

**PERAMALAN NILAI IMPOR MIGAS-NON MIGAS
INDONESIA MENGGUNAKAN METODE
*GATED RECURRENT UNIT (GRU)***

(Skripsi)

Oleh

**SULISTIAN OSKAVINA
NPM 1857031010**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2022**

ABSTRAK

PERAMALAN NILAI IMPOR MIGAS-NON MIGAS INDONESIA MENGGUNAKAN METODE *GATED RECURRENT UNIT (GRU)*

Oleh

SULISTIAN OSKAVINA

Perkembangan ekonomi disuatu negara ditandai dengan peningkatan pengiriman barang, baik itu yang berasal dari dalam negeri keluar negeri ataupun sebaliknya, salah satu pendorong utama dalam pertumbuhan ekonomi di Indonesia adalah impor. Nilai migas-non migas di Indonesia dari waktu ke waktu terlihat mengalami kenaikan ataupun penurunan disetiap tahunnya. Oleh karena itu, perlu dilakukan peramalan untuk melihat apakah ada peluang untuk meningkatkan nilai impor migas-non migas Indonesia. Dalam penelitian ini akan dilakukan peramalan nilai impor migas-non migas Indonesia menggunakan metode GRU. Hasil yang diperoleh digunakan untuk menentukan peramalan pada satu tahun kedepan menggunakan skema pembagian sebesar 80% sebagai data *training* dan 20% sebagai data *testing* diperoleh struktur terbaik berupa 32 GRU Unit, 16 *batch size*, 100 dan *dropout* sebesar 0.2, menghasilkan nilai MAPE sebesar 0.999955% dan akurasi sebesar 99.000044%.

Kata Kunci: Impor, GRU, MAPE

ABSTRACT

FORECASTING THE VALUE OF INDONESIAN OIL-NON OIL AND GAS IMPORTED USING THE *GATED RECURRENT UNIT (GRU)*

By

SULISTIAN OSKAVINA

Economic development in a country is marked by an increase in the delivery of goods, whether originating from within the country to abroad or vice versa, one of the main drivers of economic growth in a country. Indonesia is an import. Based on the value of oil and gas non-oil and gas in Indonesia from time to time, it seems to increase or decrease every year. Therefore, forecasting needs to be done to see if there is an opportunity to increase the import value of oil and gas-non-oil and gas. In this study, the value of Indonesia's oil and gas imports will be forecasted using the GRU method. The results obtained are used to determine forecasting in the next year using a distribution scheme of 80% as training and 20% as testing , the best structure is 32 GRU Units, 16 batch sizes, 100 and dropout of 0.2, resulting in a MAPE value of 0.999955%. and an accuracy of 99,00044%.

Keywords: Import, GRU, MAPE

**PERAMALAN NILAI IMPOR MIGAS-NON MIGAS
INDONESIA MENGGUNAKAN METODE
*GATED RECURRENT UNIT (GRU)***

Oleh

SULISTIAN OSKAVINA

Skripsi

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar
SARJANA MATEMATIKA**

Pada

**Jurusan Matematika
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2022**

Judul Skripsi : **PERAMALAN NILAI IMPOR MIGASNON
MIGAS INDONESIA MENGGUNAKAN
METODE *GATED RECURRENT UNIT* (GRU)**


Nama Mahasiswa : **Sulistian Oskavina**

Nomor Pokok Mahasiswa : **1857031010**

Program Studi : **Matematika**

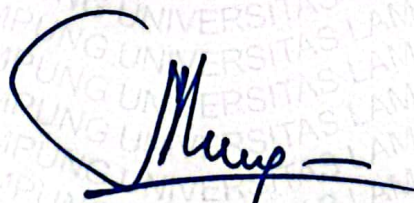
Fakultas : **Matematika dan Ilmu Pengetahuan Alam**




Dian Kurniasari, S.Si., M.Sc.
NIP.196903051996032001


Prof. Dra. Wamliana, M.A., Ph.D.
NIP. 196311081989022001

2. Ketua Jurusan Matematika


Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 197403162005011001

MENGESAHKAN

1. Tim Penguji


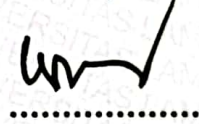
Ketua : **Dian Kurniasari, S.Si., M.Sc.**




Sekretaris : **Prof. Dra. Wamiliana, M.A., Ph. D.**



Penguji
Bukan Pembimbing : **Ir. Warsono, M.S., Ph.D.**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam




Dr. Eng. Surtpto Dwi Yuwono, S.Si., M.T.
NIP. 197407052000031001

Tanggal Lulus Ujian Skripsi : 12 Agustus 2022

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Sulistian oskavina

Nomor Pokok Mahasiswa : 1857031010

Jurusan : Matematika

Judul Skripsi : **PERAMALAN NILAI IMPOR MIGAS-NON
MIGAS INDONESIA MENGGUNAKAN
METODE *GATED RECURRENT UNIT*
(GRU)**

Dengan ini menyatakan bahwa penelitian ini adalah hasil pekerjaan saya sendiri dan apabila kemudian hari terbukti bahwa skripsi ini merupakan salinan atau dibuat oleh orang lain, maka saya bersedia menerima sanksi sesuai dengan ketentuan akademik yang berlaku.

Bandar Lampung, 26 Agustus 2021



Sulistian Oskavina
NPM. 1857031010

RIWAYAT HIDUP

Penulis memiliki nama lengkap Sulistian Oskavina lahir di Gunung Labuhan pada tanggal 21 September 2000. Penulis merupakan anak pertama dari tiga bersaudara yang lahir dari pasangan Suwandi dan Siti Aisyah.

Penulis menempuh pendidikan awal di SD Negeri Gunung Betuah pada tahun 2006 sampai tahun 2009. Selanjutnya, penulis melanjutkan pendidikan Sekolah Menengah Pertama di SMP Negeri 1 Abung Barat pada tahun 2012 sampai tahun 2015. Penulis melanjutkan Sekolah Menengah Atas di SMA Negeri 1 Kota Bumi pada tahun 2015 sampai tahun 2018.

Pada tahun 2018, penulis terdaftar sebagai mahasiswa jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui Jalur SMMPTN Barat.

Sebagai penerapan ilmu yang di dapat, pada awal semester VI penulis melaksanakan Kerja Prektik (KP) di Badan Pendapatan Daerah Kabupaten Pesawaran Provinsi Lampung Selama 40 hari. Kemudian, pada semester VII penulis melaksanakan Keliyah Kerja Nyata di Desa Bumi Raya, Kecamatan Abung Selatan, Kabupaten Lampung Utara pada tanggal 1 Agustus 2021 sampai dengan 10 September 2021.

