

# Penerapan Deep Learning Menggunakan Gated Recurrent Unit Untuk Memprediksi Harga Minyak Mentah Dunia

Nugroho Wahyu Saputra, Fitri Insani\*, Surya Agustian, Suwanto Sanjaya

Fakultas Sains dan Teknologi, Teknik Informatika, Universitas Islam Negeri Sultan Syarif Kasim Riau, Pekanbaru, Indonesia

Email: <sup>1</sup>11950115153@students.uin-suska.ac.id, <sup>2\*</sup>fitri.insani@uin-suska.ac.id, <sup>3</sup>surya.agustian@uin-suska.ac.id,

<sup>4</sup>suwantosanjaya@uin-suska.ac.id

Email Penulis Korespondensi: fitri.insani@uin-suska.ac.id

Submitted: 31/05/2023; Accepted: 27/06/2023; Published: 29/06/2023

**Abstrak**—Minyak mentah merupakan energi yang sangat dibutuhkan bagi seluruh dunia. Tiap negara tidak terlepas dari penggunaan minyak mentah untuk digunakan diberbagai sektor, seperti transportasi sehingga harga minyak mentah dunia merupakan variabel terpenting bagi dunia. Fluktuasi harga minyak akan menyebabkan berbagai permasalahan, seperti terjadinya inflasi, perubahan harga pasar, dan lain-lain. Oleh karena itu, prediksi harga minyak mentah dunia sangat penting sebagai pertimbangan untuk pengambilan keputusan. Penelitian ini mengimplementasikan deep learning dengan menggunakan model Gated Recurrent unit. Data yang digunakan adalah harga minyak brent crude oil dengan jumlah 5834 data, mulai dari 4 Januari 2000 hingga 19 Desember 2022. Adapun parameter yang digunakan adalah jumlah unit GRU, batch size, dan lookback. Model terbaik yang dihasilkan pada penelitian ini adalah model GRU dengan hyperparameter yang terdiri dari 30 lookback, 50 unit GRU, dan 256 batch size dengan menghasilkan nilai MAPE terendah diantara model yang lainnya yaitu sebesar 2,25%. Nilai MAPE tersebut menyatakan bahwa prediksi dengan model GRU dikatakan sangat baik dalam memprediksi harga minyak mentah dunia.

**Kata Kunci:** Deep Learning; Harga Minyak Mentah Dunia; Gated Recurrent Unit

**Abstract**—Crude oil is a much-needed energy for the whole world. Each country is inseparable from the use of crude oil for use in various sectors, such as transportation, so that the price of world crude oil is the most important variable for the world. Fluctuations in oil prices will cause various problems, such as inflation, changes in market prices, and others. Therefore, the prediction of world crude oil prices is very important as a consideration for decision making. This study implements deep learning using the Gated Recurrent unit model. The data used is the price of Brent crude oil with a total of 5834 data, starting from January 4, 2000 to December 19, 2022. The parameters used are the number of GRU units, batch size, and lookback. The best model produced in this study is the GRU model with hyperparameters consisting of 30 lookbacks, 50 GRU units, and 256 batch sizes with the lowest MAPE value among the other models, which is 2.25%. The MAPE value states that predictions using the GRU model are said to be very good at predicting world crude oil prices.

**Keywords:** Deep Learning; Gated Recurrent Unit; World Crude Oil Price

## 1. PENDAHULUAN

Minyak adalah salah satu sumber energi penting bagi seluruh negara di dunia [1]–[5]. Setiap negara pasti membutuhkan pasokan minyak untuk memenuhi kebutuhannya dari segi ekonomi, militer, pertanian, dan lain-lain [3]. Tercatat bahwa minyak menjadi bahan bakar terkemuka di dunia dengan menyumbang lebih dari sepertiga konsumsi energi global [6] dan lebih dari 95% penggunaan energi ini digunakan untuk transportasi yang merupakan salah satu sektor ekonomi yang penting [7].

Harga minyak seringkali terjadi kenaikan dan penurunan sehingga sering disebut dengan fluktuasi harga minyak. Fluktuasi harga minyak mentah memiliki dampak besar pada kegiatan ekonomi dunia dan perkembangan industri [8]–[11], termasuk pada pasar keuangan dan ekonomi riil [1], resiko kerugian pada konsumen dan produsen dalam industri perminyakan [8], dan pertumbuhan ekonomi suatu negara [12]. Sebagai contoh, kenaikan harga minyak yang melambung tinggi akan menyebabkan inflasi khususnya pada negara pengimpor minyak [6], [13]. Sifat yang sangat dinamis dan perubahan konstan dari harga minyak membuat para peneliti dan para ahli ekonomi memikirkan cara terbaik untuk memprediksi harga minyak mentah untuk membuat keputusan yang tepat dalam mengatasi permasalahan yang disebabkan oleh fluktuasi harga minyak [1]. Adanya perkiraan harga minyak yang akurat dapat mendukung pengambilan keputusan yang penting bagi berbagai sektor [5], [6], [8], [14].

