



PEMODELAN DAN ANALISIS AKURASI RNN (*RECURRENT NEURAL NETWORK*) PADA PREDIKSI HARGA BATU BARA DAN MINYAK MENTAH

**Muhammad Faiz Alil Himmah, Ngatini*, Doni Setio Pambudi,
Puji Andayani**

Departemen Informatika, Universitas Internasional Semen Indonesia (UISI)
Kompleks PT. Semen Indonesia (Persero) Tbk, Jl. Veteran, Kb. Dalem, Sidomoro,
Kebomas, Gresik, Jawa Timur 61122

*email: ngatini@uisi.ac.id

ABSTRACT

Crude oil and coal are fundamental energy sources for global industrialization. The stability of their prices plays an important role in supporting global economic growth. The increasing demand for crude oil and coal to meet the energy needs of various countries significantly affects price fluctuations in the global market. Crude oil and coal price volatility also exhibits a strong positive relationship, where shocks in the oil market propagate to the coal market. Therefore, reliable and accurate predictive models are essential for forecasting the price movements of these energy commodities. This study compares the performance of two Recurrent Neural Network (RNN) models, namely Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU), an approach not previously undertaken. Predictions were performed on daily time-series data covering the period from 2015 to 2026. Model performance was evaluated using Mean Absolute Percentage Error (MAPE), Mean Absolute Error (MAE), Root Mean Square Error (RMSE) and R^2 . The optimal parameters used in this study were 64 units, a dropout rate of 0.2, batch size of 32, 100 epochs, and a 60-step time window. The results indicate that the GRU model outperformed the LSTM model in terms of prediction accuracy and computational time. The proposed predictive model can support energy market risk analysis, investment planning, and policy evaluation related to the stability of energy commodity prices.

Keywords: RNN, LSTM, GRU, Crude Oil, Coal

ABSTRAK

Minyak mentah (*Crude Oil*) dan batu bara (*coal*) merupakan sumber energi fundamental dalam bidang industrialisasi secara global. Pentingnya kedua sumber energi tersebut dalam mendukung pertumbuhan ekonomi global sangat bergantung pada kestabilan harga keduanya. Tingginya kebutuhan minyak mentah dan batu bara dalam memenuhi kebutuhan energi berbagai negara berpengaruh pada fluktuasi harga di pasar global. Volatilitas harga minyak mentah dan batu bara memiliki hubungan positif yang kuat, dimana guncangan pada pasar minyak merambat ke pasar batu bara. Dalam upaya untuk memproyeksikan pergerakan harga minyak dan batu bara, penggunaan model prediktif yang handal dan akurat menjadi sangat penting. Pada penelitian ini dilakukan perbandingan prediksi harga minyak mentah dan batu bara dengan dua model RNN (*Recurrent Neural Network*) yaitu LSTM dan GRU yang belum dilakukan pada penelitian sebelumnya. Prediksi dilakukan pada data *time series* dalam satuan hari dengan menggunakan data komoditas dari tahun 2015-2026. Evaluasi performa dilakukan dengan menggunakan nilai MAPE, MAE, RMSE dan R^2 . Parameter optimal yang digunakan meliputi *units* 64, *dropout* 0.2, *batch size* 32, *epoch* 100 dan *time step* 60 langkah ke depan. Hasil menunjukkan bahwa GRU lebih baik dibandingkan LSTM dari segi akurasi dan waktu komputasi. Model prediksi yang dihasilkan dapat dimanfaatkan untuk analisis

risiko pasar energi, perencanaan investasi, serta evaluasi kebijakan terkait stabilitas harga komoditas energi.

Kata kunci: RNN, LSTM, GRU, Minyak Mentah, Batu Bara


Received: 2026-03-30; Accepted: 2026-07-01; Published: 2026-07-03

PENDAHULUAN

Sumber daya alam, baik yang dapat diperbarui seperti energi surya dan angin, maupun yang tidak dapat diperbarui seperti batu bara, gas alam, dan minyak bumi, memiliki peran yang signifikan dalam sektor industri. Minyak bumi dan batu bara merupakan bahan bakar fosil yang tidak dapat diperbarui (National Geographic Society, 2023) dan dapat diolah menjadi beragam produk melalui proses penyulingan. Hasil turunan produk tersebut memiliki peran dominan dalam mempengaruhi perekonomian global (Wen *et al.*, 2024). Dampak paling buruknya dapat mempengaruhi kondisi inflasi di suatu negara yang memiliki ketergantungan tinggi, seperti di Indonesia (Rahmania & Anis, 2024), Nepal (Sharma & Shrestha, 2023), negara-negara di Afrika (Bala & Chin, 2018) hingga Jerman dan Uni Eropa yang sangat tergantung terhadap impor sumber energi tersebut (Wettengel, 2024). Ketergantungan juga dirasakan oleh Amerika yang bahkan mempengaruhi kebijakan luar negerinya (Council on Foreign Relations, 2024) serta di negara China dimana industri minyak bumi memainkan peran penting dalam perkembangan ekonomi (Chen *et al.*, 2020).

