

Analisis Performa Model BiLSTM dan CNN-LSTM Dalam Prediksi Sea Water Level Pada Pelabuhan Berdasarkan Data Historis

Andi Kristyanto, Chairani Chairani*, Sriyanto Sriyanto

Magister Teknik Informatika, Institut Informatika dan Bisnis Darmajaya, Bandar Lampung, Indonesia

Email: ¹kristyanto.2321210018p@mail.darmajaya.ac.id, ^{2,*}chairani@darmajaya.ac.id, ³sriyanto@darmajaya.ac.id

Email Penulis Korespondensi: kristyanto.2321210018p@mail.darmajaya.ac.id

Submitted: 16/05/2025; Accepted: 16/06/2025; Published: 17/06/2025

Abstrak—Indonesia merupakan negara dengan didominasi wilayah perairan sehingga data pencatatan kenaikan permukaan laut sebagai salah satu unsur cuaca maritim menjadi penting. Badan Meteorologi, Klimatologi, dan Geofisika melaksanakan salah satu tugasnya yaitu melakukan pengamatan di bidang meteorologi. Pelabuhan Merak-Bakauheni yang melayani jalur penyeberangan terpadat di Indonesia serta sebagai penyambung pulau Jawa dan Sumatera. Apabila terdapat gangguan yang dikarenakan faktor meteorologis, maka aktivitas pelayaran dan transportasi laut akan terhambat dan terganggu. Tujuan dari penelitian ini adalah membandingkan kinerja model BiLSTM dan CNN-LSTM dalam memperkirakan sea water level di pelabuhan Merak berlandaskan hasil analisa parameter yang digunakan. Susunan langkah dalam penelitian ini diawali mengumpulkan data, processing data, selanjutnya melatih model, dan terakhir analisa model. Data yang digunakan data harian sea water level dalam rentang waktu enam tahun dari 2019 sampai 2024. Evaluasi Nilai MSE, MAE dan RMSE digunakan untuk melihat kinerja kedua model. Dari penelitian ini, model BiLSTM menghasilkan nilai 0.0058 (MSE), 0.0299 (MAE), dan 0.0763 (RMSE), sedangkan model CNN-LSTM memperoleh nilai 0.0073 (MSE), 0.0362 (MAE), dan 0.0859 (RMSE), dapat dilihat bahwa metode BiLSTM lebih optimal kinerjanya dalam memprediksi sea water level pada perairan Pelabuhan Merak.

Kata Kunci: BiLSTM; CNN-LSTM; Sea Water Level; AWS; Pelabuhan

Abstract—Indonesia is a country dominated by waters, so data on sea level rise, one of maritime weather is important. The Meteorology, Climatology, and Geophysics Agency one of its duties, namely conducting observations in meteorology. The Merak-Bakauheni Port serves the busiest crossing route in Indonesia and connects the islands of Java and Sumatra. If there is a disruption due to meteorological factors, shipping and sea transportation activities will be hampered and disrupted. The purpose of this study is to compare the performance of the BiLSTM and CNN-LSTM models in estimating sea water levels at Merak Port based on the results of the parameter analysis used. The steps begin with collecting, processing data, training the model, and analyzing the model. The data used is daily sea water level data over a period of six years from 2019 to 2024. Evaluation of MSE, MAE and RMSE values is used to see the performance of the two models. From this study, the BiLSTM model produced values of 0.0026 (MSE), 0.0224 (MAE), and 0.0512 (RMSE), the CNN-LSTM model values of 0.0044 (MSE), 0.0319 (MAE), and 0.0664 (RMSE), it can be seen that BiLSTM method has more optimal in predicting sea water levels of Merak Port.

Keywords: BiLSTM; CNN-LSTM; Sea Water Level; AWS; Pelabuhan

1. PENDAHULUAN

Perubahan kenaikan permukaan laut telah menjadi salah satu perhatian dalam kajian perubahan iklim dan pengelolaan sumber daya pesisir. Fenomena ini memiliki dampak signifikan terhadap kehidupan manusia, termasuk ancaman terhadap wilayah pesisir, peningkatan risiko banjir, serta kerusakan infrastruktur. Area yang terkena imbas langsung oleh kenaikan permukaan laut merupakan area pelabuhan yang mengakibatkan terganggunya aktivitas transportasi laut [1]. Pelabuhan Merak-Bakauheni melayani salah satu jalur penyeberangan terpadat di Indonesia sebagai penyambung pulau Jawa dan Sumatera laut [2]. Apabila aktivitas penyeberangan terganggu dikarenakan faktor meteorologis, maka akan menyebabkan terhambatnya aktivitas pelayaran masyarakat, bongkar muat, serta kerugian finansial bagi ekspedisi pengiriman karena efisiensi waktu merupakan aspek yang sangat vital [3]. Oleh karena itu, prediksi *sea water level* menjadi langkah penting untuk mengantisipasi dampak kenaikan permukaan laut yang mungkin terjadi dan menyusun strategi adaptasi yang efektif.

Indonesia merupakan negara dengan didominasi wilayah perairan sehingga data pencatatan *sea water level* sebagai salah satu unsur cuaca maritim menjadi penting. Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) melaksanakan salah satu tugasnya yaitu pengamatan dibidang meteorologi [4], dengan memasang *Marine Automatic Weather System* (MAWS) di Pelabuhan Merak yang memiliki beberapa sensor, salah satunya adalah sensor ultrasonik, berfungsi untuk mencatat *sea water level* [5]. Pada penelitian ini akan menggunakan data tersebut sebagai data input pada metode prediksi yang akan diuji.

Dalam melihat permasalahan di atas, teknik informatika sebagai salah satu cabang dari ilmu komputer, yang secara lebih luas berkaitan erat dengan kecerdasan buatan dan *machine learning*, merasa tergerak untuk membantu menangani masalah tersebut dengan memproses dan mengolah data yang hasilnya nanti bisa digunakan untuk membantu dalam pengambilan keputusan untuk mengurangi dampak bencana akibat pencatatan kenaikan permukaan laut tersebut.

