

Artikel Penelitian

Peramalan Harga Nikel Berbasis *Machine Learning* menggunakan Algoritma *Gated Recurrent Unit* (GRU)

Nickel Price Forecasting Based on Machine Learning Using the Gated Recurrent Unit (GRU)

Robby Erlangga^{1*}, Aldin Ardian¹, Heru Suharyadi¹, Frans Richard Kodong², Tedy Agung Cahyadi¹

¹Jurusan Teknik Pertambangan, Fakultas Teknologi Mineral dan Energi, Universitas Pembangunan Nasional “Veteran” Yogyakarta

²Jurusan Informatika, Fakultas Teknologi Industri, Universitas Pembangunan Nasional “Veteran” Yogyakarta

*Penulis korespondensi

e-mail: 112210118@student.upnyk.ac.id

ABSTRAK

Nikel merupakan komoditas tambang yang penting dalam pembuatan baterai kendaraan listrik (*electric Vehicle (EV)*). Meningkatnya produksi EV dalam upaya mengurangi emisi karbon menyebabkan tingginya kebutuhan Nikel sebagai bahan baku baterai kendaraan listrik diprediksi akan meningkat. Seiring meningkatnya produksi EV untuk menekan emisi karbon, kebutuhan nikel sebagai bahan baku baterai diproyeksikan terus naik. Kenaikan ini secara teori mendorong tekanan naik pada harga, terutama ketika pertumbuhan permintaan lebih cepat daripada kemampuan pasokan untuk bertambah dalam jangka pendek. Karena itu, tren permintaan yang meningkat menjadi salah satu faktor utama yang membentuk tren harga nikel ke depan. Selanjutnya, harga Nikel memiliki dampak signifikan terhadap keputusan investasi tambang, perkembangan ekonomi perusahaan Nikel, serta negara yang bergantung pada sumber daya Nikel. Namun, terdapat ketidakpastian mengenai tren harga Nikel di masa depan, sehingga solusi untuk permasalahan ini menarik untuk dikaji lebih dalam. Penelitian ini bertujuan untuk mengetahui hasil peramalan harga nikel jangka pendek dengan menerapkan algoritma *Gated Recurrent Unit (GRU)* yang merupakan bagian dari kecerdasan buatan (*Artificial Intelligent*), mengetahui akurasi peramalan harga nikel menggunakan algoritma GRU, serta menyajikan data peramalan harga informatif kepada pengguna (*user*). Hasil penelitian menunjukkan GRU sangat efektif dalam melakukan peramalan harga Nikel berdasarkan evaluasi kerja model menggunakan *Mean Absolute Percentage Error (MAPE)* sebesar 1,21%.

Kata Kunci: *Gated Recurrent Unit (GRU)*, *Machine Learning*, *Peramalan Harga Nikel*

ABSTRACT

Nickel is a critical mineral commodity for the production of electric vehicle (EV) batteries. The rising output of EVs as part of global efforts to reduce carbon emissions is expected to intensify demand for nickel as a key battery input. In line with increasing EV production, nickel demand for battery manufacturing is projected to continue growing. In theory, such demand growth exerts upward pressure on prices, particularly when demand expands more rapidly than supply can adjust in the short run. Consequently, the upward demand trajectory constitutes a major determinant shaping future nickel price trends. Furthermore, nickel prices significantly influence mining investment decisions, the economic performance of nickel-producing firms, and the macroeconomic conditions of countries that depend on nickel resources. Nevertheless, substantial uncertainty persists regarding the future direction of nickel prices, making this issue both relevant and worthy of deeper investigation. This study aims to (i) generate short-term forecasts of nickel prices by applying the Gated Recurrent Unit (GRU) algorithm, a method within the field of artificial intelligence; (ii) assess the forecasting accuracy of the GRU-based model; and (iii) present informative forecast outputs for end users. The results indicate that the GRU model is highly effective in forecasting nickel prices, as evidenced by a Mean Absolute Percentage Error (MAPE) of 1.21%.

Keywords: *Gated Recurrent Unit (GRU)*, *Machine Learning*, *Nickel Price Forecasting*

I. PENDAHULUAN

Dalam beberapa dekade terakhir, dunia mengalami transisi energi menuju sumber yang lebih bersih dan berkelanjutan akibat perubahan iklim, di mana sektor transportasi menyumbang sekitar seperempat emisi CO₂ global (Chukwuemeka dkk., 2024). Akselerasi penggunaan kendaraan listrik (EV) berbasis baterai, yang diproyeksikan tumbuh 30% per tahun hingga 2030 (IEA, 2024), mengurangi ketergantungan pada bahan bakar fosil dan emisi gas rumah kaca (Mufida dkk., 2024). Nikel, sebagai komponen utama baterai EV, menjadi kunci transisi ini, didukung oleh keunggulan EV dalam biaya dan perawatan sejak 2025 (Baker dkk., 2019; Ozdemir dkk., 2022).

