat beradaptasi dengan dinamika pasar yang terus berubah. Teknik filtering atau feature engineering, seperti moving average, log-return, maupun indikator teknikal seperti RSI, juga dapat diintegrasikan untuk membantu model mengenali sinyal pembalikan arah secara lebih efektif dan meningkatkan akurasi prediksi tren.

DAFTAR PUSTAKA

- [1] D. N. Ahsanah, “EMAS SEBAGAI INSTRUMEN INVESTASI JANGKA PANJANG,” *Jurnal Kajian Ekonomi Hukum Syariah*, vol. 8, no. 1, hlm. 177–187.
- [2] A. Amini dan R. Kalantari, “Gold price prediction by a CNN-Bi-LSTM model along with automatic parameter tuning,” *PLoS One*, vol. 19, no. 3 March, Mar 2024, doi: 10.1371/JOURNAL.PONE.0298426.
- [3] W. Gong, “Research on gold price forecasting based on lstm and linear regression,” *SHS Web of Conferences*, vol. 181, hlm. 02005, 2024, doi: 10.1051/shsconf/202418102005.
- [4] S. M. Al-Selwi, M. F. Hassan, S. J. Abdulkadir, dan A. Muneer, “RNN-LSTM: From application to modeling techniques and beyond—Systematic review,” 2024, doi: <https://doi.org/10.1016/j.jksuci.2024.102068>.
- [5] M. Aziiz Irwansyah, A. Triana, E. Darmayanti Simanullang, Y. Nur Alinda, dan A. Ibrahim, “PREDIKSI HARGA DAN VOLATILITAS EMAS DUNIA HARIAN: PERBANDINGAN MODEL GARCH DAN LONG SHORT-TERM MEMORY,” 2025.

- [6] T. G. Lasijan, R. Santoso, dan A. R. Hakim, “PREDIKSI HARGA EMAS DUNIA MENGGUNAKAN METODE LONG-SHORT TERM MEMORY,” *Jurnal Gaussian*, vol. 12, no. 2, hlm. 287–295, Jul 2023, doi: 10.14710/j.gauss.12.2.287-295.
- [7] W. M. P. Dhuhita, M. F. Farid, A. Yaqin, Haryoko, dan A. A. Huda, *2023 International Conference on Informatics, Multimedia, Cyber and Informations System*. IEEE, 2023.
- [8] W. Cahyo Utomo dan M. Aris Saputra, “Forecasting Pergerakan Harga Volatility Index dengan Menggunakan Metode Fuzzy Tsukamoto dan Evaluasi Dstat Metric,” 2023. doi: <https://doi.org/10.29407/gj.v7i1.19605>.
- [9] B. Gülmez, “Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm,” *Expert Syst Appl*, vol. 227, Okt 2023, doi: 10.1016/j.eswa.2023.120346.
- [10] J. Khatib Sulaiman, S. Handayani, D. Toresa, dan U. Lancang Kuning, “Convolutional Neural Network – Long Short Term Memory Untuk Prediksi Harga Emas Indonesia,” *The Indonesian Journal of Computer Science*, vol. 11, no. 3, Des 2022, doi: 10.33022/IJCS.V11I3.3074.
- [11] M. R. Nurhambali, Y. Angraini, dan A. Fitrianto, “Implementation of Long Short-Term Memory for Gold Prices Forecasting,” *Malaysian Journal of Mathematical Sciences*, vol. 18, no. 2, hlm. 399–422, 2024, doi: 10.47836/MJMS.18.2.11.
- [12] H. Yan, “Research on Gold Price Prediction Based on LSTM Modeling,” *Advances in Economics, Management and Political Sciences*, vol. 94, no. 1, hlm. 202–210, Okt 2024, doi: 10.54254/2754-1169/94/2024ox0166.
- [13] R. N. Adila dan R. N. Adila, “Peramalan Harga Emas Menggunakan Metode Long Short Term Memory (LSTM) dan ARIMAX,” 2024. Diakses: 16 Desember 2025. [Daring]. Tersedia pada: <https://etd.repository.ugm.ac.id/penelitian/detail/248006>
- [14] T. Hidayah, “Perbandingan Algoritma Long Short-Term Memory (LSTM) dan Gated Recurrent Unit (GRU) untuk Prediksi Harga Emas Dunia,” 2022. doi: <https://doi.org/10.37278/insearch.v21i2.600>.
- [15] Hozan K. Hamarashid, “Modified Long Short-Term memory and Utilizing in Building sequential model,” *International Journal of Multidisciplinary and Current Research*, vol. 9, no. 3, hlm. 207–211, Mei 2021, doi: 10.14741/IJMCR/V.9.3.2.