Mengingat pentingnya dan kegunaan prediksi harga minyak, semakin banyak peneliti yang membuat penelitian mengenai prediksi harga minyak. Prediksi harga minyak telah diteliti dengan model yang beragam, mulai dari *statistical*, *machine learning*, dan *deep learning*. Penelitian terkait prediksi harga minyak dunia, Dimas Kevin Natanael, Diah Safitri, dan Suparti pada tahun 2018 melakukan prediksi harga minyak dunia dengan menggunakan metode *Autoregressive Fractionally Integrated Moving Average* (ARFIMA). Hasil menunjukkan bahwa metode ARFIMA dengan model ARFIMA([1,7]; d; 0) menghasilkan nilai MSE dan MAPE berturut-turut sebesar 0,044 dan 3,23% [15]. Penelitian selanjutnya dilakukan oleh Desty Rakhmawati dan Eka Tripustikasari pada tahun 2018 dengan menggunakan metode ARIMA dalam memprediksi harga minyak dunia memiliki hasil bahwa model ARIMA(1,1,0) menghasilkan nilai SBC/BIC paling minimum sebesar -390,67 [16]. Penelitian selanjutnya dilakukan oleh Vika Putri Ariyanti dan Tristyani Yusnitasari pada tahun 2023 dengan melakukan perbandingan metode antara ARIMA dan SARIMA dalam memprediksi harga minyak dunia. Hasil menunjukkan bahwa kedua model memiliki nilai RMSE yang sama sebesar 0.01905% [17]. Penelitian selanjutnya yang diteliti oleh Jhon Veri, Surmayanti, dan Guslendra pada tahun 2020 menggunakan algoritma jaringan syaraf tiruan (JST) untuk memprediksi harga minyak dunia. Dengan

menggunakan algoritma tersebut mendapatkan model yang memiliki nilai MSE sebesar 0,4877 dan akurasi sebesar 83,6% [4]. Penelitian berikutnya yang dilakukan oleh J Shiva Keerthan, Y Nagasai, dan Subhani Shaik dengan menggunakan berbagai macam algoritma machine learning dalam memprediksi harga minyak dunia. Penelitian tersebut memberikan hasil akurasi *Support Vector Machine* (SVR) sebesar 20%, *Random Forest Regressor* sebesar 60%, dan *Linear Regression* sebesar 85% [18].

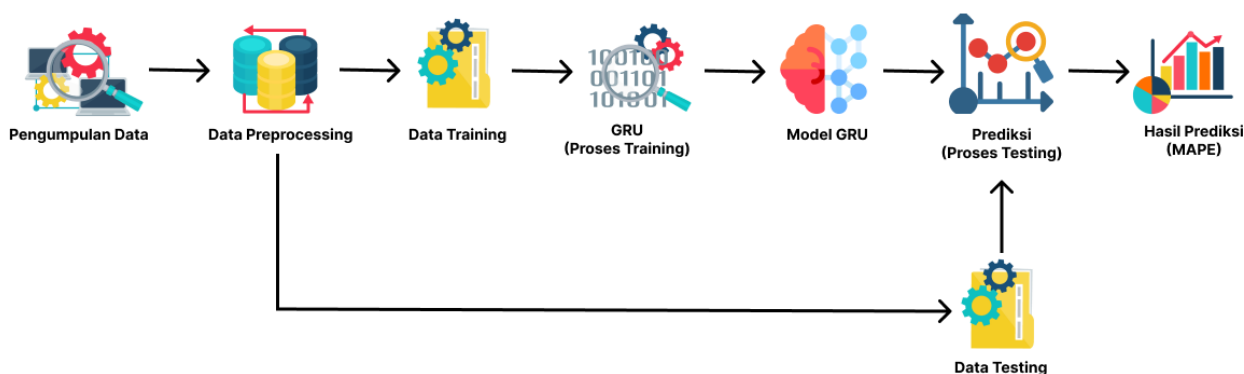
Perbedaan penelitian ini terhadap penelitian sebelumnya adalah penggunaan metode. Metode pada penelitian ini menggunakan *deep learning* dan secara khusus untuk memroses data sekuensial. *Deep learning* merupakan sebuah teknik berbasis jaringan syaraf tiruan (JST). *Deep learning* sangat berguna pada domain yang menggunakan data yang berjumlah besar dan dimensi yang tinggi, itu sebabnya *deep learning* dapat mengungguli algoritma *machine learning* sederhana pada pemrosesan data teks, gambar, video, audio, dan lain-lain [19]. *Deep learning* dapat digunakan pada pemrosesan data sekuensial termasuk data *time series*. Adapun arsitektur *deep learning* yang dapat mengatasi data sekuensial adalah *Recurrent Neural Network* (RNN). RNN dirancang secara eksplisit untuk melakukan pemrosesan pada data sekuensial seperti *time series*, urutan peristiwa, dan bahasa alami. Namun, arsitektur RNN mengalami permasalahan pada saat melakukan *backpropagation*, yaitu *vanishing gradient*. Oleh karena itu, munculah sebuah arsitektur yang dikembangkan dari RNN, yaitu *Gated Recurrent Unit* (GRU). GRU diciptakan untuk mengatasi permasalahan *vanishing gradient* yang terjadi pada RNN [20]. GRU dapat digunakan untuk memprediksi data *time-series* seperti memprediksi harga saham [21]–[23], memprediksi bilangan sunspot [20], dan memprediksi kegagalan mesin [24]. Selain itu, terdapat penelitian yang dilakukan oleh Insyiraah Oxaichiko Arissinta, Indah Dwi Sulistiyawati, Dedy Kurnianto, dan Iqbal Kharisudin pada tahun 2022 melakukan perbandingan performansi LSTM, GRU dan ARIMA dalam memprediksi *web traffic*. Dalam penelitian tersebut mendapatkan hasil akurasi GRU memiliki jumlah *error* terkecil dibandingkan dengan kedua algoritma yang lain [25].

