

IMPLEMENTASI MODEL LSTM, GRU, BiLSTM, DAN BiGRU DALAM PREDIKSI HARGA NIKEL

Muhammad Atharsyah¹, Moh. Ali Romli²

^{1,2} Program Studi Informatika, Fakultas Sains dan Teknologi, Universitas Teknologi Yogyakarta

Jalan Ringroad Utara, Jombor, Kec. Sleman, Daerah Istimewa Yogyakarta 55285
atharsyah.5210411238@student.uty.ac.id, ²ali.romli@uty.ac.id

Abstract

The use of nickel in the world is becoming increasingly widespread. Nickel is the main ingredient in stainless steel and electric car batteries. Along with the advancement of electric vehicles that use nickel batteries, nickel prices have become an interesting topic, especially for investors who are willing to invest in the nickel industry. Recent studies on nickel price prediction utilized Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), Bidirectional Long Short-Term Memory (BiLSTM), and Bidirectional Gated Recurrent Unit (BiGRU) models, with historical data of nickel prices in USD. The construction of the best prediction model involves adjusting parameters such as epoch, learning rate, batch, optimizer, and applying dropout techniques to avoid overfitting. The test results show that the BiLSTM model is the best, with R2 Score of 0.86962 and RMSE of 0.024735, indicating that the BiGRU model provides accurate predictions based on R2 and RMSE criteria.

Keywords: LSTM, GRU, BiLSTM, BiGRU, Nikel

Abstrak

Penggunaan nikel di dunia kini semakin meluas. Nikel merupakan bahan utama pembuatan baja tahan karat dan baterai mobil listrik. Seiring dengan kemajuan kendaraan listrik yang menggunakan baterai nikel, harga nikel pun menjadi topik menarik, terutama bagi investor yang berkeinginan untuk berinvestasi di industri nikel. Studi terkini tentang prediksi harga nikel memanfaatkan model Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), Bidirectional Long Short-Term Memory (BiLSTM), dan Bidirectional Gated Recurrent Unit (BiGRU), dengan data historis harga nikel dalam USD. Pembangunan model prediksi terbaik melibatkan penyesuaian parameter seperti epoch, learning rate, batch, optimizer, dan penerapan teknik dropout untuk menghindari overfitting. Hasil pengujian menunjukkan bahwa model BiLSTM adalah yang terbaik, dengan R2 Score sebesar 0.86962 dan RMSE sebesar 0.024735, menandakan bahwa model BiGRU memberikan prediksi yang akurat berdasarkan kriteria R2 dan RMSE.

Kata kunci : LSTM, GRU, BiLSTM, BiGRU, Nikel

1. PENDAHULUAN

Nikel adalah salah satu elemen dalam kimia dengan simbol Ni dan memiliki nomor atom 28. Nikel bersifat keras, lunak dan tidak mudah berkarat. Nikel merupakan logam yang beracun dan dapat menyebabkan gangguan kesehatan apabila terhirup atau terpapar dalam jumlah yang besar [1]. Nikel digunakan dalam banyak industri, termasuk kimia, metalurgi, dan pembuatan alat teknik. Nikel tidak hanya digunakan untuk

membuat baja tahan karat, tetapi juga digunakan untuk membuat baterai, terutama baterai mobil listrik.

Larangan Indonesia terhadap ekspor bijih nikel telah meningkatkan harga nikel di *London Metal Exchange* (LME), dengan larangan tahun 2014 memiliki dampak yang lebih signifikan dan berkepanjangan di pasar [2]. Tetapi Menurut data statistik dari Badan Pusat Statistik (BPS), harga nikel mengalami penurunan di bulan Desember 2023. Salah satu faktor penurunan harga nikel di

pasar global adalah hilirisasi yang dilakukan oleh pemerintah Indonesia yang mengakibatkan penurunan harga sekitar 3,33% mtm dan 43,14%. Ekspor nikel Indonesia juga mengalami penurunan pada bulan Desember 2023, dengan nilai ekspor sebesar US\$521,8 juta, turun sekitar 4,09% secara bulanan, dan volume ekspor sebesar 126,0 juta ton, turun sekitar 14,06%. Penurunan harga disebabkan oleh penurunan permintaan dari negara tujuan ekspor. Nikel memiliki dampak dan sensitivitas harga perdagangan terbesar, dengan pengaruh yang lebih kuat di Asia dan Eropa, sedangkan bijih nikel memiliki risiko volatilitas harga perdagangan impor tertinggi dan pengaruh yang kuat, namun memiliki transmisi risiko yang moderat [3].