Besarnya permintaan dan pasokan memukul perekonomian global dalam beberapa tahun terakhir (Li & Miu, 2024) yang berdampak pada peningkatan harga komoditi. Fluktuasi harga minyak mentah dan batu bara di dunia menjadi salah satu faktor signifikan yang memengaruhi perekonomian khususnya di berbagai negara pada periode tertentu (Safitri *et al.*, 2022). Data harga minyak mentah yang digunakan dalam penelitian ini adalah minyak mentah Brent, sedangkan data harga batu bara berjenis Newcastle. Menurut Gambar 1 harga minyak mentah mengalami penurunan drastis hingga mencapai titik terendah sekitar \$20 per barel pada April 2020, menurun tajam dari harga sebelumnya. Selanjutnya sepanjang 2020-2021, harga minyak mentah perlahan mulai naik sekitar \$70 per barel selanjutnya pada tahun 2022, kemudian kembali mengalami volatilitas signifikan dan awal tahun 2023 harga minyak mentah naik kembali di atas \$70 per barel dan terus meningkat hingga mendekati \$90 per barel pada pertengahan tahun, mencapai puncaknya sekitar \$90 per barel pada September 2023. Sedangkan harga batu bara mengalami peningkatan hingga pertengahan tahun 2022, kemudian mengalami fluktuasi harga dengan harga terendah mulai bulan Januari 2020 sampai Desember 2023 sebesar \$48,5 per ton dan harga maksimum sebesar \$457,8 per ton. Fluktuasi harga dari

batu bara memiliki dampak yang signifikan terhadap harga minyak mentah (Zamani, 2016) dan diprediksi akan terus meningkat dalam dekade ke depan (Economist Intelligence, 2023).



Gambar 1. Harga Minyak Mentah (*Brent Oil*) dan Batu Bara (*Newcastle Coal*) dalam \$/ton (Trading Economics, 2024)

Dua sumber energi tersebut memiliki peran kunci dalam ekonomi global. Untuk meramalkan harga kedua komoditas ini, diperlukan penelitian lebih lanjut dengan menggunakan model prediktif yang handal. *Deep learning* merupakan sebuah model yang dapat digunakan untuk melakukan prediksi data *time series*, seperti harga minyak mentah (Zhao *et al.*, 2017). Data *time series* merupakan data deret waktu yang dicatat maupun diamati dalam interval waktu yang teratur seperti harian, mingguan, bulanan maupun tahunan (PhDs at Asian Institute of Management, 2023). Prediksi ataupun peramalan deret waktu menjadi alat pendukung keputusan utama (Delcea, 2026), dan model *deep learning* mampu mengatasi permasalahan nonlinearitas pada data deret waktu (Hyndman & Athanasopoulos, 2021). Beberapa model *Deep Learning* adalah *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU). LSTM merupakan modifikasi dari RNN (*Recurrent Neural Network*) (Hochreiter & Schmidhuber, 1997) yang dapat digunakan untuk menyelesaikan data *time series* (Gao *et al.*, 2024). Algoritma pembelajaran tersebut masuk ke dalam model *Deep Learning*, termasuk dengan GRU (Elmousaid *et al.*, 2024). Secara matematis, *Recurrent Neural Network* (RNN) memproses data sekuensial dengan menggabungkan input saat ini dengan memori dari langkah waktu sebelumnya. Inti dari RNN adalah *hidden state* yang diperbarui pada setiap langkah waktu melalui perkalian matriks bobot dan fungsi aktivasi non-linear (Manu, 2022).

Pada penelitian yang dilakukan oleh Ning *et al.*, 2022 tentang perbandingan prediksi produksi minyak dengan beberapa algoritma *Machine Learning* menunjukkan LSTM memiliki performa yang lebih baik dengan data historis *time series* yang tidak memiliki musiman (Ning *et al.*, 2022). Prediksi harga minyak

mentah menjadi cukup populer saat ini karena sangat berpengaruh signifikan terhadap pasar global (Zhang & Hong, 2022), khususnya bagi investor maupun pemerintahan dalam pengambilan kebijakan (Huang *et al.*, 2023). Beberapa diantaranya yaitu prediksi minyak mentah WTI menggunakan LSTM dengan Regressor Xgboost (Simsek *et al.*, 2024). Pada penelitian tersebut perhitungan akurasi dengan menggunakan MAE, MSE, RMSE, MAPE dan R^2 . Selain itu juga perbandingan prediksi antara LSTM dan GRU dengan kombinasi algoritma AdaBoost pada prediksi harga minyak mentah menunjukkan performa AdaBoost-GRU lebih baik (Busari & Lim, 2021). Pada penelitian lain dengan optimasi hiper parameter yang dilakukan dengan menggunakan metode *Deep Learning* menunjukkan GRU memiliki performa lebih baik dibandingkan LSTM (Sen & Dutta Choudhury, 2024). Selain prediksi minyak mentah, objek penelitian yang akan dianalisis kali ini adalah *coal* (batu bara). Tren harga batu bara mengalami lonjakan perubahan setelah pandemi Covid (Alam *et al.*, 2023) yang dapat diprediksi dengan menggunakan data *time series* (Wang *et al.*, 2024). Prediksi harga batu bara dapat dilakukan dengan menggunakan model *Deep Learning* (Alameer *et al.*, 2020), beberapa diantaranya adalah LSTM dan GRU. Berdasarkan hal tersebut, maka penulis mengimplementasikan kedua metode tersebut untuk memprediksi harga minyak mentah dan batu bara.