KATA INSPIRASI

“Janganlah engkau bersedih, sesungguhnya Allah Bersama kita”
(Q.S: At-Taubah:40)

“Dan hanya kepada Tuhanmulah hendaknya kamu berharap.”

(Q.S Al-Insyirah : 8)

PERSEMBAHAN

Alhamdulillahirobbil'alamin

Dengan mengucapkan puji dan syukur atas kehadiran Allah Subhanahu Wata'ala karena limpahan nikmat dan karunia Nya sehingga skripsi ini dapat diselesaikan Tak lupashalawat beserta salam salam selalu tercurah kepada junjungan kita Nabi Muhammad Shallallahu'Alaihi Wasallam.

Dengan penuh syukur dan ketulusan, kupersembahkan karya sederhana ini untuk:

Ayah Suwandi dan Ibu Siti aisyah

Terima kasih telah menjadi sosok yang selalu kuandalkan, telah memberikan pengorbanan, kasih sayang yang tiada henti dan dukungan atas segala keputusan yang ku ambil. Menjadi rumah ternyaman sejauh apapun aku melangkah pergi dan sekeras apapun aku menghadapi dunia.

Adikku Tersayang

Terima kasih untuk dukungan yang selalu kalian. Semoga karya ini membuat kalian bangga dan kita bisa menjadi orang sukses serta membanggakan ayah dan ibu.

Almamater Tercinta Universitas Lampung

SANWACANA

Segala puji dan syukur penulis ucapkan kepada Allah SWT atas segala nikmat dan karunia-Nya yang tak terhingga sehingga penulis dapat menyelesaikan skripsi yang berjudul “Peramalan Nilai Impor Migas-Non Migas Indonesia menggunakan Metode *Gated Recurrent Unit* (GRU)”. Penulisan skripsi ini tidak dapat terselesaikan tanpa adanya bimbingan, bantuan dan dukungan dari berbagai pihak. Sehingga, dalam kesempatan ini penulis mengucapkan terimakasih kepada:

1. Ibu Dian Kurniasari, S.Si., M.Sc., selaku dosen pembimbing I yang senantiasa membimbing, memberi masukan serta saran serta mendukung penulis dalam menyelesaikan skripsi ini.
2. Prof. Dra. Wamiliana, M.A., Ph. D. selaku dosen pembimbing II memberikan bimbingan, pengarahan, serta saran sehingga penulis dapat menyelesaikan skripsi ini.
3. Bapak Ir. Warsono M.A, Ph.D. selaku dosen penguji yang telah memberikan kritik dan saran yang membangun sehingga skripsi ini dapat terselesaikan.
4. Bapak Prof.Drs. Mustofa M.A., Ph.D., selaku dosen pembimbing akademik yang telah memberikan bimbingan dan arahan selama masa perkuliahan.
5. Bapak Dr.Aang Nuryaman, S.Si., M.Si., selaku Ketua Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

6. Bapak Dr. Eng. Suropto Dwi Yuwono, S.Si., M.T. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Seluruh dosen, staff, karyawan Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
8. Orang tua serta keluarga yang telah memberikan semangat, motivasi, kasih sayang serta dukungan kepada penulis.
9. Sahabat penulis Adhanis, Juliana dan Aulia Melinda yang selalu menemani suka maupun duka.
10. Teman-teman satu bimbingan Maydia, Ferzi, Virda, Alifiah, Dalfa, Putri, Shavira, Lutfia, Febi, Farel, dan Zainal yang telah memberikan semangat maupun saran kepada penulis

Penulis menyadari bahwa masih banyak kekurangan dalam penulisan skripsi ini.

Oleh karena itu, penulis mengharapkan masukan serta saran untuk dijadikan pelajaran kedepannya.

Bandar Lampung, 26 Agustus 2022
Penulis,

Sulistian Oskavina

DAFTAR ISI

Halaman

DAFTAR TABEL	iv
DAFTAR GAMBAR.....	v
I. PENDAHULUAN	1
1.1. Latar Belakang dan Masalah	1
1.2. Tujuan Penelitian.....	4
1.3. Manfaat Penelitian	4
II. TINJAUAN PUSTAKA.....	5
2.1. Peramalan	5
2.2. Data Mining.....	5
2.3. <i>Machine Learning</i>	8
2.4. Fungsi Aktivasi.....	8
2.5. <i>Recurrent Neural Network</i>	10
2.6. <i>Gated Recurrent Unit</i>	11
2.7. <i>Hypertunning</i> Parameter.....	14
2.8. Denormalisasi	15
2.9. Evaluasi Model.....	15
III. METODE PENELITIAN.....	18
3.1. Tempat dan Waktu Penelitian	18
3.2. Data Penelitian.....	18
3.3. Metode Penelitian	19
IV. HASIL DAN PEMBAHASAN.....	21
4.1. Proses data mining.....	21
4.1.1 Input Data.....	22
4.1.2 <i>Data Preprocessing</i>	22
4.2. Pembagian <i>Data Training</i> dan <i>Data Testing</i>	23
4.3. Membangun Model <i>Gated Recurrent Unit</i>	24
4.4. Menguji Model	26
4.5. Prediksi Model <i>Gated Recurrent Unit</i>	28
4.6. Evaluasi Model <i>Gated Recurrent Unit</i>	30
4.7. Peramalan	30

V. KESIMPULAN	32
DAFTAR PUSTAKA	33
LAMPIRAN.....	34

DAFTAR TABEL

Tabel	Halaman
1. Data nilai Impor Migas-Non Migas Indonesia.....	18
2. Data nilai Impor Migas-Non Migas Indonesia.....	21
3. Data Hilang nilai Impor Migas-Non Migas Indonesia.....	22
4. Hasil Normalisasi	23
5. Pembagian Data <i>Training</i> dan Data <i>Testing</i>	24
6. Parameter yang Digunakan	24
7. Parameter Optimal untuk Data 60% <i>Training</i> dan 40% Data <i>Testing</i>	24
8. Parameter Optimal untuk Data 70% <i>Training</i> dan 30% Data <i>Testing</i>	25
9. Parameter Optimal untuk Data 80% <i>Training</i> dan 20% Data <i>Testing</i>	25
10. Perbandingan Akurasi	30
11. Peramalan.....	31

DAFTAR GAMBAR

Gambar	Halaman
1. Fungsi Aktivasi Sigmoid.....	9
2. Fungsi Aktivasi <i>Tangen Hiperbolik</i>	10
3. Struktur <i>Recurrent Neural Network</i>	11
4. Asitektur <i>Gated Recurrent Unit</i>	12
5. Alur <i>Update Gate</i>	12
6. Alur <i>reset Gate</i>	13
7. <i>Flowchart</i> Proses Metode <i>Gated Recurrent unit</i>	20
8. Plot <i>Time Series</i> Data nilai Impor Migas-Non Migas Indonesia	22
9. Grafik <i>Loss</i> untuk Data <i>Training</i> 60%	26
10. Grafik <i>Loss</i> untuk Data <i>Training</i> 70%	27
11. Grafik <i>Loss</i> untuk Data <i>Training</i> 80%	27
12. Plot Prediksi Data <i>Training</i> 60%	28
13. Plot Prediksi Data <i>Training</i> 70%	29
14. Plot Prediksi Data <i>Training</i> 80%	29
15. Plot <i>Gated Recurrent Unit</i> Hasil Peramalan	31