Penggunaan *deep learning* dapat membantu investor untuk memprediksi harga nikel dibandingkan dengan menggunakan metode tradisional. Dengan jumlah data yang cukup banyak, dengan menggunakan *deep learning* akan memproses data dengan lebih cepat dan tepat. Metode *deep learning* yang sering digunakan adalah RNN dengan model LSTM dan GRU. Baik jaringan LSTM maupun GRU mampu memprediksi biaya kuota secara akurat, namun jaringan LSTM mengungguli jaringan GRU [4].

Dalam membuat prediksi menggunakan *deep learning*, memang ditangkap menjadi lebih baik, tetapi ada beberapa faktor yang dapat membuat prediksi tidak sepenuhnya menjadi patokan. Banyak faktor eksternal, seperti saham, kadang-kadang tidak dapat diprediksi. Volatilitas harga bijih nikel sangat dipengaruhi oleh suku bunga, ketidakpastian ekonomi global, dan nilai tukar [5]. Penelitian adalah analisis algoritma untuk prediksi harga nikel.

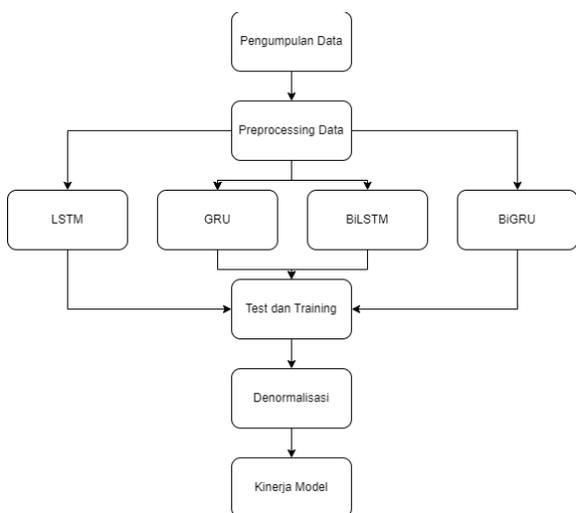
Belakangan ini, banyak penelitian telah dilakukan untuk meramalkan harga menggunakan LSTM dan GRU menjadi model yang populer, Karena model-model ini dapat menangkap dan menginterpretasikan pola temporal yang rumit pada data deret waktu dengan akurasi yang lebih tinggi, model-model ini menjadi semakin populer di bidang peramalan keuangan. Model LSTM adalah jaringan saraf tiruan berulang dari pembelajaran mendalam yang menunjukkan harapan untuk pemodelan deret waktu, terutama dalam kondisi ketika data berlimpah [6]. Oleh karena itu, model ini bekerja dengan sangat baik dalam aplikasi keuangan seperti prediksi harga saham, analisis tren, dan optimasi strategi investasi. Menurut penelitian, model LSTM dapat mengantisipasi harga saham dengan tingkat akurasi yang tinggi, sering kali mengungguli teknik peramalan yang lebih konvensional.

Model GRU adalah jaringan syaraf tiruan berulang dengan gerbang reset dan update pada lapisan tersembunyi, yang secara komputasi lebih efisien daripada LSTM konvensional [7]. Dibandingkan dengan LSTM, GRU lebih cepat untuk dikomputasi dan dilatih karena kesederhanaannya. Dalam tantangan yang melibatkan prediksi harga saham, GRU telah menunjukkan kinerja yang kuat, terutama ketika menangani fluktuasi linear dalam harga saham. Dalam sebuah penelitian, misalnya, kinerja model GRU dan LSTM dibandingkan, dan ditemukan bahwa GRU berkinerja lebih baik daripada LSTM dalam beberapa situasi, terutama ketika memproses data dengan fitur linier. Kedua model ini memiliki arsitektur yang sederhana dan dilengkapi dengan implementasi yang sudah dibuat sebelumnya dalam perangkat lunak sumber terbuka, sehingga relatif mudah digunakan dalam peramalan keuangan.

Bidirection Model dalam *Recurrent Neural Networks* (RNN) seperti *Bidirectional Long Short-Term Memory* (BiLSTM) dan *Bidirectional Gated Recurrent Unit* (BiGRU) adalah arsitektur canggih yang dirancang untuk meningkatkan performa tugas pemrosesan data berurutan dengan mempertimbangkan konteks masa lalu dan masa depan.

