

Analisis Prediksi Jangka Panjang COVID 19 Fase ke 3 di Indonesia menggunakan *Deep Learning*

Ibrahim Ade Herferry¹, Ferdiansyah², Yesi Novaria Kunang³, Susan Dian Purnamasari⁴

^{1,2,3,4}Universitas Bina Darma, Palembang, Indonesia

E-mail: ¹ibrahimadeherferry@gmail.com, ²ferdi@binadarma.ac.id, ³yesinovariakunang@binadarma.ac.id, ⁴susandian@binadarma.ac.id

Abstract

This research is motivated by the ongoing impact of the COVID-19 pandemic, which continues to pose challenges for Indonesia, affecting both the economy and daily life. Therefore, this study will discuss long-term predictions for the third phase of COVID-19 in Indonesia using a Deep Learning model. The analysis aims to assist various stakeholders in developing better planning strategies to address COVID-19 in Indonesia. In conducting this research, the author employs neural networks to create a hybrid model combining GRU and LSTM algorithms. Utilizing RMSE and MAPE values, it can be concluded that the model's performance in predicting COVID-19 cases is influenced by the number of epochs used. Furthermore, the model demonstrates optimal performance at 150 epochs for predicting the number of COVID-19 cases in the next 7 days.

Keywords: COVID-19, deep learning, Indonesia, neural network, prediction

Abstrak

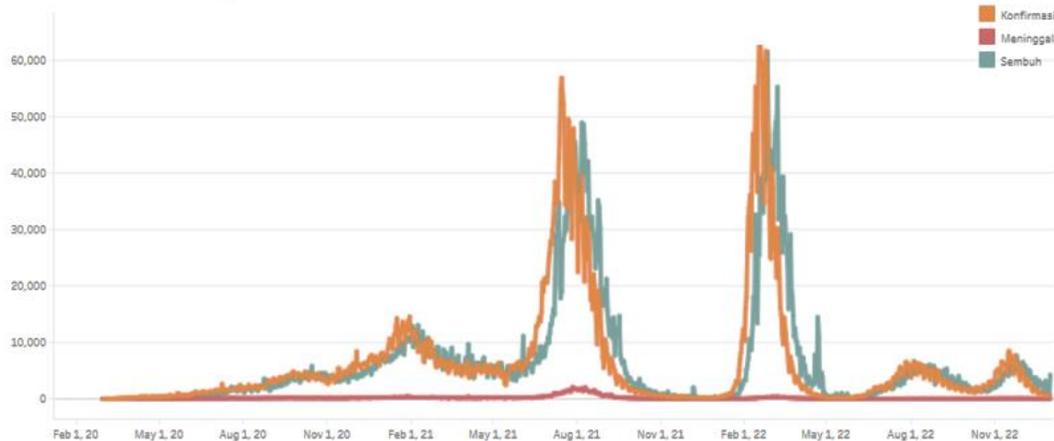
Penelitian ini dilatarbelakangi oleh dampak pandemi COVID-19 yang terus menimbulkan permasalahan bagi negara Indonesia, baik dari aspek ekonomi hingga kehidupan sehari-hari. Untuk itu, penelitian ini akan membahas prediksi jangka panjang COVID-19 fase ke-3 di Indonesia menggunakan model Deep Learning dimana melalui hasil analisis penelitian ini diharapkan dapat membantu berbagai pemangku kepentingan untuk membangun perencanaan lebih baik dalam mengatasi COVID-19 di Indonesia. Dalam melakukan penelitian, penulis menggunakan neural network dalam membangun alternatif model gabungan dari algoritma GRU dan LSTM. Dengan menggunakan nilai RMSE dan MAPE, dapat disimpulkan bahwa performa model dalam memprediksi kasus COVID-19 bergantung pada jumlah epoch yang digunakan. Di samping itu, model yang memiliki kinerja terbaik pada epoch 150 untuk memprediksi jumlah kasus COVID-19 dalam 7 hari ke depan.

Kata kunci: COVID-19, deep learning, Indonesia, neural network, prediksi

1. Pendahuluan

Seperti yang sudah diketahui bahwa pandemi COVID-19 tentunya memberikan berbagai dampak besar terhadap perekonomian dunia, terlebih dengan jumlah korban nyawa yang besar di seluruh penjuru dunia sejak flu Spanyol. Di saat yang bersamaan, dunia harus menghadapi penyakit lainnya seperti *Severe Acute Respiratory Syndrome* (SARS), *Middle East Respiratory Syndrome-related Coronavirus* (MERS) dan juga flu babi[1]. Berbagai upaya telah dikerahkan dalam menekan angka kasus COVID-19 di Indonesia pada tahun 2022 yang mengalami kenaikan pada bulan Februari-Maret berdasarkan data yang diambil dari peta

sebaran Nasional milik pemerintah. Tidak hanya itu, tentunya pemerintah juga harus berupaya dalam meminimalisir dampak lainnya yang disebabkan oleh pandemi ini.