Machine Learning (ML) merupakan bidang studi yang memungkinkan komputer untuk dapat belajar dari data sehingga fokus kepada pembuatan desain dan analisa metode. Program ML dapat mengambil keputusan berdasarkan data yang dipilih dan membantu dalam membangun model [6]. ML memiliki beraneka ragam metode yang bisa digunakan untuk prediksi, termasuk (*Bidirectional Long Short-Term Memory*) BiLSTM dan (*Convolutional Neural*

Network – Long Short-Term Memory) CNN-LSTM. CNN merupakan model yang unggul di bidang *deep learning* karena memiliki kemampuan ekstraksi yang kuat tetapi lemah untuk jangka waktu panjang. Namun [7] telah meneliti bahwa gabungan kombinasi CNN dengan LSTM mempunyai model lebih baik dalam prakiraan deret waktu yang panjang, dengan menghasilkan bentuk yang hampir sama dengan nilai observasi dan tingkat kesalahan yang lebih rendah untuk jangka waktu panjang. Pada bagian lainnya, kemampuannya untuk mengolah data *time series*, dengan menangkap pola temporal yang lebih kompleks dengan memproses data secara simultan [8]. BiLSTM sangat efektif dalam analisis deret waktu karena kemampuannya untuk menggambar pola temporal dari masa lalu.

Beberapa model dalam ML yang telah digunakan dalam Penelitian terdahulu untuk prediksi kenaikan permukaan laut. [9] memperlihatkan bahwa akurasi dan keefektifan Gated Recurrent Unit (GRU) lebih rendah dibandingkan BiLSTM, dengan nilai MAE 0.0102 dan RMSE 0.0218 untuk BiLSTM, sementara nilai MAE 0.0164 dan RMSE 0.0277 untuk GRU. Model ML juga digunakan dalam prediksi untuk hal yang lain, seperti penelitian oleh [10] menempatkan bahwa LSTM menghasilkan RMSE 16.81, MSE 282.55 dan MAD 10.43 sehingga lebih baik dari CNN dalam prediksi curah hujan. Dalam penelitian yang lain, BiLSTM digunakan untuk mengoptimalkan jadwal tanam padi memberikan nilai MAE dan RMSE yang rendah untuk suhu sebesar 0,73767 dan 0,94146, sementara untuk kelembaban sebesar 5,32157 dan 6,57378 [8].

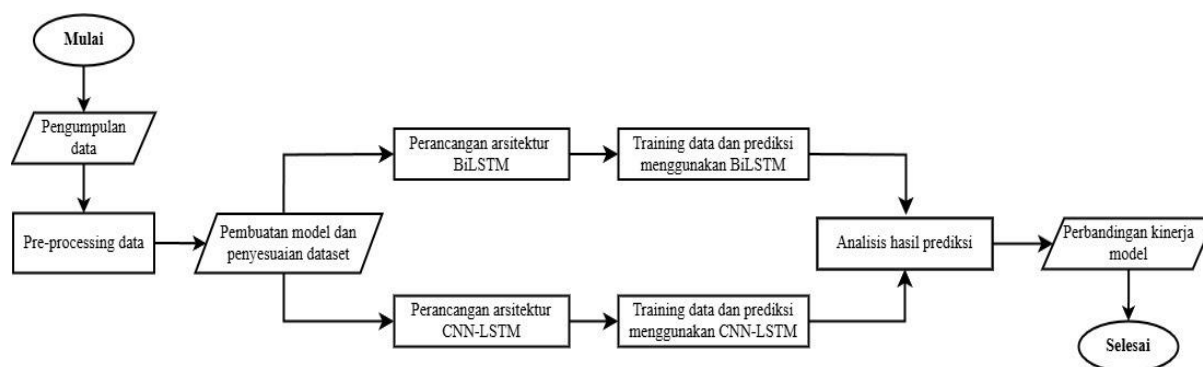
Meskipun berbagai studi sebelumnya telah menerapkan model machine learning untuk memprediksi kenaikan permukaan laut, penelitian yang secara spesifik membandingkan kinerja model BiLSTM dan CNN-LSTM dengan menggunakan data observasi langsung dari sensor MAWS di Pelabuhan Merak masih sangat terbatas. Hal ini disayangkan mengingat karakteristik oseanografis dan kondisi lokal pelabuhan tersebut memiliki peranan penting dalam memengaruhi dinamika permukaan laut, sehingga diperlukan pendekatan yang disesuaikan dengan konteks lokal guna memperoleh hasil prediksi yang lebih akurat dan aplikatif.

Tujuan dari penelitian ini adalah membuat perbandingan dan menguji efektivitas kedua model tersebut membuat prediksi *sea water level* di pelabuhan Merak. Harapannya, setelah mendapatkan model yang terbaik, kemudian dapat ditingkatkan untuk prediksi pasang surut dan tinggi gelombang sehingga mitigasi bencana lebih cepat dan tepat dilakukan agar aktivitas pelayaran tidak terhambat dan mengurangi kerusakan infrastruktur sekitar Pelabuhan Merak.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Beberapa tahapan pada penelitian ini yaitu, collecting data, preprocessing data, implementasi metode BiLSTM dan CNN-LSTM dan evaluasi model dengan MSE, MAE dan RMSE, serta melakukan analisis hasil. Berikut tahapan tersebut terlihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

2.2 Pengumpulan Data

Teknik pengumpulan data yang dilakukan dengan mengunduh dari alamat web AWS Rekayasa : BMKG. Jenis data yang tersedia seperti *time*, *Temp*, *Rh*, *Pressure*, *Rain*, *Wind Speed*, *Wind Direction*, *Solar Radiation*, *Water Temp* dan *Sea Water Level*. Tinggi rendahnya permukaan air laut diwakili data *sea water level* (m) yang digunakan untuk penelitian ini. Data ini digunakan melatih dan menguji model sehingga diharapkan memberikan prediksi yang representatif

2.3 Pre-Processing Data

Salah satu bagian dari *preparation* data adalah *preprocessing*, dan langkah ini harus dilakukan guna memperbaiki data. *Preprocessing* data pada *dataset* untuk menghilangkan *noise*, *missing/value* dan *error* data serta data yang tidak berhubungan[11]. Mengubah data mentah hingga kualitas data yang akan di analisis meningkat [12].

a. Data *cleaning*: memilah dan membuang data yang rusak atau data yang salah dan detail data yang tidak digunakan dari dataset merupakan kegiatan data *cleaning* atau data *cleansing* [13].

