

***HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE
(ARIMA) – GATED RECURRENT UNIT (GRU) DALAM PERAMALAN
HARGA SAWIT PADA PT. SAWIT SUMBERMAS SARANA DI
KALIMANTAN TENGAH***

(Skripsi)

Oleh

TIARA PRAMAY SHELLA



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDARLAMPUNG
2023**

ABSTRACT

HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) – GATED RECURRENT UNIT (GRU) IN PLAM PRICE FORECASTING AT PT. SAWIT SUMBERMAS SARANA AT KALIMANTAN TENGAH

By

TIARA PRAMAY SHELLA

The palm oil industry has a strategic role in the economy of Indonesia. Indonesia is the country that has great potential for marketing palm oil and palm kernel both domestically and abroad. Price palm oil consistently has a relationship with CPO prices, this happens because the price of palm fruit refers to the price of CPO, so it fluctuates. Steps that can be taken are to predict the price of palm oil in several future periods. ARIMA is the best method commonly used for forecasting. The weakness of ARIMA is that it is difficult to define non-linear components contained in data. GRU is a model that has 2 gates, namely the update gate and the reset gate. The two gates in the GRU model are expected to be able to capture non-linear patterns in the data. Therefore, the hybrid ARIMA-GRU method was formed to be able to predict and forecast. The ARIMA hybrid method GRU consists of 2 models: the first is predictive of ARIMA results, and the second is residual data from ARIMA results. The hybrid model in this study produces an MSE value of 868.4690, an RMSE value of 29.4698, a MAPE of 0.0117, and an accuracy of 99.9824%.

Keywords: *Hybrid ARIMA – GRU, GRU, ARIMA, time series, hybrid model, plam price, prediction and forecasting*

ABSTRAK

HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE (ARIMA) – GATED RECURRENT UNIT (GRU) DALAM PERAMALAN HARGA SAWIT PADA PT. SAWIT SUMBERMAS SARANA DI KALIMANTAN TENGAH

Oleh

TIARA PRAMAY SHELLA

Industri kelapa sawit memiliki peran strategis dalam perekonomian Indonesia. Indonesia merupakan negara yang memiliki potensi besar dalam pemasaran minyak sawit dan inti sawit baik di dalam negeri maupun di luar negeri. Harga minyak sawit secara konsisten memiliki hubungan dengan harga CPO, hal ini terjadi karena harga sawit mengacu pada harga CPO sehingga terjadi fluktuasi. Langkah yang dapat dilakukan adalah meramalkan harga sawit dalam beberapa periode mendatang. ARIMA merupakan metode terbaik yang biasa digunakan untuk peramalan. Kelemahan ARIMA adalah sulitnya mendefinisikan komponen *non-linier* yang terkandung dalam data. GRU merupakan model yang memiliki 2 *gate* yaitu *update gate* dan *reset gate*. Kedua *gate* dalam model GRU diharapkan mampu menangkap pola *non-linier* dalam data. Oleh karena itu, dibentuklah metode *hybrid* ARIMA-GRU yang diharapkan mampu prediksi dan peramalan. Metode *hybrid* ARIMA - GRU terdiri dari 2 model yaitu model pertama adalah model prediksi ARIMA dan yang kedua adalah model residual dari ARIMA. Model *hybrid* pada penelitian ini menghasilkan nilai MSE sebesar 868,4690, nilai RMSE sebesar 29,4698, MAPE sebesar 0,0117, dan akurasi sebesar 99,9824%.

Kata Kunci: ***Hybrid* ARIMA – GRU, GRU, ARIMA, deret waktu, model *hybrid*, harga sawit, prediksi dan peramalan**

***HYBRID AUTOREGRESSIVE INTEGRATED MOVING AVERAGE
(ARIMA) – GATED RECURRENT UNIT (GRU) DALAM PERAMALAN
HARGA SAWIT PADA PT. SAWIT SUMBERMAS SARANA DI
KALIMANTAN TENGAH***

Oleh

TIARA PRAMAY SHELLA

Skripsi

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

Pada

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



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2023**

Judul Skripsi

: **HYBRID AUTOREGRESSIVE INTEGRATED MOVING
AVERAGE (ARIMA) – GATED RECURRENT UNIT
(GRU) DALAM PERAMALAN HARGA SAWIT PADA
PT. SAWIT SUMBERMAS SARANA DI
KALIMANTAN TENGAH**

Nama Mahasiswa

: **Tiara Pramay Shella**

NPM

: **1917031064**

Jurusan

: **Matematika**

Fakultas

: **Matematika dan Ilmu Pengetahuan Alam**



MENYETUJUI

1. **Komisi Pembimbing**

A handwritten signature in black ink, appearing to read 'Dian Kurniasari'.

Dian Kurniasari. S.Si., M.Sc.
NIP. 19690305 199603 2 001

A handwritten signature in black ink, appearing to read 'Mustofa Usman'.

Prof. Drs. Mustofa Usman, M.A., Ph.D.
NIP. 19570101 198403 1 020

2. **Ketua Jurusan Matematika**

A handwritten signature in black ink, appearing to read 'Aang Nuryaman'.

Dr. Aang Nuryaman, S.Si., M.Si.
NIP. 19740316 200501 1 001

MENGESAHKAN

1. Tim Penguji

Ketua Penguji

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



Sekretaris

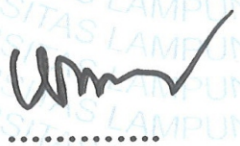
: Prof. Drs. Mustofa Usman, M.A., Ph.D



Penguji

Bukan Pembimbing

: Ir. Warsono, M.S., Ph.D.



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.
NIP. 19711001 200501 1 002

Tanggal Lulus Ujian Skripsi : 02 Agustus 2023

PERNYATAAN SKRIPSI MAHASISWA

Yang bertanda tangan dibawah ini:

Nama : **Tiara Pramay Shella**
Nomor Pokok Mahasiswa : **1917031064**
Jurusan : **Matematika**
Judul Skripsi : ***HYBRID AUTOREGRESSIVE INTEGRATED
MOVING AVERAGE (ARIMA) – GATED
RECURRENT UNIT (GRU) DALAM
PERAMALAN HARGA SAWIT PADA PT.
SAWIT SUMBERMAS SARANA DI
KALIMANTAN TENGAH***

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, 02 Agustus 2023



Penulis

Tiara Pramay Shella

RIWAYAT HIDUP

Penulis bernama lengkap Tiara Pramay Shella, dilahirkan pada tanggal 23 Mei 2001 di Riau. Penulis merupakan anak pertama dari Bapak Toto Legowo dan Ibu Sumiyati.

Penulis mengawali pendidikan di Taman Kanak-Kanak (TK) Pertiwi pada tahun 2006. Kemudian menempuh pendidikan Sekolah dasar (SD) di SD N 11 Keranji Guguh pada tahun 2007 – 2013. Kemudian melanjutkan ke Sekolah Menengah Pertama di SMP N 5 Metro pada tahun 2013-2016. Selanjutnya belajar pada jenjang Sekolah Menengah Atas di SMA N 6 Metro pada tahun 2016-2019. Pada tahun 2019 penulis terdaftar sebagai mahasiswa Program Studi S1 Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur PMPAP.

Selama menjadi mahasiswa penulis aktif dalam mengikuti kegiatan organisasi Himpunan Mahasiswa Matematika (HIMATIKA) FMIPA UNILA periode 2019. Pada Tahun 2022 penulis melaksanakan Kuliah Kerja Praktik (KP) di Badan Pengelola Pajak dan Retribusi Daerah (BPPRD) Kota Metro. Pada tahun yang sama penulis juga melaksanakan Kuliah Kerja Nyata (KKN) di Kelurahan Maringgai, Kecamatan Labuhan Maringgai, sebagai bentuk pengabdian kepada masyarakat.

KATA INSPIRASI

“Dan bersabarlah kamu. Sesungguhnya janji Allah adlah benar.”

(Q.S Ar-Rum : 60)

“Dan hanya kepada Tuhanmulah hendaknya kamu berharap.”

(Q.S Ar-Insyirah : 8)

“Sungguh Atas Kehendak Allah Semua Ini Terwujud, Tiada Kekuatan Kecuali
Dengan Pertolongan Allah.”

(Q.S Al-Kahfi : 39)

“Seseorang Yang Bersabar Tidak Akan Pernah Kehilangan Kesuksesan Meskipun
Membutuhkan Waktu Yang Lama Untuk Mencapainya.”

(Ali Bin Abi Thalib)

PERSEMBAHAN

Alhamdulillah, puji dan syukur kepada Allah SWT atas nikmat serta hidayahnya sehingga skripsi ini dapat terselesaikan dengan baik dan tepat pada waktunya.

Oleh karena itu, dengan rasa syukur dan bahagia saya persembahkan rasa terima kasih saya kepada

Ayah, Ibu dan Adik

Dua orang yang paling berga bagi hidup saya, Ayah Toto Legowo dan Ibu Sumiyati. Tidak ada kata yang dapat aku sampaikan untuk kalian kecuali ucapan terima kasihatas semua yang telah kalian berikan untukku. Cinta, kasih sayang, motivasi, doa, waktu, pengorbanan yang belum bisa aku balas, serta doa dan sujud yang selalu menantikan keberhasilanku dengan sabar dan penuh pengertian. Terimakasih karena selalu mendoakan dan mendukung setiap langkah yang aku pilih. Karena atas doa dan ridho kalian, Allah memudahkan setiap perjalanan hidup ini. Serta tidak lupa adikku tercinta Indana Zulfa yang selalu memberikan semangat.