Gambar 1. Data Pergerakan Kasus COVID-19 di Indonesia

Untuk itu, penting dalam menyediakan alat bantu prediksi kasus bagi tenaga kesehatan, pemerintah, dan pemangku kepentingan lainnya yang mengambil andil dalam mengatasi pandemi. Alat bantu prediksi yang akan dibahas dalam penelitian ini yakni peramalan deret waktu yang berfungsi dalam mengetahui prediksi peristiwa di masa depan menggunakan statistik dan algoritma pembelajaran mesin. Dengan demikian, penelitian ini diharapkan dapat menyediakan analisis Jangka Panjang waktu terjadi dan berakhirnya pandemi COVID-19 berdasarkan data yang diambil menggunakan metode *Deep Learning* (DL)[2]. Keterbatasan metode DL dalam menghasilkan prediksi data akurat, metode ini hanya dapat digunakan untuk membantu mempersiapkan satu langkah kedepan.

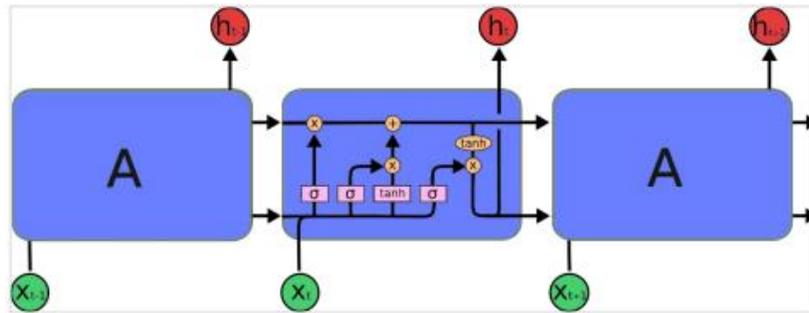
Berdasarkan paparan latar belakang tersebut, permasalahan yang terletak pada penelitian ini berfokus dalam menghasilkan prediksi jangka panjang penyebaran kasus COVID-19 fase ke-3 yang terjadi di Indonesia sejak tahun 2022[2]. Di samping itu, penelitian ini diharapkan dapat memberikan Gambaran ke depan COVID-19 melalui data penyebaran kasus COVID-19 secara perhari dan tentunya dapat membantu berbagai pemangku kepentingan negara dalam menghadapi COVID-19 fase ke-3 ini. Batasan masalah dalam penelitian ini terletak pada sumber data yang digunakan yakni hanya data yang terkonfirmasi pada web penyedia layanan data COVID-19 secara global.

2. Metodologi Penelitian

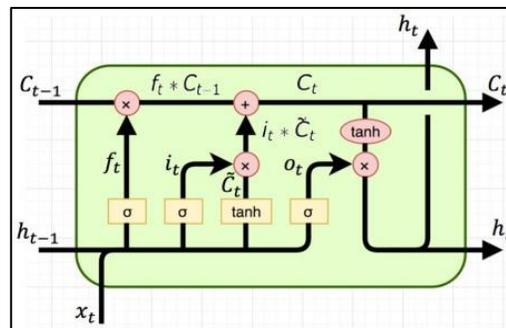
Metode penelitian ini menggunakan 4 model arsitektur hidden layer yang berbeda dengan variasi LSTM dan GRU. Hal ini dimaksudkan untuk memperoleh arsitektur hidden *layer* dengan hasil akurasi yang lebih baik (RMSE minimum). Selain itu tindakan ini juga memudahkan dalam menentukan besaran nilai *epoch* yang diperlukan sebelum proses prediksi dengan data sebenarnya dilakukan. Sehingga tidak perlu lagi melakukan coba salah (*try-error*) atas penggunaan nilai *epoch* yang diperlukan untuk proses prediksi dengan DL. Semua bahasa program yang dipergunakan dalam penelitian ini menggunakan bahasa Python. Bahasa ini dipilih karena banyak kemudahan yang dapat dilakukan, terutama untuk jenis pemrograman yang berhubungan dengan *machine learning*.