- b. *Data Transformation*: merubah dan menyamakan format data sehingga data berubah sesuai dengan model yang akan digunakan serta data menjadi efisien dan mudah dipahami [14].

Terjaganya data yang bersih dan berkualitas baik sebelum digunakan secara maksimal dalam analisis dan pemodelan adalah fungsi dari *pre-precossing* data.

2.4 Membangun model BiLSTM dan CNN-LSTM dan penyesuaian dataset

Pelatihan dan pengujian model BiLSTM dan CNN-LSTM agar untuk memperoleh hasil prediksi yang optimal, membutuhkan pengaturan parameter (parameter *tuning*). Guna mendapatkan hasil output yang diinginkan serta meningkatkan nilai akurasi dari sebuah model, maka digunakan teknik yang disebut hyperparameter *tuning* [13]. diantaranya digunakan dalam penelitian ini terlihat pada Tabel 1 berikut.

Tabel 1. Parameter model

Parameter	Value
Jumlah unit	50; 100
Optimizer	Adam; sgd
Batch Size	32; 64
Epoch	50; 100; 150; 200

Parameter dalam ML yang mengatur data historis sebagai input dalam membuat prediksi nilai masa depan adalah *Lookback* [14]. Pada *dataset* besar, parameter ini mempengaruhi efisiensi dan kecepatan pelatihan, oleh karena itu disebut hyperparameter krusial. Karakteristik data dan kemampuan komputasi yang menentukan ukuran *Batch size* yang digunakan [15]. Jumlah pengulangan siklus pelatihan penuh terhadap seluruh dataset adalah *epoch*, untuk mencapai konvergensi bobot serta nilai optimalnya [16].

Dataset diambil sebagai *training data* sebesar 80% bagian dan sebagai *test data* sebesar 20% bagian. *Training data* akan dipergunakan guna melatih model, sedangkan untuk menguji kinerja model digunakan *test data*. Pada pembelajaran sebuah ML sangat dipengaruhi oleh besarnya data *training* karena menghasilkan prediksi yang semakin baik. Pembagian *dataset* ini didasarkan dari urutan waktunya, pada periode awal data untuk pelatihan, data yang setelahnya diambil untuk pengujian

2.5 BiLSTM

Long-short term memory (LSTM) berkembang dengan banyak turunannya, salah satunya bernama *Bidirectional Long-Short Term Memory* (BiLSTM). BiLSTM memiliki dua lapisan jaringan LSTM berlawanan yang dinamai LSTM *forward* dan *backward*. Gabungan ini membuat kemampuan model untuk mempelajari pola data serta akurasi prediksi meningkat [17].

2.6 CNN-LSTM

Convolutional Neural Network (CNN) merupakan jaringan saraf tiruan yang memiliki kemampuan ekstraksi data atau informasi yang kuat. Akan tetapi, dalam proses ekstraksinya CNN memiliki sedikit kelemahan yaitu ketika mengolah data berurutan jangka waktu yang panjang. Untuk mengisi kelemahannya dikombinasikan dengan LSTM agar dapat membuat perkiraan informasi atau data dalam deret waktu yang memiliki perubahan berkala. Selain itu, prediksi *sea water level* juga membutuhkan sampel data dalam skala besar agar dapat membuat simulasi perubahan dinamis parameter tersebut dalam jangka waktu panjang [18].

2.7 Evaluasi Model

Evaluasi model berperan sangat penting dalam melihat kinerja sebuah model dalam memprediksi data [19]. Dengan menggunakan metrik MSE, MAE, dan RMSE evaluasi yang dilakukan dalam penelitian ini. Berikut penjelasannya :

- a. MSE (*Mean Square Error*): menghitung selisih antara nilai aktual dan prediksi, kemudian dikuadratkan, ini dilakukan untuk melihat nilai *error* dari suatu prediksi. Hasil nilai MSE yang kecil atau semakin mendekati nol artinya hasil prediksi mendekati nilai aktualnya. Persamaan berikut [20] :

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (1)$$

Dengan n = jumlah data total, (y_i) = menyatakan nilai aktual dari data ke i , (\hat{y}_i) = adalah nilai prediksi dari data ke i . Tanda \sum (sigma) sigma menyatakan penjumlahan dari $i=1$ sampai $i=n$, hasil dari penjumlahan dibagi n untuk memperoleh nilai rata-ratanya.

- b. MAE (*Mean Absolute Error*): digunakan untuk mengukur akurasi dalam model. Nilai rata-rata *error* antara aktual dengan prediksi, di dalam tanda mutlak yang artinya nilai selalu positif. Model dinilai baik, apabila menghasilkan nilai MAE semakin kecil. Dengan persamaan berikut [21] :

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2)$$

Dalam rumus MAE selisih nilai aktual (y_i) dan nilai prediksi (\hat{y}_i) dalam nilai absolut, seluruh hasilnya kemudian dibagi dengan jumlah total jumlah data (n). Nilai MAE menggambarkan besar kesalahan rata-rata model dengan data dalam satuan yang sama.

- c. RMSE (*Root Mean Square Error*): Akar dari perhitungan kuadrat rata-rata *error* antara nilai aktual dan prediksi. Semakin baik hasil prediksinya jika nilai hasil RMSE semakin rendah [22]. RMSE dapat dihitung menggunakan persamaan berikut:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \tag{3}$$

Rumus RMSE menghitung jumlah kuadrat selisih antara nilai aktual (y_i) dan nilai prediksi (\hat{y}_i) dan dibagi dengan jumlah data (n) kemudian diambil akarnya dari nilai rata-rata tersebut. Hal ini membuat RMSE sangat sensitif terhadap nilai *error* yang besar, sehingga apabila nilai prediksinya terlalu jauh akan sangat terlihat.

Pengujian dilakukan dengan nilai MSE, MAE dan RMSE terkecil dari kedua metode BiLSTM dan CNN-LSTM, selanjutnya dilakukan analisisnya.

3. HASIL DAN PEMBAHASAN

Bagian ini akan membandingkan kinerja model BiLSTM dan CNN-LSTM dalam analisis data *sea water level* telah dilakukan. Proses ini mencakup *impor library* dan *load dataset*, *preprocessing* dan *splitting* data, pelatihan dan komparasi model, serta visualisasi hasil. Setiap langkah dalam proses ini akan dijelaskan secara mendetail beserta hasil yang diperoleh dari masing-masing model.