Terimalah bukti kecil ini sebagai kado keseriusanku untuk membalas semua pengorbanan, keikhlasan, dan jerih payah yang selama ini kalian lakukan.

Dosen Pembimbing dan Pembahas

Terimakasih kepada dosen pembimbing dan pembahasa yang sudah sangat membantu, memberikan motivasi, memberikan arahan serta ilmu yang sangat berharga.

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 *“Hybrid Autoregressive Integrated Moving Average (ARIMA) – Gated Recurrent Unit (GRU) Dalam Peramalan Harga Sawit Pada PT. Sawit Sumbermas Sarana Di Kalimantan Tengah”*. Dalam 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 dengan sabar, memberi masukan serta saran serta mendukung penulis dalam menyelesaikan skripsi ini.
2. Bapak Prof. Drs. Mustofa Usman, M.A., Ph.D. selaku dosen pembimbing II memberikan bimbingan, pengarahan, serta saran sehingga penulis dapat menyelesaikan skripsi ini.
3. Bapak Ir. Warsono, M.S., Ph.D. selaku dosen penguji yang telah memberikan kritik dan saran yang membangun sehingga skripsi ini dapat terselesaikan.
4. Bapak Prof. Dr. La Zakaria, S.Si., M.Sc. selaku dosen pembimbing akademik yang senantiasa memberikan saran dan bimbingan 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. Heri Satria, S.Si., M.Si. 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. Teruntuk kedua orang tuaku tercinta, Ayah Toto Legowo dan Ibu Sumiyati terimakasih atas doa, dukungan, pengorbanan, cinta kasih, perhatian, demi kesuksesan penulis semoga dikemudian hari dapat membahagiakan dan menjadi kebanggan kalian.
9. Adik dan Keluarga sekalian yang selalu memberikan semangat kepada

penulis serta doa-doanya.

10. Teruntuk sahabat ku sejak maba yaitu Esti Widia Hartati terimakasih atas doa, dorongan, saran, dan motivasi, serta bantuan dalam menyelesaikan skripsi ini.
11. Teruntuk teman kuliah ku, Astina, Yeni, terimakasih atas pengalaman serta dukungan terhadap penulis dari sejak awal perkuliahan hingga selesai.
12. Semua teman sejurusan matematika 2019 yang telah membantu serta memberikan semangat kepada penulis yang mana tidak bisa disebutkan satu persatu.
13. Orang-orang baik yang namanya tidak bisa saya sebutkan satu persatu yang telah menjadi teman terbaik penulis yang selalu memberikan semangat dan menemani penulis dalam keadaan apapun serta telah memberikan pengalaman dan banyak cerita selama masa perkuliahan.
14. Teman-teman seperbimbingan Zida, Anin, Azza, Silvi, Mia, Dea, Fiqih, Nurul, Irma, Clara, Ardelia, Putri, Lisna, terimakasih atas doa, motivasi, dukungan, semangat, yang selalu di berikan kepada penulis. Semoga kalian menjadi orang yang sukses dan bahagia dimanapun kalian berada. See you on top.
15. Semua pihak yang tidak dapat disebutkan satu persatu yang telah membantu penulis dalam menyelesaikan skripsi ini.

Penulis menyadari bahwa masih banyak kekurangan dalam penulisan skripsi ini. Oleh karena itu, penulis mengharapkan masukan serta saran untuk dijadikan pelajaran kedepannya.

Bandar Lampung, 02 Agustus 2023

Penulis

Tiara Pramay Shella

DAFTAR ISI

	Halaman
DAFTAR TABEL	xvi
DAFTAR GAMBAR.....	xvii
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 (<i>Forecasting</i>)	5
2.2. Deret Waktu (<i>Time Series</i>)	5
2.2.1. Metode <i>Autoregressive Integrated Moving Average</i> (ARIMA)	6
2.2.2. Stasioneritas	8
2.2.3. Identifikasi Model.....	9
2.3. <i>Data Mining</i>	10
2.4. <i>Machine Learning</i>	11
2.5. <i>Deep Learning</i>	12
2.5.1. <i>Recurrent Neural Network</i> (RNN).....	12
2.5.2. <i>Long Short Term Memory</i> (LSTM)	13
2.5.3. <i>Gated Recurrent Unit</i> (GRU)	14
2.6. <i>Hyperparameter Model GRU</i>	16
2.7. <i>Standard Scaler</i>	17
2.8. Normalisasi <i>Min-Max</i>	17
2.9. Fungsi Aktivasi.....	18
2.10. <i>Hybrid</i>	20
2.11. Akurasi	22
III. METODE PENELITIAN.....	24
3.1. Waktu dan Tempat Penelitian	24

3.2. Spesifikasi Perangkat.....	24
3.3. Data Penelitian.....	24
3.4. Metode Penelitian	25
IV. HASIL DAN PEMBAHASAN	28
4.1. Proses <i>Input</i> Data.....	28
4.2. Prediksi Data dengan ARIMA.....	29
4.2.1. Plot ACF dan Plot PACF	30
4.2.2. Estimasi Parameter	31
4.2.3. Prediksi ARIMA	32
4.2.4. Akurasi Model	33
4.2.5. Ekstraksi data Residual.....	34
4.2.6. Peramalan Model ARIMA.....	35
4.3. Prediksi Model <i>Hybrid</i> ARIMA – GRU.....	35
4.3.1. Skema Pembagian Data	36
4.3.2. <i>Scaling</i> Data.....	36
4.3.3. Membangun Model Prediksi ARIMA dengan GRU	36
4.3.4. Membangun Model Residual ARIMA dengan GRU	39
4.3.5. Prediksi Model Prediksi ARIMA dengan GRU	43
4.3.6. Prediksi dengan Model Residual ARIMA dengan GRU.....	44
4.3.7. Prediksi <i>Hybrid</i> ARIMA - GRU.....	45
4.4. Peramalan	46
4.4.1. Hasil Peramalan Model Prediksi ARIMA - GRU	46
4.4.2. Hasil Peramalan Model Residual ARIMA - GRU	47
4.4.3. Hasil Peramalan <i>Hybrid</i>	48
V. KESIMPULAN	49
5.1. Kesimpulan.....	49
DAFTAR PUSTAKA	50

DAFTAR TABEL

Tabel	Halaman
1. Tabel 1. Pola plot ACF dan PACF.....	10
2. Tabel 2. Kriteria nilai MAPE.....	22
3. Tabel 3. Data harga sawit.....	25
4. Tabel 4. Model ARIMA.....	31
5. Tabel 5. Nilai akurasi data prediksi ARIMA	33
6. Tabel 6. Plot prediksi menggunakan model GRU prediksi ARIMA - GRU	43
7. Tabel 7. Plot prediksi menggunakan model GRU residual ARIMA - GRU.....	44
8. Tabel 8. Visualisasi model <i>hybrid</i> dan nilai evaluasi.....	45
9. Tabel 9. Plot peramalan menggunakan model prediksi ARIMA - GRU	47
10. Tabel 10. Plot peramalan menggunakan model residual ARIMA - GRU	47
11. Tabel 11. Plot peramalan model <i>hybrid</i>	48

DAFTAR GAMBAR

Gambar	Halaman
1. Pola Data <i>Time Series</i>	6
2. Arsitektur <i>Recurrent Neural Network</i>	13
3. Sel <i>Long-Short Term Memory</i>	14
4. Arsitektur <i>Gated Recurrent Unit</i>	15
5. Fungsi Aktivasi Sigmoid.....	19
6. Fungsi Aktivasi <i>Tangen Hiperbolik</i>	20
7. <i>Workflow</i> ARIMA – GRU	27
8. Proses <i>input data</i> ..	28
9. Data harga sawit... ..	28
10. Plot data harga sawit	29
11. Nilai <i>p-value</i> sebelum <i>differencing</i>	30
12. Nilai <i>p-value</i> setelah <i>differencing</i>	30
13. Hasil plot ACF dan PACF	31
14. <i>Summary</i> model ARIMA	32
15. Plot data aktual dan data prediksi ARIMA	33
16. Plot data residual..	34
17. Plot peramalan model ARIMA	35
18. <i>Hyperparameter tuning</i> model prediksi ARIMA - GRU untuk skema 80% <i>training</i> dan 20% <i>testing</i>	37
19. <i>Hyperparameter tuning</i> model prediksi ARIMA - GRU untuk skema 90% <i>training</i> dan 10% <i>testing</i>	38
20. Plot <i>training</i> dan <i>validation loss</i> dengan skema 80% <i>training</i> dan 20% <i>testing</i>	38
21. Plot <i>training</i> dan <i>validation loss</i> dengan skema 90% <i>training</i> dan 10% <i>testing</i>	39

