

**PERAMALAN HARGA MINYAK MENTAH WEST TEXAS
INTERMEDIATE MENGGUNAKAN METODE GATED RECURRENT
UNIT**

SKRIPSI



NURPADIAN

H011201061

**PROGRAM STUDI MATEMATIKA DEPARTEMEN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN**

MAKASSAR

2024

**PERAMALAN HARGA MINYAK MENTAH WEST TEXAS
INTERMEDIATE MENGGUNAKAN METODE GATED RECURRENT
UNIT**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelas Sarjana Sains
pada Program Studi Matematika Departemen Matematika Fakultas
Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin**

UNIVERSITAS HASANUDDIN

NURPADIAN

H011201061

**PROGRAM STUDI MATEMATIKA
DEPARTEMEN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS HASANUDDIN**

MAKASSAR

MEI 2024

LEMBAR PERNYATAAN KEOTENTIKAN

Saya yang bertanda tangan di bawah ini menyatakan dengan sungguh-sungguh bahwa skripsi yang saya buat dengan judul:

Peramalan Harga Minyak Mentah *West Texas Intermediate* Menggunakan Metode *Gated Recurrent Unit*

adalah benar hasil karya saya sendiri, bukan hasil plagiat dan belum pernah dipublikasikan dalam bentuk apapun.

Makassar, 20 Mei 2024



Nurpadian

NIM. H011201061

**PERAMALAN HARGA MINYAK MENTAH *WEST TEXAS*
INTERMEDIATE MENGGUNAKAN METODE *GATED RECURRENT*
*UNIT***

Disetujui oleh:

Pembimbing Utama

Dr. Khaeruddin, M.Sc.

NIP. 196509141991031003

Pada 20 Mei 2024

HALAMAN PENGESAHAN

**PERAMALAN HARGA MINYAK MENTAH *WEST TEXAS*
INTERMEDIATE MENGGUNAKAN METODE *GATED RECURRENT*
*UNIT***

Disusun dan diajukan oleh

NURPADIAN

H011201061

Telah dipertahankan dihadapan Panitia Ujian yang dibentuk dalam rangka penyelesaian Studi Program Sarjana Studi Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin pada tanggal 20 Mei 2024 dan dinyatakan telah memenuhi syarat kelulusan.

Menyetujui,

Pembimbing Utama

Dr. Khaeruddin, M.Sc.

NIP. 196509141991031003

Ketua Program Studi

Dr. Firman, S.Si., M.Si

NIP. 196804292002121001


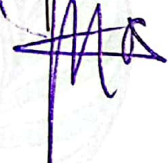

HALAMAN PENGESAHAN

Skripsi ini diajukan oleh:

Nama : Nurpadian
NIM : H011201061
Program Studi : Matematika
Judul Skripsi : Peramalan Harga Minyak Mentah *West Texas Intermediate* Menggunakan Metode *Gated Recurrent Unit*

Telah berhasil dipertahankan di hadapan Dewan Penguji dan diterima sebagai bagian dari persyaratan yang diperlukan untuk memperoleh gelar Sarjana Sains pada Program Studi Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin.

DEWAN PENGUJI

1. Ketua : Dr. Khaeruddin, M.Sc. ()
2. Anggota : Prof. Dr. Eng. Mawardi, S.Si., M.Si ()
3. Anggota : Jusmawati Massalesse, S.Si., M.Si ()

Ditetapkan di : Makassar

Tanggal : 20 Mei 2024



KATA PENGANTAR

“Tidak ada rasa bersalah yang dapat mengubah masa lalu dan tidak ada kekhawatiran yang dapat mengubah masa depan, maka jangan pernah mengucapkan tidak mungkin”, ingat “*Nothing is impossible when Allah said kun fayakun*”.

(Umar Bin Khattab)

Alhamdulillah rabbil'alamin, segala puji hanya milik Allah *Subhana Wa Ta'ala*, karena atas rahmat dan karunia-Nya lah yang senantiasa dicurahkan kepada penulis sehingga skripsi ini dapat diselesaikan dengan judul “**Peramalan Harga Minyak Mentah West Texas Intermediate Menggunakan Metode Gated Recurrent Unit**”. Skripsi ini disusun untuk memenuhi salah satu persyaratan guna menyelesaikan Pendidikan Strata Satu (S1) Sarjana Sains pada Program Studi Matematika Departemen Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin.

Penulis menyadari bahwa skripsi ini tidak dapat terselesaikan tanpa adanya bantuan, dukungan, bimbingan, motivasi, dan doa dari berbagai pihak. Oleh karena itu, pada kesempatan ini penulis mengucapkan terima kasih yang sebesar-besarnya kepada kedua orang tua penulis, Bapak **Sunardi** dan Ibu **Sabria** yang telah sabar membesarkan dan mendidik penulis, serta memberikan doa dan nasehat sehingga penulis bisa berada pada titik ini dan mampu menyelesaikan pendidikan di perguruan tinggi. Terima kasih kepada adik penulis **Islawati** yang telah memberikan dukungan pada penulis. Terima kasih telah menjadi sumber motivasi dan kekuatan bagi penulis selama perjalanan akademik ini.

Pada kesempatan ini pula, dengan segala kerendahan hati penulis ingin menyampaikan terima kasih kepada:

1. Bapak **Prof. Dr. Ir. Jamaluddin Jompa, M.Sc.**, selaku Rektor Universitas Hasanuddin.
2. Bapak **Dr. Eng. Amiruddin, S.Si., M.Si.**, selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Hasanuddin.

