



Pemodelan Runtun Waktu Harga Nikel dengan Algoritma LSTM dan GRU

Muhamad Abdul Qodir Dani^{a*}, Chandy Anugra Pratama^a, Ibnu Raihan^a, Iqbal Kharisudin^a

^a Statistika dan Sains Data, FMIPA, Universitas Negeri Semarang, Gunungpati, Semarang, 50229, Indonesia

* Alamat Surel: mohamadkodir12@students.unnes.ac.id

Abstrak

Nikel merupakan komoditas penting yang digunakan dalam beberapa industri, seperti produksi baterai untuk kendaraan listrik. Fluktuasi harga nikel yang dipengaruhi oleh permintaan global dan dinamika pasar memerlukan prediksi harga yang akurat untuk mendukung pengambilan keputusan. Dalam penelitian ini, model LSTM dan GRU diterapkan sebagai model yang mampu menangani hubungan temporal kompleks dalam data *time series*. Data harga nikel yang digunakan berasal dari situs London Metal Exchange (LME). Teknik yang digunakan adalah membuat model LSTM dan GRU untuk melihat kualitas model yang bagus terhadap data yang digunakan. Data dibagi menjadi data latih dan data uji, dan kemudian dilakukan *scaling* menggunakan *MinMaxScaler* untuk meningkatkan kinerja model. Model LSTM dan GRU dibangun dengan beberapa *layer* dan parameter yang telah dioptimalkan. Kemudian dilakukan penyesuaian *hyperparameter* pada parameter model, termasuk jumlah unit LSTM atau GRU dan *dropout rate*. Model dievaluasi menggunakan ukuran akurasi dari fungsi *Mean Squared Error* (MSE) dimana nilai terkecil yang diberikan menunjukkan performa yang lebih baik. Hasil menunjukkan bahwa model LSTM dengan optimizer adam memberikan hasil yang hampir sama dengan model GRU dengan optimizer SGD. Nilai MSE dari model LSTM adalah 0.00056 sedangkan model GRU sebesar 0.00177. Meskipun LSTM sedikit unggul dibandingkan GRU, namun kedua model tersebut memberikan akurasi yang baik dalam memprediksi harga nikel.

Kata kunci: Runtun Waktu, Harga Nikel, LSTM, GRU

© 2025 Dipublikasikan oleh Jurusan Matematika, Universitas Negeri Semarang

1. Pendahuluan

1.1. Latar Belakang

Nikel adalah salah satu komoditas logam penting di dunia yang banyak digunakan dalam berbagai industri, terutama sebagai bahan utama produksi baterai untuk kendaraan listrik (Syarifuddin, 2022). Permintaan nikel terus meningkat seiring dengan berkembangnya teknologi dan kebutuhan akan energi ramah lingkungan, sehingga menciptakan fluktuasi harga yang cukup signifikan di pasar internasional. Harga nikel yang tidak stabil memengaruhi industri pertambangan dan manufaktur yang bergantung pada bahan ini, terutama di Indonesia yang merupakan salah satu produsen utama nikel di dunia (Sholeha & Riani, 2024).

Permintaan dan penawaran nikel di pasar internasional menyebabkan harga nikel mengalami perubahan yang cukup dinamis. Ketika permintaan meningkat, harga nikel akan cenderung naik, sedangkan jika suplai melebihi permintaan, harga akan cenderung menurun. Fluktuasi ini mendorong perlunya peramalan harga yang akurat agar industri terkait dapat mempersiapkan strategi keuangan dan bisnis yang tepat. Pemodelan runtun waktu menjadi metode yang banyak digunakan dalam meramalkan pergerakan harga komoditas seperti nikel (Suryani & Wahono, 2015).

Pada penelitian ini, data harga nikel yang bersumber dari LME akan dianalisis untuk memprediksi harga di masa mendatang. Model *Long Short Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU), yang merupakan bagian dari teknik *deep learning*, diterapkan dalam penelitian ini karena keduanya memiliki kemampuan dalam menangani data runtun waktu yang memiliki pola dan keterkaitan jangka panjang.