22. <i>Hyperparameter tuning</i> model residual ARIMA - GRU untuk skema 80% <i>training</i> dan 20% <i>testing</i>	40
23. <i>Hyperparameter tuning</i> model residual ARIMA - GRU untuk skema 90% <i>training</i> dan 10% <i>testing</i>	41
24. Plot <i>training</i> dan <i>validation loss</i> dengan skema 80% <i>training</i> dan 20% <i>testing</i>	42
25. Plot <i>training</i> dan <i>validation loss</i> dengan skema 90% <i>training</i> dan 10% <i>testing</i>	42
26. Proses kombinasi antara model prediksi ARIMA - GRU dengan model residual ARIMA - GRU	45
27. Proses peramalan..	46

I. PENDAHULUAN

1.1. Latar Belakang dan Masalah

Dalam perekonomian Indonesia, industri minyak sawit memiliki peran strategis, antara lain penghasil devisa terbesar, lokomotif perekonomian nasional, pendorong sektor ekonomi dan penyerapan tenaga kerja. Perkebunan kelapa sawit Indonesia berkembang cepat. Dua pulau utama sentra perkebunan kelapa sawit di Indonesia adalah Sumatra dan Kalimantan (Ginting, dkk., 2020). Luas perkebunan kelapa sawit di Indonesia berada pada angka 15,98 juta hektar. Pada tahun 2021 Indonesia memproduksi minyak sawit mencapai 44,5 juta ton dengan pertumbuhan rata-rata 3,61% per tahun. Sebagai negara yang mempunyai potensi besar untuk memasarkan minyak sawit dan inti sawit baik di dalam maupun luar negeri. Pasar potensial yang akan menyerap pemasaran minyak sawit *Crude Palm Oil* (CPO) dan minyak inti sawit *Palm Kernel Oil* (PKO) (Kementerian Perindustrian Republik Indonesia, 2021). Harga buah sawit sendiri secara konsisten memiliki hubungan dengan harga CPO, hal ini terjadi karena penetapan harga buah sawit mengacu pada harga CPO.

Turun naiknya harga Tandan Buah Segar (TBS) terjadi karena beberapa faktor, di antaranya faktor permintaan dan penawaran perdagangan CPO, permintaan dan penawaran terus berubah seiring dengan pasokan pengeksport dan ketersediaan produk CPO bagi negara pengimpor kemudian ada faktor pengaruh biaya produksi, pengaruhnya dapat diketahui jika terjadi perubahan harga, perubahan biaya tersebut diakibatkan oleh beberapa variabel yang berubah seperti biaya pemasaran, transportasi, olah dan penyusutan. Dengan adanya fluktuasi tersebut, maka dibutuhkan suatu metode peramalan agar mampu meramalkan harga sawit di masa yang akan datang. Peramalan dapat membantu pemerintah dalam

menentukan kebijakan selanjutnya, sehingga pemerintah dapat menentukan langkah yang efektif untuk mengembangkan sektor perekonomian di Indonesia.

Time series merupakan serangkaian observasi terhadap suatu variabel yang diambil secara berurutan berdasarkan interval waktu yang tetap (Wei, 2006). Metode yang paling banyak digunakan adalah metode ARIMA. Metode ARIMA merupakan metode ARMA untuk data tidak stasioner hasil *differencing*. Metode ARMA itu sendiri gabungan dari metode AR yaitu metode untuk melihat pergerakan suatu variabel melalui variabel itu sendiri dan MA merupakan metode untuk mengetahui pergerakan suatu variabel dengan residual di masa lalu. Metode ARIMA sangat baik ketepatan ramalannya untuk jangka waktu pendek. Metode ARIMA merupakan metode yang menggunakan variabel dependen dan mengabaikan variabel independen untuk menghasilkan peramalan jangka pendek yang akurat (Salwa, dkk., 2018).

Metode *time series* atau deret waktu merupakan metode yang sering digunakan dalam melakukan prediksi. Salah satu perkembangan metode *time series* adalah *deep learning*, metode ini memungkinkan untuk melakukan pembelajaran dengan lapisan yang lebih kompleks agar mendapatkan akurasi yang tinggi dan lebih efisien serta memberikan peramalan yang lebih akurat dibandingkan dengan metode peramalan tradisional karena mampu memodelkan data yang linear maupun *non linear* (Zhang, 2004). Salah satu metode *deep learning* adalah *Recurrent Neural Network* (RNN), RNN adalah jenis arsitektur jaringan saraf 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. RNN merupakan pembelajaran jangka panjang dengan nilai *gradien* yang menghasilkan masalah *vanishing* dan *exploding gradien* (Wiranda dan Sadikin, 2019).

Karena RNN memiliki kelemahan dalam menghadapi prediksi dengan *frame* waktu yang cukup panjang maka *Gated Recurrent Unit* (GRU) datang sebagai pengembangan lebih lanjut dari unit RNN konvensional yang memiliki

kemampuan dalam menangani kasus prediksi dan klasifikasi tanpa adanya permasalahan *vanishing gradient* dan *gradient exploding* (Wira, 2014). *Gated Recurrent Unit* (GRU) adalah varian dari LSTM dimana, LSTM memiliki tiga fungsi gerbang berdasarkan jaringan RNN yaitu *forget gate*, *input gate* dan *output*. Namun, hanya ada dua gerbang dalam model GRU, *update gate* dan *reset gate* (Zhang, dkk., 2020).

Penelitian mengenai ARIMA sudah pernah dilakukan, penelitian yang dilakukan oleh Wiguna, dkk. (2020), analisis dan prediksi penyebaran COVID-19 di Jakarta dengan metode ARIMA. Hasilnya analisis prediktif memperlihatkan tren kasus positif harian yang cenderung naik di kurun waktu 14 hari ke depan dari data yang digunakan. Salwa, dkk. (2018), melakukan peramalan harga bitcoin menggunakan metode ARIMA. Hasilnya peramalan dengan menggunakan model ARIMA (0,2,1) menunjukkan bahwa harga bitcoin untuk 30 periode kedepannya mengalami penurunan secara perlahan dan hasil peramalan mendekati data sebenarnya.

Kemudian penelitian metode GRU pernah dilakukan oleh Zhao, dkk. (2018), mengenai prediksi waktu perjalanan berdasarkan metode *Gated Recurrent Unit* dan data fusion. Hasil penelitian menunjukkan bahwa model GRU dapat mencapai akurasi prediksi waktu tempuh yang lebih baik dari pada metode fusion. Arfianti, dkk. (2021), melakukan prediksi angka sunspot menggunakan algoritma GRU. Hasilnya prediksi bilangan sunspot menggunakan algoritma LSTM mendapatkan akurasi yang sangat bagus karena nilai MAPE kurang dari 10%, tetapi GRU lebih baik dari LSTM dengan nilai MAPE 9%.

Penelitian mengenai *hybrid* oleh Shafiri, dkk. (2021), tentang memprediksi harga bitcoin menggunakan *hybrid* ARIMA dan *deep learning*. Dalam penelitian ini untuk memprediksi harga bitcoin, telah digunakan kombinasi model ARIMA dan tiga jenis jaringan saraf yaitu RNN, LSTM dan GRU. Hasil penelitian menunjukkan bahwa model ARIMA-GRU memiliki hasil yang lebih baik untuk kriteria RMSE dan MAPE dibandingkan model lainnya.

Berdasarkan pemaparan di atas, penulis tertarik untuk melakukan penelitian

tentang penerapan metode *hybrid* ARIMA – GRU untuk mengatasi permasalahan asumsi linearitas pada model ARIMA dan dapat meramalkan harga sawit pada PT. Sawit Sumbermas Sarana, sehingga pemerintah dapat menentukan langkah yang efektif untuk kedepannya.

1.2. Tujuan Penelitian

Adapun tujuan dari penelitian ini yaitu sebagai berikut:

1. Mengetahui performa model dari metode *hybrid* ARIMA – GRU terhadap harga sawit.
2. Melakukan peramalan harga sawit dari metode *hybrid* ARIMA – GRU selama 6 bulan.

1.3. Manfaat Penelitian

Adapun manfaat dari penelitian ini yaitu sebagai berikut:

1. Menambah pengetahuan terkait metode ARIMA dan GRU.
2. Dapat menjadi referensi bagi peneliti selanjutnya tentang model *hybrid* ARIMA - GRU
3. Penelitian ini dapat dijadikan bahan referensi bagi PT. Sawit Sumbermas Sarana untuk menentukan harga jual selanjutnya di masa yang akan datang.

II. TINJAUAN PUSTAKA

2.1. Peramalan (*Forecasting*)

Peramalan adalah prediksi beberapa peristiwa di masa mendatang, peramalan merupakan masalah penting yang mencakup banyak bidang, termasuk bidang bisnis dan industri, bidang ekonomi, ilmu lingkungan, kedokteran, politik dan keuangan. Masalah prediksi sering diklasifikasikan sebagai jangka pendek, jangka menengah dan jangka panjang (Montgomery, dkk., 2015). Metode peramalan dibagi menjadi dua yaitu peramalan kualitatif dan peramalan kuantitatif, peramalan kualitatif adalah data kualitatif masa lalu berdasarkan pengetahuan dan pengalaman dari penulis, sedangkan metode peramalan kuantitatif didasarkan pada data kuantitatif pada informasi masa lalu dalam bentuk data yang numerik seperti model deret berkala (*time series*) dan model kausal (Makridakis, dkk., 1999).