3. Bapak **Dr. Firman, S.Si., M.Si.**, selaku Ketua Departemen Matematika beserta jajaran staf Departemen Matematika yang telah membantu proses administrasi, serta Bapak dan Ibu Dosen Departemen Matematika yang telah membagikan ilmu dan pengalamannya selama proses perkuliahan.
4. Bapak **Dr. Khaeruddin., M.Sc.**, selaku pembimbing untuk segala ilmu, nasehat, dan kesabaran dalam membimbing dan mengarahkan penulis, serta bersedia meluangkan waktunya untuk mendampingi penulis sehingga skripsi ini dapat diselesaikan.
5. Bapak **Prof. Dr. Eng. Mawardi., S.Si., M.Si.**, dan Ibu **Jusmawati Massalesse., S.Si., M.Si.**, selaku dosen penguji penulis yang telah bersedia meluangkan waktunya untuk memberikan saran dan arahan kepada penulis dalam penulisan skripsi ini.
6. **Abdillah Mushawwir An Nur**, seseorang yang selalu menemani dalam keadaan suka maupun duka, memberikan dukungan, motivasi, dan membantu penulis sehingga skripsi ini dapat terselesaikan dengan baik.
7. Sahabat-sahabat penulis **Sisilia Anggraeni, Wardalisah, dan Rofifah Fakhriyah** yang telah membantu, menyemangati dan tempat berbagi keluh-kesah penulis selama kurang lebih 4 tahun perkuliahan.
8. Teman-teman penulis **Hilda, Asfi, Fahira, Indah, Wulan, Sulfina, Mona, Nurkholisa, Afiliani, dan Nuralisa** yang telah membantu dan menjadi teman diskusi penulis selama perkuliahan dan proses penulisan skripsi.
9. Teman-teman **Matematika 2020** atas segala dukungan, kebersamaan, dan kerjasamanya selama ini.
10. Teman-teman **KKN G-110 Posko Bonra (Salwiah, Nuhi, Aulia, Aska, Aina, dan Afyah)** yang telah saling memberi semangat serta dukungan di masa semester akhir penulis.
11. Serta segala pihak yang tidak dapat disebutkan satu persatu yang telah membantu penulis dalam menyelesaikan skripsi ini.

Penulis menyadari bahwa skripsi ini masih jauh dari kesempurnaan. Oleh karena itu, kritik dan saran yang membangun diharapkan oleh penulis untuk

perbaikan dan pengembangan penelitian lebih lanjut. Akhir kata, semoga skripsi ini dapat bermanfaat bagi kalangan akademisi, praktisi, dan semua pihak.

Makassar, 20 Mei 2024

Penulis,

A handwritten signature in black ink, appearing to be the name 'Nurpadian' written in a stylized, cursive script.

Nurpadian

**PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR UNTUK
KEPENTINGAN AKADEMIS**

Sebagai sivitas akademik Universitas Hasanuddin, saya yang bertanda tangan di bawah ini:

Nama : Nurpadian
NIM : H011201061
Program Studi : Matematika
Departemen : Matematika
Fakultas : Matematika dan Ilmu Pengetahuan Alam
Jenis Karya : Skripsi

demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Universitas Hasanuddin **Hak Bebas Royalti Noneklusif** (*Non-exclusive Royalty-Free Right*) atas karya ilmiah saya yang berjudul:

“Peramalan Harga Minyak Mentah *West Texas Intermediate* Menggunakan Metode *Gated Recurrent Unit*”

Beserta perangkat yang ada (jika diperlukan). Terkait dengan hal di atas, maka pihak universitas berhak menyimpan, mengalih-media/format-kan, mengola dalam bentuk pangkalan data (*database*), merawat, dan mempublikasikan tugas akhir saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik Hak Cipta.

Demikian pernyataan ini saya buat dengan sebenarnya.

Dibuat di Makassar pada 20 Mei 2024

Yang menyatakan



Nurpadian

ABSTRAK

Minyak mentah jenis *West Texas Intermediate* (WTI) merupakan harga minyak mentah yang berpengaruh dalam perekonomian dunia, dan sebagai patokan dalam perdagangan minyak mentah. Masalah utama para *trader* minyak mentah adalah ketidakpastian harga minyak itu sendiri. Dalam penelitian ini, penulis bermaksud untuk membuat model *deep learning* yang dapat meramalkan (*forecasting*) harga dari minyak mentah menggunakan algoritma *Gated Recurrent Unit* (GRU). Evaluasi yang digunakan untuk mengukur kesalahan peramalan adalah *loss function*, MAPE dan RMSE. Berdasarkan hasil *training* dan *testing* dengan menggunakan 1508 data (02/01/2018 sampai 27/12/2023) dan 4 *variables* (*close*, *open*, *high* dan *low*), diperoleh hasil peramalan model GRU dengan akurasi “Sangat Akurat”, hal tersebut ditunjukkan pada *variable close* dengan nilai MAPE sebesar 3.1021% dan RMSE sebesar 3.1109. Kemudian pada *variable open* diperoleh nilai MAPE sebesar 3.0787% dan RMSE sebesar 2.9357. Pada *variable high* diperoleh nilai MAPE sebesar 2.7428% dan RMSE sebesar 2.6913. Serta pada *variable low* diperoleh nilai MAPE sebesar 5.5328% dan RMSE sebesar 4.7912.

Kata Kunci: Minyak Mentah, Peramalan, *Gated Recurrent Unit*

Judul : Peramalan Harga Minyak Mentah *West Texas Intermediate* Menggunakan Metode *Gated Recurrent Unit*
Nama : Nurpadian
NIM : H011201061
Program Studi : Matematika

ABSTRACT

West Texas Intermediate (WTI) crude oil is an influential crude oil price in the world economy and a benchmark in crude oil trading. The main problem for crude oil traders is the uncertainty of the oil price itself. In this research, the author intends to create a deep-learning model that can forecast the price of crude oil using the Gated Recurrent Unit (GRU) algorithm. The evaluation used to measure the forecasting error is the loss function, MAPE, and RMSE. Based on the results of training and testing using 1508 data (02/01/2018 to 27/12/2023) and 4 variables (close, open, high, and low), the GRU model forecasting results are obtained with "Very Accurate" accuracy, this is shown in the close variable MAPE value of 3.1021% and RMSE of 3.1109. Then in the open variable, the MAPE value is 3.0787% and the RMSE is 2.9357. In the high variable, the MAPE value is 2.7428% and the RMSE is 2.6913. As well as the low variable obtained a MAPE value of 5.5328% and an RMSE of 4.7912.

Keywords: *Crude Oil, Forecasting, Gated Recurrent Unit*

Title : *Forecasting West Texas Intermediate Crude Oil Prices
Using The Gated Recurrent Unit method*

Name : *Nurpadian*

Student ID : *H011201061*

Study Program : *Mathematics*

DAFTAR ISI

HALAMAN JUDUL	ii
LEMBAR PERNYATAAN KEOTENTIKAN	iii
HALAMAN PERSETUJUAN PEMBIMBING	iv
HALAMAN PENGESAHAN	v
KATA PENGANTAR	vi
PERNYATAAN PERSETUJUAN PUBLIKASI TUGAS AKHIR	ix
ABSTRAK	x
<i>ABSTARCT</i>	xi
DAFTAR ISI	xii
DAFTAR GAMBAR	xiv
DAFTAR TABEL	xvi
DAFTAR LAMPIRAN.....	xvii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	3
1.3 Batasan Masalah	4
1.4 Tujuan Penelitian	4
1.5 Manfaat Penelitian	4
BAB II TINJAUAN PUSTAKA	6
2.1 Minyak Mentah	6
2.2 Peramalan	6
2.3 Fungsi Aktivasi	7
2.4 <i>Gated Recurrent Unit (GRU)</i>	8
2.5 Inisialisasi <i>Hyperparameter</i>	13
2.6 Normalisasi Data.....	14