2.1. Long Short-Term Memory (LSTM)

Long Short Term Memory merupakan varian dari RNN, dimana konsep ini pertama kali dikemukakan oleh Hochreiter dan Schmidhuber. LSTM diciptakan dengan tujuan mengatasi masalah yang berkemungkinan muncul pada *hidden layer*. LSTM kurang lebih berprinsip sama dengan RNN, hal yang membedakan adalah isi dari *cell*. Gambar di bawah menunjukkan bahwa LSTM bersifat lebih kompleks sebab memiliki 4 *layer neuron* atau *gate*, dimana isi *cell* lebih dari 1 *layer neuron* [3].



Gambar 2. Struktur LSTM



Gambar 3. Cell LSTM

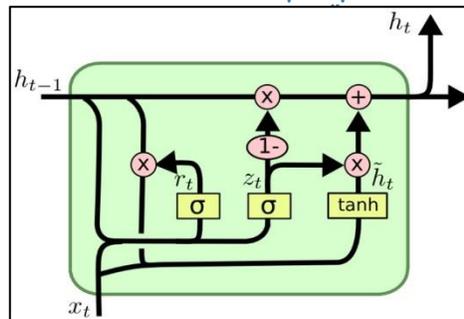
Berikut penjelasan dari setiap *gate* dalam isi *cell* berdasarkan Gambar.

- Input Gate*: $i_t = \sigma(W_i h_{t-1} + W_i h_t)$
 - Forget Gate*: $f_t = \sigma(W_f h_{t-1} + W_f h_t)$
 - Output Gate*: $o_t = \sigma(W_o h_{t-1} + W_o h_t)$
 - Intermediate Cell State*: $\tilde{C} = \tanh(W_c h_{t-1} + W_c h_t)$
 - Cell State (next memory input)*: $c_t = (i_t * \tilde{C}) + (f_t * c_{t-1})$
 - New State*: $h_t = o_t * \tanh(c_t)$
- g. X_t : *Input Vector*
 h. h_t : *Output Vector*
 i. **W, U and f**: *Parameter matrices and vector*
 \otimes *Element-wise multiplication*
 \oplus *Element-wise summation/concatenation*

2.2. Gated Recurrent Unit (GRU)

Gated recurrent unit atau disingkat GRU memiliki kemampuan dalam mengekstrak fitur dari data sekuensial dan juga membandingkan kinerja GRU bersama LSTM berdasarkan

efisiensi komputasi dan akurasi model. Keuntungan GRU yakni komputasinya yang lebih sederhana dari LSTM saat menjalankan proses ekstraksi fitur, dengan catatan memiliki akurasi yang setara dan tergolong cukup efektif dalam menghindari masalah gradien yang hilang[3]. Berikut penjelasan tiap elemen dari GRU cell menurut Gambar.

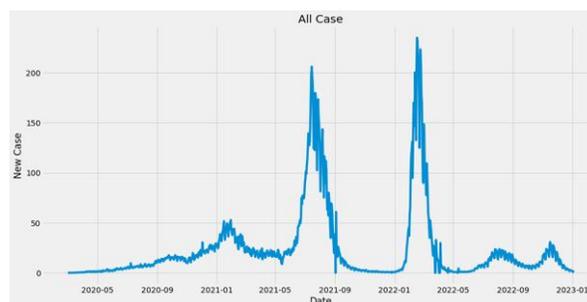


Gambar 4. GRU Cell

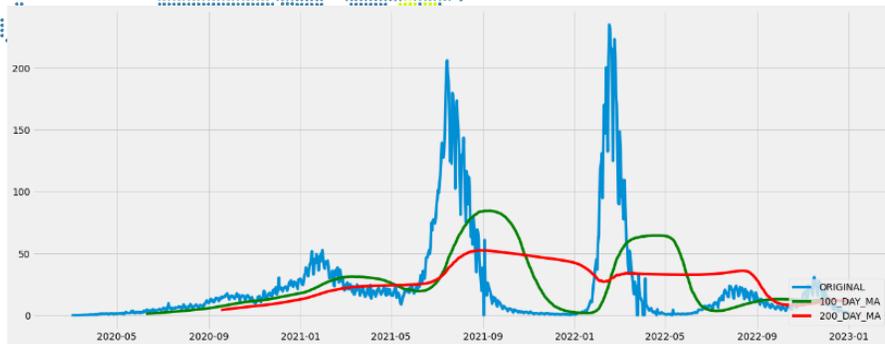
- a. *Update Gate*:
 - $z_t = \sigma(W_z h_{t-1} + U_z x_t)$
- b. *Reset Gate*:
 - $r_t = \sigma(W_r h_{t-1} + U_r x_t)$
- c. *Cell State*:
 - $\tilde{h}_t = \tanh(W_c (h_{t-1} * r) + U_c x_t)$
- d. *New State*:
 - $h_t = (z * c) + ((1 - z) * h_{t-1})$
 - ⊗ *Element-wise multiplication*
 - ⊕ *Element-wise summation/concatenation*