2.2. Deret Waktu (*Time Series*)

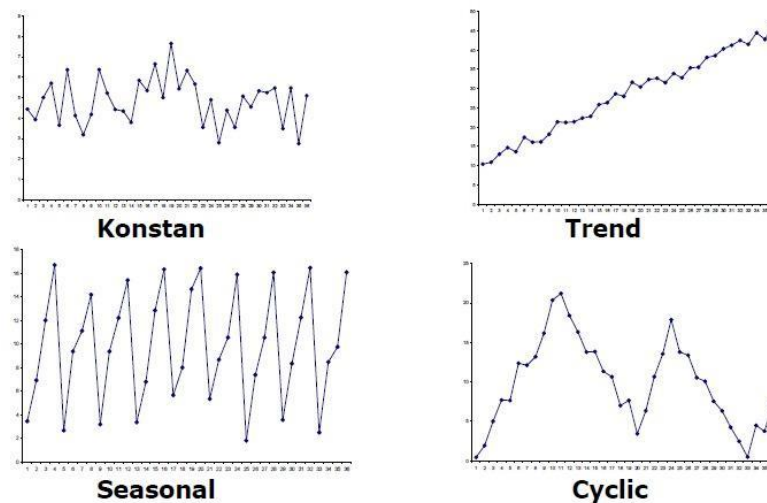
Time series adalah serangkaian observasi terhadap suatu variabel yang diambil secara berurutan berdasarkan interval waktu yang tetap (Wei, 2006). *Data time series* merupakan data yang terdiri dari satu objek namun meliputi beberapa periode waktu, yaitu harian, mingguan, bulanan, tahunan, dan lain-lain.

Menurut Hanke dan Wichern (2005), terdapat empat jenis pola data, yaitu:

1. Pola data horizontal terjadi jika data berfluktuasi pada suatu nilai konstan atau disekitar rata-rata data, data ini disebut dengan data stasioner.
2. Pola data musiman merupakan fluktuasi dari data yang terjadi secara teratur

selama kurang lebih satu tahun seperti triwulan, kuartalan, bulanan, mingguan atau harian.

3. Pola data siklis merupakan pola data dengan gerakan naik atau turun secara siklis disekitar tren atau kondisi normal.
4. Pola data *trend* merupakan kecenderungan arah data dalam jangka panjang dapat berupa kenaikan atau penurunan.



Gambar 1. Pola Data *Time Series*
(Sumber: Montgomery, dkk., 2015)

2.2.1. Metode *Autoregressive Integrated Moving Average* (ARIMA)

Metode ARIMA (*Autoregressive Integrated Moving Average*) yang biasa disebut dengan metode Box-Jenkins merupakan metode yang dikembangkan oleh George Box dan Gwilym Jenkins pada tahun 1970 (Iriawan & Astuti, 2006). Box dan Jenkins mengembangkan pendekatan praktis untuk membangun model ARIMA yang memiliki dasar pada analisis deret waktu dan aplikasi peramalan. Metode Box-Jenkins meliputi model *non-seasonal* (non-musiman) dan *seasonal* (musiman). Model *non seasonal* yang merupakan model stasioner terdiri dari

AR(p), MA(q) dan ARMA(p,q), sedangkan model ARIMA(p,d,q) merupakan bentuk model non stasioner (Zhang, 2001).

- Model *Autoregressive* (AR)

Model AR memiliki asumsi bahwa data periode sekarang dipengaruhi oleh data pada periode sebelumnya. Model AR(p) secara umum ditulis sebagai (Montgomery, dkk., 2015).

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} - \varepsilon_t \quad (2.1)$$

dimana :

Z_t : nilai pengamatan pada waktu ke- t

Z_{t-1}, \dots, Z_{t-p} : nilai masa lalu pada waktu ke- t-1, ..., t-p

$\phi_1, \phi_2 \dots \phi_p$: parameter AR ke-p

ε_t : nilai *error* pada waktu ke- t

- Model *Moving Average* (MA)

Model MA mengasumsikan bahwa prediksi suatu data saat ini dipengaruhi oleh *error* periode sebelumnya. Model MA(q) secara umum ditulis sebagai (Montgomery, dkk., 2015).

$$Z_t = \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.2)$$

dimana :

Z_t : nilai pengamatan pada waktu ke- t

$\theta_1, \theta_2 \dots \theta_q$: parameter MA ke-q

ε_t : nilai *error* pada waktu ke- t

ε_{t-q} : nilai *error* pada waktu ke- t-q

- Model *Autoregressive Moving Average* (ARMA)

Model ARMA menggabungkan metode AR dan MA yang mengasumsikan bahwa peristiwa saat ini dipengaruhi oleh kejadian yang sama dan nilai *error* pada periode sebelumnya. Model ARMA(p,q) secara umum ditulis sebagai (Montgomery, dkk., 2015).

$$Z_t = \phi_1 Z_{t-1} + \dots + \phi_p Z_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (2.3)$$

dimana :

Z_t : nilai pengamatan pada waktu ke- t

Z_{t-1}, \dots, Z_{t-p} : nilai masa lalu pada waktu ke- t-1, ..., t-p

$\phi_1, \phi_2 \dots \phi_p$: parameter AR ke-p

$\theta_1, \theta_2 \dots \theta_p$: koefisien parameter *moving average*

ε_{t-q} : nilai residual pada saat ke-q

- Model *Autoregressive Integrated Moving Average* (ARIMA)

Jika data tidak stasioner maka metode yang selanjutnya digunakan untuk membuat data menjadi stasioner yang dilakukan adalah *differencing*. Bentuk umum model ARIMA dapat dinyatakan dalam persamaan berikut (Sartono, 2006). Metode ARIMA(p,d,q) adalah metode umum dari regresi deret waktu. ARIMA(p,0,0) merupakan metode AR(p), ARIMA(0,0,q) merupakan model MA(p) dan ARIMA(p,0,q) adalah model ARMA(p,q).

$$\phi_p(B) \nabla^d Z_t = \zeta + \theta_q(B) \varepsilon_t \quad (2.4)$$

dimana :

Z_t : nilai pengamatan saat ke-t

ϕ_p : parameter *autoregressive*

B : operator geser mundur

d : parameter pembedaan (*differencing*)

ζ : parameter konstan

θ_q : parameter *moving average*

ε_t : nilai residual (*error*)

2.2.2. Stasioneritas

Stasioneritas berarti bahwa tidak terjadinya pertumbuhan dan penurunan data. Suatu data dikatakan stasioner apabila pola data tersebut berada pada

kesetimbangan di sekitar nilai rata-rata yang konstan dan variansi di sekitar rata-rata tersebut konstan selama waktu tertentu (Makridakis, dkk., 1999).

Stasioneritas dari data runtun waktu dapat dibagi menjadi 2, yaitu :

1. Stasioneritas dalam *mean* (rata-rata)

Stasioneritas dalam *mean* adalah fluktuasi data berada di sekitar suatu nilai rata-rata yang konstan, tidak tergantung pada waktu dan variansi dari fluktuasi tersebut. Dari bentuk plot data seringkali dapat diketahui bahwa data tersebut stasioner atau tidak stasioner.

2. Stasioneritas dalam variansi

Suatu data runtun waktu dikatakan stasioner dalam variansi apabila struktur data dari waktu ke waktu mempunyai fluktuasi data yang tetap atau konstan dan tidak berubah-ubah. Secara visual untuk melihat hal tersebut dapat dibantu dengan menggunakan plot runtun waktu, yaitu dengan melihat fluktuasi data dari waktu ke waktu.

2.2.3. Identifikasi Model

Dalam mengidentifikasi model yang akan digunakan data harus stasioner apabila belum stasioner maka perlu dilakukan proses stasioner terlebih dahulu untuk mendapatkan aspek AR dan MA dalam model ARIMA. Jika data yang digunakan sudah stasioner terhadap variansi dan stasioner terhadap rata-rata kemudian dilakukan plot ACF dan PACF terhadap data yang telah stasioner. Plot tersebut digunakan untuk mengidentifikasi orde AR dan MA yang akan digunakan dalam menentukan model (Wei, 2006). Berikut merupakan tabel ketentuan plot ACF dan PACF pada model ARIMA.

Tabel 1. Pola plot ACF dan PACF

Model	ACF	PACF
AR (p)	Menurun secara cepat (<i>dies down</i>)	Terpotong pada lag ke- p (<i>cut off</i>)
MA (q)	Terpotong pada lag ke-q (<i>cut off</i>)	Menurun secara cepat (<i>dies down</i>)
AR (p) dan MA (q)	Terpotong pada lag ke-q (<i>cut off</i>)	Terpotong pada lag ke- p (<i>cut off</i>)
ARMA (p,q)	Menurun secara cepat (<i>dies down</i>)	Menurun secara cepat (<i>dies down</i>)

2.3. Data Mining

Data mining adalah serangkaian proses untuk menggali nilai tambah dari suatu kumpulan data berupa pengetahuan yang selama ini tidak diketahui secara manual. *Data mining* merupakan proses pencarian pola dan relasi-relasi yang tersembunyi dalam sejumlah data yang besar dengan tujuan untuk melakukan klasifikasi, estimasi, prediksi, *association rule* (aturan asosiasi), *clustering* (pengelompokan), deskripsi dan visualisasi. *Data mining* merupakan pencarian pengetahuan dalam database yang digunakan untuk mendapatkan informasi yang dapat menjelaskan masa lalu maupun dipakai untuk memprediksi masa depan (Yulianto dan Darwis, 2021).