2.7 <i>Time Step</i>	15
2.8 Evaluasi Model Peramalan	15
BAB III METODE PENELITIAN	18
3.1 Jenis dan Sumber Data	18
3.2 Identifikasi Variabel	18
3.3 Tahapan Penelitian	19
3.4 Alur Kerja Penelitian	22
BAB IV HASIL DAN PEMBAHASAN	23
4.1 Deskripsi Data	23
4.2 <i>Preprocessing</i>	25
4.3 <i>Split Data</i>	28
4.4 Modeling	29
4.5 <i>Training Data</i>	30
4.6 Hasil Peramalan Model	32
4.7 Analisis Evaluasi Model	34
BAB V KESIMPULAN DAN SARAN	38
5.1 Kesimpulan	38
5.2 Saran	38
DAFTAR PUSTAKA	39
LAMPIRAN	42

DAFTAR GAMBAR

Gambar 2.1 Fungsi Aktivasi *Sigmoid* 7

Gambar 2.2 Fungsi Aktivasi *Tangen Hiperbolik* atau *Tanh* 8

Gambar 2.3 Arsitekstur *Gated Recurrent Unit* 9

Gambar 2.4 Alur *Reset Gate* 9

Gambar 2.5 Alur *Update Gate* 10

Gambar 2.6 *Candidate Hidden State* 11

Gambar 2.7 *Hidden State* 12

Gambar 3.1 Diagram Alur Keja Penelitian 22

Gambar 4.1 Plot Harga *Variable Close* Minyak Mentah..... 22

Gambar 4.2 Plot Harga *Variable Open* Minyak Mentah 24

Gambar 4.3 Plot Harga *Variable High* Minyak Mentah 24

Gambar 4.4 Plot Harga *Variable Low* Minyak Mentah 25

Gambar 4.5 *Dataset* Sebelum *Preprocessing* dan Pengecekan Atribut Data 26

Gambar 4.6 *Dataset* Setelah *Preprocessing* dan Pengecekan Atribut Data..... 26

Gambar 4.7 Segmentasi 60 Data pada Data *Training* dan *Testing* 28

Gambar 4.8 Arsitektur Model GRU..... 30

Gambar 4.9 Visualisasi *Training Loss* dan *Validation Loss* pada *Variable Close* 30

Gambar 4.10 Visualisasi *Training Loss* dan *Validation Loss* pada *Variable Open* .. 31

Gambar 4.11 Visualisasi *Training Loss* dan *Validation Loss* pada *Variable High* .. 31

Gambar 4.12 Visualisasi *Training Loss* dan *Validation Loss* pada *Variable Low* ... 32

Gambar 4.13 Hasil Peramalan *Variable Close* 33

Gambar 4.14 Hasil Peramalan *Variable Open* 33

Gambar 4.15 Hasil Peramalan *Variable High* 33

Gambar 4.16 Hasil Peramalan *Variable Low* 32

Gambar 4.17 Hasil Peramalan <i>Variable Close</i>	35
Gambar 4.18 Hasil Peramalan <i>Variable Open</i>	35
Gambar 4.19 Hasil Peramalan <i>Variable High</i>	36
Gambar 4.20 Hasil Peramalan <i>Variable Low</i>	36

DAFTAR TABEL

Tabel 2.1 Kriteria Akurasi Peramalan MAPE	16
Tabel 3.1 Data Harga Minyak Mentah WTI	18
Tabel 4.1 Data Harga Minyak Mentah WTI	23
Tabel 4.2 Data Harga Minyak Mentah Sebelum Normalisasi	27
Tabel 4.3 Data Harga Minyak Mentah Setelah Normalisasi	27
Tabel 4.4 Komposisi <i>Split</i> Data	28
Tabel 4.5 Evaluasi Kinerja Model	34

DAFTAR LAMPIRAN

Lampiran 1: Dataset Harga Minyak Mentah WTI	42
Lampiran 2: <i>Sorce Code Model Gated Recurrent Unit</i>	42

BAB I PENDAHULUAN

1.1 Latar Belakang

Minyak mentah merupakan salah satu sumber daya alam tak terbarukan yang dibutuhkan oleh negara-negara di seluruh dunia untuk mendorong pertumbuhan ekonomi. Selama ini minyak mentah diolah menjadi bahan bakar, sehingga peran minyak mentah sangat dibutuhkan sebagai energi terpenting di dunia (Nurlela dkk., 2023). Namun, ketersediaan minyak mentah semakin berkurang dari waktu ke waktu (Fajri dkk., 2023).

Penerapan harga minyak mentah didasarkan pada dua kelompok yaitu *West Texas Intermediate* (WTI) dan *Brent*. Minyak mentah jenis WTI merupakan nilai standarisasi minyak mentah yang berasal dari Negara Amerika Serikat dan *Brent* merupakan nilai standarisasi minyak mentah yang berasal dari laut utara (Eropa). Namun, pada tahun 2007 produksi minyak mentah jenis *Brent* terus mengalami penurunan maka berkembang standarisasi harga baru yaitu WTI (Miyanti dan Wiagustini, 2018).

Minyak mentah jenis WTI merupakan harga minyak mentah yang berpengaruh dalam perekonomian dunia, dan sebagai patokan dalam perdagangan minyak mentah (Gusti dan Luh, 2018). Perdagangan minyak mentah jenis WTI adalah minyak mentah dengan taraf yang tertinggi. Minyak mentah jenis WTI juga memiliki harga yang sangat tinggi pada *Organization of the Petroleum Exporting Countries* (OPEC) dari jenis minyak lainnya. Namun, minyak mentah WTI sering mengalami naik turun harga dalam setiap harinya (Zaccheaus dan Ajuwon, 2019).

Harga minyak mentah WTI pada tahun 2021 mengalami penurunan mencapai USD 6.69 setiap barel yang awalnya USD 78.65 menjadi USD 71.69. Kejadian ini dipengaruhi oleh pandemi *Covid-19* yang beberapa Negara mengalami *lockdown* (Latif dkk., 2023). Setelah masalah *Covid-19* usai harga minyak WTI mulai normal karena perekonomian dunia mulai pulih, namun hal tersebut tidak berlangsung lama. Pada akhir 2022 minyak mentah mengalami

penurunan mencapai USD 7.78 setiap barelnya yang awalnya memiliki harga USD 84.39 menjadi USD 76.52 (Dimasti, 2022).