Berdasarkan penjelasan yang sudah tertera diatas, penelitian ini menggunakan GRU untuk memprediksi harga minyak mentah dunia. Tujuan dari penelitian ini adalah untuk menemukan model GRU yang optimal dan mengetahui tingkat akurasi dalam memprediksi harga minyak mentah dunia. Eksperimen terhadap model GRU dilakukan dengan menggunakan beberapa *hyperparameter*. Diharapkan algoritma GRU dapat diimplementasikan untuk memprediksi harga minyak mentah dunia dengan sangat baik.

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Tahapan ini merupakan gambaran umum pada penelitian. Tahapan penelitian yang akan dilakukan tertera pada Gambar 1, dimulai dari pengumpulan data, data preprocessing seperti normalisasi data dan partisi data, pembuatan serta uji model GRU.



Gambar 1. Tahapan Penelitian


### 2.2.1 Pengumpulan Data

Data didapatkan dari organisasi U.S. *Energy Information Administration* (EIA) yang dapat diakses melalui websitenya yaitu <https://www.eia.gov/dnav/pet/hist/RBRTED.htm>. Data yang digunakan adalah data harian dari harga minyak brent. Data harga minyak harian berjumlah 5834 data, mulai dari 4 Januari 2000 hingga 19 Desember 2022 yang dapat dilihat pada Tabel 1 serta hasil plot grafik dari data tersebut dapat dilihat pada Gambar 2.

Tabel 1. Data Harian Harga Minyak Brent

Tanggal	Harga
Jan 04, 2000	23,95
Jan 05, 2000	23,72
Jan 06, 2000	23,55
Jan 07, 2000	23,35

Jan 10, 2000	22,77
Jan 11, 2000	23,93
Jan 12, 2000	24,62
Jan 13, 2000	24,9
Jan 14, 2000	25,5
...	...
Dec 19, 2022	81,66



Gambar 2. Plot Grafik Data Harian Harga Minyak Brent

### 2.2.2 Data Preprocessing

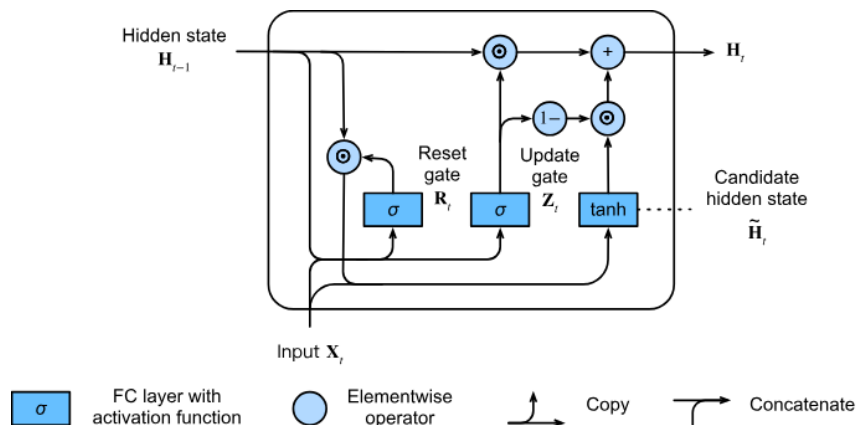
Data yang sudah didapatkan sebelumnya dibagi menjadi data latih dan data uji. Adapun pembagiannya terdiri dari 80% data latih dan 20% data uji. Setelah melakukan partisi data, selanjutnya data dinormalisasikan dengan menggunakan normalisasi *z-score*. Normalisasi *z-score* adalah metode normalisasi berdasarkan rata-rata dan simpangan baku pada data. Tujuan dari normalisasi data adalah untuk mengurangi jangkauan data yang jauh karena jangkauan data dapat mempengaruhi hasil prediksi [20]. *Z-score* dapat dihitung dengan rumus berikut :