3.1 Import Dataset

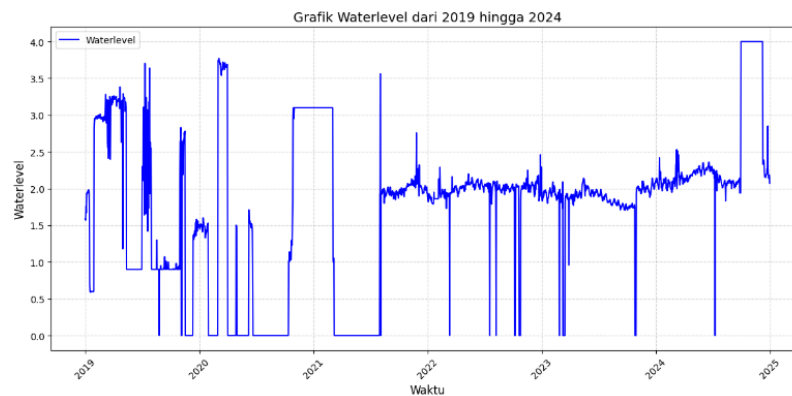
Langkah pertama dalam proses ini adalah mengimpor *library* yang diperlukan dan memuat *dataset*. *Dataset* yang digunakan berisi informasi tentang *Date* dan *sea water level* (m). Data rata-rata harian dalam rentang waktu 6 tahun yaitu 2019 – 2024 dengan total jumlah data sebanyak 2.192 *entri*. Seperti pada Gambar 2 berikut:

	Date	Waterlevel
0	01/01/2019	1,59
1	02/01/2019	1,57
2	03/01/2019	1,76
3	04/01/2019	1,67
4	05/01/2019	1,93
...
2187	27/12/2024	2,15
2188	28/12/2024	2,14
2189	29/12/2024	2,18
2190	30/12/2024	2,18
2191	31/12/2024	2,07

[2192 rows x 2 columns]

Gambar 2. Dataset Sea Water Level

Gambar 3 berikut merupakan visualisasi dari *dataset sea water level*



Gambar 3. Visualisasi dataset sea watel level

Sumbu X (horisontal) menunjukkan rentang waktu dari awal tahun 2019 sampai 2024, sumbu Y (vertikal) menunjukkan nilai ketinggian air dalam satuan meter, sedangkan garis biru adalah nilai sea water level terhadap waktu. Pada periode 2019-2022, fluktuasi tajam dan beberapa segmen atau periode yang panjang terlihat memiliki nilai nol yang kemungkinan disebabkan adanya kehilangan data atau gangguan alat sensor, kemudian awal 2022 sampai pertengahan 2024 data lebih stabil antara 1,8 -2,2 m namun dari pertengahan 2024 sampai akhir tahun terdapat lonjakan tajam dengan mendekati 4 m.

3.2 Data Preprocessing

Pada tahap ini, data akan dibersihkan dan dipersiapkan untuk analisis lanjutan. Langkah-langkah yang dilakukan termasuk pemeriksaan statistik deskriptif, nilai yang hilang, dan pemilahan variabel.

- a. Analisis Data Hilang: Langkah pertama dilakukan untuk menghitung jumlah nilai yang hilang (*missing values*) pada setiap kolom dalam *dataset*.

```
Jumlah Missing Values per Kolom:
Date          0
Waterlevel    0
dtype: int64
```

Gambar 4. Analisis data *sea water level*

Gambar 4 merupakan hasil dari analisis data hilang yang memperlihatkan nilai 0 pada kedua kolom, ini merupakan indikasi bahwa didalam dataset tidak terdapat data yang kosong, sehingga proses berikutnya bisa dilakukan tanpa perlu melakukan imputasi atau penghapusan

- b. Normalisasi Data Numerik: dilakukan normalisasi terhadap kolom numerik tersebut menggunakan metode *Min-Max Scaler* agar nilainya berada dalam rentang 0 hingga 1. Setelah proses normalisasi selesai, nilai-nilai yang telah diskalakan tersebut dikembalikan ke dalam *data frame* awal, menggantikan kolom numerik yang asli tanpa mengubah kolom non-numerik seperti tanggal.

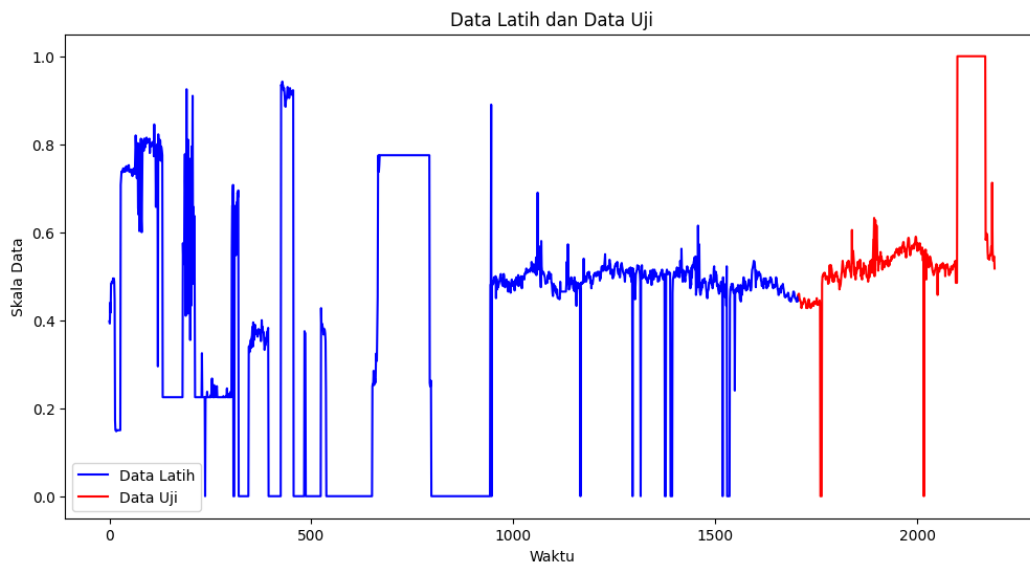
	Date	Waterlevel
0	2019-01-01	0.3975
1	2019-01-02	0.3925
2	2019-01-03	0.4400
3	2019-01-04	0.4175
4	2019-01-05	0.4825

Gambar 5. Normalisasi data

Gambar 5 memperlihatkan hasil dari normalisasi data, seperti terlihat pada lima baris pertama, data yang sebelumnya menggunakan koma ataupun nilainya terlalu besar, berubah menjadi nilai dalam rentang normalisasi tanpa mengubah struktur data aslinya. Hal ini dilakukan agar variabel numerik memiliki skala yang setara pada pemodelan yang akan dilakukan nantinya.