Dengan melihat permasalahan yang ada seerta hasil penelitian terdahulu, maka penelitian ini akan di lakukan prediksi harga nikel dengan menggunakan metode LSTM, GRU, BiLSTM dan BiGRU, metode metode ini telah banyak digunakan dalam melakukan prediksi dengan data deret waktu yang dianggap cocok dalam memprediksi harga nikel. Namun dalam penelitian ini digunakan beberapa parameter yang berbeda dan sesuai dengan data yang digunakan agar dapat memperoleh hasil yang terbaik. Parameter yang akan digunakan untuk membentuk model terbaik menacu pada penelitian sebelumnya, seperti epoch, batch, dan optimizer. Selain itu, untuk menghindari overfitting model, teknik regulasi dropout harus ditambahkan. Diharapkan bahwa penelitian ini akan mencapai dua tujuan membangun model prediksi harga saham yang paling akurat dan membandingkan hasil evaluasi dari dua pendekatan yang berbeda yang digunakan untuk memprediksi harga nikel.

2. METODOLOGI PENELITIAN



Gambar 1 Alur Penelitian

Penelitian dilakukan menggunakan empat model deep learning yaitu LSTM, GRU, BiLSTM, dan BiGRU dengan tujuan memprediksi harga nikel. Berikut rangkaian dari penelitian.

2.1. Pengumpulan Data

Pada penelitian data yang digunakan adalah history harga nikel dengan basis USD(\$) dari tanggal 7 Juli 2008 sampai tanggal 3 Juni 2024. Data didapatkan pada laman situs Investing.com dengan mengekstrak data menjadi format csv.

2.2. Preprocessing Data

Pada tahap ini data yang sudah dikumpulkan akan dilakukan penyesuaian data dengan membuang beberapa kolom yang dianggap tidak diperlukan karena memiliki nilai nul yang banyak seperti *Vol* dan *Change %*. Sehingga kolom yang akan digunakan merupakan kolom *Date*, *Price*, *Open*, *High*, *Low*. Dimana kolom *Date* akan digunakan sebagai indeks dan kolom lainnya sebagai *feature*. Setelah dilakukan penyesuaian kemudian dilakukan normalisasi data sehingga menjadi nilai dengan range interval 0-1. Metode yang digunakan adalah Min-Max Normalisasi atau *MinMax Scaling* dengan menggunakan persamaan sebagai berikut.

$$X_{norm,i} = \frac{X_i - X_{min}}{X_{max} - X_{min}} \quad i = 1,2,3, \dots, t \quad (2)$$

dengan X_{norm} adalah nilai normalisasi, X_{max} adalah nilai maksimum data, dan x_{min} adalah nilai minimum data. Selanjutnya dataset dibagi menjadi dua bagian yaitu data *training* dan data

testing. Untuk data *training* 80% dan data testing 20%. Untuk menghasilkan nilai prediksi yang lebih baik dalam penelitian ini, tahap *preprocessing* sangat penting [8].

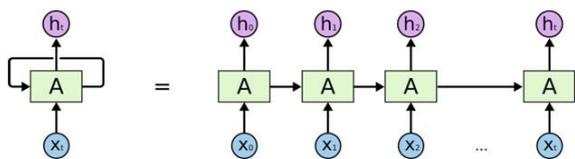
2.3. Pemodelan

Penelitian dilakukan dengan 4 model RNN dengan algoritma yang berbeda untuk melihat model mana dan parameter seperti apa yang paling baik untuk memprediksi harga nikel. Model yang digunakan yaitu LSTM, GRU, BiLSTM, dan BiGRU.

a. Recurrent Neural Network

Recurrent Neural Network (RNN) adalah pengembangan dari arsitektur jaringan saraf tiruan. Di mana output dari lapisan tersembunyi menjadi input untuk proses berikutnya [9]. Jadi, bisa dikatakan bahwa *Recurrent Neural Network* (RNN) merupakan versi dasar dari jaringan saraf berulang yang dirancang untuk mengolah data berurutan dengan cara yang efisien namun sederhana. Dengan struktur yang terdiri dari unit-unit yang terhubung secara berulang, RNN dapat mempertahankan informasi dari input sebelumnya, sehingga mampu menangani tugas-tugas seperti pengenalan pola. Namun, RNN seringkali mengalami masalah *Vanishing Gradient*, di mana informasi dari urutan yang panjang menjadi sulit untuk dipertahankan. Dalam struktur *Recurrent Neural Network* (RNN), input, lapisan tersembunyi, dan output terdiri dari satu sama lain. Lapisan tersembunyi diperbarui setiap kali langkah yang dilakukan dan mengandung informasi tentang apa yang telah dipelajari dari input sebelumnya. Algoritma *back propagation* terus digunakan untuk melatih RNN untuk mengurangi atau memastikan kesalahan antara *output* prediksi dan *output* sebenarnya. Sejak lama, RNN telah digunakan untuk mencapai hasil yang inovatif dalam berbagai tugas. Namun, untuk melakukannya dengan data yang besar, RNN membutuhkan pelatihan komputasi yang sangat intensif.