Penelitian ini bertujuan untuk menghasilkan prediksi harga yang akurat di masa depan, yang dapat dijadikan acuan dalam pengambilan keputusan strategis. Dengan prediksi yang tepat, para pelaku industri dapat mengelola risiko, mengoptimalkan portofolio investasi, dan merencanakan strategi bisnis yang lebih efektif. Diharapkan bahwa hasil penelitian ini dapat memberikan pemahaman yang lebih mendalam mengenai kelebihan model RNN yaitu LSTM dan GRU dalam memprediksi harga minyak mentah dan batu bara. Hasil penelitian ini tidak hanya akan membantu dalam meningkatkan pemahaman pembaca terhadap perilaku pasar minyak, tetapi juga dapat memberikan panduan praktis bagi pelaku pasar, analisis keuangan, dan pembuat kebijakan dalam membuat keputusan yang tepat dengan kondisi di tengah ketidakpastian pasar global.

TINJAUAN PUSTAKA

Recurrent Neural Networks (RNN)

RNN merupakan arsitektur *Deep Learning* yang masuk dalam kategori jaringan saraf dan dirancang untuk menangani data berurutan atau deret waktu (sekuensial). Rumus utamanya menghitung *hidden state* pada waktu t (H_t) dari input *time series* (x_t) dan *hidden state* sebelumnya H_{t-1} (Manu, 2022). Berikut merupakan persamaan umum dari RNN (Manu, 2022).

$$H_t = \tanh(W \cdot H_{t-1} + U \cdot x_t + b_1) \quad (1)$$

$$o_t = V \cdot H_t + b_2 \quad (2)$$

Dengan U , V dan W adalah bobot parameter serta b_1 dan b_2 adalah bias untuk *hidden state* dan *output* pada waktu t (o_t). Arsitektur ini menggunakan perulangan untuk mempertahankan memori informasi. Modifikasi dari RNN yaitu LSTM dan GRU yang dijelaskan berikut ini.

Long Short-Term Memory (LSTM)

LSTM merupakan modifikasi dari RNN untuk mengatasi masalah *vanishing gradient* pada RNN standar. Berikut merupakan persamaan umum dari LSTM (Manu, 2022).

Input gate (I_t): Fungsi ini menentukan berapa banyak informasi untuk dibaca dari inputan saat ini (x_i) dan *hidden state* sebelumnya (H_{t-1}).

$$I_t = \sigma(W_{xi} \cdot x_i + W_{hi} \cdot H_{t-1} + b_i) \quad (3)$$

Forget gate (F_t): Fungsi ini menentukan informasi yang dihilangkan atau dipertahankan dari *cell state* sebelumnya.

$$F_t = \sigma(W_{xf} \cdot x_i + W_{hf} \cdot H_{t-1} + b_f) \quad (4)$$

Output gate (O_t): Fungsi ini menentukan hasil dari *cell* saat ini.

$$O_t = \sigma(W_{xo} \cdot x_i + W_{ho} \cdot H_{t-1} + b_o) \quad (5)$$

Dengan W_{xi} , W_{xf} , W_{xo} , W_{hi} , W_{hf} , W_{ho} adalah parameter bobot dan b_i , b_f dan b_o adalah bias.

Pada *Input gate*, dibuat vektor nilai kandidat baru yang akan ditambahkan ke *state* ($\tilde{C}_t$).

$$\tilde{C}_t = \tanh(W_{xc} \cdot x_t + W_{hc} \cdot H_{t-1} + b_c) \quad (6)$$

W_{xc} dan W_{hc} adalah parameter bobot dan b_c merupakan bias. Berikutnya adalah pembaruan *cell state* dari *cell* lama (C_{t-1}) menjadi baru (C_t).

$$C_t = F_t \odot C_{t-1} + I_t \odot \tilde{C}_t \quad (7)$$

Dan menghitung nilai output *hidden state*

$$H_t = O_t \tanh(C_t) \quad (8)$$

Gated Recurrent Unit (GRU)

GRU merupakan modifikasi dari RNN yang memiliki struktur lebih sederhana dibandingkan LSTM, dengan parameter yang lebih sedikit dan waktu komputasi yang lebih cepat. Jika terdapat 3 *gate* pada LSTM, GRU hanya terdapat dua *gate* yaitu *reset gate* (R_t) dan *update gate* (U_t). Berikut penjelasan persamaan umumnya (Manu, 2022).

Reset gate: *gate* ini menentukan seberapa banyak informasi masa lalu yang harus diabaikan atau dilupakan.

$$R_t = \sigma(W_{xr} \cdot x_t + W_{hr} \cdot H_{t-1} + b_r) \quad (9)$$

Update gate: *gate* ini menentukan seberapa banyak informasi masa lalu yang dipertahankan untuk memproses informasi baru

$$U_t = \sigma(W_{xu} \cdot x_t + W_{hu} \cdot H_{t-1} + b_u) \quad (10)$$

Dengan W_{xr} , W_{xu} , W_{hr} , W_{hu} adalah parameter bobot serta b_r dan b_u adalah bias. Kemudian dihitung kandidat *hidden state* ($\widetilde{H}_t$) berikut.

$$\widetilde{H}_t = \tanh(W_{xh} \cdot x_t + W_{hh} \cdot R_t \odot H_{t-1} + b_h) \quad (11)$$

Dengan W_{xh} , W_{hh} adalah parameter bobot dan b_h merupakan bias. *Hidden state* akhir dihitung dengan menggunakan formula berikut.

$$H_t = U_t \odot H_{t-1} + (1 - U_t) \odot \widetilde{H}_t \quad (12)$$

METODE PENELITIAN

Metode penelitian adalah rangkaian langkah yang diambil oleh peneliti untuk melaksanakan penelitian. Tahapan penelitian mencakup pengumpulan dan analisis data, penerapan LSTM dan GRU dalam memprediksi harga, serta analisis hasil dan perbandingan keduanya.