$$v' = \frac{v_i - E_i}{std(E)} \tag{1}$$

### 2.2.3 Gated Recurrent Unit (GRU)

GRU pertama kali diperkenalkan oleh Kyunghyun Cho pada tahun 2014 [26]. *Gated Recurrent Unit* (GRU) merupakan algoritma yang dikembangkan dari Recurrent Neural Network (RNN) dan memiliki kesamaan dengan varian lain dari RNN, yaitu *Long Short Term Memory* (LSTM)[23]. GRU memiliki arsitektur yang lebih sederhana dibandingkan LSTM. Arsitektur RNN menyebabkan *vanishing gradient* pada saat melakukan *Backpropagation Through Time* (BPTT). GRU diciptakan untuk mengatasi permasalahan tersebut [20]. GRU memiliki 2 gate, yaitu *update gate* dan *reset gate* [26].

Gambar 3 menunjukkan arsitektur GRU. *Reset gate* memiliki fungsi untuk memilih informasi mana yang harus diatur ulang atau dihapus. *Update gate* memiliki fungsi untuk memilih informasi mana yang harus dipertahankan. Setelah itu menghitung *candidate hidden state* yang berfungsi untuk menyimpan informasi yang relevan dari masa lalu dengan menggunakan *update gate*. Terakhir menghitung *hidden state* baru ( $h_t$ ).



Gambar 3. Arsitektur GRU

### 2.2.4 Hyperparameter Tuning

Setelah melakukan tahap data *preprocessing*, langkah berikutnya adalah *hyperparameter tuning*. Tahapan ini bertujuan untuk mendapatkan parameter yang optimal untuk digunakan pada peramalan harga minyak dunia. Parameter yang diuji pada penelitian ini adalah jumlah *hidden neurons*, *lookback*, dan *batch size*. Adapun algoritma optimasi yang digunakan pada penelitian ini adalah Adam. Adapun rangkaian *hyperparameter* untuk model GRU dapat dilihat pada Tabel 2.

Tabel 2. Kandidat *Hyperparameter* Untuk Model GRU

<i>Hyperparameter</i>	<i>Value</i>
Jumlah Unit GRU	[10, 20, 50]
<i>Lookback</i>	[5, 10, 15, 20, 25, 30]
<i>Batch size</i>	[32, 64, 128, 256]
<i>Epoch</i>	[100]
<i>Learning rate</i>	[0.001]
<i>Optimizer</i>	[Adam]

### 2.2.5 Evaluasi

Langkah terakhir adalah menghitung nilai error untuk mengukur akurasi hasil prediksi dari model-model GRU. Pada penelitian ini, pengujian akurasi dilakukan dengan menggunakan *Mean Absolute Percentage Error* (MAPE). MAPE adalah perhitungan untuk mengukur akurasi dari sebuah prediksi [27]. MAPE dapat dihitung dengan rumus berikut :

$$MAPE = \left( \frac{100\%}{n} \right) \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \tag{5}$$

Dimana,  $y_i$  adalah data asli,  $\hat{y}_i$  adalah nilai prediksi, dan  $n$  adalah jumlah data. Semakin kecil nilai MAPE, maka akurasi dari prediksi akan baik. Kriteria dari MAPE dapat dilihat pada tabel 3 [27]:


Tabel 3. Kriteria MAPE

<b>Value MAPE</b>	<b>Kriteria</b>
MAPE < 10%	Kemampuan peramalan sangat baik
10% ≤ MAPE ≤ 20%	Kemampuan peramalan baik
20% ≤ MAPE ≤ 50%	Kemampuan peramalan cukup
50% ≥ MAPE	Kemampuan peramalan buruk

## 3. HASIL DAN PEMBAHASAN

### 3.1 Data Preprocessing

Pada penelitian ini, jumlah data yang digunakan sebanyak 5832 data harian harga minyak brent yang dikumpulkan dari 4 Januari 2000 hingga 19 Desember 2022. Data di *preprocessing* dengan melakukan partisi data dan normalisasi dengan menggunakan *z-score normalization*. Data kemudian dibagi menjadi 80:20 berturut-turut untuk data latih dan data uji. Total untuk data latih sebanyak 4667 dimulai dari 4 Januari 2000 hingga 15 Mei 2018 dan data uji sebanyak 1167 dimulai dari 16 Mei 2018 hingga 19 Desember 2022. Grafik partisi data bisa dilihat pada Gambar 4.



Gambar 4. Plot Grafik Hasil Partisi Data Harian Harga Minyak Brent

Bisa dilihat pada Gambar 4, terdapat partisi data antara data latih dan data uji yang diberi warna sehingga terlihat perbedaannya. Data latih sebanyak 4667 diberi warna biru, dan data uji sebanyak 1167 diberi warna orange.