2.3. Tahapan Penelitian

Berdasarkan penelitian terdahulu yang digunakan untuk mendukung penelitian ini, penulis menyimpulkan bahwa *neural network* dapat digunakan dalam membangun alternatif model prediksi jumlah kasus COVID-19 dengan menghasilkan nilai *error R-squared* sebesar 0.9793. Data yang dikumpulkan untuk penelitian ini melalui tahap *preprocessing* dimana ditujukan untuk memfilter data yang akan digunakan[4]. Data dikumpulkan melalui *Github* yang di arahkan dari web ourworldindata.org yang menyediakan layanan data covid-19 dari seluruh dunia. Data historis yang digunakan berjarak 3 tahun yang dimulai dari tanggal 06 Maret 2020 hingga 03 Januari 2023 dan jumlah dataset yang digunakan berjumlah 1034 dataset. Berikut adalah data awal dan rata-rata pola pergerakan.



Gambar 5. Line Chart All Case COVID-19

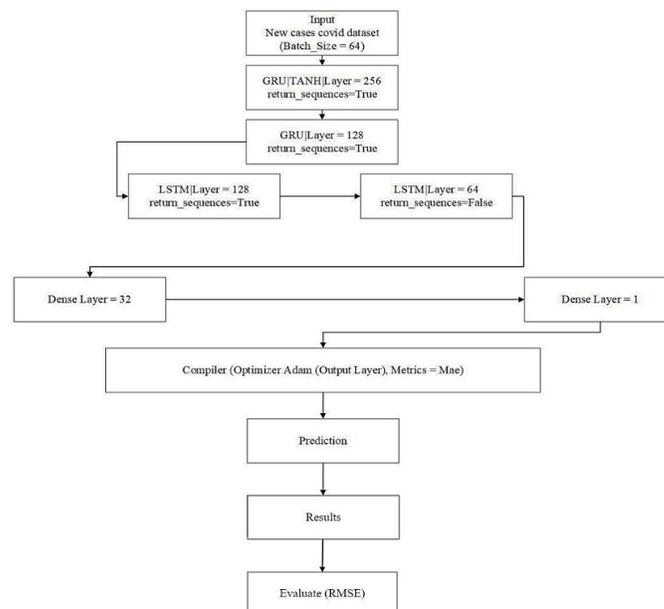


Gambar 2. Line Chart Data Awal dan Pola

Sementara itu pada tahapan pemodelan, model *deep learning* yang digunakan dalam kasus ini adalah RNN. RNN memiliki beberapa jenis layer yang dapat digunakan untuk mengelola data *time series*, berikut merupakan *layer* yang digunakan dalam penelitian ini:

2.4. GRU-LSTM Model

Kerangka model pada Gambar diatas tersebut merupakan gabungan dari algoritma GRU dan LSTM, dimana data diproses melalui 2 *layer* GRU dengan aktivasi *tanh*. *Layer* pertama menggunakan unit 256 dan *layer* kedua menggunakan unit 128. Sementara pada LSTM, *layer pertama* adalah unit 128 dan *layer* kedua adalah unit 64. *Return sequences* yang digunakan di setiap *layer* menghasilkan nilai *true* dan *false* pada *layer* terakhir. Kemudian, data yang dilalui GRU dan LSTM diproses melalui *layer dense* yang merupakan model tradisional *neural network*. *Layer dense* pada model ini menggunakan 3 *layer* dengan jumlah unit masing-masing yaitu 64, 32, dan 1. Di akhir, semua *layer* model disusun menggunakan *compiler* dengan menggunakan *optimizer Adam*. Model yang terbuat kemudian dikodekan menggunakan *Python*.