I. PENDAHULUAN

1.1 Latar Belakang

Perkembangan ekonomi suatu negara ditandai dengan nilai impor, baik itu yang berasal dari dalam negeri keluar negeri ataupun sebaliknya. Hal ini merupakan salah satu pendorong utama dalam pertumbuhan dari suatu negara. Sektor perekonomian di Indonesia salah satunya adalah kegiatan impor sangat berpengaruh terhadap keseimbangan kehidupan masyarakat saat ini. Impor adalah membeli barang dari luar negeri ke dalam peredaran Republik Indonesia dan barang yang dibeli tersebut harus dilaporkan ke Direktorat jenderal Bea dan Cukai Departemen Keuangan (Hamdani dan Haikal, 2018). Komponen impor yang berpengaruh terhadap pertumbuhan ekonomi di Indonesia terdiri dari migas-non migas. Kegiatan impor bermanfaat untuk mengisi kekosongan barang atau jasa yang tidak dapat dihasilkan atau diproduksi di dalam negeri. Setiap negara tidak dapat terlepas dari kegiatan perdagangan terutama perdagangan antar negara yang sangat dibutuhkan untuk saling melengkapi dan memenuhi kebutuhan di dalam negerinya. Nilai impor di Indonesia dari waktu ke waktu masih terlihat mengalami kenaikan dan penurunan setiap bulan. Oleh karena itu, salah satu cara untuk meningkatkan jumlah impor di Indonesia yang dikaitkan dengan perkembangan ilmu matematika saat ini, yaitu melakukan peramalan. Prediksi atau peramalan merupakan metode yang digunakan untuk memprediksi ketidakpastian di masa depan dalam upaya pengambilan keputusan yang lebih baik (Fauziah, dkk., 2016).

Prediksi atau peramalan dilakukan untuk melihat perkembangan nilai impor migas-non migas Indonesia sehingga dapat membantu pemerintah dalam menentukan kebijakan lebih lanjut dalam mengembangkan sektor perekonomian pada masa yang akan datang menggunakan metode yang tepat. Metode prediksi data *time series* yang sering digunakan adalah ARIMA (*Autoregressive Integrated Moving Average*), tetapi metode ini memerlukan asumsi-asumsi yang harus dipenuhi dan hanya bisa memodelkan data yang bersifat stasioner ataupun linear, sehingga akan ditelusuri metode lain yang dapat digunakan untuk memprediksi data *time series*. Salah satu perkembangan metode *time series* adalah *deep learning*, metode ini memungkinkan untuk melakukan pembelajaran dengan lapisan yang lebih kompleks agar mendapatkan akurasi tinggi dan lebih efisien serta memberikan peramalan lebih akurat dibandingkan dengan metode peramalan karena mampu meramalkan data yang linear maupun non linear (Zhang, 2004).

Salah satu metode *deep learning* adalah *Recurrent neural network* (RNN) jaringan saraf berulang. Dikatakan jaringan saraf berulang karena nilai *neuron* pada *hidden layer* akan digunakan kembali sebagai input dimana nilai *neuron* akan terus diperbaharui sehingga RNN terpenuhi. *Recurrent neural network* adalah jenis arsitektur jaringan syaraf tiruan dimana kerjanya menggunakan *input* yang diproses secara berulang-ulang, tetapi metode ini tidak mampu menampung memori jangka panjang sehingga sulit untuk mengingat informasi sebelumnya, akibatnya informasi penting dari awal akan tertinggal. *Recurrent neural network* merupakan pembelajaran jangka panjang dengan *gradient descent* menghasilkan masalah menghilang atau meledaknya *gradient* atau *vanishing gradient* (Wiranda dan Sadikin, 2019). Oleh karena itu, untuk menutupi kelemahan dari metode RNN maka digunakan metode *Gated recurrent unit* (GRU) yaitu merupakan variasi dari *Long Short Term Memory* (LSTM).

Gated recurrent unit adalah struktur berulang dirancang dengan hati-hati yang membuat pertukaran baik antara kinerja dan kecepatan. Kelebihan GRU dibandingkan dengan LSTM yaitu komputasinya yang lebih sederhana, namun

akurasi yang dihasilkan setara dan masih cukup efektif untuk menangani permasalahan *vanishing gradient* (Chung, dkk., 2014). Pemodelan GRU lebih sederhana dari LSTM yaitu tidak menggunakan *cell state* tetapi memanfaatkan *hidden state* untuk menyimpan informasi. Komputasi GRU lebih mudah dari pada LSTM karena hanya memiliki dua *gate* yaitu *reset gate* dan *update gate* dimana *reset gate* akan menentukan bagaimana untuk menggabungkan *input* baru dengan informasi sebelumnya dan *update gate* akan menentukan beberapa banyak informasi masa lalu yang harus tetap disimpan.

Berdasarkan beberapa penelitian terkait penerapan algoritma *deep learning* telah banyak digunakan dalam penelitian sebelumnya. Salah satunya oleh penelitian Saputra, dkk. (2020), mengenai prediksi permintaan kargo pada *cargo service center* Tangerang *city* menggunakan metode GRU, penelitian ini melakukan pencarian nilai *Root Mean Square Error* (RMSE) terkecil dalam melakukan prediksi, namun terdapat beberapa hasil prediksi yang masih belum maksimal mendekati nilai aktual. Selain itu, penelitian Arfianti, dkk. (2021) tentang Prediksi Angka *Sunspot* Menggunakan algoritma GRU untuk mengetahui informasi jumlah bintik matahari di masa yang akan datang dengan menghasilkan nilai *Mean Absolute Percentage Error* (MAPE) sebesar 2,7847% dengan skema 70% data *training* dan 30% data *testing*.

Oleh karena itu, penelitian ini akan menerapkan kembali metode GRU dengan menggunakan data yang berbeda mengenai nilai impor migas-non migas Indonesia (juta US \$) untuk dapat menghasilkan nilai prediksi yang akurat. Perhitungan tingkat kesalahan yang akan digunakan adalah RMSE dan MAPE.

1. 2 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah:

1. Mengetahui struktur terbaik peramalan nilai impor migas-non migas Indonesia (juta US \$) menggunakan metode GRU.
2. Mengetahui hasil prediksi dan peramalan nilai impor migas dan non migas Indonesia (juta US \$) menggunakan metode GRU.
3. Mengetahui peramalan nilai impor migas-non migas Indonesia (juta US \$) untuk 24 bulan kedepan.