Setelah melakukan partisi data, data dinormalisasikan dengan menggunakan *z-score normalization*. Hasil *preprocessing* data dapat dilihat pada Tabel 4.

**Tabel 4.** Hasil Data Preprocessing

Data Latih		Data Uji	
Tanggal	Harga	Tanggal	Harga
Jan 04, 2000	-1.2882172	May 16, 2018	0.45958413
Jan 05, 2000	-1.29560273	May 17, 2018	0.45829969
Jan 06, 2000	-1.30106159	May 18, 2018	0.52509055
⋮	⋮	⋮	⋮
May 11, 2018	0.47756628	Dec 15, 2022	0.58674366
May 14, 2018	0.45348304	Dec 16, 2022	0.51802613
May 15, 2018	0.51449392	Dec 19, 2022	0.56490818

### 3.2 Pemodelan GRU

Model GRU dibuat dengan menggunakan salah satu library python, yaitu Tensorflow. Adapun arsitektur model yang dibuat pada penelitian ini adalah model *sequential*. Salah satu model *sequential* pada penelitian ini dapat dilihat pada Gambar 5. Arsitektur model GRU pada penelitian ini terdiri dari 4 *layer* yang terdiri dari 1 *input layer* GRU dengan *output shape* terdiri dari *value* berturut-turut jumlah *lookback* dan jumlah unit GRU, dilanjutkan dengan 1 *layer* GRU yang memiliki *output shape* dengan *value* jumlah unit GRU, 1 *dense layer* yang terdiri dari 16 *neuron*, serta 1 *output layer* berupa *dense layer* dengan 1 *neuron*.

```

Model: "sequential"
-----
Layer (type)                Output Shape              Param #
-----
gru (GRU)                   (None, 30, 50)           7950
gru_1 (GRU)                 (None, 50)               15300
dense (Dense)               (None, 16)               816
dense_1 (Dense)             (None, 1)                17
-----
Total params: 24,083
Trainable params: 24,083
Non-trainable params: 0
    
```

**Gambar 5.** Model Sequential

Setelah pembuatan model kemudian dilakukan *hyperparameter tuning*. Pada penelitian ini, *hyperparameter* yang akan digunakan terdiri dari *hidden neurons*, *lookback*, dan *batch size*. Dari berbagai kombinasi *hyperparameter* yang digunakan, maka pada penelitian ini dilakukan eksperimen sebanyak 72 model GRU. Selanjutnya dari masing-masing model GRU dilakukan pengujian terhadap data prediksi dengan data uji. Pengujian akurasi dilakukan dengan menggunakan *Mean Absolute Percentage Error* (MAPE). Hasil akurasi dari masing-masing model GRU dapat dilihat pada Tabel 5.

**Tabel 5.** Hasil MAPE dari Model GRU

Nomor Eksperimen	Lookback	Jumlah Unit GRU	Batch Size	MAPE	Rata-rata MAPE
1			32	4,06%	
2			64	3,77%	
3		10	128	2,90%	
4			256	3,85%	
5			32	4,74%	
6	5	20	64	3,59%	3,735%
7			128	3,43%	
8			256	3,98%	
9			32	2,58%	
10			64	3,66%	
11		50	128	3,12%	
12			256	5,14%	
13			32	4,40%	
14			64	2,85%	
15	10	10	128	2,62%	3,486%
16			256	3,56%	