Gambar 7. Kerangka Model GRU-LSTM

RMSE sering digunakan untuk mengukur akurasi prediksi karena memperbesar dampak kesalahan besar dengan mengkuadratkan selisih antara nilai prediksi dan nilai aktual, sehingga kesalahan besar memiliki pengaruh lebih besar pada nilai akhir dan mendorong pengembangan model yang lebih akurat. RMSE memberikan hasil dalam satuan yang sama dengan data asli, sehingga lebih mudah dipahami dan relevan untuk aplikasi praktis. Selain itu, RMSE sensitif terhadap perubahan dalam data, memberikan informasi rinci tentang kinerja model[5].

3. Hasil dan Pembahasan

3.1. Evaluasi

Evaluasi dilakukan dengan 2 penilaian yaitu RMSE dan MAPE. Rumus RMSE dapat dilihat pada persamaan (1) dimana N merupakan jumlah observasi, x_i adalah sebagai sebenarnya dan \hat{x}_i sebagai nilai prediksi

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \hat{x}_i)^2} \quad (1)$$

MAPE mengGambarkan persentase kesalahan dalam estimasi atau peramalan hasil aktual selama periode tertentu dengan perhitungannya dapat dilihat pada persamaan [6].

$$MAPE = \frac{100}{n} \sum \frac{|At - Ft|}{At} \quad (2)$$

Nilai MAPE dapat diartikan atau diinterpretasikan menjadi 4 kategori, yaitu:

- <10% = Sangat Akurat
- 10-20% = Bagus
- 20-50% = Wajar
- >50% = Tidak Akurat

Dapat disimpulkan bahwa semakin kecil nilai MAPE, maka semakin kecil *error* hasil estimasi. Setelah dilakukan *training* pada model menggunakan *dataset* yang tersedia, hasil prediksi dari model dapat dievaluasi menggunakan *library sklearn* pada *Python* maupun secara manual. Dimana hasil evaluasi dapat dilihat melalui Tabel di bawah berikut yang menunjukkan nilai RMSE dan MAPE dari data hasil prediksi yang dipilih. Nilai RMSE pada *epoch* 150 memiliki nilai terstabil di antara kedua yang diuji.

Tabel 1. Hasil Evaluasi

No.	Epoch	RMSE	MAPE
1.	50	1.6917	7.6739
2.	100	0.8350	8.4607
3.	150	0.1890	1.0678
4.	200	2.2267	9.1418
5.	250	1.0089	1.1045

3.2. Pelatihan Model

Setiap baris mewakili satu *layer* dalam model beserta informasi mengenai jenis *layer*, *Output shape* (bentuk *output*) dari *layer* tersebut, dan jumlah parameter yang dapat diatur selama proses pelatihan model.

```

model.summary()

Model: "sequential"
-----
Layer (type)                Output Shape                Param #
-----
gru (GRU)                   (None, 7, 256)             198912
gru_1 (GRU)                 (None, 7, 128)             148224
lstm (LSTM)                 (None, 7, 128)             131584
lstm_1 (LSTM)              (None, 64)                 49408
dense (Dense)              (None, 32)                 2080
dense_1 (Dense)            (None, 1)                  33
-----
Total params: 530,241
Trainable params: 530,241
Non-trainable params: 0
  
```

Gambar 8. Summary Model

Lapisan pada model yang dipakai terdiri dari :

1. GRU (*Gated Recurrent Unit*): Layer GRU dengan *Output shape* (None, 7, 256) dan total 198,912 parameter.
2. GRU_1 (*Gated Recurrent Unit*): Layer GRU lainnya dengan *Output shape* (None, 7, 128) dan total 148,224 parameter.
3. LSTM (*Long Short-Term Memory*): Layer LSTM dengan *Output shape* (None, 7, 128) dan total 131,584 parameter.
4. LSTM_1 (*Long Short-Term Memory*): Layer LSTM lainnya dengan *Output shape* (None, 64) dan total 49,408 parameter.
5. Dense (*Fully Connected*): Layer Dense dengan *Output shape* (None, 32) dan total 2,080 parameter.
6. Dense_1 (*Fully Connected*): Layer Dense lainnya dengan *Output shape* (None, 1) (kemungkinan prediksi tunggal) dan total 33 parameter.