Di Indonesia, nikel merupakan komoditas utama yang mendukung perekonomian nasional, dengan cadangan terbesar dunia menurut United States Geological Survey (2023). Kebijakan larangan ekspor bijih mentah sejak 2020 dan pengembangan smelter telah meningkatkan pendapatan negara hingga 40% dalam tiga tahun terakhir (ESDM, 2021), menjadikan Indonesia pemain kunci dalam rantai pasok baterai EV global. Melalui hilirisasi, kebijakan ini mempercepat industrialisasi EV, mendukung tujuan berkelanjutan, dan meningkatkan kepercayaan investor, sehingga sektor nikel menjadi pilar ekonomi nasional (Ferreira & Pinto, 2022; Widiatedja, 2021)

Fluktuasi harga nikel berdampak luas pada ekonomi mikro, seperti pendapatan perusahaan tambang, operasional, PHK, dan UMKM sekitar pertambangan, serta makro, termasuk pajak, neraca perdagangan, inflasi, dan pertumbuhan nasional (Khoshalan dkk., 2021; Wang dkk., 2019). Volatilitas ini memengaruhi perencanaan bisnis dan manajemen risiko di industri pertambangan (Bhatia dkk., 2018; Gong & Lin, 2018), di mana pemahaman tren harga masa depan krusial untuk optimalisasi produksi (Abdel Sabour, 2002; Chatterjee & Dimitrakopoulos, 2020). Oleh karena itu, peramalan harga akurat esensial untuk mengurangi risiko investasi (Hatayama & Tahara, 2018), dengan *machine learning* seperti GRU yang mengatasi keterbatasan RNN seperti *vanishing gradient* (Cho dkk., 2014; Ribeiro dkk., 2020) dipilih untuk mengolah data time series secara efektif (Kong dkk., 2025; Wang dkk., 2019). Beberapa penelitian terdahulu mengenai GRU dapat dilihat pada tabel 1 sebagai berikut.

No	Penulis	Metode	Kesimpulan
1	Cho dkk., (2014)	GRU	Pengenalan metode GRU sebagai alternatif RNN yang mampu menangani <i>vanishing gradient</i> dan <i>exploding gradient</i>

2	El-Naggar dkk., (2022)	GRU	GRU memiliki kelemahan dalam mengingat informasi jangka panjang karena strukturnya yang sederhana. Hal ini membuat GRU kurang efektif untuk peramalan harga yang sangat panjang
3	Ozdemir dkk (2022)	LSTM & GRU	Melakukan komparasi LSTM & GRU untuk peramalan harga nikel menggunakan evaluasi metrik Mean Absolute Percentage Error (MAPE) dengan hasil evaluasi LSTM sebesar 7,06% dan GRU sebesar 6,98%.
4	Sudiatmika dkk., (2024)	GRU	Melakukan peramalan harga Emas dengan algoritma GRU. Peramalan harga dievaluasi dengan menggunakan metrik evaluasi Mean Absolute Error (MAE) dengan hasil evaluasi sebesar 0,012
5	Mienye dkk., (2024)	RNN	Algoritma RNN digunakan untuk melakukan peramalan deret waktu, pemrosesan bahasa, dan pengenalan suara
6	Lamprecht (2023)	Delphi method	Peramalan harga komoditas logam dapat dilakukan dengan menggunakan metode Delphi (kualitatif). Dilakukan dengan cara mengumpulkan parah ahli untuk memberikan opini dan justifikasi

Tabel 1 menyajikan ringkasan beberapa penelitian terdahulu yang menggunakan algoritma GRU dalam

peramalan data deret waktu. Tabel pertama menunjukkan penelitian yang dilakukan oleh Cho dkk., (2014) merupakan studi awal yang memperkenalkan GRU sebagai alternatif dari RNN. GRU dipandang lebih mampu mengatasi permasalahan *vanishing gradient* dan *exploding gradient*, yang umum terjadi dalam pelatihan jaringan RNN pada data deret waktu. Namun di sisi lain, El-Naggar dkk., (2022) menyoroti kelemahan algoritma GRU, yakni ketidakampuannya dalam mengingat informasi jangka panjang akibat arsitektur yang lebih sederhana dibandingkan LSTM. Hal ini menjadikan GRU kurang cocok untuk prediksi harga dengan cakupan waktu yang sangat panjang. Selanjutnya, penelitian yang dilakukan oleh Ozdemir dkk., (2022) secara khusus membandingkan performa algoritma GRU dengan LSTM dalam peramalan harga nikel menggunakan metrik evaluasi MAPE. Hasilnya menunjukkan bahwa GRU memiliki performa yang lebih baik (MAPE 6,98%) dibandingkan LSTM (MAPE 7,06%). Terakhir, Sudiatmika dkk., (2024) melakukan peramalan harga komoditas emas menggunakan algoritma GRU, dengan hasil evaluasi MAE sebesar 0,012. Penelitian ini menunjukkan bahwa GRU efektif untuk memprediksi harga dengan akurasi tinggi.

kontribusi kebaruan penelitian ini yaitu melalui penerapan GRU pada dataset, periode waktu, dan skenario analisis yang berbeda, serta melalui penyesuaian tahapan *pre-processing*, skema pelatihan, dan parameter model yang berbeda dengan penelitian sebelumnya, serta adanya komparasi antara data hasil pengolahan menggunakan GRU dengan data *real-time* pada situs London Metal Exchange. Selanjutnya, Penelitian ini dilakukan dengan tujuan untuk mengetahui peramalan harga Nikel jangka pendek dengan menggunakan GRU, mengetahui akurasi peramalan harga Nikel menggunakan algoritma GRU, dan menyajikan data peramalan harga informatif kepada pengguna (*user*).