Harga minyak terus mengalami pergerakan fluktuatif, seringkali harga minyak mentah menginjak level tertinggi dari volalitas (Oud, 2014). Ketidakstabilan harga minyak mentah bergantung pada faktor-faktor yang mempengaruhi diantaranya peristiwa geopolitik dan kekurangan pasokan (Nurlela dkk., 2023). Oleh karena itu, diperlukan sistem yang dapat membantu *trader* ataupun investor untuk mengetahui kejadian di masa mendatang dan untuk mengambil keputusan mengenai minyak mentah dengan melakukan peramalan harga (Fadillah dkk., 2020).

Peramalan adalah tugas umum ilmu data (*data science*) yang membantu jaringan dengan perencanaan kapasitas, ketepatan keputusan, penempatan tujuan dan deteksi anomali. Terlepas dari kepentingannya, ada beberapa tantangan terkait dalam menghasilkan perkiraan yang andal dan berkualitas tinggi, terlebih lagi pada berbagai deret waktu atau *time series* dan analisa dengan keahlian dalam pemodelan *time series* yang relatif jarang (Jange, 2022). Salah satu perkembangan metode *time series* yang dapat digunakan untuk mengatasi hal tersebut yaitu dengan menggunakan *Deep Learning*.

Deep Learning adalah bagian pengembangan *Machine Learning* dan *Artificial Intelligence* (AI) yang merupakan konsep mengenai membuat mesin-mesin yang dapat berpikir cerdas yang mampu belajar dari berbagai input dengan *outcome* yang akurat (Primartha dan Rifkie, 2018). Jenis algoritma *Deep Learning* yang dapat digunakan adalah *Gated Recurrent Unit* (GRU) untuk melakukan peramalan pada pola data yang berbentuk *time series*. GRU merupakan algoritma yang berbasis *time series* yang dikenal lebih unggul dalam melakukan suatu peramalan dengan menyusun arsitektur yang memanfaatkan sistem gerbang untuk menyimpan informasi dalam waktu lama. GRU memiliki parameter yang tersusun atas dua *gate* yaitu *reset gate* dan *update gate*. Arsitektur GRU terdiri dari 2 *sigmoid* dan *tanh* sehingga GRU memberikan konvergensi yang lebih cepat (Hastomo dkk., 2021).

Nurlela dkk (2023), menganalisis prediksi harga minyak mentah WTI menggunakan metode *Fuzzy Time Series Markov Chain*. Pada hasil penelitian ini

menunjukkan akurasi prediksi harga minyak menggunakan metode *Fuzzy Time Series Markov Chain* cukup baik dengan mendapatkan hasil akurasi prediksi lebih dari 98% dengan nilai dari MAPE sebesar 1.18%.

Abumohsen dkk (2023), melakukan penelitian *Electrical Load Forecasting Using LSTM, GRU, and RNN Algorithms*. Pada penelitian tersebut menggunakan algoritma *deep learning* untuk meramalkan beban listrik, diantaranya LSTM, GRU dan RNN. Model-model tersebut diuji, dan model GRU mencapai kinerja terbaik dalam hal akurasi dan kesalahan terendah. Hasilnya menunjukkan bahwa model GRU mencapai *R-squared* sebesar 90.228%, *Mean Square Error* (MSE) sebesar 0.00215, dan *Mean Absolute Error* (MAE) sebesar 0.03266.

Tanudy dkk (2023), menganalisis prediksi harga emas di Indonesia menggunakan *Gated Recurrent Unit*. Pada penelitian ini *dataset* yang digunakan untuk melatih model adalah data historis harga penutupan emas, harga penutupan saham PT. Aneka Tambang dan harga penutupan kurs dollar yang didapatkan pada *website Yahoo Finance* mulai dari Januari 2018 hingga Oktober 2023. Hasil *training* model terbaik dengan *hyperparameter* data *training* 70%, data *testing* 30%, *timestep* 20, *epoch* 50, *batch size* 16 dengan nilai *R-Squared* sebesar 0.97, nilai MAE sebesar 300.17, dan nilai RMSE sebesar 17.33.

Berdasarkan latar belakang di atas menunjukkan bahwa metode GRU memiliki performa baik dalam meramalkan sesuatu, maka peneliti tertarik untuk melakukan penelitian menggunakan metode GRU sebagai metode untuk meramalkan harga minyak mentah WTI dan untuk memperlihatkan data *actual* dengan data uji maka model evaluasi yang digunakan pada penelitian ini ialah *Mean Absolute Percentege Error* (MAPE) dan *Root Mean Square Error* (RMSE). Oleh karena itu, penelitian ini berjudul **“Peramalan Harga Minyak Mentah West Texas Intermediate Menggunakan Metode Gated Recurrent Unit”**.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka yang menjadi permasalahan dalam penelitian ini adalah bagaimana akurasi model yang dihasilkan menggunakan metode Algoritma *Gated Recurrent Unit* dalam

melakukan peramalan harga minyak mentah WTI dengan memanfaatkan beberapa model evaluasi yaitu MAPE dan RMSE?

1.3 Batasan Masalah

Untuk menjaga fokus pembahasan pada penelitian, masalah dalam penelitian ini dibatasi pada:

- 1.3.1 Data yang akan digunakan adalah data *series* harga minyak mentah WTI mulai dari Januari tahun 2018 hingga Desember tahun 2023.
- 1.3.2 Pengujian menggunakan segmentasi 60 data berturut-turut untuk meramalkan harga minyak mentah WTI pada data ke 61 dan seterusnya, harga minyak mentah WTI yang digunakan meliputi harga *Close*, *Open*, *High*, dan *Low*.
- 1.3.3 Algoritma yang digunakan adalah *Gated Recurrent Unit* (GRU).
- 1.3.4 Metode evaluasi yang digunakan untuk penentuan akurasi hasil peramalan harga minyak mentah WTI adalah evaluasi model menggunakan *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE).
- 1.3.5 Tools bahasa pemrograman yang digunakan adalah Python.

1.4 Tujuan Penelitian

Berdasarkan masalah yang dirumuskan, maka penelitian ini memiliki tujuan untuk mengetahui akurasi kinerja model yang dihasilkan menggunakan metode algoritma *Gated Recurrent Unit* dalam melakukan peramalan harga minyak mentah dengan memanfaatkan model evaluasi MAPE dan RMSE.