Menurut Kotu dan Deshpande (2015), tugas-tugas data mining bisa dikelompokkan ke dalam delapan kelompok berdasarkan fungsionalitasnya sebagai berikut :

1. Klasifikasi (*classification*) : Menggeneralisasi struktur yang diketahui untuk diaplikasikan pada data-data baru.
2. Regresi (*regression*) : Menemukan suatu fungsi yang memodelkan data dengan galat (*error*) seminimal mungkin.

3. Klasterisasi (*clustering*) : Mengelompokkan data yang tidak diketahui label kelasnya ke dalam sejumlah kelompok tertentu sesuai dengan ukuran kemiripannya.
4. Pembelajaran aturan asosiasi (*association rule learning*) atau pemodelan kebergantungan (*dependency modeling*) : mencari relasi antar variabel.
5. Deteksi anomali (*anomaly detection*) : Mengidentifikasi data yang tidak umum, bisa berupa pencilan (*outlier*), perubahan atau deviasi yang mungkin sangat penting dan perlu investigasi lebih lanjut.
6. Peramalan seri waktu (*time series forecasting*) : Proses data mining yang bertujuan untuk membentuk model agar dapat memprediksi suatu nilai di masa depan dengan melihat atau menganalisa model di masa yang lalu.
7. Penambangan teks (*text mining*) : Perbatasan baru analisa prediktif dan domain dari data mining tidak terstruktur.
8. Seleksi fitur (*feature selection*) : Proses identifikasi beberapa variabel atau atribut yang paling penting dalam model untuk peramalan yang akurat.

2.4. Machine Learning

Machine learning merupakan mesin yang digunakan untuk belajar dengan sendirinya tanpa arahan dari penggunanya. Pembelajaran mesin dikembangkan berdasarkan disiplin ilmu lainnya seperti statistika, matematika dan data mining sehingga mesin dapat belajar dengan menganalisa data tanpa perlu di program ulang atau diperintah (Sihombing dan Arsani, 2021). *Machine learning* bertujuan untuk mengatasi sebuah masalah secara otomatis dengan mempelajari data, dari data machine learning memperoleh wawasan dan belajar hal baru agar terbentuk sebuah sistem yang baik. *Machine learning* bergantung pada data, untuk mengeluarkan *output* dari proses *machine learning* diperlukan data untuk bahan *training* dan *testing*.

Dalam pembelajarannya *machine learning* dikelompokkan menjadi 2 yaitu :

1. Pembelajaran terarah (*supervised learning*) merupakan proses pembelajaran dimana jika *output* yang diinginkan telah diketahui sebelumnya. Biasanya pembelajaran ini menggunakan data yang telah ada. Keterbatasan *supervised learning* yaitu membutuhkan data dengan jumlah yang besar sehingga memakan waktu yang lama, serta membutuhkan validasi berulang dengan dataset lainnya untuk melatih ketepatan model.
2. Pembelajaran tidak terarah (*unsupervised learning*) merupakan proses pembelajaran yang tidak terawasi dimana tidak memerlukan target output. Tujuan metode ini yaitu mengelompokkan unit yang memiliki kemiripan pada area tertentu. Kelebihannya dapat menentukan pola tersembunyi dari data-data yang akan diidentifikasi, namun kekurangannya yaitu sulitnya menentukan pola awal untuk membentuk algoritma.

2.5. Deep Learning

Deep learning merupakan adalah implementasi konsep dasar *machine learning* yang mengadaptasikan algoritma jaringan syaraf tiruan dengan lapisan yang lebih banyak. Lebih banyak lapisan tersembunyi yang digunakan antara lapisan masukan dan lapisan keluaran, maka dapat dibilang jaringan tersebut adalah *deep neural network* (Goodfellow, dkk., 2016).

2.5.1. Recurrent Neural Network (RNN)

Menurut Tian, dkk. (2018), *Recurrent Neural Network* adalah sejenis jaringan saraf tiruan yang memiliki kemampuan untuk melihat korelasi tersembunyi yang terjadi pada data dalam aplikasi pengenalan suara, pemrosesan bahasa alami, dan prediksi deret waktu. RNN sangat baik digunakan untuk masalah pemodelan

urutan dengan mengoperasikan informasi *input* serta jejak informasi yang diperoleh sebelumnya karena koneksi berulang.

$$S_t = f((U * X_t) + (W * S_{t-1})) \quad (2.5)$$

$$O_t = g(V * S_t) \quad (2.6)$$

dimana :


S_t : memori jaringan pada waktu ke-t

U, V, dan W : matriks bobot berbagi di setiap *layer*

X_t dan O_t : mewakili *input* dan *output* pada waktu ke-t

$f(...)$ dan $g(...)$: mewakili fungsi *non linear*

RNN terdiri dari *unit input*, *output*, dan *unit tersembunyi*. 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 berhubungan dan dapat memberikan informasi ke *hidden layer* (Sen, dkk., 2020).



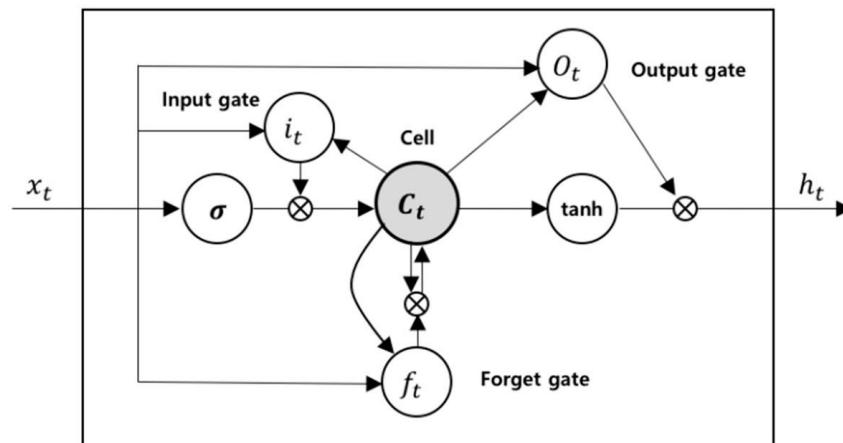
Gambar 2. Arsitektur *Recurrent Neural Network*

(Sumber: Tian, dkk., 2018)

2.5.2. *Long Short Term Memory (LSTM)*

Long Short Term Memory (LSTM) merupakan pengembangan dari *Recurrent Neural Network (RNN)* dengan mengatasi salah satu kekurangan RNN yaitu


kemampuan pengelolaan informasi dalam periode yang lama. Diusulkan oleh Sepp Hochreiter dan Jurgen Schmidhuber pada tahun 1997, LSTM banyak dipilih untuk prediksi berbasis waktu atau *time-series* karena dikenal lebih unggul dan handal dalam melakukan prediksi dalam waktu lama dibanding algoritma lain (Zahara, dkk., 2019).



Gambar 3. Sel *Long-Short Term Memory*
(Sumber: Chung dan Shin., 2018)

2.5.3. *Gated Recurrent Unit (GRU)*

Gated Recurrent Unit (GRU) adalah salah satu variasi dari *Recurrent Neural Network (RNN)* yang dibuat untuk menghindari masalah ketergantungan jangka panjang pada RNN. GRU dapat mengingat informasi jangka panjang dan juga terdiri dari modul pemrosesan berulang (Zaman, dkk., 2019). Berikut skema *cell* dari arsitektur GRU.



Gambar 4. Arsitektur *Gated Recurrent Unit*

(Sumber: Hastomo, dkk., 2022)

1. *Update gate* (Z_t) dilakukan untuk menentukan berapa banyak informasi dari langkah atau *cell* sebelumnya untuk dibawa menuju masa depan.

$$z_t = \sigma(w_z * [h_{t-1}, x_t] + b_z) \quad (2.7)$$

dimana :

- z_t : *update gate*
- σ : fungsi *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_z : nilai bias pada *update gate*

2. *Reset gate* (r_t) digunakan untuk menentukan bagaimana menggabungkan informasi *input* baru dengan informasi masa lalu.

$$r_t = \sigma(w_r * [h_{t-1}, x_r] + b_r) \quad (2.8)$$

dimana :

- r_t : *reset gate*
- σ : fungsi *sigmoid*
- w_r : nilai *weight* untuk *reset gate*
- h_{t-1} : nilai *output* sebelum orde ke-t
- x_t : nilai *input* pada orde ke-t
- b_r : nilai bias pada *reset gate*

Kemudian penentuan kandidat *hidden state* pada *time step* saat ini (t) dan informasi pada masa lalu ($t - 1$) menggunakan fungsi aktivasi *tanh*.

$$\tilde{h}_t = \tanh(W * x_t + (r_t * h_{t-1}) * W + b_h) \quad (2.9)$$

dimana :

- \tilde{h}_t : kandidat *hidden state*
- tanh* : fungsi *tangen hiperbolik*
- W : nilai parameter *weight*
- x_t : nilai *input* pada orde ke- t
- r_t : *reset gate*
- h_{t-1} : nilai *output* sebelum orde ke- t
- b_h : nilai bias pada *hidden state*

Proses perhitungan *output* terakhir dengan persamaan sebagai berikut.

$$h_t = (1 - z_t) * \tilde{h}_t + z_t * h_{t-1} \quad (2.10)$$

dimana :

- h_t : *output*
- h_{t-1} : *hidden state* sebelum orde ke- t
- z_t : *output* pada *update gate*
- \tilde{h}_t : kandidat *hidden state*

2.6. Hyperparameter Model GRU

Hyperparameter merupakan salah satu faktor yang mempengaruhi kinerja dari model GRU untuk mendapatkan performa yang lebih tinggi saat melatih model GRU (Pratamasunu, dkk., 2022). Pengujian *hyperparameter* ini memiliki tujuan menemukan model terbaik untuk memprediksi dengan tepat. Pengujian parameter menggunakan banyaknya unit GRU, *batch size*, *dropout* dan *epoch*.