II. METODE

Tahapan penelitian

Metode yang digunakan dalam penelitian ini adalah metode eksperimen komputasional dengan metodologi kuantitatif berbasis *machine learning* menggunakan algoritma GRU. Penelitian ini diawali dengan persiapan penelitian, yang meliputi identifikasi masalah penelitian serta studi literatur untuk memperoleh dasar teori dan penelitian terdahulu yang relevan. Selanjutnya dilakukan eksplorasi data, yaitu pengumpulan data yang dibutuhkan dan pemahaman karakteristik data agar sesuai dengan tujuan penelitian. Data yang telah dikumpulkan kemudian masuk ke tahap data *pre-processing*, yang mencakup proses *splitting data* serta normalisasi data untuk memastikan kualitas dan kesiapan data sebelum pemodelan. Tahap berikutnya adalah pembangunan model, di mana data yang telah diproses digunakan untuk melakukan

training dan pengujian model menggunakan algoritma GRU. Setelah model terbentuk, dilakukan analisis dan evaluasi kinerja model dengan menggunakan indikator MAPE untuk menilai tingkat akurasi peramalan. Tahap akhir adalah hasil penelitian, yang berisi penyajian data hasil peramalan secara deskriptif serta interpretasi hasil penelitian sebagai dasar penarikan kesimpulan.

Data Harga Nikel

Data harga nikel dikutip dari Situs resmi London Metal Exchange (LME) (<https://www.lme.com/>), yang merupakan bursa perdagangan komoditas logam dunia. Data yang diambil meliputi harga harian nikel dalam rentang waktu 17 Juli 2020 hingga 17 Juli 2025. Pemilihan rentang waktu tersebut didasarkan pada batas maksimal dan minimal periode pengunduhan data yang tersedia di situs LME, yaitu selama 5 tahun. Ilustrasi bentuk data yang diolah disajikan pada tabel 2 sebagai berikut.

Tanggal	Harga Nikel
17/07/2020	13220
20/07/2020	13236
21/07/2020	13466
...	...
14/07/2025	15064
15/07/2025	15146
16/07/2025	15026

Gated Recurrent Unit (GRU)

GRU merupakan varian *Recurrent Neural Network* (RNN) yang dikembangkan untuk mengatasi masalah *vanishing* dan *exploding gradient* pada RNN (Cho dkk., 2014). GRU terdiri dari dua elemen utama, yaitu *gate* dan *state*, yang membaginya menjadi *update gate* (z_t), *reset gate* (r_t), *candidate hidden state* (\hat{h}_t), dan *hidden state* (h_t) (Cho dkk., 2014) yang secara matematis dihitung menggunakan persamaan sebagai berikut.

$$z_t = \sigma(X_t W_{xz} + h_{t-1} W_{hz})$$

$$r_t = \sigma(X_t W_{xr} + h_{t-1} W_{hr})$$

$$\hat{h}_t = \tanh(X_t W_{xh} + (r_t \odot h_{t-1}) W_{hh})$$

$$h_t = z_t \odot h_{t-1} + (1 - z_t) \odot \hat{h}_t$$

z_t : *update gate*

r_t : *reset gate*

\hat{h}_t : *candidate hidden state*

h_t : *hidden state*

x_t : input pada waktu ke- t

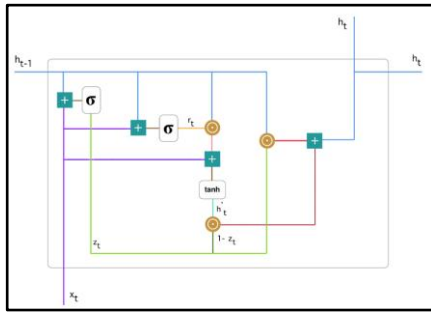
w_{xz}, w_{hz} : bobot (*weight*)

h_{t-1} : *hidden state* sebelumnya

σ : fungsi aktivasi sigmoid

\tanh : fungsi aktivasi tanh

Persamaan tersebut divisualkan pada gambar 2 sebagai berikut.



Gambar 1. Arsitektur GRU

Update gate (z_t) dihitung dengan memproses input data X_t yang dinormalisasi (garis ungu) dikalikan bobot W_z , ditambah informasi sebelumnya H_{t-1} dikalikan U_z (garis biru), kemudian dijumlahkan dan diaktifkan sigmoid (garis hijau) untuk mengatur proporsi informasi lama yang disimpan dan baru yang ditambahkan, sehingga memutuskan aliran memori ke timestep berikutnya. Secara paralel, *reset gate* (r_t) dihitung dari H_{t-1} dan X_t yang masing-masing dikalikan bobotnya, dijumlahkan, dan diproses sigmoid, guna menentukan informasi lama yang perlu dilupakan. Selanjutnya, *candidate hidden state* (\hat{h}_t) dibentuk melalui X_t dikalikan W_h , H_{t-1} dikalikan U_h , perkalian element-wise (garis jingga) untuk seleksi informasi yang relevan, dijumlahkan, dan diaktifkan tanh (garis biru muda), menghasilkan kandidat memori baru. Akhirnya, *hidden state* (h_t) dibuat menambahkan memori lama dengan memori baru, yang disimpan sebagai informasi saat ini dan diteruskan ke langkah GRU berikutnya, memungkinkan GRU menyeimbangkan retensi informasi masa lalu dengan pembaruan terkini.