3.3 Splitting Data

Dataset dipisah dua bagian yaitu *training data* dengan persentase 80% dan *test data* dengan persentase 20%. Jumlah *Training data* sebanyak 1705 (80%) dan untuk *test data* sebanyak 427 (20%). Gambar 6 merupakan visualisasi dari *splitting data*.



Gambar 6. Visualisaasi pembagian *training data* dan *test data*

Grafik diatas memperlihatkan proses pembagian berdasarkan urutan waktunya, sehingga pola historisnya masih seperti semula. Data ini telah berada dalam skala 0 hingga 1, membuat perbandingan kedua bagian menjadi konsisten, yang ditandai dengan garis batas antara data latih dan data uji yang berupa warna biru dan merah



3.4 Pelatihan Model BiLSTM dan CNN-LSTM

Setelah proses kompilasi model dilakukan dengan menetapkan fungsi *loss*, *optimizer*, dan metrik evaluasi, langkah selanjutnya adalah melatih model menggunakan data *training*. Parameter pelatihan seperti jumlah *epoch*, *batch size*, dan jumlah unit *neuron* pada *hidden layer* diatur sesuai variasi yang dibuat. Dalam penelitian ini, dua jenis model yaitu BiLSTM dan CNN-LSTM, dilatih dengan kombinasi berbagai parameter. Jumlah unit *neuron* yang digunakan adalah 50 dan 100, dengan *optimizer* Adam dan SGD, *batch size* 32 dan 64, serta variasi *epoch* sebanyak 50, 100, 150, dan 200.

Tabel 2. Hasil Pengujian MSE, RMSE dan MAE

Jumlah Unit	Optimizer	Batch Size	Epoch	BiLSTM			CNN-LSTM		
				MSE	RMSE	MAE	MSE	RMSE	MAE
50	Adam	32	50	0.0059	0.0288	0.0766	0.0102	0.0502	0.1012
			100	0.0061	0.0351	0.0781	0.0096	0.0504	0.0982
			150	0.0078	0.0295	0.0885	0.0088	0.0406	0.0938
			200	0.0071	0.0312	0.0845	0.0084	0.0411	0.0917
		64	50	0.0062	0.0296	0.0790	0.0101	0.0486	0.1009
			100	0.0276	0.0276	0.0759	0.0100	0.0516	0.1003
			150	0.0070	0.0343	0.0836	0.0099	0.0423	0.0997
			200	0.0074	0.0309	0.0864	0.0097	0.0394	0.0988
	sgd	32	50	0.0118	0.0524	0.1086	0.0139	0.0558	0.1180
			100	0.0102	0.0465	0.1012	0.0127	0.0541	0.1127
			150	0.0094	0.0422	0.0971	0.0120	0.0500	0.1096
			200	0.0086	0.0403	0.0930	0.0117	0.0482	0.1083
		64	50	0.0142	0.0585	0.1193	0.0155	0.0604	0.1248
			100	0.0122	0.0514	0.1107	0.0138	0.0566	0.1177
			150	0.0102	0.0456	0.1014	0.0124	0.0514	0.1115
			200	0.0099	0.0469	0.0999	0.0126	0.0517	0.1126
Adam	32	50	0.0059	0.0327	0.0769	0.0095	0.0384	0.0975	
		100	0.0058	0.0299	0.0763	0.0091	0.0411	0.0958	
		150	0.0076	0.0321	0.0875	0.0074	0.0441	0.0860	
		200	0.0071	0.0348	0.0846	0.0073	0.0362	0.0859	
	64	50	0.0065	0.0366	0.0809	0.0101	0.0494	0.1007	
		100	0.0061	0.0392	0.0785	0.0095	0.0405	0.0976	
		150	0.0059	0.0313	0.0774	0.0095	0.0444	0.0975	
		200	0.0082	0.0346	0.0906	0.0084	0.0398	0.0920	
sgd	32	50	0.0121	0.0516	0.1102	0.0124	0.0501	0.1116	
		100	0.0099	0.0472	0.0995	0.0124	0.0502	0.1116	
		150	0.0090	0.0422	0.0951	0.0120	0.0495	0.1096	
		200	0.0091	0.0457	0.0957	0.0119	0.0512	0.1095	
	64	50	0.0134	0.0554	0.1158	0.0160	0.0661	0.1267	
		100	0.0114	0.0495	0.1071	0.0132	0.0537	0.1150	
		150	0.0103	0.0464	0.1016	0.0130	0.0552	0.1144	
		200	0.0096	0.0459	0.0981	0.0126	0.0518	0.1123	

Berdasarkan hasil pengujian yang terlihat pada Tabel 2, metode BiLSTM menunjukkan kecenderungan menghasilkan nilai lebih rendah bila dibandingkan dengan metode CNN-LSTM pada kombinasi parameter yang berbeda. Nilai terendah yang dihasilkan yang diperoleh BiLSTM yaitu MSE 0.0058, MAE 0.0299 dan RMSE 0.0763 dan CNN-LSTM memperoleh nilai MSE terkecil 0.0073, MAE 0.0362 dan RMSE 0.0859.

Dengan hasil ini didapatkan bila BiLSTM adalah lebih baik dibandingkan CNN-LSTM. Hal ini dikarenakan oleh struktur BiLSTM yang lebih sederhana, hal tersebut membuat model bisa melihat pola yang lebih cepat selama proses pelatihan. Sedangkan hasil dari pengujian dengan metode CNN-LSTM menunjukkan bahwa nilai hasil evaluasi

yang lebih fluktuatif. Hal ini sejalan dengan penelitian [22], nilai *error* bisa menjadi sangat rendah maupun tinggi dengan *range* yang lebar, dihasilkan oleh metode CNN-LSTM, sedangkan metode BiLSTM cenderung lebih stabil.