To cite this article:

Dani, M. A. Q., Pratama, C. A., Raihan, I., & Kharisudin, I. (2025). Pemodelan Runtun Waktu Harga Nikel dengan Algoritma LSTM dan GRU. *PRISMA, Prosiding Seminar Nasional Matematika* 8, 392-398

Melalui pemodelan dengan LSTM dan GRU, diharapkan dapat diperoleh hasil prediksi yang lebih akurat untuk mendukung pengambilan keputusan di industri.

1.2. Rumusan Masalah

Fluktuasi harga nikel yang dinamis di pasar internasional memerlukan adanya model prediksi yang dapat membantu industri dalam mengantisipasi perubahan harga. Oleh karena itu, dalam penelitian ini akan dikaji pemodelan prediksi harga nikel menggunakan model LSTM dan GRU untuk memahami keakuratan dan efektivitas model tersebut dalam memperkirakan pergerakan harga nikel.

1.3. Tujuan

Penelitian ini bertujuan untuk melakukan pemodelan dan prediksi harga nikel menggunakan algoritma LSTM dan GRU. Hasil dari penelitian ini diharapkan dapat memberikan wawasan terkait keandalan model LSTM dan GRU dalam meramalkan harga nikel, serta mendukung industri dalam menyusun strategi menghadapi dinamika pasar.

2. Metode

Metode yang akan digunakan dalam penelitian ini adalah metode analisis runtun waktu modern. Dalam penelitian ini terdapat beberapa paket yang digunakan dalam melakukan proses analisis yaitu numpy, pandas, matplotlib, sklearn, keras LSTM, dan keras GRU.

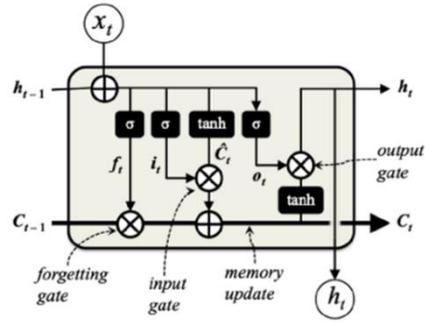
LSTM dan GRU adalah dua varian *Recurrent Neural Networks* (RNN) yang memungkinkan memori jangka panjang. RNN belajar dengan menyebarkan kembali gradien saat mencari nilai optimal (Laraswati, 2022). Namun, gradien dapat menghilang atau menyimpang jika t menjadi lebih panjang. Hal itu terjadi karena RNN biasa tidak cukup melatih memori jangka panjang yang bergantung pada data sekuensial. LSTM dan GRU diusulkan sebagai algoritma untuk mengatasi masalah tersebut. RNN hanya memiliki satu fungsi aktivasi di lapisan perantara, sedangkan LSTM dan GRU memiliki beberapa fungsi aktivasi dengan operasi lanjutan yang kompleks yang dilakukan pada berbagai gerbang (Baytas et al., 2017; Ingle & Deshmukh, 2021; Le et al., 2019).

2.1. Dataset

Dalam makalah ini, kita memperoleh kumpulan data dari situs London Metal Exchange (LME) khususnya, data perdagangan nikel, yang terdiri dari 15.000 entri deret waktu. Setiap entri mewakili harga penjualan harian perdagangan nikel sejak 20 November 2017 hingga 15 Oktober 2024. Oleh karena itu, kita mengumpulkan data dan membaginya menjadi dua bagian, data pelatihan (*train*) dan data uji (*test*). Pengambilan sampel acak digunakan dalam pemisahan itu untuk memastikan bahwa semua model dapat mewakili semaksimal mungkin dan bebas dari bias.

2.2. Long Short Term Memory

Jenis jaringan saraf LSTM dimaksudkan untuk mengatasi masalah gradien hilang yang sering terjadi pada RNN tradisional (Deleviar, Oktaviani, & Permatasari, 2025). Diperkenalkan oleh Hochreiter dan Schmidhuber pada tahun 1997, arsitektur LSTM memungkinkan penyimpanan informasi untuk jangka waktu yang lebih lama dibandingkan RNN konvensional. Arsitektur model LSTM memiliki enam komponen utama yaitu input layer, forget gate, input gate, unit state, output gate dan output layer (Nurashila, Hamami, & Kusumasari, 2023). Melalui mekanisme tersebut, LSTM dapat menyimpan informasi penting dan mengabaikan informasi yang tidak relevan (Zarzycki & Ławryńczuk, 2021), sehingga sangat efektif untuk aplikasi seperti prediksi harga nikel (Irwanto et al, 2024).