Selain kelebihanannya dalam melakukan peramalan harga, GRU memiliki beberapa keterbatasan. Yaitu akurasi akan berkurang terhadap data yang memiliki dependensi yang sangat panjang, tidak cocok jika digunakan untuk peramalan yang bersifat jangka panjang (*long-term*), serta tidak cocok untuk data yang bersifat linear (Chung dkk., 2014). Di sisi lain, GRU kesulitan dalam menangani pola linear sederhana dalam prediksi *time series*. Alasan utamanya adalah ketergantungan GRU pada mekanisme *gating* (*update gate* dan *Reset gate*) yang dirancang khusus untuk menangani pola non-linear (Jordan dkk., 2021).

Dalam penerapan GRU untuk peramalan harga, jumlah data yang terlalu sedikit menyebabkan model mudah mengalami *overfitting* dan menghasilkan prediksi yang tidak stabil. Dengan bertambahnya ukuran data hingga mencapai ratusan titik, performa model mulai menunjukkan perbaikan, namun kestabilan prediksi baru tercapai pada kisaran 750–1.500 data (Zantvoort dkk., 2024). Di sisi lain, tidak ada minimum dataset yang digunakan. Namun bergantung pada faktor

sumber daya komputasi, memori RAM, waktu pelatihan, dan biaya (Abadi dkk., 2016; Li, 2025).

Normalisasi data

Normalisasi data dilakukan untuk menyetarakan nilai-nilai input data ke dalam skala yang sama. Tujuannya adalah agar tidak ada nilai input yang terlalu mempengaruhi hasil model karena angkanya jauh dari nilai input lainnya (Singh & Singh, 2020). Normalisasi data yang digunakan dalam penelitian ini yaitu Robust Scaling, yang dihitung secara matematis menggunakan persamaan sebagai berikut.

$$X_{scaled} = \frac{X - median}{Q3 - Q1}$$

Berdasarkan persamaan tersebut, \hat{x} adalah nilai aktual dari data yang ingin dinormalisasi. $Q1$ merupakan kuartil pertama, yaitu 25% nilai terbawah dari data, sedangkan $Q3$ adalah kuartil ketiga, yaitu nilai pada posisi 75% teratas dari data. Kelebihan *Robust Scaling* adalah tidak terganggu jika ada nilai yang sangat besar atau sangat kecil. Metode ini menggunakan nilai tengah (median) dan IQR untuk melakukan proses skalanya. Oleh karena itu, metode ini lebih stabil dan tetap bekerja dengan baik meskipun mengandung data *outlier*. Suatu data dikategorikan sebagai data outlier apabila melebihi batas atas dan batas bawah dari persamaan sebagai berikut.

$$fl = Q3 + 1.5 \times IQR$$

$$fu = Q3 - 1.5 \times IQR$$

Penelitian ini menggunakan metode normalisasi *Robust Scaling* untuk mentransformasi data harga nikel sebelum digunakan dalam proses pelatihan model. Pemilihan *Robust Scaling* didasarkan pada keunggulannya dalam menangani data *outlier*, yang umumnya ditemukan pada data harga komoditas logam seperti nikel yang bersifat fluktuatif dan tidak stasioner. Berbeda dengan metode *Min-Max Scaling* yang sensitif terhadap nilai ekstrem, *Robust Scaling* bekerja dengan menggunakan median dan *interquartile range* (*IQR*) dalam proses transformasi datanya. Pendekatan ini menjadikan *Robust Scaling* lebih stabil dan tidak terpengaruh oleh nilai ekstrim, sehingga model peramalan yang dibangun menjadi lebih tahan terhadap noise dan penciran data yang tidak representatif. Setelah proses pelatihan selesai, data yang telah diprediksi oleh model kemudian didenormalisasi kembali ke satuan aslinya (USD) menggunakan persamaan sebagai berikut.

$$x = (\bar{x} \times IQR) + median$$

Namun, di sisi lain, kekurangan metode ini adalah kurang optimal untuk data distribusi normal (Anderson, 2024).

Tuning Hyperparameter

Hyperparameter merupakan parameter yang menentukan bentuk atau struktur model dan digunakan untuk mengatur proses pembelajaran (Gridin, 2022), yang terdiri dari epoch, batch size, dropout, learning

rate, dan neuron. *Hyperparameter* tidak dapat diperkirakan secara langsung diperoleh dari data yang digunakan. *Hyperparameter* memiliki sejumlah karakteristik, diantaranya (1) umumnya digunakan untuk membantu dalam proses estimasi parameter model; (2) nilainya ditentukan berdasarkan pengetahuan praktis; (3) sering kali disesuaikan menggunakan pendekatan praktikal; (4) umumnya dikonfigurasi dalam pemodelan prediktif. Menentukan nilai optimal dari *hyperparameter* pada suatu permasalahan tertentu bukanlah hal yang dapat dilakukan secara pasti. Salah satu pendekatan umum adalah dengan mengadopsi konfigurasi yang digunakan pada kasus serupa atau melalui proses eksperimental (*trial and error*). Dalam melakukan *tuning hyperparameter*, penelitian ini menggunakan *Library Optuna* dengan opsi *epoch*, *batch size*, *neuron*, *dropout*, *learning rate* pada tabel 1 sebagai berikut.