3.5 Evaluasi Kinerja Model

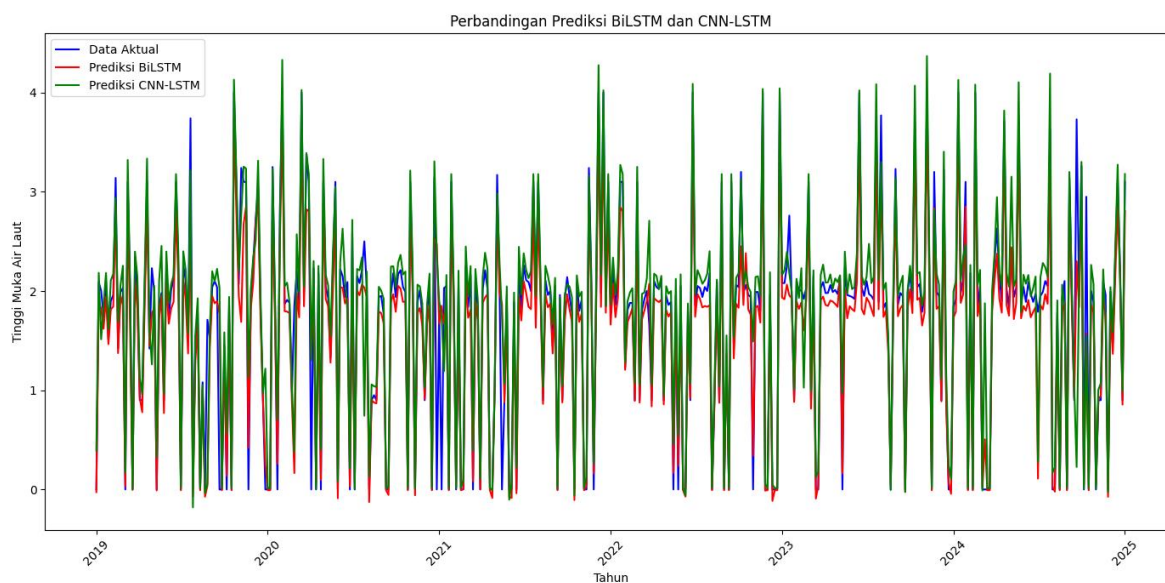
Evaluasi dari hasil nilai MSE, MAE dan RMSE yang digabungkan dalam berbagai parameter menghasilkan variasi nilai yang penting sesuai kinerja masing-masing model yang digunakan dalam prediksi ketinggian permukaan air laut. Berdasarkan hasil evaluasi tersebut, parameter yang menghasilkan nilai paling baik pada model BiLSTM yaitu menggunakan jumlah unit 100, *optimizer adam*, *batch size* 32 dan *epoch* 100. Berbeda dengan metode CNN-LSTM yang menunjukkan hasil terbaiknya pada jumlah unit 100, *optimizer adam* pada *batch size* 32 dan *epoch* 200. Dari evaluasi terlihat bahwa dalam penggunaannya, jumlah unit 100 memberikan hasil lebih kecil MSE, MAE dan RMSE bila dibandingkan jumlah unit 50. Meningkatnya kapasitas representasi model karena jumlah unit yang digunakan lebih banyak sehingga dapat menangkap pola dan hubungan dalam data secara lebih kompleks. Seperti dalam penelitian [23] yang menunjukkan bahwa pemilihan jumlah unit merupakan proses uji coba yang berbeda untuk setiap kasus. Penambahan jumlah unit dapat menambah kemampuan model dalam mengolah pola data yang kompleks.

Optimizer adam dan *optimizer sgd* yang digunakan pada kedua metode BiLSTM dan CNN-LSTM menampilkan hasil evaluasi yang berbeda. Nilai MSE, MAE dan RMSE lebih rendah muncul pada *optimizer adam*. Ini disebabkan adaptif *learning rate* digunakan oleh algoritma adam, yaitu yang dapat menyesuaikan diri sewaktu pelatihan sehingga performa model menjadi lebih optimal. Berbeda halnya dengan *optimizer sgd* yang bisa menjadi lebih lambat dan rentan terhadap konvergensi juga terhadap lokal minimum karena hanya menggunakan satu *learning rate* tetap. Ini juga sesuai penelitian [24] model dengan nilai akurasi paling tinggi diperoleh model *optimizer adam* dengan nilai yaitu 98,45%. Penelitian lainnya [25] juga menunjukkan bahwa Adam, dengan penyesuaian *learning rate* yang adaptif, sering kali mengungguli SGD dalam tahap awal pelatihan karena konvergensi yang lebih cepat

Nilai hasil evaluasi MSE, MAE dan RMSE dipengaruhi oleh penggunaan *batch size* 32 dan 64. Diantara keduanya, *batch size* 32 memberi hasil lebih rendah, sehingga apabila memori terbatas dapat mempengaruhi nilai evaluasi menjadi lebih tinggi. Dapat disimpulkan bahwa hasil evaluasi nilai *error* lebih baik adalah dengan menggunakan *batch size* ukuran kecil. Hal ini selaras dengan penelitian [26].

Perbedaan kinerja terlihat antara BiLSTM dan CNN-LSTM bila menggunakan jumlah *epoch* yang digunakan berbeda. Performa metodenya bisa terpengaruhi dari peningkatan jumlah *epoch*, seperti dari 50, 100, dan 200 memberikan nilai MSE, MAE dan RMSE yang berbeda. Dari sini terlihat model mendapatkan manfaat bila proses pelatihan dilakukan lebih lama. Pada *epoch* 100 menghasilkan nilai MSE, MAE dan RMSE lebih rendah pada model BiLSTM sedangkan pada model CNN-LSTM dengan *epoch* 200. Hal ini dikarenakan dalam menangkap pola sekuensial lebih efektif dilakukan model BiLSTM dibandingkan CNN-LSTM, seperti ditunjukkan penelitian [27].