1. 3 Manfaat penelitian

Manfaat dari penelitian ini adalah:

1. Dapat memberi pengetahuan dan wawasan terkait metode GRU.
2. Mengetahui hasil dari suatu prediksi dan peramalan menggunakan metode GRU sehingga dapat dijadikan referensi untuk peneliti selanjutnya.
3. Sebagai bahan pertimbangan bagi pihak pemerintah dalam menentukan kebijakan selanjutnya.

II. TINJAUAN PUSTAKA

2.1 Peramalan

Peramalan merupakan suatu proses dalam memperkirakan sesuatu yang mungkin terjadi dimasa depan berdasarkan informasi pada masa lalu dan masa sekarang. Metode peramalan dikategorikan menjadi dua kategori, yaitu metode peramalan kualitatif dan metode kuantitatif. Metode peramalan kualitatif didasarkan pada data kualitatif masalah berdasarkan pengetahuan dan pengalaman penulis, sedangkan metode peramalan kuantitatif didasarkan pada data kuantitatif pada informasi masa lalu dalam bentuk data yang numerik seperti model deret waktu berkala (*time series*) dan kasual (Makridakis, dkk., 1999).

Heizer dan Render (1996) menyatakan bahwa, jangka waktu peramalan terbagi menjadi tiga kategori, yaitu:

1. Peramalan jangka pendek, yaitu peramalan untuk jangka waktu kurang dari tiga bulan.
2. Peramalan jangka menengah, yaitu peramalan untuk jangka waktu antara tiga bulan sampai tiga tahun.
3. Peramalan jangka panjang, yaitu peramalan untuk jangka waktu lebih dari tiga tahun.

2.2 Data Mining

Data *mining* adalah pencarian pola yang menarik dari sejumlah besar data yang biasanya terdapat pada *database*, *data warehouse*, ataupun repositori informasi lainnya (Han, dkk., 2012). Secara umum, data *mining* merupakan proses yang

menggunakan teknik statistik, matematika, kecerdasan buatan dan *machine learning* untuk mengekstraksi dan mengidentifikasi informasi yang bermanfaat dan pengetahuan yang terkait dengan *database* yang besar (Kusrini dan Emha, 2009).

Kegunaan data *mining* dapat dibagi menjadi dua, yaitu deskriptif dan prediktif (Suyanto, 2017). Deskriptif dapat diartikan yaitu data *mining* digunakan untuk mencari pola-pola yang dapat dipahami manusia yang menjelaskan karakteristik data, sedangkan prediktif dapat diartikan yaitu data *mining* digunakan untuk membentuk sebuah model pengetahuan yang akan digunakan untuk melakukan prediksi.

Data *mining* merupakan proses dalam mengerjakan satu atau lebih teknik pembelajaran komputer untuk menganalisis dan memperoleh pengetahuan secara otomatis dari suatu kumpulan data (Hermawati, 2013). Proses data *mining* merupakan bagian dari *Knowledge Discovery in Database* (KDD) yang sering kali digunakan untuk mendapatkan informasi dari sekumpulan data yang besar.

Fayyad (1996) menyatakan bahwa, tahapan KDD adalah data *mining* dengan tahapan sebagai berikut:

1. *Data Selection*

Seleksi data merupakan tahapan pengambilan data yang berhubungan dengan analisis dari basis data dan dilakukan teknik perolehan sebuah pengurangan representasi dari data untuk meminimalkan hilangnya informasi data. Data hasil seleksi yang akan digunakan untuk proses data *mining* akan disimpan dalam suatu berkas terpisah dari basis data operasional.

2. *Pre-processing Data*

Sebelum proses data *mining* dilakukan maka perlu dilakukan proses *pre-processing* data yang bertujuan untuk membuang duplikasi data, memeriksa data yang hilang, memeriksa data yang tidak konsisten, serta memperbaiki kesalahan pada data.

3. Transformasi Data

Transformasi adalah proses data *mining* untuk merubah skala pengukuran data dari bentuk asli kedalam bentuk lain sehingga data tersebut sesuai dengan data *mining*. Dalam melakukan proses transformasi terdapat beberapa teknik, salah satunya adalah normalisasi data. Normalisasi merupakan teknik pada pemrosesan data untuk memperkecil rentang nilai pada suatu atau keluaran untuk menghindari terjadinya ketidak konsistenan suatu data.

Lewis (2017) menyatakan bahwa, terdapat beberapa teknik normalisasi data. Salah satu teknik normalisasi data adalah:

a. *Min-max Normalization*

Teknik ini digunakan untuk mengatasi perbedaan nilai yang cukup besar antar variabel dalam dataset, dengan mengubah nilai data menjadi nilai berskala (0,1) tanpa mengubah informasi yang ada.

$$x' = \frac{(x - x_{min})}{(x_{max} - x_{min})} \quad (2.1)$$

dengan:

- x' : data hasil normalisasi
- x : data asli
- x_{min} : nilai minimum dari x
- x_{max} : nilai maksimum dari x

4. Data *mining*

Data *mining* adalah proses mencari pola atau informasi menarik dalam data terpilih dengan menggunakan teknik atau metode tertentu. Teknik-teknik, metode, dan algoritma dalam data *mining* sangat bervariasi. Pemilihan metode atau algoritma yang tepat sangat bergantung pada proses KDD secara keseluruhan

5. *Interpretation/Evaluation*

pola informasi yang dihasilkan dari proses data *mining* perlu ditampilkan dalam bentuk yang mudah dimengerti. Tahapan ini mencakup pemeriksaan apakah pola atau informasi yang ditemukan bertentangan dengan fakta atau hipotesa yang ada. Pola informasi yang dihasilkan dari proses data *mining* perlu ditampilkan dalam bentuk yang mudah dimengerti dan dipahami.

2.3 Machine Learning

Machine learning merupakan pembelajaran mesin yang termasuk kedalam pendekatan *artificial intelligence* (Russell and Norvig, 2016). *Machine learning* adalah adanya pelatihan (*training*) dan pembelajaran (*learning*) serta memungkinkan komputer mempelajari sejumlah data sehingga dapat menghasilkan suatu model untuk melakukan proses *input-output* tanpa dapat menggunakan kode program yang dibuat secara eksplisit.