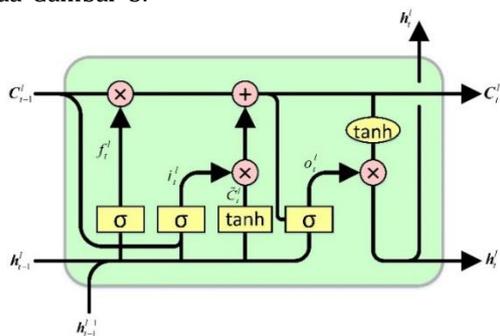
RNN terutama berfokus pada sifat data di mana waktu saat ini atau saat sebelumnya (t) mempengaruhi waktu berikutnya ($t + 1$). Konsep dasar RNN adalah menggunakan algoritma yang dilakukan berulang, yang berarti bahwa operasi yang sama dilakukan untuk setiap elemen secara berurutan, dengan *output* bergantung pada *input* dan operasi sebelumnya. seperti pada Gambar 2.



Gambar 2 Rangkaian Recurrent Neural Network

b. Long Short-Term Memory

Long Short-Term Memory (LSTM) adalah arsitektur jaringan saraf tiruan yang dikembangkan untuk mengatasi masalah vanishing gradient yang ditemukan pada model *Recurrent Neural Network* (RNN). [10]. LSTM merupakan pengembangan dari RNN. LSTM dirancang untuk pembelajaran sekuen yang lebih panjang. Arsitektur LSTM terdiri dari struktur sel dengan gerbang-gerbang khusus yang mengatur aliran informasi. Gerbang-gerbang tersebut, yaitu *input gate*, *forget gate*, dan *output gate*, memiliki fungsi khusus untuk mempertahankan, menambah, atau menghapus informasi berdasarkan kebutuhan seperti yang di ditampilkan pada Gambar 3.



Gambar 3 Rangkaian Long Short-Term Memory

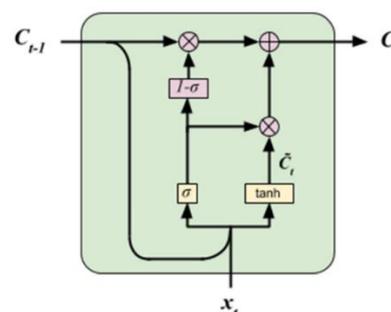
Selain itu, penelitian ini menggunakan *library Keras*, jaringan syaraf imitasi yang berfungsi dengan *TensorFlow*, untuk mempercepat proses pengolahan data. [11].

c. Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) merupakan model jaringan saraf yang diaplikasikan untuk analisis data berurutan. Model ini dikembangkan sebagai alternatif dari *Long Short-Term Memory* (LSTM) dengan struktur yang lebih simpel dan efisien secara komputasi. GRU terdiri dari dua pintu utama: pintu reset dan pintu *update*. Pintu reset menentukan jumlah informasi masa lalu yang perlu dilupakan, sementara pintu *update* menentukan jumlah informasi saat ini yang akan digabungkan ke dalam proses [12]. GRU memiliki dua gate utama: gate reset dan gate update. Gate reset bertindak untuk mengatur seberapa banyak informasi dari masa lalu yang harus diabaikan,

sedangkan gate update mengatur seberapa banyak informasi dari masa kini yang harus diintegrasikan ke dalam proses [13].

Kelebihan GRU adalah bahwa itu adalah proses komputasi yang lebih sederhana daripada LSTM. Namun, GRU masih tepat dan efektif dalam menangani masalah gradien yang hilang. Pada GRU, kita pertama-tama menghitung kandidat konteks \tilde{C}_t sebagai tanh dari gabungan input x_t dan konteks lama C_{t-1} . Kemudian, kita menggunakan gerbang update u_t , sebuah gerbang sigmoid, untuk menghitung jumlah konteks baru C_t yang berasal dari kandidat \tilde{C}_t dan jumlah konteks lama C_{t-1} .