Dilihat dari Tabel 2, pengujian metode BiLSTM terbaik terjadi bila menggunakan jumlah unit 100, *optimizer adam*, *batch size* 32 dan *epoch* 100 dengan menghasilkan nilai evaluasi MSE 0.0058, MAE 0.0299 dan RMSE 0.0763. Kombinasi parameter yang menghasilkan nilai terendah untuk metode CNN-LSTM menggunakan jumlah unit 100, *optimizer adam*, *batch size* 32 dan *epoch* 200 dengan sebesar MSE 0.0073, MAE 0.0362 dan RMSE 0.0859. Gambar 7 berikut adalah perbandingan menggunakan metode BiLSTM dan CNN-LSTM dengan parameter tersebut untuk *sea water level* aktual dan hasil prediksi.



Gambar 7. Komparasi prediksi BiLSTM dan CNN-LSTM

Gambar 7, warna garis merah menunjukkan prediksi BiLSTM dan warna garis hijau menunjukkan prediksi CNN-LSTM, sedangkan warna garis biru adalah data *sea water level* aktual. Secara umum, kedua model berhasil

mengikuti pola data aktual, namun BiLSTM terlihat lebih akurat dan stabil, dengan prediksi yang lebih dekat ke data sebenarnya. CNN-LSTM pada beberapa titik ekstrem menunjukkan penyimpangan lebih besar dan cenderung lebih fluktuatif, yang mengindikasikan bahwa terhadap variasi data model ini lebih sensitif. BiLSTM tetap mempertahankan performa yang lebih konsisten seiring bertambahnya waktu, mendukung hasil evaluasi sebelumnya yang menunjukkan bahwa model ini memiliki MSE, MAE, dan RMSE lebih rendah. Dengan demikian, dalam memprediksi *sea water level* di Perairan Pelabuhan Merak, BiLSTM lebih unggul dalam menangkap pola temporal jangka panjang.

4. KESIMPULAN

Dari penelitian memperlihatkan bahwa model *Bidirectional Long Short-Term Memory* (BiLSTM) memiliki kemampuan lebih baik dibandingkan model *Convolutional Neural Network - Long Short-Term Memory* (CNN-LSTM) dalam membuat prakiraan *sea water level*. BiLSTM mampu menghasilkan prediksi yang lebih stabil serta nilai MSE, MAE, dan RMSE yang lebih rendah. Model BiLSTM mampu menghasilkan nilai 0.0058 (MSE), 0.0299 (MAE), dan 0.0763 (RMSE), jika menggunakan konfigurasi terbaiknya yaitu dengan jumlah unit 100, *optimizer* Adam, *batch size* 32, dan *epoch* 10. Sedangkan, Model CNN-LSTM hanya mampu menghasilkan nilai 0.0073 (MSE), 0.0362 (MAE), dan 0.0859 (RMSE), jika menggunakan konfigurasi terbaiknya, yaitu dengan jumlah unit 100, *batch size* 32, dan *epoch* 200. Sementara itu, *optimizer* Adam tampak lebih efektif daripada SGD dan ukuran *batch* yang lebih kecil dapat meningkatkan hasil evaluasi. Dengan demikian, BiLSTM lebih unggul untuk menangkap pola sekuensial dan menjadi pilihan yang lebih akurat dan konsisten dibandingkan CNN-LSTM. Untuk penelitian lanjutan, disarankan agar menggunakan data dengan resolusi temporal yang lebih rapat agar model dapat menangkap fluktuasi jangka pendek dengan lebih baik. Selain itu, disarankan untuk menambahkan variabel eksternal seperti data curah hujan, kecepatan angin, dan tekanan atmosfer, yang berpotensi memengaruhi tinggi muka air laut. Penelitian juga dapat diperluas dengan melakukan pengujian model pada lokasi geografis yang berbeda guna menguji kemampuan generalisasi dan adaptabilitas model.