Dalam pembelajaran *machine learning* dikelompokkan menjadi dua yaitu:

1. Pembelajaran terarah (*supervised learning*) adalah proses pembelajaran terawasi dimana jika *output* yang diinginkan telah diketahui sebelumnya. Biasanya pembelajaran ini menggunakan data ada. Keterbatasan *supervised learning* adalah membutuhkan data dalam jumlah yang besar sehingga memakan waktu yang lama karena harus dilabel manual oleh manusia, serta membutuhkan validasi berulang dengan dataset lainnya untuk melatih ketepatan model. Algoritma yang cocok adalah *neural network*.
2. Pembelajaran tidak terarah (*unsupervised learning*) adalah proses pembelajaran yang tidak terawasi dimana tidak memerlukan target *output*. Tujuan dari metode ini ialah mengelompokkan unit yang memiliki kemiripan pada area tertentu. Keuntungannya adalah dapat menentukan pola tersembunyi dari data-data yang akan diidentifikasi, namun kekurangannya adalah sulit menemukan pola awal untuk menentukan algoritma.

2.4 Fungsi aktivasi

Fungsi aktivasi adalah fungsi yang digunakan pada jaringan saraf untuk mengaktifkan *neuron* (Julpan, dkk., 2015). Fungsi aktivasi yang sering digunakan salah satunya adalah sebagai berikut:

1. Fungsi aktivasi *sigmoid* merupakan fungsi non linear yang menampilkan nilai dalam *range* 0 sampai 1. Fungsi *sigmoid* ditunjukkan pada persamaan berikut.


$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (2.2)$$

Turunan fungsi aktivasi *sigmoid* adalah sebagai berikut:

$$f'(x) = \frac{u(x)}{v(x)} = \frac{u'(x)v(x) - u(x)v'(x)}{[v(x)]^2}$$

$$\begin{aligned} \frac{d}{dx} \sigma(x) &= \frac{d}{dx} \frac{1}{1 + e^{-x}} \\ &= \frac{e^{-x}}{(1 + e^{-x})^2} \\ &= \frac{1 - 1 + e^{-x}}{(1 + e^{-x})^2} \\ &= \frac{1 + e^{-x}}{(1 + e^{-x})^2} - \frac{1}{(1 + e^{-x})^2} \\ &= \frac{1}{1 + e^{-x}} - \frac{1}{(1 + e^{-x})} \\ &= \frac{1}{(1 + e^{-x})} \left(1 - \frac{1}{(1 + e^{-x})} \right) \\ &= f(x)[1 - f(x)] \end{aligned} \quad (2.3)$$

Sedangkan grafik dari fungsi aktivasi *sigmoid*, digambarkan sebagai berikut:



Gambar 1. Fungsi Aktivasi *Sigmoid*


2. Fungsi aktivasi *tangen hiperbolik (tanh)*. *Input* untuk fungsi aktivasi *tanh* berupa bilangan asli dan *outputnya* memiliki *range* antara -1 sampai 1 dengan persamaan sebagai berikut.

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.4)$$

Turunan fungsi aktivasi *tangen hiperbolik* adalah sebagai berikut:

$$\begin{aligned} f'(x) &= \frac{u(x)}{v(x)} = \frac{u'(x)v(x) - u(x)v'(x)}{[v(x)]^2} \\ \frac{d}{dx} \tanh(x) &= \frac{d \sinh(x)}{dx \cosh(x)} \\ &= \frac{\cosh^2(x) - \sinh^2(x)}{\cosh^2(x)} \\ &= \frac{\cosh^2(x) - \sinh^2(x)}{\cosh^2(x) \cosh^2(x)} \\ &= 1 - \tanh^2(x) \end{aligned} \quad (2.5)$$

Grafik dari fungsi aktivasi *tangen hiperbolik*, digambarkan sebagai berikut:



Gambar 2. Fungsi aktivasi *Tangen Hiperbolik*


2.5 Recurrent Neural Network (RNN)

Recurrent Neural Network adalah salah satu bagian dari *Artificial Neural Network* (ANN) yang memproses sejumlah data yang berurutan (*Sequential data*). *Recurrent neural network* biasanya digunakan untuk mengolah data yang berkaitan dengan *time series*. *Recurrent neural network* terdiri dari unit *input*, unit *output*, dan unit tersembunyi. *Recurrent neural network* dikatakan jaringan

syaraf berulang karena *output* dari unit tersembunyi yang sebelumnya akan di gunakan kembali sebagai data *input* bagi pemrosesan selanjutnya.

Ciri dari RNN dalam melakukan suatu prediksi tidak hanya menggunakan *input* satu waktu saja namun membutuhkan masukan dan *input* sebelumnya. Oleh karena itu antar *input* saling berhubung dan dapat memberikan informasi ke *hidden layer* (Sen, dkk., 2020).

Struktur diagram dari arsitektur RNN adalah sebagai berikut:

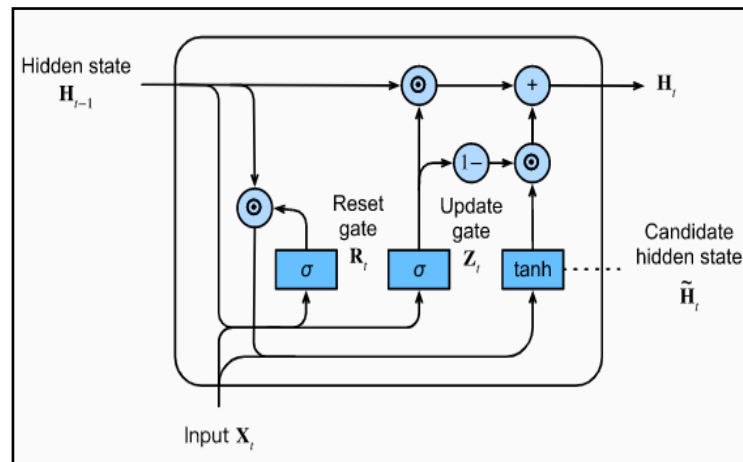


Gambar 3. Struktur RNN
(Hochreiter and Schmidhuber, 1997)

2.6 Gated Recurrent Unit

Gated Recurrent Unit pertama kali diperkenalkan oleh Chung pada tahun 2014 sebagai pengembangan dari LSTM. Proses yang dilakukan dalam metode GRU mirip dengan pengoperasian metode LSTM, namun metode GRU hanya menggunakan satu sel tersembunyi. Tujuan utama dari pembuatan metode GRU adalah membuat setiap *unit* berulang untuk dapat menangkap hubungan (dependensi) dalam skala waktu yang berbeda-beda dan mudah menyesuaikan dengan keadaan.