Gambar 4 Rangkaian Gated Recurrent Unit

Gambar 4 merupakan rangkaian model GRU yang disederhanakan. Untuk melakukan perhitungan \tilde{C}_t , rangkaian lengkap GRU memiliki gerbang r_t yang disebut reset gate. Ini membuat diagram sedikit rumit.

d. Bidirectional

Model *bidirectional* merupakan variasi dari model jaringan saraf berulang (RNN) yang dapat memproses data dalam dua arah waktu, baik dari masa lalu maupun masa depan [18].

BiLSTM merupakan variasi dari model LSTM yang beroperasi dalam dua arah waktu. Arsitektur BiLSTM dibangun dari dua LSTM yang beroperasi secara terbalik: satu bergerak maju dari awal hingga akhir, dan yang lainnya bergerak mundur dari akhir ke awal. Output dari kedua LSTM tersebut lalu diintegrasikan untuk menyediakan konteks yang lebih komprehensif pada tiap titik waktu [14]. Prosesnya dapat di tulis sebagai berikut:

$$ht = [ht \rightarrow, ht \leftarrow] \quad (1)$$

Dimana $ht \rightarrow$ adalah output dari forward GRU dan $ht \leftarrow$ adalah output dari backward GRU [15].

BiGRU adalah desain RNN khusus yang dirancang untuk menangani kerumitan data berurutan dengan menangkap pola kompleks dalam urutan maju dan mundur. BiGRU terdiri dari dua lapisan GRU dengan model GRU sebagai

fondasi; satu lapisan mengamati urutan input dalam lintasan maju, dan lapisan lainnya memeriksanya secara terbalik. Metode dua arah ini memungkinkan jaringan untuk memahami pola dan ketergantungan dari konteks masa lalu dan masa depan. Ini meningkatkan pemahaman mereka tentang data berurutan. BiGRU secara efektif mengatasi kendala model searah dengan menggabungkan wawasan dari kedua arah. Ini menunjukkan bahwa itu cocok untuk berbagai tugas penelitian seperti pemrosesan bahasa alami, analisis sentimen, dan peramalan deret waktu, terutama dalam situasi di mana penangkapan hubungan dua arah diperlukan.

2.4. Training dan Testing

Setelah proses *preprocessing* data selesai, dilakukan proses pelatihan data dengan empat model yang telah disiapkan dengan data pelatihan. Selanjutnya, proses pengujian dilakukan dengan data pengujian, dan hasil dari model pelatihan sebelumnya diuji untuk mengetahui seberapa efektif model yang digunakan untuk memprediksi harga nikel.

Baik pelatihan data maupun pengujian data pada pembentukan model LSTM, GRU, BiLSTM, dan BiGRU membutuhkan parameter untuk mendapatkan model terbaik. Parameter yang disarankan untuk digunakan dalam penelitian ini disajikan dalam Tabel 1.

TABEL I. DESKRIPSI PARAMETER

Parameter	Value
Learning Rate	0.01,0.001
Epoch	50,100
Batch	32
Optimizer	Adam

2.5. Denormalisasi

Denormalisasi adalah proses untuk mengubah hasil keluaran yang masih dalam rentang 0-1 menjadi nilai data aktual. Perhitungannya dilakukan dengan menggunakan persamaan berikut:

$$d = y(max - min) + min \quad (3)$$

dengan d adalah nilai *denormalisasi*, y adalah hasil prediksi, dan max dan min adalah nilai maksimum dan minimum data.

2.6. Kinerja Model

Dalam penelitian evaluasi kinerja model diperoleh dengan menggunakan nilai *Root Mean Squared Error* (RMSE), dan *R-squared* (R2) Score. RMSE dihitung dengan mengambil akar kuadrat dari rata-rata kuadrat kesalahan antara nilai aktual dan prediksi. Sebagai contoh, rumus RMSE dapat ditulis sebagai berikut:

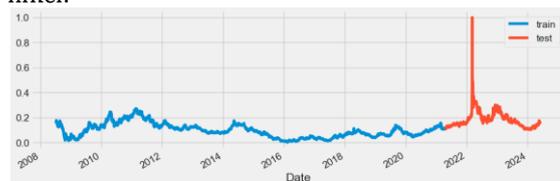
$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