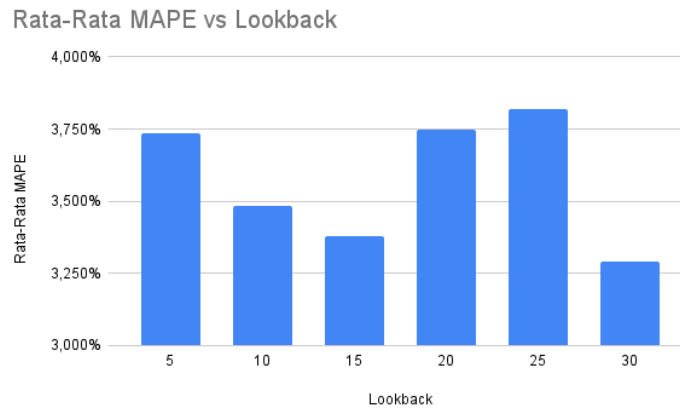


17			32	4,12%	
18			64	3,68%	
19		20	128	3,01%	
20			256	4,57%	
21			32	2,73%	
22		50	64	2,80%	
23			128	3,17%	
24			256	4,32%	
25			32	4,90%	
26		10	64	3,51%	
27			128	2,99%	
28			256	3,49%	
29			32	3,89%	
30		20	64	3,73%	
31	15		128	3,23%	3,38%
32			256	3,56%	
33			32	2,44%	
34		50	64	2,56%	
35			128	3,74%	
36			256	2,52%	
37			32	3,90%	
38		10	64	3,60%	
39			128	3,61%	
40			256	3,40%	
41			32	3,95%	
42		20	64	3,75%	
43	20		128	2,52%	3,75%
44			256	3,89%	
45			32	2,69%	
46		50	64	3,88%	
47			128	4,71%	
48			256	5,10%	
49			32	4,79%	
50		10	64	3,20%	
51			128	3,11%	
52			256	3,33%	
53			32	5,28%	
54		20	64	4,11%	
55	25		128	3,17%	3,82%
56			256	3,90%	
57			32	3,65%	
58		50	64	4,16%	
59			128	3,38%	
60			256	3,70%	
61			32	4,34%	
62		10	64	2,61%	
63			128	2,85%	
64			256	3,35%	
65			32	3,66%	
66		20	64	3,56%	
67	30		128	3,13%	3,29%
68			256	3,46%	
69			32	2,72%	
70		50	64	3,42%	
71			128	4,08%	
72			256	2,25%	

### 3.3 Analisa

Pada Gambar 6 menunjukkan grafik rata-rata pada masing-masing *lookback*. Grafik menunjukkan bahwa terjadi penurunan rata-rata MAPE dengan menggunakan *lookback* sebanyak 5 sampai dengan 15. Namun pada *lookback* sebanyak 20 dan 25 terjadi peningkatan rata-rata nilai MAPE dan kembali turun drastis pada *lookback* sebanyak 30

dengan nilai MAPE terkecil yaitu sebesar 3,29%. Hal ini disebabkan karena *lookback* sebanyak 15 dan 30 dapat menangkap tren pada dataset dengan lebih baik dibandingkan menggunakan *lookback* dengan jumlah yang lain.



**Gambar 6.** Grafik Rata-rata nilai MAPE Pada *Lookback*

Model GRU yang optimal merupakan model yang memiliki nilai MAPE yang rendah sesuai pada Tabel 1. Adapun secara spesifik model GRU yang memiliki hasil optimal yaitu model ke 72 dengan menggunakan 30 *lookback*, 50 jumlah unit GRU, dan 256 *batch size* dengan nilai MAPE terendah yaitu sebesar 2,25%. Untuk hasil akurasi didapatkan dengan pengurangan 100% dengan nilai MAPE, sehingga nilai akurasi didapatkan sebesar 97,75%. Dengan nilai MAPE dan akurasi tersebut dapat dikatakan bahwa model memiliki kemampuan prediksi dengan sangat baik.

Perbandingan antara data aktual dan data prediksi pada model terbaik GRU pada penelitian ini dapat divisualisasikan pada Gambar 7. Bisa dilihat pada gambar tersebut bahwa garis prediksi berada pada garis aktual dan terlihat seperti melakukan *shifting* atau pergeseran sehingga dapat dikatakan bahwa model dapat memprediksi harga minyak *brent* dengan sangat baik. Untuk memperjelas hasil perbandingan, terdapat gambar perbandingan data pada rentang hari ke 400 – 600 dan 800 – 1000.



**Gambar 7.** Hasil Perbandingan Data Prediksi dan Data Aktual Harga Minyak Brent

Berdasarkan pada penelitian sebelumnya yang dilakukan oleh J Shiva Keerthan, Y Nagasai, dan Subhani Shaik dengan algoritma SVR dengan akurasi sebesar 20%, *Random Forest Regressor* dengan akurasi sebesar 60%, dan *Linear Regression* dengan akurasi sebesar 85% [18], perbandingan terhadap penelitian ini GRU memiliki nilai akurasi terbesar diantara algoritma *machine learning* yang telah diteliti pada penelitian tersebut. Begitu pula untuk penelitian yang dilakukan oleh Jhon Veri, Surmayanti, dan Guslendra dengan menggunakan algoritma jaringan syaraf tiruan (JST) dengan nilai akurasi sebesar 83,6% [4]. GRU memberikan nilai akurasi lebih besar dibandingkan dengan menggunakan algoritma jaringan syaraf tiruan (JST) pada penelitian sebelumnya. Selain itu, penelitian yang dilakukan oleh Dimas Kevin Natanael, Diah Safitri, dan Suparti yang menggunakan metode AFRIMA dengan hasil MAPE sebesar 3,23%. Dengan melakukan perbandingan dengan model GRU yang optimal pada penelitian ini yang memiliki nilai MAPE sebesar 2,25%, hasil menunjukkan bahwa GRU memiliki nilai error lebih kecil dibandingkan metode AFRIMA dalam memprediksi harga minyak dunia.