1.5 Manfaat Penelitian

Manfaat yang dapat diperoleh dari penelitian mengenai peramalan harga minyak mentah menggunakan metode *Gated Recurrent Unit* adalah sebagai berikut:

- 1.5.1 Memberikan informasi hasil peramalan harga minyak mentah WTI pada periode yang akan datang sehingga dapat dilakukan antisipasi untuk mencegah menurunnya harga minyak mentah dan juga sebagai bahan

pertimbangan bagi instansi terkait untuk menentukan kebijakan kedepannya.

- 1.5.2 Memberikan informasi apakah metode dengan algoritma *Gated Recurrent Unit* memiliki akurasi yang baik dalam melakukan peramalan harga minyak mentah WTI.

BAB II TINJAUAN PUSTAKA

2.1 Minyak Mentah

Sumber daya alam yang tidak dapat diperbaharui salah satunya adalah minyak mentah. Sedangkan permintaan minyak selalu meningkat untuk memenuhi kebutuhan sehari-hari. Hal tersebut mempengaruhi kapasitas minyak semakin berkurang di setiap harinya. Jika konsumsi minyak meningkat terus-menerus tetapi tidak diimbangi dengan ketersediaan minyak yang ada maka akan terjadi kelangkaan sumber daya minyak. Dampak dari terjadinya ketidakseimbangan antara produksi dan konsumsi minyak saat ini salah satunya adalah kenaikan harga minyak yang berfluktuatif (Fauzannissa dkk., 2015).

Rahman (2008) mengklaim harga minyak dunia dipengaruhi oleh tiga faktor, yaitu:

- a) Faktor pertama adalah faktor fundamental, yang terdiri dari permintaan minyak, pasokan minyak, stok minyak, kapasitas produksi cadangan dunia dan kemampuan industri dunia.
- b) Faktor kedua adalah faktor non fundamental, yang terdiri dari geopolitik, kebijakan pemerintah, cuaca, bencana alam, pemogokan, kerusakan instalasi ranah produksi, pelemahan nilai dollar dan spekulasi.
- c) Faktor ketiga adalah pengaruh kebijakan pasukan OPEC.

2.2 Peramalan (*Forecasting*)

Forecasting atau peramalan merupakan suatu proses untuk memperkirakan apa yang mungkin terjadi dimasa depan berdasarkan informasi yang tersedia saat ini berupa data masa lalu dan masa sekarang (Oktaviani dan Hustinawati, 2021). Secara umum, peramalan dapat dikategorikan dalam berbagai aspek, tergantung dari sudut pandangnya (Robial, 2018). Jika dikelompokkan berdasarkan sifatnya, peramalan dapat dibagi menjadi 3 jenis, diantaranya adalah peramalan berdasarkan sifat penyusunannya, peramalan menurut jangka waktu ramalan yang disusunnya, dan peramalan menurut kategori jenis data yang digunakan (Herjanto, 2019).

Metode peramalan dapat dikelompokkan menjadi dua jenis berdasarkan data yang digunakan, yaitu metode kualitatif dan metode kuantitatif. Metode kualitatif dapat digunakan tanpa adanya model matematik, hal ini biasanya disebabkan oleh data yang tersedia tidak cukup untuk mewakili situasi atau kondisi di masa depan. Metode kuantitatif ini menggunakan data historis dan serangkaian model matematika untuk membuat ramalan tentang hasil di masa depan. Dalam metode kuantitatif terdapat beberapa macam model salah satunya adalah model *Time Series* yang menganalisis data historis untuk menemukan pola atau *trend*, kemudian memproyeksikan pola atau *trend* tersebut ke masa depan (Robial, 2018).

2.3 Fungsi Aktivasi


Fungsi aktivasi merupakan fungsi yang digunakan pada jaringan saraf untuk mengaktifkan dan tidak mengaktifkan *neuron*. Terdapat 2 fungsi aktivasi yang sering digunakan yaitu sebagai berikut.

a) Fungsi aktivasi *sigmoid*

Fungsi aktivasi *sigmoid* merupakan fungsi nonlinier yang menampilkan nilai dengan *range* 0 hingga 1, yang memiliki arti menggambarkan banyak masing-masing komponen yang harus dilewati. Fungsi *sigmoid* ditunjukkan pada persamaan berikut.

$$f(x) = \sigma(x) = \frac{1}{1+e^{-x}} \quad (2.1)$$

Berikut grafik dari fungsi aktivasi *sigmoid*.



Sumber : Julpan dkk., 2015


Gambar 2.1 Fungsi Aktivasi *Sigmoid*

b) Fungsi aktivasi *tangen hiperbolik* atau *tanh*

Fungsi aktivasi *tangen hiperbolik* atau *tanh* merupakan fungsi alternatif dari lapisan *sigmoid*. *Input* untuk fungsi aktivasi *tanh* ini berupa bilangan asli dan *outputnya* memiliki *range* -1 sampai 1 dengan persamaan sebagai berikut.

$$f(x) = \tanh(x) = \frac{2}{(1+e^{-2x})} - 1 \quad (2.2)$$

Berikut grafik dari fungsi aktivasi *tanh*.



Sumber : Julpan dkk., 2015

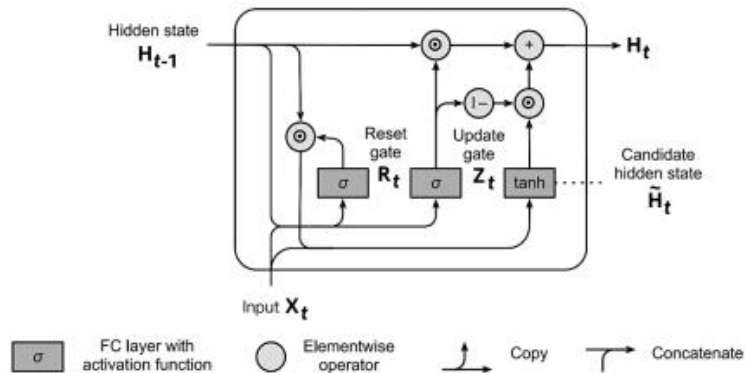
Gambar 2.2 Fungsi Aktivasi *Tangen Hiperbolik* atau *Tanh*

Dimana x adalah data *input* dan $e \approx 2.718281828459045 \dots$. Karakteristik terpusat di nol pada fungsi aktivasi *tanh* dapat lebih mudah memusatkan data sehingga proses pengoptimalan menjadi lebih muda dibanding fungsi aktivasi *sigmoid* dengan *threshod* berada di 0.5 yang hanya dapat memutuskan bahwa *input* yang diberikan hanya memiliki dua tipe kelas. Karena *output* fungsi *sigmoid* yang tidak berpusat membuat proses optimal lebih sulit, sehingga fungsi *tanh* selalu lebih baik jika dibandingkan dengan fungsi *sigmoid* (Julpan dkk., 2015).