R-squared (R2) Score adalah suatu metrik statistik yang digunakan untuk mengevaluasi kualitas model regresi linear. *R-squared* dapat dihitung menggunakan rumus berikut:

$$R2 = 1 - \frac{(\sum (y_i - \hat{y}_i)^2)}{\sum ((y_i - \hat{y}_m)^2)} \quad (5)$$

3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan 3920 data yang kemudian dibagi menjadi 80% untuk data pelatihan dan 20% untuk data pengujian, yaitu 3136 data pelatihan dan 784 data pengujian seperti yang ditunjukkan pada Gambar 4. Setelah *preprocessing* dan data dianggap siap untuk dimasukkan ke dalam model, dilakukan *tuning parameter* melalui metode *trial and error*. Terdapat 16 kombinasi parameter yang diuji dalam penelitian ini. Dari 16 model tersebut, akan dipilih kombinasi parameter terbaik dan model yang paling efektif untuk memprediksi harga nikel.



Gambar 5. Grafik Pembagian Data Training dan Data Testing

Hasil dari pengujian parameter dataset history harga nikel dari model *Long Short-Term Memory* (LSTM) dengan *Learning Rate* 0.001 dan 0.01, *Epoch* 100 dan 50, *Batch Size* 32, dengan *optimizer* Adam menghasilkan hasil seperti pada tabel II.

TABEL II Hasil Pengujian Menggunakan LSTM

Learning Rate	Epoch	RMSE	R2 Score
0.001	50	0.027672	0.836827
0.01	50	0.042335	0.618355

0.001	100	0.025496	0.861417
0.01	100	0.038629	0.682086

Pada Tabel II dapat di katakan bahwa model LSTM yang memiliki parameter dengan *Learning rate* 0.001 dan *epoch* 100 merupakan parameter terbaik. Karena menunjukan nilai *R2 Score* yang lebih tinggi dari yang lain. Pada model ini dapat dikatakan bahwa semakin kecil *learning rate* semakin baik dan semakin besar *epoch* semakin baik juga.

Hasil dari pengujian parameter dataset history harga nikel dari model *Gated Recurrent Unit* (GRU) dengan *Learning Rate* 0.001 dan 0.01, *Epoch* 100 dan 50, *Batch Size* 32, dengan *optimizer* Adam menghasilkan hasil seperti pada Table III.

TABEL III Hasil Pengujian Menggunakan GRU

Learning Rate	Epoch	RMSE	R2 Score
0.001	50	0.027439	0.839502
0.01	50	0.032884	0.769529
0.001	100	0.039464	0.668307
0.01	100	0.034871	0.740821

Pada Table III dapat di katakan bahwa model GRU dengan parameter *learning rate* 0.001 dengan *epoch* 50 menjadi parameter terbaik dengan menunjukan nilai *R2 score* dan *RMSE* yang lebih baik dari parameter yang lain. Dalam model ini dapat dilihat 100 *epoch* pada *learning rate* 0.001 dengan *epoch* 50 nilainya lebih rendah sehingga dapat dikatakan Ketika *epoch* dinaikan akan terjadi *overfitting*.

Hasil dari pengujian parameter dataset history harga nikel dari model *Bidirectional Long Short-Term Memory* (BiLSTM) dengan *Learning Rate* 0.001 dan 0.01, *Epoch* 100 dan 50, *Batch Size* 32, dengan *optimizer* Adam menghasilkan hasil seperti pada Tabel IV.

TABEL IV Hasil Pengujian Menggunakan BiGRU

Learning Rate	Epoch	RMSE	R2 Score
0.001	50	0.026669	0.848378
0.01	50	0.031603	0.787027
0.001	100	0.025267	0.863866
0.01	100	0.037897	0.693921

Tabel IV dapat dikatakan bahwa model BiLSTM dengan parameter *learning rate* 0.001 dan *epoch* 100 merupakan parameter terbaik dengan menunjukan nilai *R2 score* dan *RMSE* yang lebih baik dengan parameter yang lain. Pada model BiLSTM dengan parameter *learning rate* 0.01 dengan *epoch* 100 menunjukan penurunan

dibandingkan parameter yang menggunakan *epoch* 50.

Hasil dari pengujian parameter dataset history harga nikel dari model *Bidirectional Gated Recurrent Unit* (BiGRU) dengan *Learning Rate* 0.001 dan 0.01, *Epoch* 100 dan 50, *Batch Size* 32, dengan *optimizer* Adam menghasilkan hasil seperti pada Tabel V.