Pengumpulan Data

Pada tahap pengumpulan data, peneliti menggunakan data terkait harga minyak mentah (*Brent Crude Oil*) dan batu bara (*Newcastle Coal*) dari periode 1 Januari 2015 hingga 8 Juni 2026. Satuan harga dengan kategori *time series* atau data harian. Data ini diambil dari situs resmi <https://tradingeconomics.com>, dengan pembagian data training yaitu tahun 2015-2021, data *validation* dari tahun 2022-2023 dan data *testing* yaitu tahun 2024-2026. Tidak ada random split sehingga data *leakage* dapat dihindari. Setelah data berhasil diperoleh, penulis melakukan *pre-processing* untuk mengolah data sehingga dapat digunakan sesuai dengan kebutuhan penelitian, khususnya terkait data waktu dan harga. Jumlah observasi pada masing-masing split data dapat dilihat pada Tabel 1 berikut.

Tabel 1. Jumlah Observasi pada Pembagian Data

Dataset	Split	Baris	Tanggal
Minyak Mentah	<i>Train</i>	1.783	2-1-2015 hingga 31-12-2021
Minyak Mentah	<i>Validation</i>	503	3-1-2022 hingga 29-12-2023
Minyak Mentah	<i>Test</i>	615	2-1-2024 hingga 8-6-2026
Batu Bara	<i>Train</i>	1.803	2-1-2015 hingga 31-12-2021
Batu Bara	<i>Validation</i>	515	3-1-2022 hingga 29-12-2023
Batu Bara	<i>Test</i>	628	2-1-2024 hingga 8-6-2026

Analisis Data

Setelah pengumpulan data, penulis melakukan analisis mendalam terhadap data historis minyak mentah (*crude oil*) dan batu bara (*coal*), dengan fokus pada dua variabel: tanggal (*date*) dan harga (*price*). Analisis dimulai dengan pembersihan data melalui proses *pre-processing*, termasuk penggunaan teknik

interpolasi untuk mengisi nilai-nilai yang hilang dalam dataset, tahapan ini penting dilakukan dalam analisis data *time series*.

Implementasi Metode LSTM dan GRU

LSTM adalah salah satu metode peramalan *time series* dan merupakan modifikasi dari *Recurrent Neural Network* (RNN) yang mampu mempertahankan informasi dalam jangka waktu yang lama (Masum *et al.*, 2020). Prosedur peramalan harga minyak mentah (*Crude Oil*) dan batu bara (*Coal*) menggunakan metode *Long Short-Term Memory* (LSTM) melibatkan beberapa langkah utama. Dimulai dengan inisiasi proses prediksi dan pengumpulan data *time series* x_t , data ini kemudian divisualisasikan untuk memahami tren dan pola. Dataset dibagi menjadi dua bagian untuk pelatihan dan pengujian. Model LSTM diinisiasi dan dilatih dengan dataset pelatihan menggunakan algoritma optimasi adam untuk mendapatkan parameter optimal. Model *hidden state* dibentuk melalui formula pada Persamaan (3) hingga Persamaan (8). Setelah itu, model dilatih ulang untuk meningkatkan kinerja dan kemudian digunakan untuk prediksi pada dataset pengujian. Proses diakhiri dengan analisis dan evaluasi hasil prediksi. Sedangkan prosedur peramalan harga minyak mentah dengan model GRU dimulai dengan pengumpulan dan visualisasi data *time series* x_t . Data dibagi untuk pelatihan dan pengujian. Model GRU diinisiasi dan dilatih menggunakan algoritma optimasi adam, kemudian digunakan untuk memprediksi data pengujian. GRU merupakan pengembangan dari metode LSTM yang memiliki struktur sederhana dengan parameter yang terbatas (Chung *et al.*, 2014). Model *hidden state* dibentuk melalui formula pada Persamaan (9) hingga Persamaan (12). Penelitian sebelumnya berhasil menggunakan kedua metode (LSTM dan GRU) untuk prediksi (Lahmiri, 2026).

Tahapan selanjutnya adalah perhitungan akurasi prediksi dari kedua model yang diukur dengan MAE (*Mean Absolute Error*), MAPE (*Mean Absolute Percentage Error*), RMSE (*Root Mean Square Error*), dan R^2 serta hasil prediksi divisualisasikan untuk dilakukan analisis dan evaluasi akhir. Perhitungan akurasinya adalah sebagai berikut (Chai & Draxler, 2014) (Armstrong & Collopy, 1992).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (13)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (15)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (16)$$

Dengan n adalah jumlah data. y_i adalah nilai aktual, $\hat{y}_i$ adalah nilai prediksi, $\bar{y}_i$ adalah nilai rata-rata y ke i .