Gambar 1. Struktur Blok LSTM

LSTM memiliki variabel C_t untuk penyimpanan informasi jangka panjang dalam sel atau bloknya. Informasi lama dihapus atau informasi baru diperbarui ke C_t untuk mengaktifkan memori jangka panjang yang sesuai. Bagian aritmatika pada lapisan tengah LSTM disebut sebagai sel atau blok (Moghar & Hamiche, 2020). Struktur blok LSTM dan gerbang-gerbangnya ditunjukkan pada Gambar 1, *Input Gate*, Memori jangka panjang kandidat dalam keadaan sel saat ini \tilde{C}_t dan tingkat penyimpanan i_t dihitung menggunakan persamaan 1 dan 2.

$$\tilde{C}_t = \tanh(w_c x_t + u_c h_{(t-1)} + b_c). \quad (1)$$

$$i_t = \sigma(w_i x_t + u_i h_{(t-1)} + b_i). \quad (2)$$

Forgetting Gate, Gerbang ini mengontrol penghapusan informasi jangka panjang. Tingkat penyimpanan f_t dihitung menggunakan persamaan 3.

$$f_t = \sigma(w_f x_t + u_f h_{(t-1)} + b_f). \quad (3)$$

Output Gate, Nilai keluaran o_t dan h_t masing-masing dihitung menggunakan persamaan 4 dan 5.

$$o_t = \sigma(w_o x_t + u_o h_{(t-1)} + b_o). \quad (4)$$

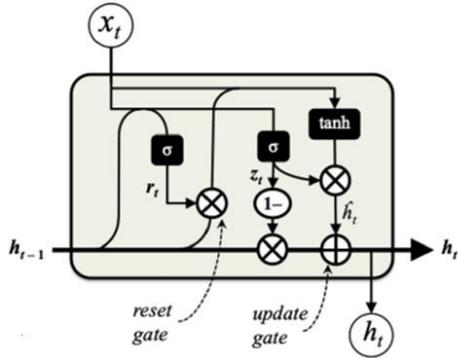
$$h_t = o_t \otimes \tanh(C_t) \quad (5)$$

Memory Update, Memori jangka panjang terbaru C_t diperbarui menggunakan persamaan 6.

$$C_t = (f_t \otimes C_{(t-1)} + i_t \otimes \tilde{C}_t) \quad (6)$$

2.3. Gated Recurrent Unit

GRU memiliki struktur yang lebih sederhana dibandingkan LSTM. Arsitektur model GRU memiliki lima komponen utama yaitu lapisan masukan, gerbang pembaruan, gerbang reset, keadaan tersembunyi, dan lapisan keluaran (Zarzycki & Ławryńczuk, 2021). GRU lebih efisien secara komputasi dan sederhana, menjadikannya pilihan menarik untuk aplikasi real-time seperti pemodelan harga nikel (Gao *et al.*, 2020).



Gambar 2. Struktur Balok GRU

Gambar 2 menunjukkan struktur blok GRU dan dua gerbangnya. Reset Gate, Tingkat memori r_t dihitung menggunakan persamaan 7 untuk mengontrol memori jangka panjang yang dilupakan atau dipertahankan.

$$r_t = \sigma(w_r x_t + u_r h_{(t-1)} + b_r), \tag{7}$$

Di mana x_t adalah data saat ini, dan h_{t-1} adalah memori sebelumnya. Kemudian Update Gate, Memori jangka panjang diperbarui menggunakan persamaan 8, 9 dan 10, kemudian diteruskan ke keadaan berikutnya.