TABEL V Hasil Pengujian Menggunakan BiGRU

Learning Rate	Epoch	RMSE	R2 Score
0.001	50	0.024735	0.86962
0.01	50	0.027932	0.833746
0.001	100	0.027352	0.84058
0.01	100	0.038112	0.690372

Berdasarkan Tabel V dapat di katakan bahwa model BiGRU dengan parameter *learning rate* 0.001 dan *epoch* 50 merupakan parameter terbaik dengan menunjukan nilai *R2 score* dan *RMSE* yang lebih baik dengan parameter yang lain. Sama halnya seperti BiLSTM pada model BiGRU juga terjadi penurunan pada parameter *learning rate* 0.01 dengan *epoch* 100 dibandingkan dengan parameter yang menggunakan *epoch* 50. Kemungkinan hal ini dapat terjadi karena model Bidirectional kurang bisa beradaptasi dengan *learning rate* tinggi yang mengakibatkan *overfitting*.



Gambar 6. Harga Aktual dan Prediksi model LSTM



Gambar 7. Harga Aktual dan Prediksi Model GRU



Gambar 8. Harga Aktual dan Prediksi Menggunakan BiLSTM



Gambar 9. Harga Aktual dan Prediksi Menggunakan BiGRU

Dari semua hasil terbaik dari setiap model kemudian akan di dibandingkan untuk mendapatkan model dengan parameter terbaik seperti pada Tabel VI.

TABEL VI Perbandingan Hasil dari Setiap Model

Model	Learning Rate	Epoch	RMSE	R2 Score
LSTM	0.001	100	0.025496	0.861417
GRU	0.001	50	0.027439	0.839502
BiLSTM	0.001	100	0.025267	0.863866
BiGRU	0.001	50	0.024735	0.86962

Tabel VI dapat dikatakan *learning rate* 0.001 merupakan *learning rate* terbaik di setiap model. Epoch 100 bekerja baik pada model LSTM dan BiLSTM sedangkan *epoch* 50 baik pada model GRU dan BiGRU. BiGRU dengan *Learning rate* 0.001 dan *epoch* 50 menunjukan nilai R2 score paling tinggi dan nilai RMSE yang rendah sehingga dapat dikatakan model BiGRU merupakan model terbaik untuk melakukan prediksi harga nikel.

4. KESIMPULAN

Dengan data 3920 baris dari 7 Juli 2008 hingga 3 Juni 2024, model LSTM, GRU, BiLSTM, dan BiGRU digunakan untuk memprediksi harga nikel historis. Mengacu pada Tabel VI dapat dikatakan *learning rate* 0.001 merupakan *learning rate* terbaik di setiap model. *Epoch* 100 bekerja baik pada model LSTM dan BiLSTM sedangkan *epoch* 50 baik pada model GRU dan BiGRU. BiGRU dengan *Learning rate* 0.001 dan *epoch* 50 menunjukan nilai R2 score paling tinggi dengan nilai 0.86962 dan nilai RMSE yang rendah dengan nilai 0.024735 sehingga dapat dikatakan model BiGRU merupakan model terbaik untuk melakukan prediksi harga nikel. Sedangkan model LSTM dengan parameter *learning rate* 0.01 dan *epoch* 50 menjadi model paling kurang baik dengan nilai R2 score yang paling rendah dengan nilai 0.618355 dan RMSE yang paling tinggi dari model lain yaitu dengan nilai 0.042335.

Daftar Pustaka:

- [1] F. Menz, M. Bauer, O. Böse, M. Pausch, And M. A. Danzer, "Investigating The Thermal Runaway Behaviour Of Fresh And Aged Large Prismatic Lithium-Ion Cells In Overtemperature Experiments," *Batteries*, Vol. 9, No. 3, Mar. 2023, Doi: 10.3390/Batteries9030159.
- [2] X. Zhou *Et Al*, "Risk Transmission Of Trade Price Fluctuations From A Nickel Chain Perspective: Based On Systematic Risk Entropy And Granger Causality Networks," *Entropy*, Vol. 24, No. 9, Sep. 2022, Doi: 10.3390/E24091221.
- [3] B. Lim, H. S. Kim, And J. Park, "Implicit Interpretation Of Indonesian Export Bans On Lme Nickel Prices: Evidence From The Announcement Effect," *Risks*, Vol. 9, No. 5, May 2021, Doi: 10.3390/Risks9050093.
- [4] R. S. Ekhlakov And V. A. Sudakov, "Forecasting The Cost Of Quotes Using Lstm & Gru Networks," *Keldysh Institute Preprints*, No. 17, Pp. 1–13, 2022, Doi: 10.20948/Prepr-2022-17.
- [5] A. Muhammad Raihan And J. Ceilendra Saksana, "Analysis Of Stock Price Index Volatility In Indonesia Using Macroeconomic Variables And Global Economic Uncertainty Index," 2023. Doi: <https://doi.org/10.24252/Assets.V13i1.37616>.
- [6] E. Ahmadzadeh, H. Kim, O. Jeong, N. Kim, And I. Moon, "A Deep Bidirectional Lstm-Gru Network Model For Automated