Tabel 1. Inisiasi hyperparameter

<i>Hyperparameter</i>	Nilai
<i>Neuron</i>	[32, 64, 128, 256]
<i>Dropout</i>	[0.1, 0.2, 0.3, 0.4, 0.5]
<i>Learning rate</i>	[1e-4, 1e-2]
<i>Batch size</i>	[16, 32, 64, 128]
<i>Epoch</i>	[50, 100, 150, 200, 250]

Pada percobaan ini digunakan beberapa kombinasi *hyperparameter* untuk memperoleh model GRU terbaik dalam memprediksi harga nikel. Jumlah neuron yang diuji bervariasi dari 32 hingga 256 untuk melihat pengaruh kapasitas jaringan terhadap performa model. Nilai *dropout* ditetapkan antara 0,1 hingga 0,5 sebagai upaya mencegah *overfitting* dengan mengatur proporsi neuron yang diabaikan selama pelatihan. *Learning rate* yang dicoba adalah 1e-4 dan 1e-2, masing-masing mewakili pembelajaran yang lebih lambat dan lebih cepat, guna menemukan laju pembaruan bobot yang optimal. Selain itu, *batch size* divariasikan dari 16 hingga 128 untuk menilai keseimbangan antara stabilitas gradien dan efisiensi komputasi. Terakhir, jumlah epoch ditentukan antara 50 hingga 250, yang memungkinkan model berlatih dengan durasi berbeda agar dapat mencapai hasil yang lebih representatif tanpa mengalami *overfitting*. Model GRU terdiri dari lapisan GRU sebagai lapisan utama, dan tambahan lapisan *dropout* untuk mengurangi resiko *overfitting*. Bagian *output* model menggunakan lapisan *dense* dengan fungsi aktivasi non-linear agar menghasilkan prediksi untuk beberapa waktu kedepan. Pelatihan model dilakukan dengan menggunakan metode *early stopping* untuk menghentikan pelatihan lebih awal apabila performa pada data validasi tidak membaik selama beberapa kali percobaan, sehingga mencegah pelatihan yang berlebihan. Selain itu, *Optuna* menggunakan *callback* untuk menghentikan percobaan yang tidak memberikan hasil baik berdasarkan nilai *loss*. Model dilatih dengan data pelatihan dan diuji pada data validasi menggunakan jumlah epoch dan batch size yang sudah diatur.

Evaluasi Kinerja


Evaluasi kinerja model pada penelitian ini dilakukan dengan menggunakan *Mean Absolute Percentage Error (MAPE)* yang dihitung secara matematis dengan persamaan sebagai berikut.

$$MAPE (\%) = \frac{100}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|}$$

Berdasarkan persamaan tersebut, n merupakan jumlah dataset. Kemudian, y_i merepresentasikan data aktual. Sedangkan \hat{y}_i merepresentasikan data hasil peramalan harga. MAPE dipilih karena mampu memberikan gambaran seberapa besar presentase kesalahan rata-rata antara prediksi dengan nilai aktual. Proses evaluasi dilakukan setelah pemodelan GRU. Nilai MAPE yang dihasilkan akan digunakan sebagai acuan untuk menilai seberapa baik model dalam melakukan peramalan harga.

Perancangan Graphic User Interface

Arsitektur sistem merupakan gambaran dari proses berjalannya sistem. Pada tahap awal, pengguna (*user*) memilih jangka waktu dari data historis. Selanjutnya pengguna memilih jangka waktu prediksi harga Nikel, kemudian dilakukan prediksi dengan menggunakan model yang telah di-*training*. Setelah itu sistem akan menampilkan grafik harga prediksi Nikel. Alur perancangan arsitektur sistem dapat dilihat pada gambar 3 Sebagai berikut.



Gambar 2. Perancangan sistem antarmuka

Berdasarkan gambar 3, pengguna memasukkan harga nikel pada waktu yang ingin dituju menggunakan fitur “start” dan “end” pada kalender melalui *website* peramalan harga Nikel untuk mengetahui harga peramalan. Selanjutnya *website* melakukan *request* kepada *server* sesuai dengan permintaan pengguna yang dilanjutkan pada algoritma GRU untuk melakukan prediksi. Setelah melakukan peramalan, nilai hasil peramalan akan dikembalikan sebagai respon dari *request* menuju *server* hingga kembali ke pengguna.

III. HASIL DAN PEMBAHASAN

Peramalan harga Nikel

Berdasarkan hasil *tuning hyperparameter* dengan menggunakan *Optuna*, didapatkan hasil pada tabel 5.1 sebagai berikut.