2.7. *Standard Scaler*

Standard Scaler merupakan metode *preprocessing* dimana metode melakukan standarisasi dengan menghapus rata-rata dan menskalakan *unit* varian. *Preprocessing* ini dilakukan untuk mencegah adanya data yang memiliki nilai terlalu besar dibanding dengan nilai yang lain yang akan dapat mengakibatkan proses *training* tidak sesuai keinginan (Prasetyo, dkk., 2022).

$$Z = \frac{x_t - \bar{x}}{\sigma} \quad (2.11)$$

dimana :

- Z : nilai hasil normalisasi
- x_t : nilai sampel
- \bar{x} : rata – rata
- σ : standar deviasi

2.8. *Normalisasi Min-Max*

Normalisasi *Min-Max* adalah teknik sederhana, dimana teknik tersebut dapat secara khusus menyesuaikan data dalam batas yang telah ditentukan sebelumnya (Sugiartawan, dkk., 2017). Teknik ini digunakan untuk mengatasi perbedaan nilai yang cukup besar antar dataset dengan mengubah nilai data aktual menjadi nilai dengan skala (0,1) tanpa mengubah informasi yang ada.

$$x' = \frac{(x - x_{min})}{(x_{max} - x_{min})} \quad (2.12)$$

dimana :

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

2.9. Fungsi Aktivasi

Fungsi aktivasi merupakan suatu fungsi yang digunakan untuk menentukan *output* suatu *neuron*. Fungsi aktivasi digunakan untuk mengaktifkan atau tidak mengaktifkan *neuron* yang dipakai pada jaringan tersebut. Fungsi aktivasi yang akan menentukan apakah sinyal dari *input neuron* akan diteruskan ke *neuron* lain atau tidak. (Siang, 2005).


Fungsi aktivasi yang sering digunakan salah satunya adalah sebagai berikut.

1. Fungsi aktivasi *sigmoid* merupakan fungsi *non linier* yang menampilkan nilai dengan *range* 0 sampai 1, yang artinya menggambarkan banyak masing-masing komponen yang harus dilewati. Fungsi *sigmoid* ditunjukkan pada persamaan berikut.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.13)$$

Fungsi *sigmoid* diperoleh dengan menggunakan turunan sebagai berikut :

$$\begin{aligned} f(x) &= \frac{u(x)}{v(x)} \\ f'(x) &= \frac{u'(x)v(x) - u(x)v'(x)}{[v(x)]^2} \\ \frac{d}{dx} \sigma(x) &= \frac{d}{dx} \frac{1}{(1 + e^{-x})^2} \\ &= \frac{e^{-x}}{(1 + e^{-x})^2} \\ &= \frac{1 - 1 + e^{-x}}{(1 + e^{-x})^2} \\ &= \frac{1 + e^{-x}}{(1 + e^{-x})^2} - \frac{1}{(1 + e^{-x})^2} \\ &= \frac{1}{(1 + e^{-x})} - \frac{1}{(1 + e^{-x})^2} \\ &= \frac{1}{(1 + e^{-x})} \left(1 - \frac{1}{(1 + e^{-x})} \right) \\ &= \sigma(x)(1 - \sigma(x)) \end{aligned} \quad (2.14)$$



Gambar 5. Fungsi Aktivasi *Sigmoid*

(Sumber: Fausett, L., 1994)


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

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.15)$$

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} \quad (2.16)$$

Fungsi *tanh* diperoleh dengan menggunakan aturan turunan sebagai berikut :

$$\begin{aligned} f(x) &= \frac{u(x)}{v(x)} \\ \frac{d}{dx} \tanh(x) &= \frac{d \sinh(x)}{dx \cosh(x)} \\ &= \frac{\cosh^2(x) - \sinh^2(x)}{\cosh^2(x)} \\ &= \frac{\cosh^2(x)}{\cosh^2(x)} - \frac{\sinh^2(x)}{\cosh^2(x)} \\ &= 1 - \tanh^2(x) \end{aligned} \quad (2.17)$$



Gambar 6. Fungsi Aktivasi *Tangen Hiperbolik*

(Sumber: Fausett, L., 1994)

2.10. *Hybrid*

Metode *hybrid* merupakan perkembangan dalam peramalan *time series* dengan menggabungkan dua metode, salah satunya penggabungan ARIMA dan GRU. Secara umum kombinasi dari model *time series* yang memiliki struktur *linear* dan *non-linear* dapat ditulis sebagai berikut (Zhang, 2003):

$$y_t = L_t + N_t \quad (2.18)$$

dimana :

- y_t : nilai aktual ke- t
- L_t : komponen *linear* ke- t
- N_t : komponen *non linear* ke- t
- t : indeks waktu

komponen di atas didapat dari ramalan data, pertama hasil ramalan data *time series* dengan model ARIMA digunakan sebagai komponen *linear* kemudian residual dari model *linear* sebagai komponen *non-linear*, maka :

$$e_t = y_t - \hat{L}_t \quad (2.19)$$

dimana :

- y_t : nilai aktual ke- t
- \hat{L}_t : komponen *linear* ke- t

e_t : nilai residual ke- t
 t : indeks waktu

dimana \hat{L}_t adalah nilai prediksi ARIMA pada waktu ke- t . Sebuah model *linier* tidak akan terpenuhi apabila masih terdapat struktur korelasi *linier* pada residual. Pemodelan residual menggunakan GRU dapat menemukan hubungan *non-linear* pada data *time series*. Pemodelan residual menggunakan GRU dengan unit *input* sebanyak n dapat dituliskan sebagai berikut:

$$e_t = f(e_{(t-1)}, e_{(t-2)}, \dots, e_{(t-n)} + \varepsilon_t) \quad (2.20)$$

dimana :

e_t : nilai residual ke- t
 f : fungsi *non linear* dari GRU
 t : indeks waktu

Fungsi f adalah fungsi *non-linear* yang ditentukan oleh GRU dan ε_t adalah *error* yang acak ke- t . Persamaan diatas sebagai N'_t , sehingga peramalan *hybrid* ditulis sebagai berikut:

$$y'_t = L'_t + N'_t \quad (2.21)$$

dimana :

y'_t : prediksi dari model *hybrid* ke- t
 L'_t : prediksi komponen *linear* dari GRU ke- t
 N'_t : prediksi komponen residual dari GRU ke- t
 t : indeks waktu

Metode *hybrid* terdiri dari dua langkah. Langkah pertama, model ARIMA digunakan untuk memprediksi bagian *linear*. Langkah kedua, model GRU dibangun untuk memodelkan residual dari model ARIMA bagian *non-linear*. Karena model ARIMA tidak dapat menangkap struktur data *non-linier*, model residual akan berisi informasi tentang *non-linear* dari data.

2.11. Akurasi

Makridakis dkk. (1999) menyatakan bahwa, akurasi menunjukkan seberapa jauh model peramalan tersebut mampu mereproduksi data yang telah diketahui. Ukuran ketepatan model sebagian besar menggunakan faktor kesalahan galat yang diperoleh dari perbedaan antara data aktual dan hasil peramalan.

Terdapat beberapa parameter evaluasi yang bisa digunakan, diantaranya adalah *mean square error* (MSE) dan *mean absolute percentage error* (MAPE). MAPE mengindikasikan seberapa besar kesalahan dalam memprediksi yang dibandingkan dengan nilai aktual. Dengan persamaan sebagai berikut.

$$MAPE = \sum_{t=1}^n \frac{|Y_t - \hat{Y}_t|}{Y_t} \times 100\% \quad (2.22)$$

dimana :

Y_t : data aktual ke-t

\hat{Y}_t : data prediksi ke-t

n : banyaknya periode prediksi

t : indeks waktu

Tabel 2. Kriteria nilai MAPE

No	MAPE	Penjelasan Nilai
1	<10	Sangat Baik
2	10 – 20	Baik
3	20 – 50	Sedang
4	> 50	Buruk

Mean Squared Error merupakan rata-rata dari kesalahan prediksi dikuadratkan. *Mean Squared Error* (MSE) adalah metode lain untuk mengevaluasi metode prediksi. Nilai MSE yang rendah atau mendekati nol menunjukkan bahwa hasil prediksi semakin sesuai dengan data aktual.

$$MSE = \frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n} \quad (2.23)$$

dimana :

- Y_t : data aktual ke-t
 \hat{Y}_t : data prediksi ke-t
 n : banyaknya periode prediksi
 t : indeks waktu

Root Mean Squared Error (RMSE) adalah akar dari rata-rata kesalahan prediksi dikuadratkan. RMSE merupakan besarnya tingkat kesalahan hasil prediksi. Hasil prediksi yang baik apabila nilai RMSE semakin mendekati nilai nol.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (Y_t - \hat{Y}_t)^2}{n}} \quad (2.24)$$

dimana :

- Y_t : data aktual ke-t
 \hat{Y}_t : data prediksi ke-t
 n : banyaknya periode prediksi
 t : indeks waktu

III. METODE PENELITIAN

3.1. Waktu dan Tempat Penelitian

Penelitian ini dilakukan pada semester ganjil tahun akademik 2022/2023, bertempat di Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung.