HASIL DAN PEMBAHASAN


Implementasi metode LSTM dan GRU diawali dengan tahapan pengolahan data yaitu diperlukan terlebih dahulu pembuatan dan normalisasi data. Data harga minyak mentah dan batu bara disimpan dalam format csv yang kemudian dinormalisasi dengan menggunakan 'MinMaxScaler'. Normalisasi dilakukan untuk mengubah nilai-nilai harga menjadi rentang antara 0-1, hal ini membantu dalam meningkatkan stabilitas dan konvergensi model LSTM dan GRU selama pelatihan. Selanjutnya, dilakukan pemisahan antara data *training*, data *validation* dan data *testing*. *Train* digunakan untuk membangun pola historis, *validation* digunakan untuk memantau generalisasi selama training, dan *test* digunakan untuk evaluasi akhir pada periode yang tidak dilihat model selama pelatihan.

Pelatihan model LSTM dan GRU diimplementasikan menggunakan *Keras Sequential* dari TensorFlow. Model LSTM yang dibangun terdiri dari dua *layer* LSTM berturut-turut, masing-masing diikuti oleh *Layer Dropout* untuk mengurangi *overfitting*. Detail parameter model yang digunakan dapat dilihat pada Tabel 2 berikut ini. *Layer dense* terakhir digunakan sebagai output. Model dikompilasi dengan optimizer Adam dan menggunakan *mean squared error* sebagai fungsi *loss* untuk menyesuaikan masalah regresi. Sedangkan model GRU dibangun dengan struktur yang mirip dengan model LSTM, tetapi menggunakan layer GRU sebagai pengganti LSTM. Model GRU terdiri dari dua layer GRU berturut-turut, di mana setiap layer juga diikuti oleh *layer Dropout* untuk mengurangi risiko *overfitting*. *Layer Dropout* membantu mematikan sebagian neuron selama pelatihan sehingga model tidak terlalu bergantung pada pola tertentu di data *training*. *Layer dense* terakhir digunakan sebagai *output* untuk menghasilkan prediksi harga dari model. Setelah melatih model menggunakan data *training*, selanjutnya data *validation* digunakan selama proses pelatihan untuk memantau performa dan menyesuaikan pengaturan model, kemudian model dievaluasi menggunakan data *testing* untuk memperkirakan performanya dalam memprediksi harga. Selanjutnya dilakukan evaluasi dengan menggunakan *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Percentage Error* (MAPE).

Tabel 2. Parameter Model LSTM dan GRU

Parameter	Nilai
<i>Time_step</i>	jumlah jangka waktu sebelumnya untuk memprediksi langkah berikutnya
<i>Units</i>	Jumlah unit neuron
<i>Dropout</i>	Rasio unit yang di-dropout untuk mencegah <i>overfitting</i>
<i>Batch_size</i>	Jumlah sampel yang diproses sebelum model diperbarui
<i>Epoch</i>	Jumlah iterasi pelatihan

Untuk mengevaluasi proses pembelajaran model, dilakukan observasi terhadap perubahan nilai *training loss* dan *validation loss* selama proses *training*. Grafik *learning curve* digunakan untuk melihat kemampuan model dalam mempelajari pola data historis harga batu bara dan minyak mentah. Berdasarkan Gambar 2, dapat dilihat grafik penurunan pada *training loss* untuk minyak mentah (*Brent Oil*) GRU dan LSTM dengan *validation loss* mengalami naik turun walaupun meningkat di akhir. Pada *learning curve* *Brent Oil* GRU terdapat *gap train-validation*, tetapi lebih terkendali dibanding *Brent LSTM*. Sedangkan *training loss* untuk batu bara (*Newcastle Coal*) GRU cepat turun dan sangat rendah, sedangkan LSTM juga sangat rendah setelah *epoch* awal dan hampir datar mendekati nol. Untuk *validation loss* keduanya di atas *train loss* dengan fluktuasi yang cukup besar. Keduanya memiliki gap sangat lebar antara *train* dan *validation loss* pada *learning curve*. Dari Visualisasi tersebut dapat disimpulkan bahwa model *Brent Oil* GRU tidak terlihat *overfitting* kuat, sedangkan yang lainnya *overfitting* sedang.




Gambar 2. *Learning Curve*


((a). Minyak mentah (*Brent Oil*) GRU; (b). Minyak mentah (*Brent Oil*) LSTM;
(c). Batu Bara (*Newcastle Coal*) GRU; (d). Batu Bara (*Newcastle Coal*) LSTM)

Grafik pada Gambar 3 dan 4 berikut menunjukkan perbandingan kinerja model LSTM dan GRU dalam memprediksi harga dua komoditas energi, yaitu batu bara dan minyak mentah. Setiap grafik menampilkan data harga aktual yang digunakan sebagai acuan, serta hasil prediksi pada data pelatihan, validasi dan pengujian. Secara umum, baik model LSTM maupun GRU menunjukkan hasil yang cukup baik dalam mengikuti tren data aktual, meskipun terdapat sedikit deviasi antara prediksi dan data riil. Dalam Penelitian ini, dilakukan perbandingan performa antara dua Metode *Recurrent Neural Network* (RNN), yaitu LSTM dan

GRU, dalam memprediksi harga komoditas batu bara dan minyak mentah. Evaluasi dilakukan dengan perhitungan MAE, RMSE, dan MAPE, dan R^2 yang ditunjukkan pada Tabel 3.