Jumlah parameter dalam suatu *layer* menunjukkan berapa banyak "bobot" yang harus dipelajari oleh model selama proses pelatihan. Dalam pelatihan model nilai *hyperparameter* juga penting. *Hyperparameter* memungkinkan pengaturan dan penyesuaian yang diperlukan untuk mengoptimalkan kinerja dan hasil akhir dari model *Deep Learning*. *Hyperparameter* yang dipakai dalam penelitian ini adalah:

Tabel 2. Nilai *Hyperparameter* Model

<i>Hyperparameter</i>	Nilai
<i>Epoch</i>	150
<i>Optimizer</i>	Adam
<i>Batch size</i>	64
<i>Loss function</i>	<i>mean squared error</i>

Dalam konteks pelatihan model yang dilakukan, telah ditetapkan nilai untuk beberapa *hyperparameter*:

1. *Epoch*: Proses pelatihan akan melalui seluruh *dataset* sebanyak 150 kali.
2. *Optimizer*: Algoritma optimisasi yang digunakan adalah Adam yakni algoritma yang populer dan efektif dalam menyesuaikan *learning rate* secara adaptif selama proses pelatihan.
3. *Batch size*: Dalam setiap iterasi pelatihan, model akan menerima 64 sampel data sebelum pembaruan bobot dilakukan.
4. *Loss function*: Metrik yang digunakan untuk mengukur seberapa baik model memprediksi target adalah *mean squared error* (MSE), yang menghitung rata-rata dari kuadrat selisih antara prediksi model dan nilai sebenarnya. Tujuan pelatihan adalah untuk meminimalkan nilai MSE ini.

3.3. Hasil Prediksi

Setelah melatih model dengan *dataset* yang tersedia. Berikut adalah Tabel yang menunjukkan perbandingan jumlah kasus sebenarnya dengan prediksi dari model tersebut dengan menampilkan 5 tanggal terakhir:

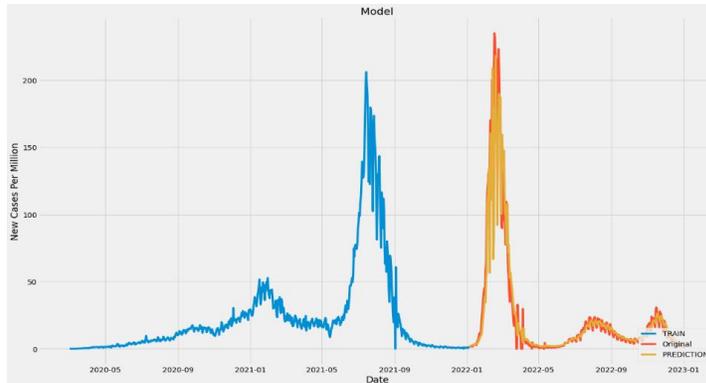
Tabel 3. Perbandingan Hasil Prediksi

<i>Epoch</i>	Tanggal	Jumlah Kasus	Prediksi
50	2022-12-30	2.004	1.661034
	2022-12-31	1.771	1.489319
	2023-01-01	1.328	1.277437
	2023-01-02	0.951	1.051421
	2023-01-03	2.367	0.797809
100	2022-12-30	2.004	2.305237
	2022-12-31	1.771	2.091476
	2023-01-01	1.328	1.877293
	2023-01-02	0.951	1.650859
	2023-01-03	2.367	1.405830
150	2022-12-30	2.004	1.937253
	2022-12-31	1.771	1.686934
	2023-01-01	1.328	1.469361
	2023-01-02	0.951	1.209324
	2023-01-03	2.367	0.936049
200	2022-12-30	2.004	3.171061
	2022-12-31	1.771	2.972338
	2023-01-01	1.328	2.758180
	2023-01-02	0.951	2.594739
	2023-01-03	2.367	2.460161
250	2022-12-30	2.004	1.829014
	2022-12-31	1.771	1.627345
	2023-01-01	1.328	1.394793
	2023-01-02	0.951	1.246774
	2023-01-03	2.367	1.148843

Pada Tabel hasil prediksi di atas menunjukkan perbandingan kasus asli dan prediksi menggunakan model dengan *epoch* 150 yang dimana paling sesuai dengan perbandingan 5

hari awal pada saat ingin melakukan prediksi jangka panjang kasus COVID-19 fase 3 di Indonesia.

Jumlah *epoch* yang digunakan ada 50 hingga 250 *epoch* yang berarti adalah jumlah iterasi (putaran) yang dilakukan pada seluruh *dataset* selama proses pelatihan model. Semakin besar jumlah *epoch*, semakin banyak model mempelajari pola dari data pelatihan. Dengan kata lain, semakin banyak *epoch*, semakin kompleks dan kuat modelnya. Hal ini terlihat dari kesamaan antara grafik biru (hasil pelatihan model *Deep Learning*) dan grafik merah (hasil prediksi model), yang menunjukkan bahwa prediksi model cocok dengan data sebenarnya secara akurat.