3.2. Spesifikasi Perangkat

Perangkat yang digunakan pada penelitian ini adalah laptop merek acer dengan model ES1-432-C1P4 tipe Aspire ES 14. Spesifikasi *hardware* perangkat tersebut adalah sebagai berikut:

- *Processor name* : Intel(R) Celeron(R) CPU N3350
- *Processor speed* : 1.10GHz
- RAM : 2 GB DDR3

3.3. Data Penelitian

Data yang digunakan pada penelitian ini adalah data sekunder yang diperoleh dari *link* <https://id.investing.com/equities/sawit-sumberma-historical-data> mengenai data histori harga sawit pada PT. Sawit Sumbermas Sarana selama 9 tahun terhitung sejak Januari 2014 sampai dengan November 2022 dalam skala mingguan. Data yang digunakan pada penelitian ini adalah data harga terakhir sawit yang diambil setiap minggu sehingga terdapat 459 data.

Tabel 3. Data harga sawit

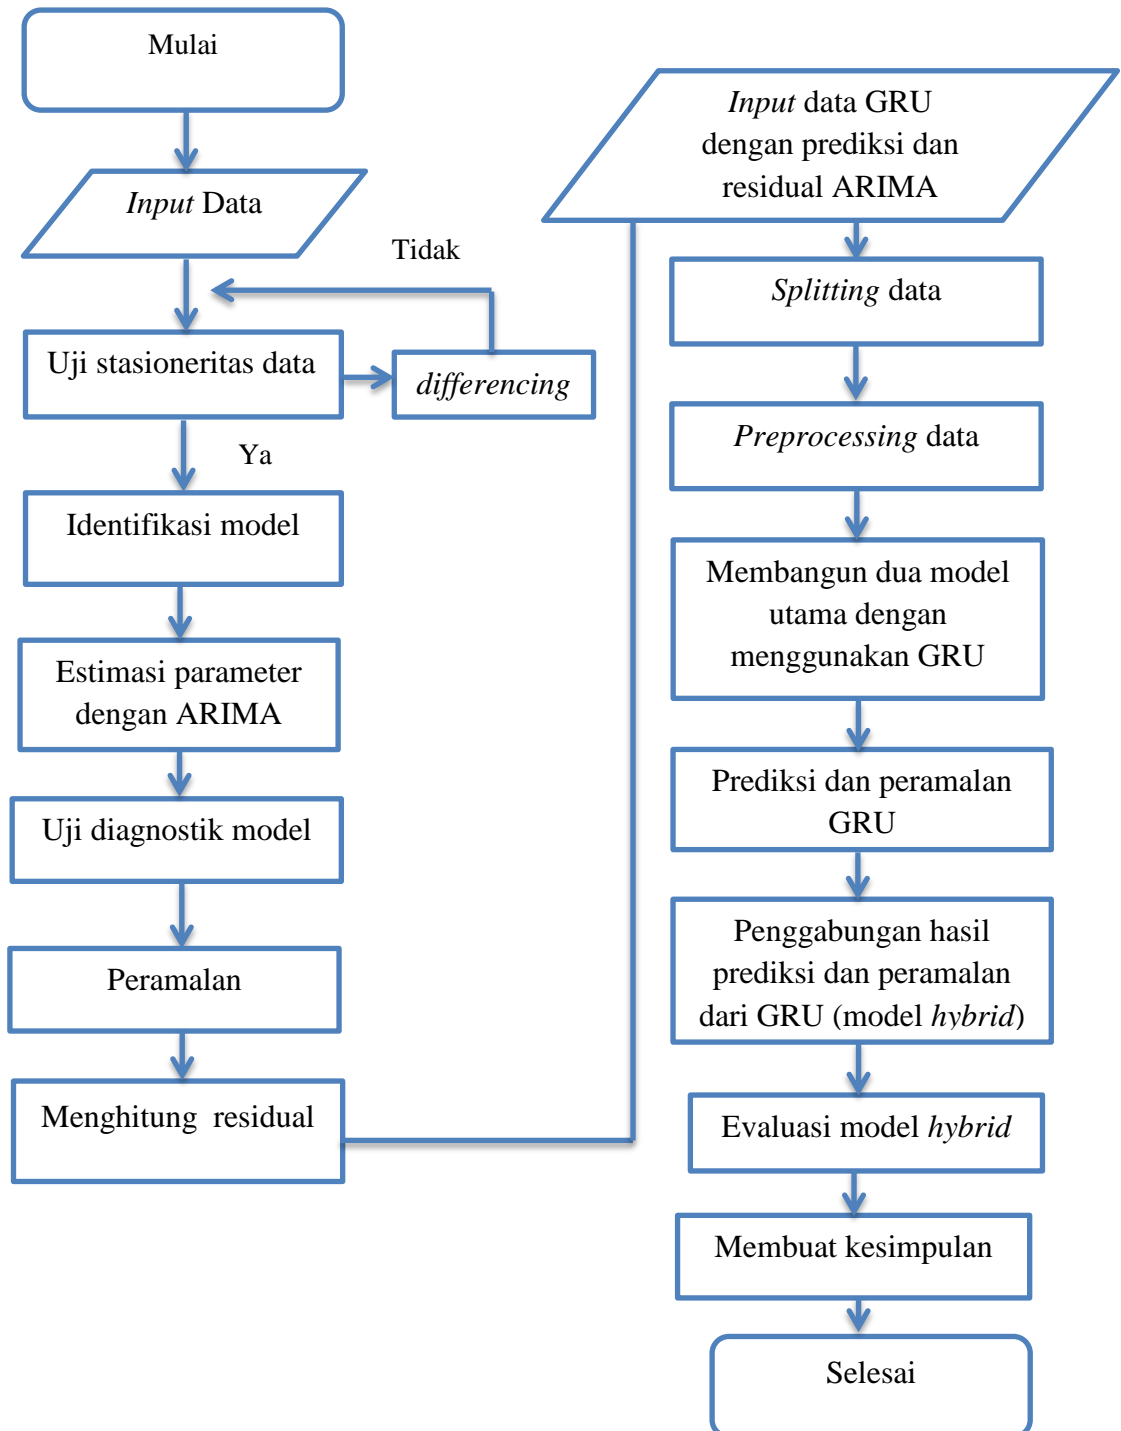
Tanggal	Terakhir
05/01/2014	920
12/01/2014	895
19/01/2014	810
26/01/2014	840
.	.
.	.
.	.
27/11/2022	1.510

3.4. Metode Penelitian

Berikut merupakan alur dari pengerjaan metode *hybrid* ARIMA – GRU :

1. Melakukan studi literatur mengenai proses model *hybrid* ARIMA – GRU yang diambil dari jurnal serta dibantu oleh narasumber yang memahami model *hybrid* ARIMA – GRU.
2. Mengumpulkan data yang digunakan untuk proses peramalan dengan metode *hybrid* ARIMA – GRU.
3. Melakukan *input* data ke bahasa pemrograman dengan menggunakan aplikasi *google colab*.
4. Melakukan uji stasioneritas terhadap data, lalu identifikasi, estimasi model dan diagnostik model
5. Berdasarkan Model ARIMA yang telah ada, kemudian dilakukan untuk memprediksi data.
6. Melakukan ekstraksi data residual yang merupakan selisih antara data prediksi ARIMA dengan data aktual.
7. Data prediksi dan data residual ARIMA digunakan sebagai *input* untuk diolah dengan menggunakan GRU.

8. Melakukan pembagian data yaitu data *training* dan data *testing* dengan skema pembagian data sebesar 80% *training* dan 20% *testing* dan 90% *training* dan 10% *testing*.
9. Melakukan normalisasi data dengan menggunakan *standardscaler*.
10. Menentukan inisialisasi parameter-parameter yang dibutuhkan yaitu *unit GRU*, *dropout*, *batch size*, dan *epoch*.
11. Membangun model GRU untuk data prediksi dari ARIMA, dilakukan dengan menggunakan *hypertuning* untuk menentukan parameter terbaik.
12. Melakukan prediksi data dengan model GRU
13. Melakukan proses denormalisasi untuk mengembalikan hasil prediksi agar dibandingkan dengan data aktual.
14. Membandingkan data hasil prediksi dan aktual dengan *plotting*.
15. Melakukan evaluasi terhadap model GRU yang telah dibangun dengan nilai RMSE dan MAPE.