Gambar 3. Perbandingan Prediksi Harga Batu Bara



Gambar 4. Perbandingan Prediksi Harga Minyak Mentah

Tabel 3. Perbandingan Error Prediksi Data *Testing*

Komoditas	Metode	MAE	RMSE	MAPE	R^2
Batu Bara	LSTM	4.1273	5.0175	3.3773	0.8985
	GRU	1.3865	2.3085	1.1269	0.9785
Minyak Mentah	LSTM	3.6137	5.3349	4.3491	0.8411
	GRU	2.8268	4.1328	3.3830	0.9046

Pada Tabel 3 menunjukkan bahwa untuk pengujian data batu bara dengan metode GRU memiliki nilai *error* yang lebih rendah yaitu 1.3865 untuk MAE dan

2.3085 untuk RMSE, dengan R^2 nilainya mendekati 1 yaitu 0.9785. Selain itu, dalam hal persentase *error* (MAPE), GRU juga lebih unggul dengan nilai 1.1269%, sedangkan MAPE LSTM sebesar 3.3773%. Dengan demikian, GRU menunjukkan kemampuan yang lebih baik dalam memprediksi harga batu bara berdasarkan data uji, dibandingkan dengan LSTM. Untuk prediksi harga minyak mentah, metode GRU juga menunjukkan performa yang lebih baik yaitu 2.8268 untuk MAE dan 4.1328 untuk RMSE, sedangkan LSTM memiliki nilai yang sedikit lebih tinggi, yaitu 3.6137 untuk MAE dan 5.3349 untuk RMSE. Dalam hal persentase *error* (MAPE), GRU lebih unggul yaitu 3.3830%, sedangkan LSTM 4.3491% serta nilai R^2 dari GRU juga mendekati 1 yaitu 0.9046. Dengan demikian, GRU menunjukkan kemampuan yang lebih baik dalam memprediksi harga minyak mentah berdasarkan data uji, dibandingkan dengan LSTM. Nilai *error* yang lebih rendah menunjukkan bahwa GRU mampu menghasilkan prediksi yang lebih dekat dengan nilai aktual dibandingkan LSTM.

Secara matematis, performa GRU yang lebih baik dapat dijelaskan melalui struktur arsitekturnya yang lebih sederhana dibandingkan LSTM. GRU hanya menggunakan dua mekanisme gerbang (*update gate* dan *reset gate*), sedangkan LSTM menggunakan tiga gerbang utama (*input gate*, *forget gate*, dan *output gate*) serta *cell state* yang terpisah. Struktur yang lebih sederhana menyebabkan jumlah parameter yang harus dipelajari GRU lebih sedikit dibandingkan LSTM. Dengan jumlah parameter yang lebih sedikit, ruang optimasi menjadi lebih kecil sehingga proses pelatihan dapat berlangsung lebih efisien dan stabil. Selain itu, risiko *overfitting* juga dapat berkurang karena model tidak perlu menyesuaikan terlalu banyak bobot terhadap pola-pola spesifik pada data pelatihan. Kemampuan model dalam menangkap dependensi temporal jangka panjang (*long-term dependency*) juga menjadi faktor penting pada prediksi harga komoditas. Data harga batu bara dan minyak mentah memiliki karakteristik *time series* yang dipengaruhi oleh kondisi pasar pada periode-periode sebelumnya, sehingga informasi historis perlu dipertahankan dalam proses prediksi. Baik LSTM maupun GRU dirancang untuk mengatasi permasalahan *vanishing gradient* yang umum terjadi pada RNN konvensional. Namun, mekanisme *update gate* pada GRU memungkinkan informasi penting dari periode sebelumnya dipertahankan secara lebih langsung tanpa memerlukan *cell state* terpisah seperti pada LSTM. Hal ini menyebabkan propagasi informasi temporal menjadi lebih efisien sehingga pola tren dan fluktuasi harga dapat dipelajari dengan lebih baik.

Pada Gambar 3 dan Gambar 4 menampilkan grafik prediksi GRU pada data batu bara maupun minyak mentah tampak mengikuti pola pergerakan data aktual dengan lebih konsisten dibandingkan LSTM, terutama pada periode pengujian. Pada data batu bara yang memiliki volatilitas tinggi akibat lonjakan dan penurunan harga yang tajam, GRU mampu mempertahankan kedekatan pola prediksi terhadap data aktual sehingga menghasilkan *error* yang lebih kecil dibandingkan LSTM. Sementara itu, pada data minyak mentah, GRU tetap menunjukkan hasil akurasi

yang lebih baik pula. Dari sisi kompleksitas komputasi, jumlah parameter yang lebih sedikit pada GRU menyebabkan kebutuhan memori dan waktu pelatihan menjadi lebih rendah dibandingkan LSTM. Kompleksitas komputasi yang lebih ringan membuat proses optimasi lebih cepat dan mengurangi kemungkinan terjadinya ketidakstabilan selama pelatihan. Oleh karena itu, hasil penelitian ini menunjukkan bahwa GRU tidak hanya memberikan nilai *error* yang lebih rendah secara empiris, tetapi juga memiliki keunggulan teoritis dalam efisiensi parameter, kemampuan mempertahankan informasi temporal, serta kompleksitas komputasi yang lebih rendah. Kombinasi karakteristik tersebut menjadikan GRU lebih efektif untuk memodelkan pola harga komoditas batu bara dan minyak mentah pada penelitian ini. Kemudian Pada tahap residual analisis, seluruh model masih memiliki residual yang tidak normal dan autocorrelation yang cukup kuat. Hal ini dikarenakan adanya perubahan volatilitas, lonjakan harga, dan kejadian pasar ekstrem dari harga minyak mentah maupun batu bara. Tentu hal tersebut perhatian penting untuk dilakukan optimalisasi pada penelitian selanjutnya.