Gambar 9. Grafik Hasil Prediksi *Epoch* 150

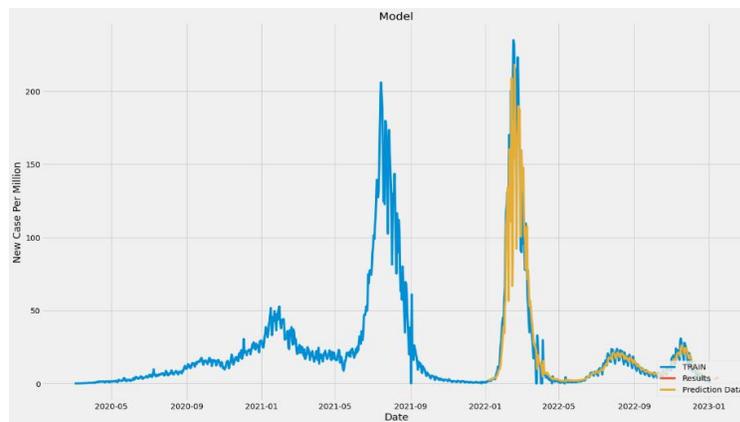
Pada Gambar 9 jumlah *epoch* yang digunakan adalah 150, yang mengindikasikan jumlah iterasi yang dilakukan pada seluruh *dataset* selama pelatihan model pada jumlah kasus covid-19 terhadap prediksi jumlah kasus COVID-19 dalam satu tahun kedepan. Setelah membandingkan hasil prediksi dengan kasus sesungguhnya model dijalankan untuk mendapatkan hasil prediksi 7 hari kedepan yang digambarkan pada Tabel dibawah ini.

Tabel 4. Hasil Prediksi 7 Hari kedepan

<i>Epoch</i>	Tanggal	Prediksi
50	2023-01-04	4.8196692
	2023-01-05	5.61532
	2023-01-06	6.5483546
	2023-01-07	7.4144044
	2023-01-08	8.226907
	2023-01-09	9.065586
	2023-01-10	9.971575
100	2023-01-04	0.9779622
	2023-01-05	0.73641217
	2023-01-06	0.4094314
	2023-01-07	0.11087617
	2023-01-08	-0.16625234
	2023-01-09	-0.41600728
	2023-01-10	-0.6453031
150	2023-01-04	1.3031656
	2023-01-05	0.9856681
	2023-01-06	0.80439574
	2023-01-07	0.5650169
	2023-01-08	0.36716947
	2023-01-09	0.17372753
	2023-01-10	0.00242624

Epoch	Tanggal	Prediksi
200	2023-01-04	1.6589165
	2023-01-05	1.6527767
	2023-01-06	1.5527745
	2023-01-07	1.4838618
	2023-01-08	1.435684
	2023-01-09	1.4152876
	2023-01-10	1.41972
250	2023-01-04	1.0026371
	2023-01-05	0.89502954
	2023-01-06	0.63515025
	2023-01-07	0.3864201
	2023-01-08	0.1359804
	2023-01-09	-0.07687452
	2023-01-10	-0.1762323

Pada Tabel 4 hasil model yang diprediksi kelima *epoch*, bahwa pada *epoch* 150 memberikan hasil terbaik dan sesuai. Hasil prediksi *epoch* 150 tersebut dapat dilihat pada Gambar grafik dibawah ini.



Gambar 10. Hasil Prediksi 7 hari kedepan *Epoch* 150

Berdasarkan model memprediksi tren kasus COVID-19 dengan data sebenarnya yang ada. Selain itu, akurasi prediksi model terhadap model yang telah dilatih sebelumnya dan hasil *value* pada Tabel 3 yang diwarnai hijau yang artinya prediksi model secara keseluruhan dekat dengan data asli. Sementara itu, nilai MAPE mengukur kesalahan relatif antara prediksi model dan nilai sebenarnya.

Visualisasi pada Gambar 10 menunjukkan bahwa model memprediksi tren kasus COVID-19 dengan baik berdasarkan data aktual yang tersedia. RMSE (*Root Mean Squared Error*) dan MAPE (*Mean Absolute Percentage Error*) memberikan informasi tentang akurasi prediksi model terhadap data yang telah dilatih sebelumnya. Dengan menggunakan 150 *epoch*, RMSE dapat mengukur dekatnya prediksi model dengan data sebenarnya. Semakin rendah nilai RMSE, semakin baik kualitas prediksi model. Selain itu, dalam Gambar ini, perbedaan antara prediksi model dan data yang telah dilatih sebelumnya hampir sama, khususnya pada tahun 2022 dan 2023. Dengan demikian, dapat diperkirakan jumlah kasus COVID-19 dalam 7 hari ke depan dengan menggunakan prediksi model yang telah teruji dan akurat.