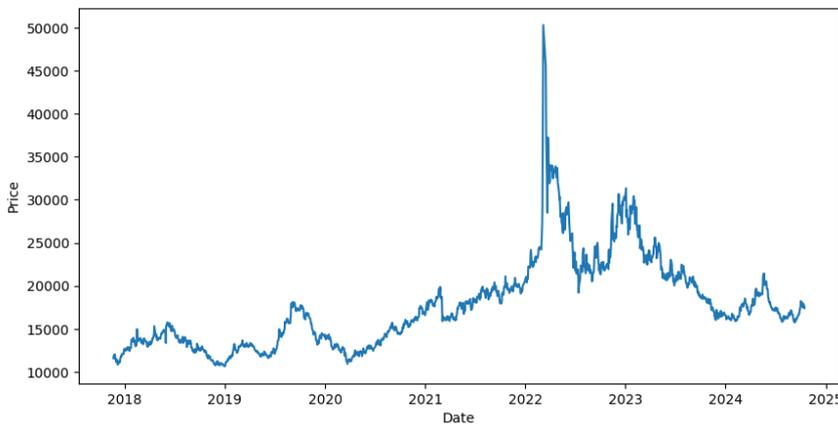
$$\tilde{h}_t = \tanh(w_h x_t + r_t \otimes (u_h h_{(t-1)}) + b_h), \tag{8}$$

$$z_t = \sigma(w_z x_t + u_z h_{(t-1)} + b_z), \tag{9}$$

$$h_t = z_t \otimes \tilde{h}_t + (1 - z_t) \otimes h_{(t-1)} \tag{10}$$

3. Hasil dan Pembahasan

3.1. Visualisasi Data



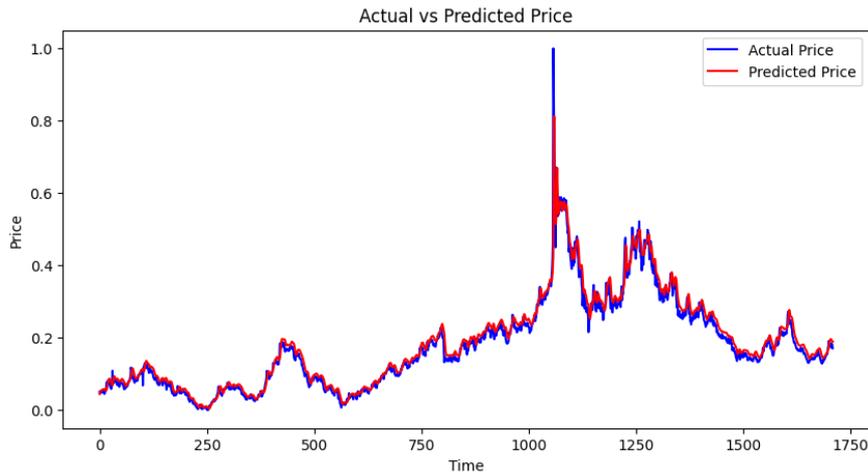
Gambar 3.1. Visualisasi data harga nikel LME *Select Nickel 3-Month* tahun 2017-2024

Dari Gambar 3.1 dapat dilihat bahwa data memiliki pola yang tidak menentu di setiap tahun. Terdapat beberapa data yang menunjukkan peningkatan tinggi di antara tahun 2022, hal itu wajar karena harga nikel sangat dipengaruhi oleh berbagai kondisi di dunia salah satunya adalah kondisi geopolitik. Meskipun terdapat peningkatan yang tinggi, grafik menunjukkan bahwa harga kembali turun dan fluktuasi harganya

kembali normal. Kelonjakan harga yang tidak normal bisa jadi mempengaruhi hasil akurasi model LSTM dan GRU.

3.2. Long-Short Term Memory (LSTM)

Pada algoritma LSTM dataset terbagi menjadi data *training* 80% dan data *testing* 20%. Model LSTM adalah suatu struktur yang terdiri dari beberapa layer, layer merupakan hal penting dalam LSTM untuk memantau jumlah nilai setiap layer agar dapat mengatasi masalah *underfitting* atau *overfitting*. Model LSTM dikonfigurasi dengan 5 layer LSTM, masing-masing dengan 50 unit, dan *dropout rate* sebesar 0,2. Optimizer yang digunakan adalah adam. Setelah melakukan *training* dengan epoch sebanyak 50 dan batch size sebesar 32 maka diperoleh hasil pemodelan runtun waktu harga nikel sebagai berikut.