KESIMPULAN

Berdasarkan hasil metode LSTM dan GRU dalam memprediksi harga minyak mentah (*crude oil*) dan batu bara (*coal*), dapat ditarik kesimpulan terkait kinerja dan karakteristik kedua metode tersebut. Secara keseluruhan, baik LSTM maupun GRU adalah metode yang cukup baik untuk prediksi dengan persentase *error* MAPE di bawah 5%. GRU menunjukkan kinerja yang lebih baik dalam hal akurasi prediksi dan efisiensi komputasi, menjadikannya pilihan yang lebih baik dengan sumber daya komputasi yang terbatas. Namun, LSTM tetap relevan untuk kasus di mana ketergantungan jangka panjang sangat penting dan sumber daya komputasi tidak menjadi kendala utama. Secara matematis, kinerja GRU yang lebih baik dipengaruhi oleh jumlah parameter yang lebih sedikit sehingga proses optimasi menjadi lebih efisien, risiko *overfitting* dapat diminimalkan, serta kemampuan dalam menangkap dependensi temporal tetap terjaga. Penelitian selanjutnya dapat difokuskan pada optimasi hyperparameter dan pengembangan model hybrid untuk meningkatkan akurasi prediksi serta kemampuan model dalam menangkap pola data yang lebih kompleks maupun prediksi multivariat.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Lembaga Penelitian dan Pengabdian kepada Masyarakat Universitas Internasional Semen Indonesia (UISI) atas dukungannya sehingga penelitian ini dapat terselesaikan dengan baik

REFERENSI

Alam, M. S., Murshed, M., Manigandan, P., Pachiyappan, D., & Abduvaxitovna, S. Z. (2023). Forecasting Oil, Coal, and Natural Gas Prices in the Pre-and

- Post-COVID Scenarios: Contextual Evidence from India Using Time Series Forecasting Tools. *Resources Policy*, 81, 103342. <https://doi.org/https://doi.org/10.1016/j.resourpol.2023.103342>
- Alameer, Z., Fathalla, A., Li, K., Ye, H., & Jianhua, Z. (2020). Multistep-Ahead Forecasting of Coal Prices using a Hybrid Deep Learning Model. *Resources Policy*, 65, 101588. <https://doi.org/https://doi.org/10.1016/j.resourpol.2020.101588>
- Armstrong, J. S., & Collopy, F. (1992). Error Measures for Generalizing about Forecasting Methods: Empirical Comparisons. In *International Journal of Forecasting* (Vol. 8).
- Bala, U., & Chin, L. (2018). Asymmetric Impacts of Oil Price on Inflation: An Empirical Study of African Opec Member Countries. *Energies*, 11(11). <https://doi.org/10.3390/en11113017>
- Busari, G. A., & Lim, D. H. (2021). Crude Oil Price Prediction: A Comparison between AdaBoost-LSTM and AdaBoost-GRU for Improving Forecasting Performance. *Computers & Chemical Engineering*, 155, 107513. <https://doi.org/https://doi.org/10.1016/j.compchemeng.2021.107513>
- Chai, T., & Draxler, R. R. (2014). Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)? – Arguments Against Avoiding RMSE in the Literature. *Geoscientific Model Development*, 7(3), 1247–1250. <https://doi.org/10.5194/gmd-7-1247-2014>
- Chen, S.-Y., Zhang, Q., McLellan, B., & Zhang, T.-T. (2020). Review on the Petroleum Market in China: History, Challenges and Prospects. *Petroleum Science*, 17(6), 1779–1794. <https://doi.org/10.1007/s12182-020-00501-6>
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling*. <http://arxiv.org/abs/1412.3555>
- Council on Foreign Relations. (2024). *Oil Dependence and U.S. Foreign Policy*. Council on Foreign Relations. <https://www.cfr.org/timeline/oil-dependence-and-us-foreign-policy>
- Delcea, C. (2026). Recent Advances in Time Series Forecasting Methods. *Applied Sciences*, 16(3). <https://doi.org/10.3390/app16031417>
- Economist Intelligence. (2023, July 10). *Fossil Fuel Demand to Continue Expanding this Decade*. Economist Intelligence. <https://www.eiu.com/n/fossil-fuel-demand-to-continue-expanding-this-decade/>
- Elmousaid, R., Drioui, N., Elgouri, R., Agueny, H., & Adnani, Y. (2024). Ultra-Short-Term Global Horizontal Irradiance Forecasting Based on a Novel and Hybrid GRU-TCN model. *Results in Engineering*, 23, 102817. <https://doi.org/https://doi.org/10.1016/j.rineng.2024.102817>
- Gao, B., Xu, J., Zhang, Z., Liu, Y., & Chang, X. (2024). Marine Diesel Engine Piston Ring Fault Diagnosis Based on LSTM and Improved Beluga Whale