#### 4. KESIMPULAN

Penelitian ini melakukan prediksi terhadap harga minyak mentah dunia dengan menggunakan model *Gated Recurrent Unit*. Hasil pada penelitian ini adalah model yang dapat memprediksi harga minyak mentah dunia dengan akurat. Data didapatkan dari organisasi *U.S. Energy Information Administration* (EIA) yang dapat diakses melalui websitenya yaitu <https://www.eia.gov/dnav/pet/hist/RBRTED.htm>. Jenis harga minyak yang digunakan adalah data harian dari harga minyak brent yang dimulai dari 4 Januari 2000 hingga 19 Desember 2022. Hasil penelitian ini menunjukkan bahwa dari sebanyak 72 model yang telah diteliti, model yang optimal dengan menghasilkan nilai MAPE terendah adalah model yang menggunakan *hyperparameter 30 lookback*, 50 jumlah unit GRU, dan 256 *batch size* dengan nilai MAPE sebesar 2,25%. Dengan penggunaan model tersebut dapat disimpulkan bahwa model memiliki kemampuan peramalan dengan sangat baik. Selain itu, dari 72 model dapat ditarik rata-rata dari setiap penggunaan *lookback* dan menghasilkan rata-rata MAPE terendah, yaitu penggunaan 30 *lookback* dengan nilai rata-rata MAPE sebesar 3,29%. Dengan penggunaan *lookback* sebanyak 30 dapat menangkap tren atau pola pada dataset dengan sangat baik. Untuk penelitian selanjutnya disarankan untuk membandingkan hasil akurasi pada model dengan menggunakan berbagai macam algoritma optimasi dan melakukan eksperimen dengan melakukan *tuning* pada beberapa parameter yang lain seperti *learning rate*, penambahan layer pada GRU, dan lain-lain.

#### REFERENCES

- [1] A. Daneshvar, M. Ebrahimi, F. Salahi, M. Rahmaty, and M. Homayounfar, "Brent Crude Oil Price Forecast Utilizing Deep Neural Network Architectures," *Comput Intell Neurosci*, vol. 2022, 2022, doi: 10.1155/2022/6140796.
- [2] K. Czech and I. Niftiyev, "The Impact of Oil Price Shocks on Oil-Dependent Countries' Currencies: The Case of Azerbaijan and Kazakhstan," *Journal of Risk and Financial Management*, vol. 14, no. 9, p. 431, Sep. 2021, doi: 10.3390/jrfm14090431.
- [3] M. Hussein and Y. Azhar, "Prediksi Harga Minyak Dunia Dengan Metode Deep Learning," *Fountain of Informatics Journal*, vol. 6, no. 1, pp. 2548–5113, 2021, doi: 10.21111/fij.v6i1.4446.
- [4] J. Veri, S. Surmayanti, and G. Guslendra, "Prediksi Harga Minyak Mentah Menggunakan Jaringan Syaraf Tiruan," *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, vol. 21, no. 3, pp. 503–512, Jul. 2022, doi: 10.30812/matrik.v21i3.1382.
- [5] C. Deng, L. Ma, and T. Zeng, "Crude oil price forecast based on deep transfer learning: Shanghai crude oil as an example," *Sustainability (Switzerland)*, vol. 13, no. 24, Dec. 2021, doi: 10.3390/su132413770.
- [6] M. Hasan, M. Z. Abedin, M. H. Peta Hajek, N. Sultan, and B. M. Lucey, "A Blending Ensemble Learning Model for Crude Oil Price Prediction," *SSRN Electronic Journal*, 2022, doi: 10.2139/ssrn.4153206.
- [7] N. Gupta and S. Nigam, "Crude Oil Price Prediction using Artificial Neural Network," in *Procedia Computer Science*, Elsevier B.V., 2020, pp. 642–647. doi: 10.1016/j.procs.2020.03.136.
- [8] Y. Zhao, W. Zhang, X. Gong, and C. Wang, "A novel method for online real-time forecasting of crude oil price," *Appl Energy*, vol. 303, Dec. 2021, doi: 10.1016/j.apenergy.2021.117588.
- [9] Y. Arifin, "Pengaruh Harga Minyak Dunia, Nilai Tukar dan Inflasi terhadap Pertumbuhan Ekonomi Indonesia," *Economics Development Analysis Journal*, vol. 5, no. 4, pp. 474–483, Mar. 2018, doi: 10.15294/edaj.v5i4.22184.
- [10] S. D. Purnomo, I. Istiqomah, and L. S. Badriah, "PENGARUH HARGA MINYAK DUNIA TERHADAP PERTUMBUHAN EKONOMI, INFLASI, DAN PENGANGGURAN DI INDONESIA," *Jurnal PROFIT Kajian Pendidikan Ekonomi dan Ilmu Ekonomi*, vol. 7, no. 1, pp. 13–24, Apr. 2020, doi: 10.36706/jp.v7i1.11025.
- [11] Y. Mailida, Z. Azhar, and M. R. Adry, "Analisis Kausalitas Shock Harga Minyak Dunia, Pengeluaran Dan Penerimaan Pemerintah Di Indonesia," *Jurnal Kajian Ekonomi dan Pembangunan*, vol. 1, no. 1, p. 153, Mar. 2019, doi: 10.24036/jkep.v1i1.5361.
- [12] Y. Zhang, F. Ma, and Y. Wang, "Forecasting crude oil prices with a large set of predictors: Can LASSO select powerful predictors?," *J Empir Finance*, vol. 54, pp. 97–117, Dec. 2019, doi: 10.1016/j.jempfin.2019.08.007.
- [13] U. N. Almaya, W. H. Rianto, and S. Hadi, "Pengaruh Harga Minyak Dunia, Inflasi, Konsumsi Rumah Tangga terhadap Pertumbuhan Ekonomi Indonesia," *Jurnal Ilmu Ekonomi JIE*, vol. 5, no. 2, pp. 262–278, Jul. 2021, doi: 10.22219/jie.v5i2.14101.
- [14] A. M. Nyangarika and B. J. Tang, "Oil Price Factors: Forecasting on the Base of Modified ARIMA Model," in *IOP Conference Series: Earth and Environmental Science*, Institute of Physics Publishing, Nov. 2018. doi: 10.1088/1755-1315/192/1/012058.