Diagram arsitektur GRU adalah sebagai berikut:

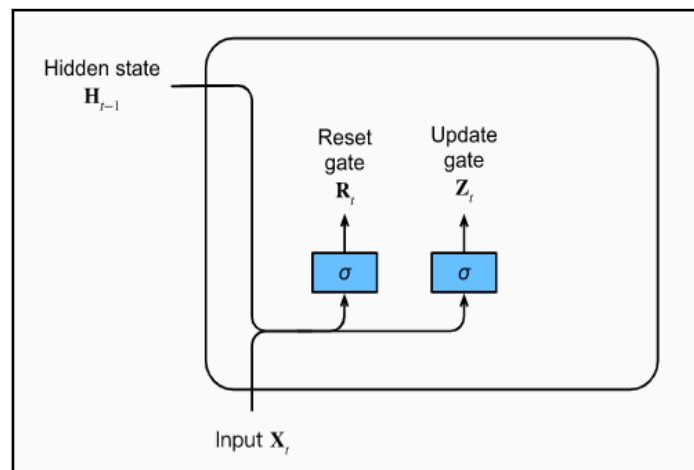


Gambar 4. Arsitektur Model GRU

(Chung, dkk., 2014)

Metode GRU memiliki dua komponen *gate* (gerbang) yaitu *reset gate* dan *update gate* (Chung, dkk., 2014).

- a. *Update gate* merupakan gerbang yang akan memutuskan seberapa banyak informasi masa lalu yang tetap disimpan.



Gambar 5. Alur *update gate*

(Chung, dkk., 2014)

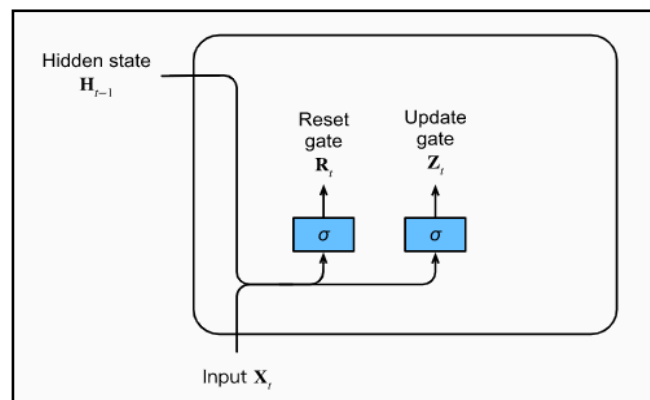
dengan persamaan sebagai berikut:

$$Z_t = \sigma(W_z * [h_{t-1}, x_t] + b_z) \quad (2.6)$$

dengan:

- z_t : *update gate*
- σ : Fungsi Aktivasi *Sigmoid*
- W_z : nilai *weight* untuk *update gate*
- h_{t-1} : nilai *output* sebelum orde ke t
- X_t : nilai *input* pada orde ke t
- b_r : parameter bias

b. *Reset gate* digunakan untuk menentukan bagaimana akan menggabungkan informasi *input* baru dengan informasi masa lalu.



Gambar 6. Alur *Reset gate*

(Chung, dkk., 2014)

dengan persamaan sebagai berikut:

$$R_t = \sigma(W_r * [h_{t-1}, x_t] + b_r) \quad (2.7)$$

dengan:

- R_t : *Reset gate*
- σ : Fungsi Aktivasi *Sigmoid*
- W_z : nilai *weight* untuk *reset gate*
- h_{t-1} : nilai *output* sebelum orde ke t

X_t : nilai *input* pada orde ke t
 b_r : parameter bias

Selanjutnya, dilakukan perhitungan kandidat *hidden state* pada *time step* saat ini dan informasi masa lalu menggunakan fungsi aktivasi *tanh* dengan persamaan sebagai berikut

$$\widetilde{H}_t = \tanh(W * X_t + (R_t * h_{t-1})W + b_h) \quad (2.8)$$

dengan:

\widetilde{H}_t : kandidat *hidden state*
 W : nilai parameter *weight*
 h_{t-1} : nilai *output* sebelum orde ke t
 x : nilai *input* pada orde ke t
 b_h : parameter bias

Kemudian dilakukan proses perhitungan *output* terakhir dengan persamaan sebagai berikut.

$$H_t = (1 - Z_t) * \widetilde{H}_t + Z_t * h_{t-1} \quad (2.9)$$

dengan:

H_t : *output*
 \widetilde{H}_t : kandidat *hidden state*
 h_{t-1} : nilai *output* sebelum orde ke t
 z_t : *output* pada *update gate*

2.7 Hypertuning Parameter

Hyperparameter merupakan parameter yang terdapat dalam suatu model dan telah ditentukan sebelum proses *training* dilakukan (Abirawa, dkk., 2017). Kombinasi parameter yang optimal akan menghasilkan model yang baik. Kombinasi parameter yang optimal dapat dicari dengan menggunakan *hypertuning*, akan tetapi *hypertuning* membutuhkan waktu yang lama . Oleh

karena itu, proses *hypertuning* akan menggunakan *early stopping* agar proses *training* yang dilakukan pada model berhenti ketika kondisi telah terpenuhi. Parameter yang digunakan dalam proses *hypertuning* adalah *dropout*, *batch size*, dan *epoch*. *Epoch* terjadi apabila seluruh dataset telah melalui proses *training* pada *neural network* sampai dengan kembali dalam putaran pertama. *Batch size* salah satu *hyperparameter* penting yang digunakan dalam pembelajaran mesin dan mengacu pada jumlah contoh pelatihan yang digunakan dalam satu kali iterasi. *Dropout* dilakukan untuk mencegah terjadinya *overfitting* yang terjadi selama proses *training*.

2.8 Denormalisasi Data

Setelah didapatkan hasil prediksi maka sebelum dilakukan perhitungan akurasi hasil prediksi perlu dilakukan denormalisasi yaitu data diubah menjadi nilai aktual kembali, dikarenakan data hasil prediksi masih dalam bentuk *range* interval pada saat normalisasi data (Ashar, dkk., 2018). Berikut persamaan denormalisasi:

$$X_t = x' (X_{\max} - X_{\min}) + X_{\min} \quad (2.10)$$

dengan:

- X_t : nilai hasil denormalisasi
- x' : nilai data normalisasi
- X_{\max} : nilai maksimal data aktual
- X_{\min} : nilai minimal data aktual

2.9 Evaluasi Model

Ketetapan atau akurasi menunjukkan seberapa jauh model peramalan tersebut mampu mereproduksi data yang diketahui (Makridakis, dkk., 1999). Metode-metode yang dibutuhkan untuk mengukur seberapa besar *error* yang dihasilkan untuk melihat akurasi model maka digunakan ukuran sebagai berikut (Budiman, 2016):

1. Mean Square Error (MSE)

Mean square error digunakan untuk mengevaluasi metode suatu peramalan yang menghasilkan kesalahan-kesalahan sedang yang memungkinkan lebih baik untuk kesalahan yang kecil. Dengan persamaan sebagai berikut:

$$MSE = \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n} \quad (2.11)$$

dengan:

Y_i : permintaan aktual pada periode t

\hat{Y}_i : peramalan permintaan pada periode t

n : jumlah periode peramalan yang terlibat

2. Root Mean Square Error (RMSE)

Root mean square error adalah akar kuadrat dari penjumlahan kuadrat *error* atau selisih antara nilai sebenarnya dan nilai prediksi, serta membagi hasil penjumlahan tersebut dengan banyaknya waktu peramalan. Nilai RMSE digunakan untuk menghitung nilai kesalahan atau perbedaan antara data prediksi dengan aktual, semakin kecil (mendekati 0) nilai RMSE maka hasil prediksi akan semakin akurat. Nilai RMSE dapat dihitung dengan persamaan sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}} \quad (2.12)$$

dengan:

Y_i : permintaan aktual pada periode t

\hat{Y}_i : peramalan permintaan pada periode t

n : jumlah periode peramalan yang terlibat

3. Mean Absolute Percentage Error (MAPE)

Mean absolute percentage error merupakan rata-rata diferensiasi absolute antara nilai peramalan aktual, yang dinyatakan sebagai persentase nilai aktual (Riyadi, 2015). Nilai MAPE digunakan untuk menghitung persentase kesalahan antara nilai aktual dan nilai prediksi. Nilai MAPE dirumuskan sebagai berikut:

$$100\% \times \frac{1}{n} \sum_{i=1}^n \frac{\hat{Y}_i - Y_i}{Y_i} \quad (2.13)$$

dengan:

Y_i : permintaan aktual pada periode t

\hat{Y}_i : peramalan permintaan pada periode t

n : jumlah periode peramalan yang terlibat

III. METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester genap tahun akademik 2021/2022, bertempat di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

3.2 Data Penelitian

Data yang digunakan pada penelitian ini adalah data bulanan nilai impor migas-non migas Indonesia (juta US \$) yang diperoleh dari situs Badan Pusat Statistik sebagai berikut <https://www.bps.go.id/indicator/8/1754/1/nilai-impor-migas-nonmigas.html> yang terhitung sejak Januari tahun 2000 sampai dengan Juni tahun 2022 dalam juta US \$ data bulanan diunduh dengan cara satu per satu dalam bentuk *software excel*. Berikut adalah data penelitian yang digunakan.

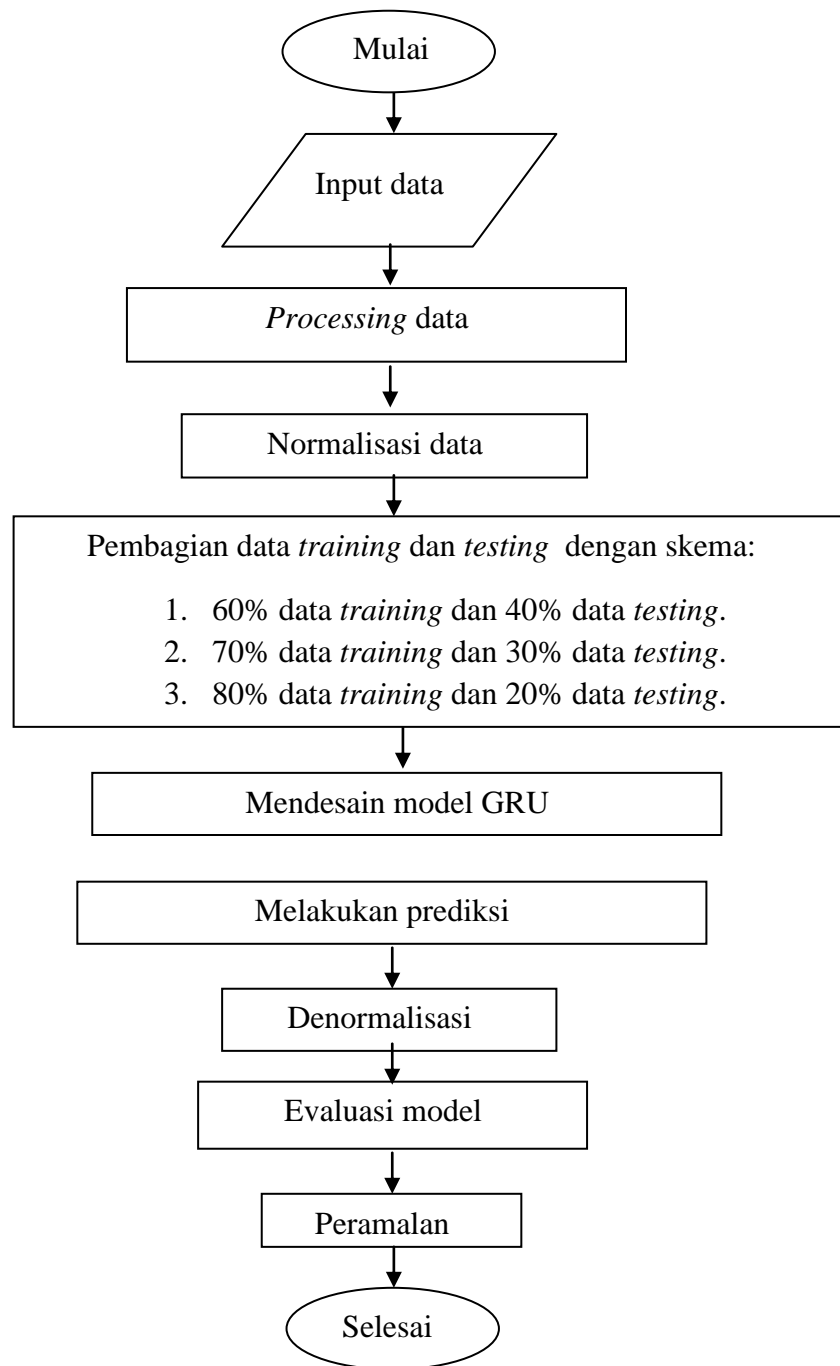
Tabel 1. Data Jumlah Impor di Indonesia

Periode	nilai Impor migas-non migas Indonesia (juta US \$)
2000-01	2169.5
2000-02	2120.4
2000-03	2265.1
2000-04	2338.9
2000-05	2383.9
...	...
2022-02	16638.5
2022-03	21962.4
2022-04	19757.4
2022-05	18606.3
2022-06	21003.4

3.3 Metode Penelitian

Pada penelitian ini melakukan prediksi dan peramalan nilai impor migas-non migas Indonesia (Juta US \$) menggunakan metode GRU dengan bantuan *software python* aplikasi *Google colab*. Adapun langkah-langkah yang harus dilakukan adalah sebagai berikut:

1. Melakukan *input* data nilai impor migas-non migas Indonesia (juta US \$) kedalam aplikasi *Google Colab*.
2. Melakukan *Preprocessing* data dengan pengecekan data hilang (*missing value*) dan kemudian melakukan transformasi data dengan *min-max normalization*.
3. Melakukan pembagian data dengan skema pembagian data *training* sebesar 60% dan data *testing* sebesar 40%, skema pembagian data *training* sebesar 70% dan data *testing* sebesar 30%, serta skema pembagian data *training* 80% dan data *testing* sebesar 20% .
4. Mendesain model GRU berdasarkan parameter terbaik yang di peroleh dari *hypertuning*, yaitu GRU Unit, *batch size*, *dropout* dan *epoch*.
5. Melakukan prediksi menggunakan parameter terbaik serta melakukan perbandingan hasil prediksi terhadap data aktual. Namun terlebih dahulu dilakukan denormalisasi pada data aktual.
6. Melakukan evaluasi model dengan menggunakan nilai MAPE, RMSE, dan akurasi.
7. Melakukan peramalan nilai impor migas-non migas Indonesia (juta US \$) untuk dua tahun kedepan.