Tabel 2. Hyperparameter terbaik

Tuning Hyperparameter	Nilai
Batch size	32
Epoch	195
Neuron	256
Dropout	0.4
Learning rate	0.002

Berdasarkan tabel 2, hasil eksplorasi menggunakan Optuna, *Batch size* 32 menunjukkan bahwa model melakukan pembaruan bobot setiap 32 sampel data. Selanjutnya, jumlah *epoch* didapatkan sebesar 200, yang mengindikasikan banyaknya iterasi pada keseluruhan dataset. Adapun jumlah *neuron* optimal pada hidden layer berjumlah 256 *neuron*. Untuk menjaga kemampuan generalisasi, didapatkan nilai *dropout* sebesar 0,4. Mekanisme ini memungkinkan sebagian *neuron* dinonaktifkan selama proses pelatihan sebanyak 40% secara acak selama pelatihan, dengan tujuan mencegah model terlalu bergantung pada pola tertentu (*co-adapting*) dan mengurangi risiko *overfitting*. Terakhir, *learning rate* yang didapatkan sebesar 0,002. *Learning rate* merepresentasikan besarnya langkah pembaruan bobot pada setiap iterasi. Nilai *learning rate* yang kecil ini membuat proses pembelajaran berjalan lebih stabil dan memungkinkan model mencapai konvergensi yang lebih baik. Konfigurasi *hyperparameter* tersebut secara keseluruhan dipandang optimal dalam menyeimbangkan kapasitas komputasi, kestabilan pelatihan, serta kemampuan generalisasi model. Dengan demikian, model GRU diharapkan dapat memberikan hasil peramalan harga nikel yang akurat. Optimalisasi ini sekaligus menunjukkan bahwa proses eksplorasi *hyperparameter* berperan penting dalam meningkatkan kinerja model.

Analisis dan hasil evaluasi


Hasil *model fitting* divisualisasikan dalam bentuk grafik loss yang ditunjukkan oleh gambar 4 sebagai berikut.



Gambar 3. Grafik training loss

Berdasarkan gambar 4, kurva *loss* (MSE) selama proses pelatihan model GRU dengan jumlah epoch sebanyak 200. Pada awal pelatihan (epoch < 10), nilai *loss* relatif tinggi, yakni di atas 1,4. Namun seiring bertambahnya *epoch*, nilai *loss* mengalami penurunan yang konsisten hingga mencapai kisaran 0,2 pada akhir pelatihan. Pola ini menunjukkan bahwa model secara bertahap berhasil menyesuaikan bobotnya sehingga


error prediksi semakin kecil. Secara keseluruhan, tren menurun yang stabil mengindikasikan bahwa model tidak mengalami *underfitting* maupun *overfitting* secara signifikan, dan proses pelatihan dapat dikatakan berhasil. Selain itu, hasil evaluasi dengan menggunakan metrik *Mean Absolute Percentage Error (MAPE)* menunjukkan nilai sebesar 1,21%, yang menandakan tingkat kesalahan prediksi model sangat rendah berdasarkan kategori akurasi nilai menurut Lewis, (1982). Nilai MAPE di bawah 10% mengindikasikan bahwa model GRU memiliki akurasi tinggi dan dapat diandalkan dalam meramalkan harga nikel. Evaluasi kinerja model dari data peramalan harga dengan data aktual dapat dilihat pada gambar 5 sebagai berikut.



Gambar 4. Grafik perbandingan data aktual dengan data peramalan

Grafik tersebut memperlihatkan perbandingan antara data aktual harga nikel (garis biru) dengan hasil peramalan (garis merah). Secara visual, hasil peramalan terlihat sangat mendekati data aktual, mengikuti pola fluktuasi harga nikel dengan baik. Hal ini diperkuat oleh nilai MAPE sebesar 1,21%, yang berarti rata-rata kesalahan prediksi hanya sekitar 1,21% dari harga sebenarnya. Nilai ini menunjukkan performa model yang sangat baik, mengingat dalam analisis time series, MAPE di bawah 10% tergolong akurat. Dengan demikian, model peramalan ini dapat dikatakan andal dalam memproyeksikan harga nikel.

Berdasarkan data historis, harga nikel yang telah diolah, dilakukan proses peramalan untuk memperkirakan pergerakan harga pada periode berikutnya. Hasil peramalan ditampilkan dalam bentuk grafik yang membandingkan antara data historis dan prediksi harga. Adapun hasil peramalan harga nikel dapat dilihat pada gambar 6 sebagai berikut.



Gambar 5. Hasil peramalan harga Nikel

Gambar 6 menunjukkan hasil peramalan harga nikel yang divisualkan dalam dua kurva berbeda. Garis biru merepresentasikan data historis harga nikel selama 730 hari terakhir, sedangkan garis merah menunjukkan hasil peramalan harga nikel untuk periode mendatang. Secara visual, terlihat bahwa model mampu mengikuti pola pergerakan harga pada data historis dengan baik, yang ditunjukkan oleh tingkat kesalahan MAPE sebesar 1,21%, menandakan akurasi prediksi yang tinggi. Dari hasil peramalan terlihat bahwa harga nikel diperkirakan bergerak fluktuatif dengan kisaran nilai tertentu. Harga minimum tercatat sebesar 14.803,72 USD pada tanggal 27 Desember 2025, sedangkan harga maksimum diprediksi mencapai 16.500,20 USD pada tanggal 19 Oktober 2025. Secara keseluruhan, rata-rata harga nikel selama periode peramalan berada di kisaran 15.527,85 USD, menunjukkan kecenderungan harga tetap berada dalam rentang stabil meskipun mengalami fluktuasi naik turun sepanjang periode prediksi Rancangan Desain Antarmuka.