- Optimization. *Alexandria Engineering Journal*, 109, 213–228. <https://doi.org/https://doi.org/10.1016/j.aej.2024.08.075>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Huang, W., Gao, T., Hao, Y., & Wang, X. (2023). Transformer-Based Forecasting for Intraday Trading in the Shanghai Crude Oil Market: Analyzing Open-High-Low-Close Prices. *Energy Economics*, 127, 107106. <https://doi.org/https://doi.org/10.1016/j.eneco.2023.107106>
- Hyndman, rob J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice (3rd ed)*. <https://otexts.com/fpp3/>
- Lahmiri, S. (2026). A Hybrid CNN-LSTM-GRU System Tuned by Whale Optimization Algorithm for Enhanced Gold and Brent Price Prediction. *Finance Research Open*, 2(1), 100100. <https://doi.org/10.1016/j.finr.2026.100100>
- Li, L., & Miu, P. (2024). Diversifying Crude Oil Price Risk with Crude Oil Volatility Index: The Role of Volatility-of-Volatility. *Journal of Commodity Markets*, 100425. <https://doi.org/10.1016/j.jcomm.2024.100425>
- Manu, Joseph. (2022). *Modern Time Series Forecasting with Python: Explore Industry-Ready Time Series Forecasting using Modern Machine Learning and Deep Learning*. Packt publishing limited.
- Masum, M., Shahriar, H., Haddad, H. M., & Alam, Md. S. (2020). r-LSTM: Time Series Forecasting for COVID-19 Confirmed Cases with LSTM Based Framework. *2020 IEEE International Conference on Big Data (Big Data)*, 1374–1379. <https://doi.org/10.1109/BigData50022.2020.9378276>
- National Geographic Society. (2023, October 19). *Fossil Fuels*. <https://education.nationalgeographic.org/resource/fossil-fuels/>
- Ning, Y., Kazemi, H., & Tahmasebi, P. (2022). A Comparative Machine Learning Study for Time Series Oil Production Forecasting: ARIMA, LSTM, and Prophet. *Computers & Geosciences*, 164, 105126. <https://doi.org/https://doi.org/10.1016/j.cageo.2022.105126>
- PhDs at Asian Institute of Management. (2023). *Time Series Analysis Handbook*. https://phdinds-aim.github.io/time_series_handbook
- Rahmania, S. T., & Anis, A. (2024). Dampak Guncangan Harga Minyak Dunia terhadap Dinamika Inflasi di Indonesia. *Jurnal Kajian Ekonomi dan Pembangunan*, 6(1), 13–20. <http://ejournal.unp.ac.id/students/index.php/epb/index>
- Safitri, M., Anwar, K., & Abbas, T. (2022). Pengaruh Harga Minyak Dunia, Inflasi, dan Ekspor Neto terhadap Pertumbuhan Ekonomi di Indonesia. *Jurnal Ekonomi Regional Unimal*, 5. https://ojs.unimal.ac.id/ekonomi_regional/index

- Sen, A., & Dutta Choudhury, K. (2024). Forecasting the Crude Oil Prices for Last Four Decades Using Deep Learning Approach. *Resources Policy*, 88, 104438. <https://doi.org/https://doi.org/10.1016/j.resourpol.2023.104438>
- Sharma, B., & Shrestha, A. (2023). Petroleum Dependence in Developing Countries with an Emphasis on Nepal and Potential Keys. *Energy Strategy Reviews*, 45, 101053. <https://doi.org/https://doi.org/10.1016/j.esr.2023.101053>
- Simsek, A. I., Bulut, E., Gur, Y. E., & Gültekin Tarla, E. (2024). A Novel Approach to Predict WTI Crude Spot Oil Price: LSTM-Based Feature Extraction with Xgboost Regressor. *Energy*, 309, 133102. <https://doi.org/https://doi.org/10.1016/j.energy.2024.133102>
- Trading Economics. (2024). *Crude oil*. Trading Economics. <https://tradingeconomics.com/>
- Wang, C., Xu, G., Sun, C., Xu, J., Xu, K., Jiang, L., Wang, Y., Su, S., Hu, S., & Xiang, J. (2024). Modeling and Forecasting of Coal Price Based on Influencing Factors and Time Series. *Journal of Cleaner Production*, 467, 143030. <https://doi.org/https://doi.org/10.1016/j.jclepro.2024.143030>
- Wen, D., Wang, H., Wang, Y., & Xiao, J. (2024). Crude Oil Futures and the Short-Term Price Predictability of Petroleum Products. *Energy*, 307, 132750. <https://doi.org/https://doi.org/10.1016/j.energy.2024.132750>
- Wettengel, J. (2024, April 3). *Germany, EU Remain Heavily Dependent on Imported Fossil Fuels*. Journalism for the Energy Transition. <https://www.cleanenergywire.org/factsheets/germanys-dependence-imported-fossil-fuels>
- Zamani, N. (2016). International Journal of Energy Economics and Policy the Relationship between Crude Oil and Coal Markets: A New Approach. *International Journal of Energy Economics and Policy*, 6(4), 801–805. <http://www.econjournals.com>
- Zhang, K., & Hong, M. (2022). Forecasting Crude Oil Price using LSTM Neural Networks. *Data Science in Finance and Economics*, 2(3), 163–180. <https://doi.org/10.3934/dsfe.2022008>
- Zhao, Y., Li, J., & Yu, L. (2017). A Deep Learning Ensemble Approach for Crude Oil Price Forecasting. *Energy Economics*, 66, 9–16. <https://doi.org/https://doi.org/10.1016/j.eneco.2017.05.023>