2.4 Gated Recurrent Unit (GRU)

Gated Recurrent Unit (GRU) merupakan turunan dari *Recurrent Neural Network* dan merupakan versi sederhana dari *Long-Short Term Memory* (LSTM) sehingga tidak membutuhkan waktu pelatihan yang lama dengan kinerja jaringan yang ditingkatkan. Dalam melakukan proses sel GRU menggunakan satu sel tersembunyi (*hidden unit*) dalam arsitektur GRU yang memiliki dua komponen utama yang disebut sebagai *reset gate* dan *update gate*. Tujuan utama dari pembuatan metode GRU adalah untuk membuat setiap *unit* berulang untuk dapat menangkap hubungan dalam skala waktu yang berbeda-beda dan mudah

menyesuaikan dengan keadaan (Chung dkk., 2014). Berikut gambar diagram arsitektur GRU.

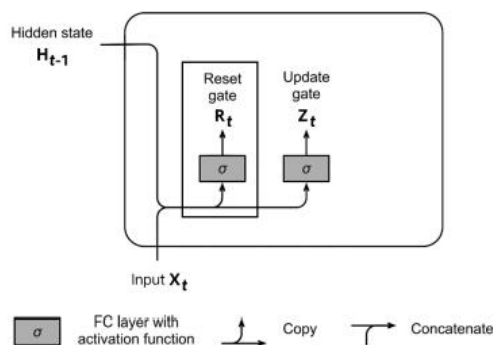


Sumber : Pu dkk., 2022

Gambar 2.3 Arsitektur *Gated Recurrent Unit*

2.4.1 Reset Gate

Langkah pertama pada arsitektur GRU *reset gate* yaitu dengan menentukan bagaimana menggabungkan informasi dari *time step* sebelumnya dan masukan baru di *reset gate*. Pada proses ini *reset gate* akan menentukan berapa banyak informasi dari *time step* terdahulu yang dapat dilupakan menggunakan fungsi aktivasi *sigmoid*. *Output* dari *reset gate* bernilai 0 dan 1. Jika *output* semakin mendekati 0 berarti informasi dari *time step* sebelumnya tidak terlalu berpengaruh dan akan dihapus sedangkan jika mendekati 1 berarti informasi dari *time step* terdahulu berpengaruh dan akan disimpan (Chung dkk., 2014). Proses pada *reset gate* dapat dilihat pada **Gambar 2.4**.



Sumber : Pu dkk., 2022

Gambar 2.4 Alur *Reset Gate*

Perhitungan pada *reset gate* diuraikan pada persamaan (2.3).

$$R_t = \sigma(X_t W_{xr} + H_{t-1} W_{hr} + b_r) \tag{2.3}$$

Keterangan:

R_t : *Reset gate*

σ : Fungsi aktivasi *sigmod*

W_{xr}, W_{hr} : Nilai *weight* untuk *reset gate*

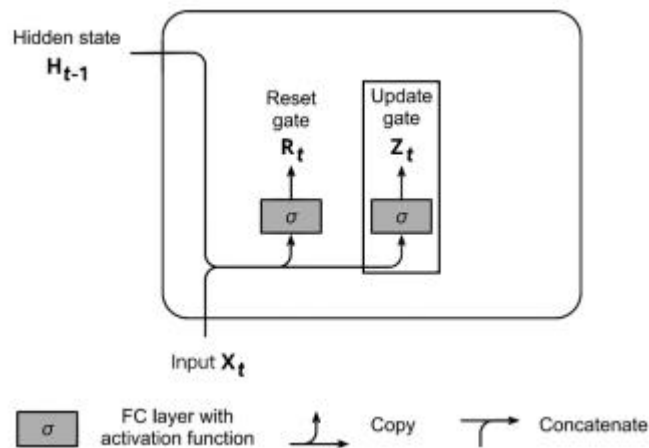
b_r : Parameter bias pada *reset gate*

H_{t-1} : *Hidden state* dari *time step* sebelumnya ($t - 1$)

X_t : Nilai *input* pada saat ini (t)

2.4.2 Update Gate

Update gate adalah gerbang yang akan memutuskan seberapa banyak informasi dari *time step* terdahulu yang akan disimpan untuk perhitungan *hidden state* yang digunakan sebagai *input* pada *time step* berikutnya dan menentukan pengaruh informasi dari *time step* terdahulu pada *output* di *time step* saat ini, yang nantinya menggunakan fungsi aktivasi *sigmoid*. Ketika *output* sama dengan 1, informasi dari *time step* sebelumnya memiliki pengaruh pada *output* saat ini, dan jika *output* sama dengan 0 maka informasi dari *time step* sebelumnya tidak berpengaruh pada *output* saat ini (Chung dkk., 2014). Alur *update gate* dapat dilihat pada **Gambar 2.5**.



Sumber : Pu dkk., 2022

Gambar 2.5 Alur *Update Gate*

Perhitungan pada *reset gate* diuraikan pada persamaan (2.4).

$$Z_t = \sigma(X_t W_{xz} + H_{t-1} W_{hz} + b_z) \tag{2.4}$$

Keterangan:

Z_t : *Update gate*

σ : Fungsi aktivasi *sigmoid*

W_{xz}, W_{hz} : Nilai *weight* untuk *update gate*

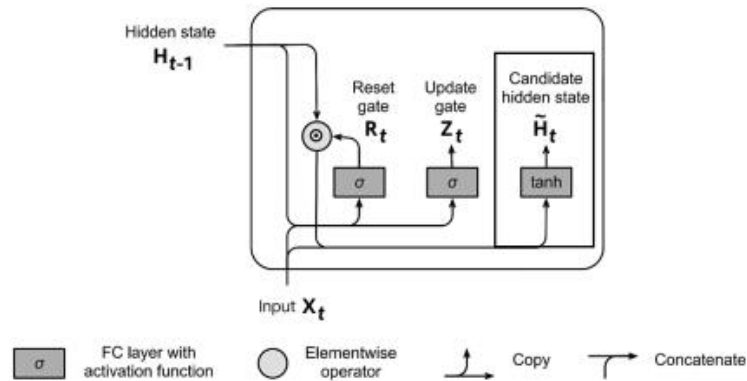
b_z : Parameter bias *update gate*

H_{t-1} : *Hidden state* dari *time step* sebelumnya ($t - 1$)

X_t : Nilai *input* pada saat ini (t)

2.4.3 Candidate Hidden State

Langkah selanjutnya dilakukan perhitungan *candidate hidden state* pada *time step* saat ini (t) dari informasi yang relevan pada *time step* masa lalu ($t - 1$) menggunakan fungsi aktivasi *tanh*. *Candidate hidden tanh* ini bukanlah *output final* dari unit ini melainkan *content memory* pada *time step* saat ini. Nilai *candidate hidden state* dipengaruhi oleh *output* dari *reset gate* (Chung dkk., 2014). Proses penentuan nilai *candidate hidden state* dapat dilihat pada **Gambar 2.6**.