Selain itu, pada penelitian ini juga dilakukan komparasi antara hasil penelitian dengan data harga nikel *real-time* pada laman London Metal Exchange. Adapun hasil komparasi tersebut dapat dilihat pada gambar 6 sebagai berikut.



menampilkan grafik perbandingan antara harga nikel aktual di LME (ditunjukkan oleh garis biru) dengan hasil peramalan harga (ditunjukkan oleh garis merah) selama periode Juni hingga September 2025. Grafik ini menunjukkan bahwa pola pergerakan harga hasil peramalan mengikuti tren harga aktual dengan tingkat kesalahan prediksi yang relatif rendah ($<10\%$), ditunjukkan oleh MAPE sebesar 2,85%.

Rancangan antarmuka

Perancangan antarmuka meliputi struktur menu pada *Graphic Pengguna Interface (GUI)* yang menjelaskan menu dari sistem yang akan dibangun dan yang akan dilihat oleh Pengguna. Perancangan antar muka mencakup halaman “*Research summary*” dan “*Nickel Price Prediction*” ditunjukkan pada gambar 7 sebagai berikut.



Gambar 6. Graphic user interface

Berdasarkan gambar 7, rancangan desain antar muka terdiri dari beberapa komponen, yaitu “*Navigation bar*”, “*Graph actual vs prediction*”, “*performance bar*”, dan “*date filter*”. “*Navigation bar*” berfungsi untuk navigasi utama yang memungkinkan pengguna (*user*) untuk berpindah antar menu atau halaman dengan mudah, sehingga meningkatkan aksesibilitas dan efisiensi penggunaan aplikasi. Selanjutnya, “*Graph actual vs prediction*” menyajikan visualisasi perbandingan antara data aktual dan hasil prediksi dalam bentuk grafik, yang membantu pengguna dalam mengevaluasi akurasi model. “*performance bar*” menampilkan harga data historis dan harga prediksi serta metrik evaluasi MAPE. Terakhir “*date filter*” memungkinkan penyaringan data berdasarkan rentang tanggal, sehingga pengguna (*user*) dapat fokus pada periode waktu spesifik.

IV. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa algoritma GRU mampu menghasilkan peramalan harga nikel jangka pendek selama 180 hari (17 Juli 2025–12 Januari 2026) dengan kisaran harga prediksi minimum sebesar 14.803,72 USD, maksimum 16.500,20 USD, dan rata-rata 15.527,85 USD. Selain itu, kinerja model menunjukkan tingkat akurasi yang tinggi dengan nilai MAPE sebesar 1,21%, yang termasuk dalam kategori prediksi sangat akurat menurut kriteria Lewis (1982), sehingga GRU dinilai efektif untuk peramalan harga nikel jangka pendek.

DAFTAR PUSTAKA

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., Devin, M., Ghemawat, S., Irving, G., Isard, M., Kudlur, M., Levenberg, J., Monga, R., Moore, S., Murray, D. G., Steiner, B., Tucker, P., Vasudevan, V., Warden, P., ... Zheng, X. (2016). TensorFlow: A System for Large-Scale Machine Learning. *Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI '16)*, 265–283.
- Abdel Sabour, S. A. (2002). Mine size optimization using marginal analysis. *Resources Policy*, 28(3–4), 145–151. <https://doi.org/10.1016/j.resourpol.2004.01.001>