Gambar 7. Workflow ARIMA - GRU

V. KESIMPULAN

5.1. Kesimpulan

Metode *hybrid* ARIMA – GRU dapat digunakan untuk melakukan peramalan terhadap harga sawit dengan baik. Akurasi pada metode ARIMA diperoleh sebesar 99,9653% sedangkan dengan metode *hybrid* diperoleh akurasi sebesar 99.9824%. Plot hasil peramalan pada metode ARIMA tidak mengikuti data *ter-update* untuk plot hasil peramalan *hybrid* ARIMA – GRU menghasilkan data peramalan yang mengikuti data *ter-update*. Kesimpulan yang didapatkan selama proses pengerjaan penelitian peramalan harga sawit dengan metode *hybrid* ARIMA – GRU adalah sebagai berikut:

1. Metode *hybrid* ARIMA – GRU adalah model yang tergolong sangat baik untuk melakukan prediksi serta peramalan untuk data harga sawit. Metode *hybrid* ARIMA – GRU memiliki parameter terbaik dengan:
Skema *splitting* data 90% *training* dan 10% *testing*
Model 1 : GRU *unit* sebesar 64 dan *batch size* sebesar 128
Model 2 : GRU *unit* sebesar 128 dan *batch size* sebesar 64
2. Hasil peramalan yang diperoleh selama 6 bulan menggunakan metode *hybrid* ARIMA – GRU mengikuti pola data *ter-update*, dengan skema *splitting* data 90% *training* dan 10% *testing* memiliki nilai evaluasi yang lebih baik dibandingkan dengan skema *splitting* 80% *training* dan 20% *testing*, dengan nilai MSE sebesar 868.4690, RMSE sebesar 29.4698, MAPE sebesar 0.0117 dan akurasi sebesar 99.9824%.

DAFTAR PUSTAKA

- Arfianti, I. U., Novitasari, R. C. D., Widodo, N., Hafiyusholeh, M., dan Utami, D.W. 2021. Sunspot Number Prediction Using Gated Recurrent Unit (GRU) Algorithm. *Indonesian Journal of Computing and Cybernetics Systems*. **15**(2): 141-152.
- Chung, H., dan Shin, K.S. 2018. Genetik Algorithm-Optimized Long Short-Term Memory Network for Stock Market Prediction. *Sustainability*. **10**(10): 2-18.
- Fausett, L. 1994. *Fundamentals of Neural Networks : Architectures, Algorithms, and Applications*. Prentice Hall, New Jersey.
- Ginting, G. H., Azmi, Z., dan Ginting, I. R. 2020. Jaringan Syaraf Tiruan dalam Peramalan Harga Jual Sawit dengan Metode Backpropagation. *Jurnal CyberTech*. **10**(10): 1-15.
- Goodfellow, I., Bengio, Y., dan Courville, A. 2016. *Deep Learning*. Massachusetts Institute of Technology, London.
- Hanke, J.E. dan Wichern, D.W. 2005. *Business Forecasting*. Edition-8. Pearson Prentice Hall, New Jersey.
- Hastomo, W., Aini, N., Karno, A.S.B., dan Rere, L.M.R. 2022. Metode Pembelajaran Mesin untuk Memprediksi Emisi Manure Management. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*. **11**(2): 131-139
- Iriawan, N. dan Astuti, P.S. 2006. *Mengelolah Data Statistik dengan Mudah Menggunakan Minitab 14*. Andi, Yogyakarta.
- Kementrian Perindustrian Republik Indonesia. 2021. *Tantangan dan Prospek Hilirisasi Sawit Nasional*. Edisi ke-6. Kemenperin.
- Kotu, V. dan Deshpande, B. 2015. *Predictive Analytics and Data Mining: Concepts and Practice with RapidMiner*. Elsevier, Waltham.
- Makridakis, S., Wheelwright, S.C., dan McGee, V.E. 1999. *Metode dan Aplikasi Peramalan*. Edisi ke-2. Erlangga, Jakarta.

- Montgomery, D. C., Jennings, L. C. dan Kulahci, M. 2015. *Introduction to Time Series Analysis and Forecasting*. Edition-2. New Jersey: John Wiley dan Sons.
- Pratamasunu, O. Q. G., Fajri, N. F. dan Sari, K. P. 2022. Deteksi Tangan Otomatis pada Video Percakapan Bahasa Isyarat Indonesia Menggunakan Metode Deep Gated Recurrent Unit (GRU). *Jurnal Komputer Terapan*. **8**(1): 186-193.
- Prasetyo, V.R., Mercifia, M., Averina, A., Sunyoto, L., dan Budiarmo. 2022. Prediksi Rating Film pada Website IMDB Menggunakan Metode Neural Network. *Jurnal Ilmiah Nero*. **7**(1): 1-8.
- Salwa, N., Tatsara, N., Amalia, R. dan Zohra, F.A. 2018. Peramalan Harga Bitcoin Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average). *Journal of Data Analysis*. **1**(1): 21-31.
- Sartono, B. 2006. *Modul Kuliah Pelatihan Time Series Analysis*. Institut Pertanian Bogor, Bogor
- Sen, S., Sugiarto, D., dan Rochman, A. 2020. Komparasi Metode Multilayer Perceptron (MLP) dan Long-Short Term Memory (LSTM) dalam Peramalan Harga Beras. *Jurnal Teknik Informatika*. **11**(1): 35-41.
- Shafiri, M.A., Damghani, K.K., Abdi, F. dan Sardar, S. 2021. Predicting the Price of Bitcoin Using Hybrid ARIMA and Deep Learning. *Journal of Industrial Management Studies*. **19**(61): 125-146.
- Siang, Jong Jek. 2005. *Jaringan Syaraf Tiruan dan Pemrogramannya Menggunakan Matlab*. Andi, Yogyakarta.
- Sihombing, P. R. dan Arsani, A. M., 2021. Perbandingan Metode Machine Learning dalam Klasifikasi Kemiskinan di Indonesia Tahun 2018. *Jurnal Teknik Informatika*. **2**(1): 51-56.
- Sugiartawan, P., Pulungan, R., dan Kartika, A. 2017. Prediction by a Hybrid of Wavelet Transform and Long-Short-Term-Memory Neural Network. *International Journal of Advanced Computer Science and Applications*. **8**(2): 326-332.
- Tian, C., Ma, J., Zhang, C., dan Zhan, P. 2018. A Deep Neural Network Model for Short-Term Load Forecast Based on Long-Short Term Memory Network and Convolution Neural Network. *Energies Journal*. **11**(12): 1-13.
- Wiguna, H., Nugraha, Y., Rizka, R.F., Andika, A., Kangrawan, I.J. dan Suherman, L.A. 2020. Kebijakan Berbasis Data: Analisis dan Prediksi Penyebaran COVID-19 di Jakarta dengan Metode Autoregressive

- Integrated Moving Average (ARIMA). *Jurnal Sistem Cerdas*. **03**(02): 74-83.
- Wei, W.W.S. 2006. *Time Series Analysis Univariate and Multivariate Methods*. Edition-2. Addison Wesley Publishing Company, New York.
- Wira, D. 2014. *Analisis Fundamental Saham*. Edisi ke-2. Exceed Books, Jakarta.
- Wiranda, L. dan Sadikin, M. 2019. Penerapan Long Short Term Memory pada Data Time Series untuk Memprediksi Penjualan Produk PT. Metiska Farma. *Jurnal Nasional Pendidikan Teknik Informatika*. **8**(3): 184-196.
- Yulianto, P, A. dan Darwis, S. 2021. Penerapan Metode K-Nearest Neighbors (kNN) pada Bearing. *Jurnal Riset Statistika*. **1**(1): 10-18.
- Zahara, S., Sugianto. dan Imiddafiq, M. B. 2019. Prediksi Indeks Harga Konsumen Menggunakan Metode Long Short Term Memory (LSTM) Berbasis Cloud Computing. *Jurnal Rekayasa Sistem dan Teknologi Informasi*. **3**(3): 357-363.
- Zaman, L., Sumpeno, S., dan Hariadi, M. 2019. Analisis Kinerja Lstm dan Gru Sebagai Model Generatif untuk Tari Remo. *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*. **8**(2): 142–150.
- Zhang, G. P. dan Berardi, V. 2001. Time Series Forecasting with Neural Network Ensembles: an Application for Exchange Rate Prediction. *Journal of the Operational Research Society*. **52**(6): 652-664.
- Zhang, G. P. 2003. Time Series Forecasting Using a Hybrid ARIMA and Neural Network Model. *Neurocomputing*. **50**:159-175.
- Zhang, G. P. 2004. *Neural Network in Business Forecasting*. Georgia State University, USA.
- Zhang, Z., Pan, X., Jiang, T., Sui, B., Liu, C. dan Sun, W. 2020. Monthly and Quarterly Sea Surface Temperature Prediction Based on Gated Recurrent Unit Neural Network. *Journal of Marine Science and Engineering*. **8**(249): 1-15
- Zhao, J., Gao, Y., Qu, Y., Yin, H., Liu, Y. dan Sun, H. 2018. Travel Time Prediction: Based on Gated Recurrent Unit Method and Data Fusion. *Digital Object Identifier*. **6**: 70463-70472.