Sumber : Pu dkk., 2022

Gambar 2.6 Candidate Hidden State

Perhitungan pada *candidate hidden state* diuraikan pada persamaan (2.5).

$$\tilde{H}_t = \tanh(X_t W_{xh} + (R_t \odot H_{t-1} W_{hh}) + b_h) \tag{2.5}$$

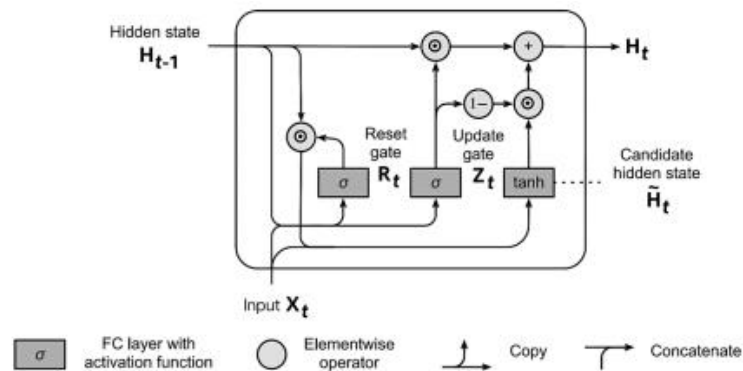
Keterangan:

\tilde{H}_t : *Candidate hidden state*

- W_{xh}, W_{hh} : Nilai *weight* untuk *candidate hidden state*
- R_t : *Output* pada *reset gate*
- b_h : Nilai *bias* pada *candidate hidden state*
- H_{t-1} : *Hidden state* dari *time step* sebelumnya ($t - 1$)
- X_t : Nilai *input* pada saat ini (t)

2.4.4 Hidden State

Langkah terakhir adalah *hidden state* dimana pada *state* ini akan dihitung *output* terakhir unit saat ini (t) dan meneruskan ke *time step* berikutnya sebagai *hidden state*. *Hidden state* yang akan dikirimkan ke *time step* berikutnya akan digunakan untuk menghitung kembali *output* pada unit *time step* tersebut. Prosesnya akan berjalan sama dan berulang seperti pada proses di *time step* saat ini hanya dengan nilai *input* yang berbeda. Perhitungan *output* terakhir ini dipengaruhi oleh nilai *candidate hidden state*, nilai *hidden state* pada *time step* sebelumnya dan *output* dari *update gate* (Chung dkk., 2014). Proses perhitungan nilai *hidden state* dapat dilihat pada **Gambar 2.6**.



Sumber : Pu dkk., 2022

Gambar 2.7 *Hidden State*

Perhitungan pada *hidden state* diuraikan pada persamaan (2.6).

$$H_t = Z_t \odot H_{t-1} + (1 - Z_t) \odot \tilde{H}_t \tag{2.6}$$

Keterangan:

- H_t : *Output* GRU
- Z_t : *Output* pada *update gate*
- \tilde{H}_t : *Candidate hidden state*
- H_{t-1} : *Hidden state* dari *time step* sebelumnya ($t - 1$)

2.5 Inisialisasi *Hyperparameter*

Hyperparameter adalah variabel yang digunakan untuk mengontrol proses pelatihan dan pengoptimalan model. *Hyperparameter* salah satu faktor yang mempengaruhi kinerja dari model yang dibuat untuk mendapatkan performa yang baik. Menentukan *hyperparameter* lebih seperti seni daripada sains, dan ada baiknya menguji beberapa opsi untuk memahami apa yang paling baik pada data pengujian dan dalam produksi. Inisialisasi *hyperparameter* pada penelitian ini meliputi *epoch*, *batch size*, *neuron*, *dropout*, *optimizer* dan *learning rate*.

2.5.1 *Epoch dan Batch Size*

Epoch (iterasi) adalah *hyperparameter* yang menentukan berapa kali algoritma akan bekerja melalui seluruh *training dataset*. Jumlah *epoch* secara umum dimulai dari puluhan, ratusan atau ribuan dimana seringkali dalam contoh *coding epoch* diatur dengan angka 10, 50, 100, 500, 1000 dan lebih besar. Sedangkan *batch size* adalah *hyperparameter* yang menentukan jumlah sampel yang harus dikerjakan sebelum memperbaharui parameter model *internal*. Secara umum, jumlah *batch size* yang populer adalah 24, 32, 64 dan 128 sampel yang seringkali dilihat pada *literature* dan *tutorial* (Brownlee, 2022).

2.5.2 *Neuron (Nodes)*

Hidden neuron adalah suatu *units* pada *neural network* yang berfungsi untuk menyimpan dan mengirimkan informasi yang terdapat pada *hidden layer*. Secara umum, penentuan jumlah *neuron* atau *nodes* merupakan model *hyperparameter* yang harus dicari sesuai dengan karakteristik atau spesifikasi *dataset*. Dalam menentukan *neuron* yang tepat membuat model menggeneralisasi data lebih baik, akurasi yang tepat dan mengurangi kompleksitas pada *neural network*. Secara umum jumlah *neuron* yang sering digunakan adalah 32, 64, 128 dan 256. Nilai *neuron* yang rendah membuat model tidak terlalu kompleks sehingga mudah untuk dipahami sedangkan jika nilai *neuron* yang tinggi membuat model sulit memahami peramalan karena model terlalu kompleks (Brownlee, 2018).

2.5.3 Dropout

Dropout merupakan teknik regularisasi model jaringan syaraf tiruan untuk mengurangi *overfitting* dan juga mempercepat proses *learning* pada *dataset*, dimana metode ini secara acak melakukan *drop* atau menonaktifkan sementara *neuron* pada suatu *epoch*, kemudian mengaktifkan kembali semua *neuron* sebelum dilakukan lagi *drop* secara acak pada *epoch* berikutnya (Klein, 2022).