Gambar 7. *Flowchart* proses metode GRU

V. KESIMPULAN

Berdasarkan hasil dan pembahasan yang telah dilakukan mengenai metode GRU dapat diambil kesimpulan sebagai berikut.

1. Model parameter terbaik untuk melakukan prediksi nilai impor-non migas Indonesia (juta us \$) menggunakan metode GRU adalah 32 GRU unit, *dropout* sebesar 0,2, 16 *batch size*, dan 100 *epoch* pada komposisi data *training* sebesar 80% dan data *testing* sebesar 80%.
2. Hasil prediksi dengan menggunakan GRU pada nilai impor migas dan non migas Indonesia (juta us \$) menghasilkan MAPE sebesar 0.999955%, sehingga dapat diartikan bahwa hasil tersebut memiliki kemampuan prediksi yang baik dengan akurasi sebesar 99.000044%. Oleh karena itu, metode ini dapat digunakan untuk melakukan peramalan periode dua tahun kedepan.
3. Peramalan nilai impor migas-non migas Indonesia (juta us \$) pada periode bulan Juni tahun 2022 sampai Juli tahun 2024 mengalami kenaikan.

DAFTAR PUSTAKA

- Abirawa, H., Jondri, dan Arfianto A. 2017. Face Recognition Using Convolution Neural Network. *E-Proceeding Engineering*. 4(3):4907-4961.
- Arfianti, U., Novitasari, D.C.R., Widodo, N., Hafiyusholeh, M., dan Utami, W.D. 2021. Prediksi Angka Sunspot Menggunakan Algoritma Gated Recurrent Unit. *Indonesia Journal Of Computing and Cybernetics Systems*. 15 (2): 141-152.
- Ashar, N. M., Cholissodin, I., dan Dewi, C. 2018. Penerapan Metode Extreme Learning Machine (LEM) untuk Memprediksi Jumlah Produksi Pipa yang Layak (Studi Kasus pada PT. KHI Pipe Industries). *Jurnal Pengembangan Teknologi Informasi dan Ilmu computer*. 2(11): 4621-4628.
- Budiman, H. 2016. Analisis dan perbandingan akurasi Model Prediksi Rentet Waktu Support Vector Machines Dengan Support Vector Machines Particle Swarm Optimizaton Untuk Arus lalu Lintas Jangka Pendek. *Systemic: Information System and Information Journal*. 2(1): 19-24.
- Chung,J., Gulcehre, C., Cho, K., and Bengio, Y. 2014. Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *arXiv*, 1-9.
- Fauziah, N.,Wahyuningsih, S., dan Nasution, Y.N. 2016. Peramalan menggunakan Fuzzy Time Series Chen (Studi Kasus : Curah Hujan Kota Samarinda). *Jurnal Statistika Universitas Muhammadiyah Semarang*. 4(2):52-61.
- Fayyad, U. 1996. *Advamce in Knowledge Discovery and Data Mining*. MIT Press,USA
- Hamdani dan Haikal. 2018. *Seluk Beluk Perdagangan Eksor Impor*. Edisi ke-2. Bushindo, Jakarta
- Han, J., Kamber, M., and Pei,J. 2012. *Data mining: Concept and Techniques, Third Edition*. Morgan Kaufmann Publishers, Waltham.
- Heizer, J. and Render, B. 1996. *Operations Management*. Prentice Hall, New Jersey.

- Hermawati, F.A. 2013. *Data Mining*. Andi Offset, Yogyakarta
- Hochreiter, S. And Schmidhuber, J. 1997. Long Short-Term Memory. *Neural Computation*. **9**(8):1735-1780.
- Julpan, Budhiarti, E., dan Zarlis, M. 2015. Analisis Fungsi Aktivasi Sigmoid Biner dan Sigmoid Bipolar Dalam Algoritma Backpropagation pada Prediksi Kemampuan Mahasiswa. *Jurnal Teknik dan Inovasi Mesin Otomotif, Komputer, Industri dan Elektronika*. **2**(1): 103-116.
- Kusrini dan Emha, T.L. 2009. *Algoritma Data Mining*. Cv Andi Offset, Yogyakarta.
- Lewis, N.D. 2017. *Neural Network For Time Series Forecasting With R*. Pearson Education, New York.
- Makridakis, S., Wheelwright, S.C., dan McGee, V.E. 1999. *Metode dan Aplikasi Peramalan*. Edisi ke-2. Erlangga, Jakarta.
- Riyadi, S. 2015. Aplikasi Peramalan penjualan Obat Menggunakan Metode Pemulusan (Studi Kasus: Instalasi Farmasi Rsud Dr Murjani). *Seminar Nasional Teknologi Informasidan Multimedia*. (1): 1-6.
- Russel, S. J. and Norvig, P. 2016. *Artificial Intelligence: A Modern Approach*. Pearson Education Limited, Malaysia.
- Saputra , R, A., Azhar, Y, dan Rahmayanti, V. 2020. Prediksi Permintaan Kargo pada Cargo Service Center Tangerang City Menggunakan Metode Gated Recurrent Unit. *REPOSITOR*. **2**(8): 1113-1122.
- Sen, S., Sugiarto, D., dan Rochman, A. 2020. Komparasi Metode Multilayer Perceptron (MLP) dan Long-Short term Memory (LSTM) dalam Peramalan Harga Beras. *ULTIMATICS*. **11**(1): 35-41.
- Suyanto. 2017. *Data Mining Untuk Klasifikasi dan Klasterisasi Data*. Edisi ke-1. Informatika, Bandung.
- Wiranda, L., dan Sadikin, M. 2019. Penerapan Long Short Term Memory Pada Data *Time Series* Untuk Memprediksi Penjualan Produk Pt. Metiska Farma. *Jurnal Nasional Pesndidikan Teknik Informatika*. **8**(3): 184-196.
- Zhang, G. P. 2004. *Neural Network in Business Forecasting*. Idea Group Publishing, USA.