4. Kesimpulan

Kesimpulan dalam penelitian ini adalah model dengan menggunakan nilai RMSE dan MAPE, dapat disimpulkan bahwa performa model dalam memprediksi kasus COVID-19 bergantung pada jumlah *epoch* yang digunakan. *Epoch* 150 menunjukkan hasil yang stabil dengan nilai RMSE yang rendah, menandakan prediksi yang baik terhadap data sebenarnya. Namun, pada *epoch* 200, RMSE meningkat, mengindikasikan prediksi yang kurang akurat. Hal ini juga diperkuat dengan nilai MAPE yang besar pada *epoch* tersebut, menunjukkan kesalahan relatif yang signifikan antara prediksi model dan data sebenarnya. Oleh karena itu, dapat disimpulkan bahwa model memiliki kinerja terbaik pada *epoch* 150 untuk memprediksi jumlah kasus COVID-19 dalam 7 hari ke depan.

Daftar Pustaka

- [1] Aria Hendrawan, Vensy Vydia, & Saifur Rohman Cholil, “Prediksi Pandemi Covid 19 Kota Semarang Menggunakan Pendekatan Neutral Network”, *Jurnal Riptek*, 15(1), 43–46, 2021.
- [2] Karno, A. S. B., Hastomo, W., & Wardhana, I. S. K, “Prediksi Jangka Panjang Covid-19 Indonesia Menggunakan Deep Learning”, 2020.
- [3] Aprian, B. A., Azhar, Y., & Nastiti, V. R. S, “Prediksi Pendapatan Kargo Menggunakan Arsitektur Long Short Term Memory”, *Jurnal Komputer Terapan*, 6(2), 148–157, 2020.
- [4] Cahyaningsih, A., “Model Prediksi Jumlah Kumulatif Kasus Covid-19 Di Indonesia Menggunakan Deep Learning”. *Journal Of Informatics Information System Software Engineering And Applications (Inista)*, 3(1), 76–83, 2020.
- [5] Hyndman, R. J., & Koehler, A. B. “Another Look At Measures Of Forecast Accuracy. *International Journal Of Forecasting*”, 22(4), 679-688. 2006.
- [6] H. Purnomo, H. Suyono And R. N. Hasanah, "Peramalan Beban Jangka Pendek Sistem Kelistrikan Kota Batu Menggunakan Deep Learning Long Short-Term Memory," *Transmisi : Jurnal Ilmiah Teknik Elektro*, 23, (3), Vol. 23, No. 3, Pp. 97-102, 2021.
- [6] Ferdiansyah, Othman, S. H., Radzi, R. Z. M., Stiawan, D., & Sutikno, T., “Hybrid Gated Recurrent Unit Bidirectional-Long Short-Term Memory Model To Improve Cryptocurrency Prediction Accuracy”. *Iaes International Journal Of Artificial Intelligence*, 12(1), 251–261, 2023.
- [7] Ferdiansyah, Othman, S. H., Zahilah Raja Md Radzi, R., Stiawan, D., Sazaki, Y., & Ependi, U., “A Lstm-Method For Bitcoin Price Prediction: A Case Study Yahoo Finance Stock Market”. *Icecos 2019 - 3rd International Conference On Electrical Engineering And Computer Science, Proceeding, June*, 206–210, 2019.
- [8] Raup, A., Ridwan, W., Khoeriyah, Y., Supiana, & Zaqiah, Q. Y. (2022). Deep Learning Dan Penerapannya Dalam Pembelajaran. *Jiip (Jurnal Ilmiah Ilmu Pendidikan)*, 5(9), 3258–3267, 2022.
- [9] Syafa’ah, L., & Lestandy, M., “Penerapan Deep Learning Untuk Prediksi Kasus Aktif Covid-19”. *J-Sakti (Jurnal Sains Komputer Dan Informatika)*, 5(1), 453–457, 2021.
- [10] Zhahrina, A., & Wibawa, S. W. (2020, January 31). “Who Umumkan Wabah Virus Corona Berstatus Darurat Global, Apa Artinya?”, Kompas., 2020.