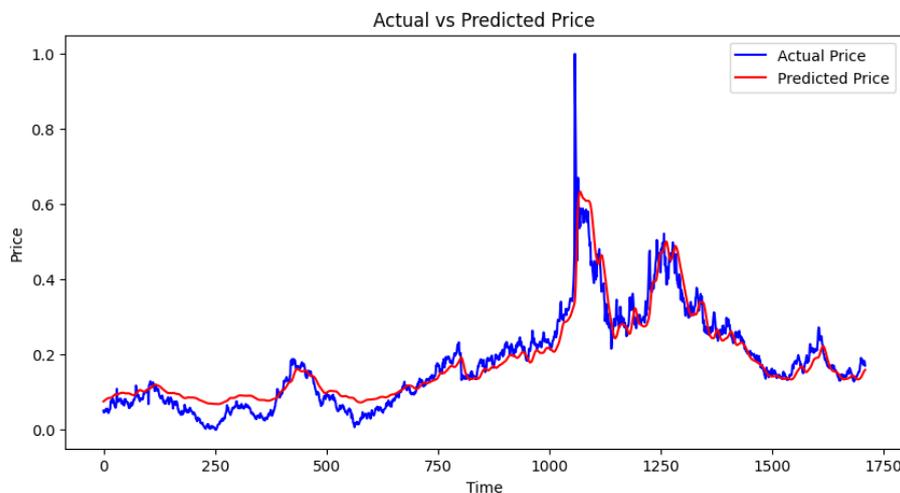


Gambar 3.2. Plot Tampilan data aktual dan data peramalan LSTM

Visualisasi hasil prediksi dan data aktual menunjukkan bahwa model LSTM mampu mengikuti tren pergerakan harga nikel dengan cukup baik, meskipun terdapat beberapa deviasi pada titik-titik tertentu. Garis merah yang merupakan hasil prediksi dilihat sangat baik dalam mengikuti data asli terutama pada lonjakan grafik yang tidak normal.

3.3. Gated Recurrent Unit (GRU)

Sama seperti sebelumnya, data untuk pemodelan GRU terbagi menjadi 80% data *training* dan 20% data *testing*. Model GRU memiliki arsitektur yang hampir sama seperti LSTM, yaitu 5 layer GRU dengan 50 unit dan *dropout rate* 0,2. Optimizer yang digunakan pada model GRU adalah SGD. Setelah dilakukan *training* dengan epoch dan batch size yang sama dengan model LSTM maka diperoleh hasil pemodelan runtun waktu harga nikel sebagai berikut.



Gambar 3.3. Plot tampilan data aktual dan data peramalan GRU

Visualisasi hasil prediksi dan data aktual menunjukkan bahwa model GRU kurang mampu dalam menangkap fluktuasi harga nikel secara akurat dibandingkan model LSTM. Hasil prediksi menggunakan model GRU juga menunjukkan bahwa model tersebut sederhana namun tetap memberikan hasil prediksi yang hampir mendekati data aslinya. Dalam kasus ini, data harga nikel tepat untuk pemodelan GRU dan LSTM.

Selanjutnya untuk dapat menyimpulkan hasil terbaik dari kedua pemodelan runtun waktu dengan LSTM dan GRU penelitian ini menggunakan MSE untuk melihat secara jelas hasil uji keakuratan model. Meskipun hasil plot prediksi kedua model terlihat bagus akan tetapi Skor MSE dapat memberikan hasil yang jelas mengenai keakuratan setiap model.

Tabel 1. Perbandingan nilai MSE

Evaluasi Model	LSTM	GRU
<i>Mean Squared Error</i>	0.0005600527743440718	0.0017740846508340804

Hasil MSE menunjukkan bahwa meskipun pada grafik data prediksi kedua model sedikit berbeda, namun kedua model tersebut memberikan akurasi yang terbilang bagus untuk data harga nikel. Hasil MSE model LSTM dan GRU hampir sama, namun LSTM menjadi pemenangnya dalam pemodelan tersebut.