- Anderson, K. (2024). *The Role of Data Preprocessing in Machine Learning Accuracy for Heart Disease Prediction Hybrid Models for Heart Disease Prediction: Combining Neural Networks with Traditional*.
- Baker, T., Aibino, S., Belsito, E., Aubert, G., & Sahoo, A. (2019). *Electric Vehicles Are a Multibillion Dollar Opportunity for Utilities*.
- Bhatia, V., Das, D., Tiwari, A. K., Shahbaz, M., & Hasim, H. M. (2018). Do precious metal spot prices influence each other? Evidence from a nonparametric causality-in-quantiles approach. *Resources Policy*, 55, 244–252. <https://doi.org/10.1016/j.resourpol.2017.12.008>
- Chatterjee, S., & Dimitrakopoulos, R. (2020). Production scheduling under uncertainty of an open-pit mine using Lagrangian relaxation and branch-and-cut algorithm. *International Journal of Mining, Reclamation and Environment*, 34(5), 343–361. <https://doi.org/10.1080/17480930.2019.1631427>
- Cho, K., Merrienboer, B. van, Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). *Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation* (No. arXiv:1406.1078). arXiv. <https://doi.org/10.48550/arXiv.1406.1078>
- Chukwuemeka, N. K., Ulusow, A. H., & Sylvanus, O. M. (2024). Climate change, causes, economic impact and mitigation. *International Journal of Scientific Research Updates*, 8(1), 001–008. <https://doi.org/10.53430/ijrsru.2024.8.1.0043>
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *arXiv Preprint arXiv:1412.3555*, <https://arxiv.org/abs/1412.3555>.
- Ferreira, R., & Pinto, F. (2022). An Overview of World Stainless Steel Scrap Trade in 2022. *INSG SECRETARIAT BRIEFING PAPER*, 38.
- Gong, X., & Lin, B. (2018). Structural breaks and volatility forecasting in the copper futures market. *Journal of Futures Markets*, 38(3), 290–339. <https://doi.org/10.1002/fut.21867>
- Gridin, I. (2022). *Time series forecasting using deep learning: Combining PyTorch, RNN, TCN, and deep neural network models to provide production-ready prediction solutions* (First edition). BPB Publications.
- Hatayama, H., & Tahara, K. (2018). Adopting an objective approach to criticality assessment: Learning from the past. *Resources Policy*, 55, 96–102. <https://doi.org/10.1016/j.resourpol.2017.11.002>
- International Energy Agency. (2024). *Global Critical Minerals Outlook 2024*. International Energy Agency (IEA) Data and Statistics. <https://www.iea.org/data-and-statistics>
- Jordan, I. D., Sokół, P. A., & Park, I. M. (2021). Gated Recurrent Units Viewed Through the Lens of Continuous Time Dynamical Systems. *Frontiers in Computational Neuroscience*, 15, 678158. <https://doi.org/10.3389/fncom.2021.678158>
- Khoshalan, H. A., Shakeri, J., Najmoddini, I., & Asadizadeh, M. (2021). Forecasting copper price by application of robust artificial intelligence techniques. *Resources Policy*, 73, 102239. <https://doi.org/10.1016/j.resourpol.2021.102239>
- Kong, X., Chen, Z., Liu, W., Ning, K., Zhang, L., Muhammad Marier, S., Liu, Y., Chen, Y., & Xia, F. (2025). Deep learning for time series forecasting: A survey. *International Journal of Machine Learning and Cybernetics*. <https://doi.org/10.1007/s13042-025-02560-w>
- Lahadalia, B., Wijaya, C., Dartanto, T., & Subroto, A. (2024). Nickel Downstreaming in Indonesia: Reinventing Sustainable Industrial Policy and Developmental State in Building the EV Industry in ASEAN. *JAS (Journal of ASEAN Studies)*, 12(1), 79–106. <https://doi.org/10.21512/jas.v12i1.11128>
- Lewis, Colin. D. (1982). *Industrial and business forecasting methods _ a practical guide to exponential smoothing and curve fitting*. Butterworth Scientific.
- Li, C. (2025). Enhancing Stock Price Prediction with Distributed Learning. *Proceedings of the 2025 International Conference on Digital Economy and Intelligent Computing*, 18–23. <https://doi.org/10.1145/3746972.3746976>
- Mufida, farah ayu, Eltivia, N., & Riwijanti, N. indah. (2024). Time Series Forecasting of Nickel Sales in Nickel Mining Companies Listed on Indonesia Stock Exchange (IDX). *eCo-Fin*, 6(2), 133–142. <https://doi.org/10.32877/ef.v6i2.1110>
- Ozdemir, A. C., Buluş, K., & Zor, K. (2022). Medium-to long-term nickel price forecasting using LSTM and GRU networks. *Resources Policy*, 78, 102906. <https://doi.org/10.1016/j.resourpol.2022.102906>
- Ribeiro, A. H., Tiels, K., Aguirre, L. A., & Schön, T. B. (2020). *Beyond exploding and vanishing gradients: Analysing RNN training using attractors and smoothness* (No. arXiv:1906.08482). arXiv. <https://doi.org/10.48550/arXiv.1906.08482>
- Singh, D., & Singh, B. (2020). Investigating the impact of data normalization on classification performance. *Applied Soft Computing*, 97,

105524.
<https://doi.org/10.1016/j.asoc.2019.105524>
- United States Geological Survey. (2023). *Mineral Commodity Summaries 2024*.
<https://pubs.usgs.gov/periodicals/mcs2023/mcs2023-nickel.pdf>
- Wang, C., Zhang, X., Wang, M., Lim, M. K., & Ghadimi, P. (2019). Predictive analytics of the copper spot price by utilizing complex network and artificial neural network techniques. *Resources Policy*, 63, 101414.
<https://doi.org/10.1016/j.resourpol.2019.101414>
- Widiatedja, I. G. N. P. (2021). Indonesia's Export Ban on Nickel Ore: Does It Violate the World Trade Organization (WTO) Rules? *Journal of World Trade*, 55(Issue 4), 667–696.
<https://doi.org/10.54648/TRAD2021028>
- Zantvoort, K., Nacke, B., Görlich, D., Hornstein, S., Jacobi, C., & Funk, B. (2024). Estimation of minimal data sets sizes for machine learning predictions in digital mental health interventions. *Npj Digital Medicine*, 7(1), 361. <https://doi.org/10.1038/s41746-024-01360-w>