Umumnya, penggunaan nilai *dropout* antara 20%-50% dari nilai *neuron*, dimana 20% merupakan titik awal. Nilai *dropout* yang terlalu rendah dapat mengurangi model dalam menggeneralisasi data sehingga kemampuan model dalam meramalkan data yang baru menjadi berkurang. Sedangkan nilai *dropout* yang terlalu tinggi maka model dapat menjadi kurang efektif dalam mempelajari pola-pola yang kompleks pada data sehingga model kehilangan terlalu banyak informasi selama proses *training*, dan menyebabkan kinerja model menurun (Singla, 2020). Ini akan membantu dalam menentukan *dropout* yang terbaik untuk model dan *dataset*.

2.5.4 Optimizer dan Learning Rate

Optimizer digunakan untuk menyesuaikan parameter jaringan syaraf dalam meminimalkan *loss function*, dalam penelitian ini menggunakan *Adaptive Moment Estimation* (Adam). Adam adalah algoritma pengoptimalan yang dapat digunakan untuk memperbaharui *weight network* secara iteratif berdasarkan data *training*, optimasi ini efisien secara komputasi, kebutuhan memori yang kecil dan sesuai untuk masalah yang memiliki banyak data maupun parameter. Adam adalah algoritma yang populer digunakan karena mencapai hasil yang baik dan cepat dibandingkan dengan *optimizer* lainnya.

Learning rate digunakan untuk mengontrol kecepatan pelatihan dan mempengaruhi ketelitian jaringan untuk menghitung nilai koreksi pada proses *training*. Nilai α ini berada pada range 0 hingga 1. Jika *learning rate* semakin besar mengakibatkan *training* set bobot terlalu cepat atau proses *training* yang tidak stabil, maka ketelitian akan semakin berkurang, tetapi berlaku sebaliknya, apabila *learning rate* semakin kecil, maka ketelitiannya semakin bertambah tetapi dengan proses *training* yang semakin lama (Wardana, 2020).

2.6 Normalisasi Data

Normalisasi data merupakan proses membuat skala nilai pada variabel sehingga data berada pada rentang nilai yang sama. Langkah ini sangat penting karena dapat meminimalkan *error* dan juga mempercepat proses *training*. Tujuan dari normalisasi data adalah menghindari fitur yang memiliki nilai yang lebih besar mendominasi fitur yang memiliki nilai lebih kecil (Wardana, 2020). Metode normalisasi data yang digunakan dalam penelitian ini adalah *Min-Max Scalling Normalization*, yang mengubah nilai data menjadi nilai berskala [0,1] tanpa mengubah informasi yang ada dengan persamaan sebagai berikut.

$$x' = \frac{(x-x_{min})}{(x_{max}-x_{min})} \quad (2.7)$$

Keterangan:

x'	: Nilai data normalisasi
x	: Nilai data asli
x_{max}	: Nilai maksimal data asli
x_{min}	: Nilai minimum data asli

2.7 Time Step

Time step adalah jumlah data yang digunakan untuk melakukan peramalan. Jumlah *time step* yang ditentukan akan didefinisikan sebagai jumlah *variable input* (x) yang digunakan untuk meramalkan *time step* berikutnya (y). Untuk setiap *time step* yang ditentukan sebagai representasi akan dihapus dari *dataset* dari awal. Hal ini karena tidak ada pengamatan sebelumnya yang digunakan sebagai *time step* untuk nilai awal pada *dataset*.

2.8 Evaluasi Model Peramalan

Evaluasi model merupakan proses untuk mengukur tingkat akurasi kinerja suatu metode yang digunakan. Untuk melakukan evaluasi model atau validasi model terdapat beberapa metode yang dapat digunakan. Pada penelitian ini dalam mengukur kinerja metode yang digunakan dengan melihat *Loss Function* dan menghitung *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE).

2.8.1 Loss Function

Loss function dihitung berdasarkan *training* data dan validasi data serta interpretasinya didasarkan pada seberapa baik kinerja model dalam dua set ini. *Loss function* adalah jumlah kesalahan yang dibuat setiap contoh dalam set *training* atau validasi. Nilai kerugian (*loss*) menyiratkan seberapa buruk atau baiknya suatu model diterapkan pada setiap iterasi optimasi. *Error* yang didapat dari *loss function* akan dipropagasi ke belakang (*backpropagatio*) agar model dapat melakukan *update* parameter bobot.

Dalam *deep learning*, *loss* adalah nilai yang coba diminimalkan oleh *neural network*. Itulah bagaimana *neural network* belajar dengan menyesuaikan bobot dan bias dengan cara mengurangi *loss*. *Training loss* dan *validation loss* berbeda karena *training loss* diterapkan pada data *training* sedangkan, *validation loss* diterapkan pada data *validation loss* atau *testing*.

2.8.2 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah ukuran akurasi dari suatu peramalan dengan memberikan nilai mutlak dari persentase *error* data terhadap rata-rata (Nabillah dan Ranggadar, 2020). Nilai *Mean Absolute Percentage Error* (MAPE) dihitung menggunakan rumus sebagai berikut:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - y'_i}{y_i} \right| \times 100\% \quad (2.8)$$

Keterangan:

- y_i : Nilai asli
- y'_i : Nilai hasil peramalan
- i : Urutan data pada data *series*
- n : Jumlah periode atau data yang digunakan

Hasil keakuratan peramalan dari nilai MAPE ditunjukkan dengan semakin kecilnya presentasi. Tabel kriteria penilaian akurasi dari nilai MAPE sebagai berikut (Maricar, 2019):

Tabel 2.1 Kriteria Akurasi Peramalan MAPE

MAPE	Keterangan
<10%	Hasil peramalan sangat akurat
10-20%	Hasil peramalan akurat
20-50%	Hasil peramalan cukup akurat
>50%	Hasil peramalan buruk

Sumber: Maricar, 2019

2.8.3 *Root Mean Square Error (RMSE)*

Root Mean Square Error (RMSE) adalah jumlah dari kesalahan kuadrat selisih nilai peramalan model dan nilai sebenarnya dalam dataset kemudian membagi jumlah tersebut dengan banyaknya data dan menarik akarnya. Semakin kecil nilai RMSE mengindikasikan semakin baik performa dari model dalam peramalan. Nilai *Root Mean Square Error (RMSE)* diuraikan pada persamaan berikut (Putro dkk., 2021).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y'_i)^2} \quad (2.9)$$

Keterangan:

y_i	: Nilai asli,
y'_i	: Nilai hasil peramalan
i	: Urutan data pada data <i>series</i>
n	: Jumlah periode atau data yang digunakan