4. Simpulan

Hasil penelitian menunjukkan bahwa meskipun kedua model memberikan hasil yang baik, tetapi model LSTM dengan optimizer adam menunjukkan performa yang lebih baik dibandingkan performa dengan model GRU dengan optimizer SGD dalam melakukan prediksi harga nikel. Model LSTM mampu menangkap tren dan pola pergerakan data harga nikel secara baik, meskipun terdapat beberapa deviasi pada titik-titik tertentu. Prediksi harga nikel adalah pekerjaan yang kompleks dan sangat dipengaruhi oleh banyak faktor eksternal. Model yang dikembangkan dalam penelitian ini hanya mempertimbangkan data historis harga nikel dan mungkin tidak sepenuhnya akurat dalam memprediksi pergerakan harga di masa depan. Pemodelan *deep learning*, khususnya LSTM, memiliki potensi yang baik untuk digunakan dalam prediksi harga nikel. Namun, perlu dilakukan penelitian lebih lanjut untuk meningkatkan akurasi serta keandalan suatu model.

Daftar Pustaka

- Baytas, I. M., Xiao, C., Zhang, X., Wang, F., Jain, A. K., & Zhou, J. (2017). Patient subtyping via time-aware LSTM networks. *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Halifax, Canada.
- Deleviar, A. F., Oktaviani, I., & Permatasari, H. (2025). Pengembangan Website Speech To Video Bahasa Isyarat Indonesia (Bisindo) Berbasis Algoritma Long Shot Term Memory. *Infotek: Jurnal Informatika Dan Teknologi*, 8(1), 23–33.
- Gao, S., Huang, Y., Zhang, S., Han, J., Wang, G., Zhang, M., & Lin, Q. (2020). Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation. *Journal of Hydrology*, 589, 125188.
- Ingle, V., & Deshmukh, S. (2021). Ensemble deep learning framework for stock market data prediction (EDLF-DP). *Global Transitions Proceedings*, 2(1), 47–66.
- Irwanto, F., Hafizh Sasongko, M. F., Febrian, S., Santoso Gunawan, A. A., & Setiawan, K. E. (2024). Analyzing Nickel Stock Price Prediction: A Comparative Study of Long Short-Term Memory and Convolutional Neural Network Models. in *2024 IEEE International Conference on Industry 4.0, Artificial Intelligence, and Communications Technology (IAICT)*. Bali.
- Laraswati Dea, B. 2022. Perbedaan LSTM Network dengan Recurrent Neural Network. (*Online*). (<https://blog.algorit.ma/lstm-network/>, diakses 18 Oktober 2024)

- Le, X. H., Ho, H. V., Lee, G., & Jung, S. (2019). Application of Long Short-Term Memory (LSTM) Neural Network for Flood Forecasting. *Water* 2019, 11(7), 1387.
- Metal.com. (n.d.). Nickel LME 3M. (Online). (https://www.metal.com/Nickel/LME_NI_3M, diakses 17 Oktober 2024)
- Moghar, A., & Hamiche, M. (2020). Stock Market Prediction Using LSTM Recurrent Neural Network. *Procedia Computer Science*, 170, 1168–1173.
- Nurashila, S. S., Hamami, F., & Kusumasari, T. F. (2023). Perbandingan Kinerja Algoritma Recurrent Neural Network (Rnn) Dan Long Short-Term Memory (Lstm): Studi Kasus Prediksi Kemacetan Lalu Lintas Jaringan Pt Xyz. *JUPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika)*, 8(3), 864-877.
- Sholeha, U., & Riani, L. P. (2024). Analisis Larangan Ekspor Biji Nikel Indonesia Terhadap Kondisi Ekonomi Nasional. In *Prosiding Pendidikan Ekonomi*. Madiun.
- Suryani, I., & Wahono, R. S. (2015). Penerapan exponential smoothing untuk transformasi data dalam meningkatkan akurasi neural network pada prediksi harga emas. *Journal of Intelligent Systems*, 1(2), 67-75.
- Syarifuddin, N. (2022). Pengaruh Industri Pertambangan Nikel Terhadap Kondisi Lingkungan Maritim di Kabupaten Morowali, *Jurnal Riset & Teknologi Terapan Kemaritiman*, 1(2), 19-23.
- Zarzycki, K., & Ławryńczuk, M. (2021). LSTM and GRU Neural Networks as Models of Dynamical Processes Used in Predictive Control: A Comparison of Models Developed for Two Chemical Reactors. *Sensors (Basel, Switzerland)*, 21(16), 5625.