- [15] D. Kevin Natanael and D. Safitri, “PREDIKSI HARGA MINYAK DUNIA DENGAN METODE AUTOREGRESSIVE FRACTIONALLY INTEGRATED MOVING AVERAGE (ARFIMA),” 2018. doi: <https://doi.org/10.26714/jsunimus.6.1.2018.%25p>
- [16] D. Rakhmawati et al., “Konferensi Nasional Sistem Informasi 2018 STMIK Atma Luhur Pangkalpinang,” 2018.
- [17] V. P. Ariyanti and Tristyanti Yusnitasari, “Comparison of ARIMA and SARIMA for Forecasting Crude Oil Prices,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 7, no. 2, pp. 405–413, Mar. 2023, doi: 10.29207/resti.v7i2.4895.
- [18] J. S. Keerthan, Y. Nagasai, and S. Shaik, “Machine Learning Algorithms for Oil Price Prediction,” 2019. [Online]. Available: [www.indexwiz.com](http://www.indexwiz.com)
- [19] C. Janiesch, P. Zschech, and K. Heinrich, “Machine learning and deep learning,” *Electronic Markets*, vol. 31, no. 3, pp. 685–695, 2021. doi:10.1007/s12525-021-00475-2
- [20] 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.
- [21] S. Samsudin, A. M. Harahap, and S. Fitri, “Implementasi Gated Recurrent Unit (Gru) Untuk Prediksi Harga Saham Bank Konvensional Di Indonesia,” *JISTech (Journal of Islamic Science and Technology)*, vol. 6, no. 2, Dec. 2021, doi: 10.30829/jistech.v6i2.11058.
- [22] A. Lawi, H. Mesra, and S. Amir, “Implementation of Long Short-Term Memory and Gated Recurrent Units on grouped time-series data to predict stock prices accurately,” *J Big Data*, vol. 9, no. 1, Dec. 2022, doi: 10.1186/s40537-022-00597-0.
- [23] A. Ilham Caniago, W. Kaswidjanti, and U. Pembangunan Nasional Veteran Yogyakarta, “Recurrent Neural Network With Gate Recurrent Unit For Stock Price Prediction Recurrent Neural Network Dengan Gate Recurrent Unit Untuk Prediksi Harga Saham,” *Jurnal Informatika dan Teknologi Informasi*, vol. 18, no. 3, pp. 345–360, 2021, doi: 10.31515/telematika.v18i3.6650.
- [24] Z. Zainuddin, E. A. P. Akhir, and M. H. Hasan, “Predicting machine failure using recurrent neural network-gated recurrent unit (RNN-GRU) through time series data,” *Bulletin of Electrical Engineering and Informatics*, vol. 10, no. 2, pp. 870–878, 2021, doi: 10.11591/eei.v10i2.2036.
- [25] I. Oxaichiko Arissinta, I. Dwi Sulistiyawati, and D. Kurnianto Iqbal Kharisudin, “Pemodelan Time Series untuk Peramalan Web Traffic Menggunakan Algoritma Arima,” *Prosiding Seminar Nasional Matematika*, vol. 5, pp. 693–700, 2022, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/prisma/>
- [26] L. Xiedong, M. Dongliang, Z. Songlin, and W. Deyu, “GRU neural network-based method for box girder crack damage detection,” *Chinese Journal of Ship Research*, vol. 17, no. 4, pp. 194–203, 2022. doi:<https://doi.org/10.19693/j.issn.1673-3185.02415>
- [27] H. Hewamalage, K. Ackermann, and C. Bergmeir, “Forecast evaluation for data scientists: common pitfalls and best practices,” *Data Mining and Knowledge Discovery*, vol. 37, no. 2, pp. 788–832, Dec. 2022, doi: 10.1007/s10618-022-00894-5.