- Ciphertext Classification," *Ieee Access*, Vol. 10, Pp. 3228–3237, 2022, Doi: 10.1109/Access.2022.3140342.
- [7] T. Lees *Et AL*, "Benchmarking Data-Driven Rainfall-Runoff Models In Great Britain: A Comparison Of Long Short-Term Memory (Lstm)-Based Models With Four Lumped Conceptual Models," *Hydrol Earth Syst Sci*, Vol. 25, No. 10, Pp. 5517–5534, Oct. 2021, Doi: 10.5194/Hess-25-5517-2021.
- [8] M. Haris, "Analysis Of The Application Of Hyperparameter Tuning In Machine Learning To Increase The Accuracy Of Sales-Level Prediction," 2024. [Online]. Available: [Http://E-Journal.Stmiklombok.Ac.Id/Index.Php/Jir eissn.2620-6900](http://E-Journal.Stmiklombok.Ac.Id/Index.Php/Jir eissn.2620-6900)
- [9] K. H. Suradiradja, "Algoritme Machine Learning Multi-Layer Perceptron Dan Recurrent Neural Network Untuk Prediksi Harga Cabai Merah Besar Di Kota Tangerang," *Faktor Exacta*, Vol. 14, No. 4, P. 194, Jan. 2022, Doi: 10.30998/Faktorexacta.V14i4.10376.
- [10] Y. Karyadi And H. Santoso, "Prediksi Kualitas Udara Dengan Metoda Lstm, Bidirectional Lstm, Dan Gru," *Jurnal Teknik Informatika Dan Sistem Informasi*, Vol. 9, No. 1, Pp. 671–684, 2022.
- [11] F. Ferdiawan, B. Hartono, J. T. Lomba, J. No, And S. 50241, "Deteksi Suara Chord Piano Menggunakan Metode Convolutional Neural Network," 2022. [Online]. Available: [Http://E-Journal.Stmiklombok.Ac.Id/Index.Php/Jir e](http://E-Journal.Stmiklombok.Ac.Id/Index.Php/Jir e)
- [12] U. I. Arfianti, D. C. R. Novitasari, N. Widodo, Moh. Hafiyusholeh, And W. D. Utami, "Sunspot Number Prediction Using Gated Recurrent Unit (Gru) Algorithm," *Ijccs (Indonesian Journal Of Computing And Cybernetics Systems)*, Vol. 15, No. 2, P. 141, Apr. 2021, Doi: 10.22146/Ijccs.63676.
- [13] I. P. G. A. Sudiatmika, I. M. A. W. Putra, And W. W. Artana, "The Implementation Of Gated Recurrent Unit (Gru) For Gold Price Prediction Using Yahoo Finance Data: A Case Study And Analysis," *Brilliance: Research Of Artificial Intelligence*, Vol. 4, No. 1, Pp. 176–184, Jun. 2024, Doi: 10.47709/Brilliance.V4i1.3865.
- [14] Z. M. Shaikh And S. Ramadass, "Unveiling Deep Learning Powers: Lstm, Bilstm, Gru, Bigru, Rnn Comparison," *Indonesian Journal Of Electrical Engineering And Computer Science*, Vol. 35, No. 1, Pp. 263–273, Jul. 2024, Doi: 10.11591/Ijeecs.V35.I1.Pp263-273.
- [15] D. I. Puteri, "Implementasi Long Short Term Memory (Lstm) Dan Bidirectional Long Short Term Memory (Bilstm) Dalam Prediksi Harga Saham Syariah," *Euler: Jurnal Ilmiah Matematika, Sains Dan Teknologi*, Vol. 11, No. 1, Pp. 35–43, May 2023, Doi: 10.34312/Euler.V11i1.19791.