REFERENCES

- [1] A. Salim, "Dampak Perubahan Iklim Terhadap Transportasi Laut," *Ris. Sains dan Teknol. Kelaut.*, vol. 6, no. 2, pp. 170–173, 2023, doi: 10.62012/sensistek.v6i2.31711.
- [2] T. K. Utami, "Kajian Evaluasi Lintas Penyeberangan Merak–Bakauheni," *War. Penelit. Perhub.*, vol. 32, no. 1, pp. 43–52, 2020, doi: 10.25104/warlit.v32i1.1543.
- [3] F. Widianti and A. R. Pahlevi, "Analisis Klimatologi Arus Laut Selat Sunda Terhadap Situasi Penyeberangan Merak–Bakauheni," *Bul. Meteorol. Klimatologi, Dan Geofis.*, vol. 4, no. 2, pp. 21–27, 2023, doi: 10.3451/buletinmkg.v3i2.
- [4] B. Hartanto, N. Astriawati, S. Supartini, and D. K. Yekti, "Pencarian dan Pemanfaatan Informasi Data Badan Meteorologi, Klimatologi, dan Geofisika (BMKG)," *INSOLOGI J. Sains dan Teknol.*, vol. 1, no. 5, pp. 553–564, 2022, doi: 10.55123/insologi.v1i5.906.
- [5] T. Sandro, H. Hairatunnisa, and M. Putra, "Analisis Kinerja Sensor Water Level - Pressure Transducer (Studi Kasus Automatic Weather System Di Pelabuhan Merak)," *Electr. J. Otomasi Kelistrikan dan Energi Terbarukan*, vol. 2, no. 2, pp. 37–42, 2020, doi: 10.32722/ees.v2i2.3588.
- [6] A. Roihan, P. A. Sunarya, and A. S. Rafika, "Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper," *IJCIT (Indonesian J. Comput. Inf. Technol.)*, vol. 5, no. 1, pp. 75–82, 2020, doi: 10.31294/ijcit.v5i1.7951.
- [7] X. Yang and Z. Zhang, "A CNN-LSTM Model Based on a Meta-Learning Algorithm to Predict Groundwater Level in the Middle and Lower Reaches of the Heihe River, China," *Water (Switzerland)*, vol. 14, no. 15, 2022, doi: 10.3390/w14152377.
- [8] H. Awarulloh, D. F. Shiddieq, and D. Nurhayati, "Penggunaan Multivariat Model Bidirectional LSTM untuk Prediksi Cuaca : Optimalisasi Waktu Tanam Padi Petani Kabupaten Garut," *J. Ilm. Sinus*, vol. 23, no. 1, pp. 127–138, 2025, doi: 10.30646/sinus.v23i1.891.
- [9] A. B. N. Sinurat, W. A. Arifin, and W. A. Larasati, "Sea Level Prediction Using Gated Recurrent Unit And Bidirectional Long Short-Term Memory Methods," *J. INOVTEK POLBENG - SERI Inform.*, vol. 9, no. 2, pp. 753–764, 2024, doi: 10.35314/r9bk6j70.
- [10] M. D. A. Carnegie and C. Chairani, "Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Memprediksi Curah Hujan," *J. Media Inform. Budidarma*, vol. 7, no. 3, p. 1022, 2023, doi: 10.30865/mib.v7i3.6213.
- [11] A. A. A. Daniswara and I. K. D. Nuryana, "Data Preprocessing Pola Pada Penilaian Mahasiswa Program Profesi Guru," *JINACS (Journal Informatics Comput. Sci.)*, vol. 5, no. 01, pp. 97–100, 2023, doi: 10.26740/jinacs.v5n01.p97-100.
- [12] F. Alghifari and D. Juardi, "Penerapan Data Mining Pada Penjualan Makanan Dan Minuman Menggunakan Metode Algoritma Naïve Bayes," *J. Ilm. Inform.*, vol. 9, no. 02, pp. 75–81, 2021, doi: 10.33884/jif.v9i02.3755.
- [13] I. G. T. Isa and B. Junedi, "Hyperparameter Tuning Epoch dalam Meningkatkan Akurasi Data Latih dan Data Validasi pada Citra Pengendara," *Pros. Sains Nas. dan Teknol.*, vol. 12, no. 1, p. 231, 2022, doi: 10.36499/psnst.v12i1.6697.
- [14] A. Wijayanto, A. Sugiharto, and R. Santoso, "Identifikasi Dini Curah Hujan Berpotensi Banjir Menggunakan Algoritma Long Short-Term Memory (Lstm) Dan Isolation Forest," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 3, pp. 637–646, 2024, doi: 10.25126/jtiik.938718.
- [15] S. A. Maulana, S. H. Batubara, T. A. Amelia, and Y. P. P. Pasaribu, "Penerapan Metode CNN (Convolutional Neural Network) Dalam Mengklasifikasi Jenis Ubur-Ubur," *J. Penelit. Rumpun Ilmu Tek.*, vol. 2, no. 4, pp. 122–130, 2023, doi: 10.55606/juprit.v2i4.3084.
- [16] M. Wasil, H. Harianto, and F. Fathurrahman, "Pengaruh Epoch pada Akurasi menggunakan Convolutional Neural Network untuk Klasifikasi fashion dan Furniture," *Infotek J. Inform. dan Teknol.*, vol. 5, no. 1, pp. 53–61, 2022, doi: 10.29408/jit.v5i1.4393.



- [17] R. Siringoringo, J. Jamaluddin, R. Perangin-angin, E. J. G. Harianja, G. Lumbantoruan, and E. N. Purba, “Model Bidirectional Lstm Untuk Pemrosesan Sekuensial Data Teks Spam,” *METHOMIKA J. Manaj. Inform. dan Komputerisasi Akunt.*, vol. 7, no. 2, pp. 265–271, 2023, doi: 10.46880/jmika.vol7no2.pp265-271.
- [18] D. Gunawan and H. Setiawan, “Convolutional Neural Network dalam Citra Medis,” *KONSTELASI Konvergensi Teknol. dan Sist. Inf.*, vol. 2, no. 2, pp. 376–390, 2022, doi: 10.24002/konstelasi.v2i2.5367.
- [19] B. A. Sadewa and Y. Yamasari, “Implementasi Deep Transfer Learning untuk Klasifikasi Nominal Uang Kertas Rupiah,” *J. Informatics Comput. Sci.*, vol. 5, no. 04, pp. 543–551, 2024, doi: 10.26740/jinacs.v5n04.p543-551.
- [20] C. S. Audinasyah and Solehudin, “Sistem Forecasting Perencanaan Produksi dengan Metode Single Exponential Smoothing Pada Home Industry Tempe Putera Sejahtera,” *J. EMT KITA*, vol. 8, no. 3, pp. 845–853, 2024, doi: 10.35870/emt.v8i3.2589.
- [21] J. N. Gustin and M. A. I. Pakereng, “Peramalan Trend Pendapatan di Toko Online XYZ Menggunakan Single Moving Average,” *J. JTİK (Jurnal Teknol. Inf. dan Komunikasi)*, vol. 7, no. 1, pp. 130–139, 2023, doi: 10.35870/jtik.v7i1.683.
- [22] Y. A. Nugroho and H. A. Hutahaean, “Pengembangan Model Deep Learning LSTM dan CNN untuk Peramalan Penjualan Sepeda Motor di Indonesia,” *Jupiter Publ. Ilmu Keteknikan Ind. Tek. Elektro dan Inform.*, vol. 3, no. 2, pp. 94–104, 2025, doi: 10.61132/jupiter.v3i2.795.
- [23] I. G. N. Wijayakusuma, Lanang, and N. K. E. Sapitri, “Penerapan Jaringan Syaraf Tiruan Dalam Pembentukan Model Peramalan Angka Melek Huruf di Kabupaten Karangasem,” *J. Mat.*, vol. 10, no. 1, pp. 11–21, 2020, doi: 10.24843/JMAT.2020.v10.i01.p119.
- [24] S. Sonang and K. Sinaga, “Model jaringan saraf tiruan untuk prediksi permintaan produk umkm di pematangsiantar,” *TEKINKOM*, vol. 7, no. 2, pp. 1054–1060, 2024, doi: 10.37600/tekinkom.v7i2.1849.
- [25] D. Kurniadi, R. M. Shidiq, and A. Mulyani, “Perbandingan Penggunaan Optimizer dalam Klasifikasi Sel Darah Putih Menggunakan Convolutional Neural Network,” *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 14, no. 1, pp. 77–86, 2025, doi: 10.22146/jnteti.v14i1.17162.
- [26] V. Arinal and M. Puspita, “Peningkatan Akurasi Nilai Harga Saham Menggunakan Metode Long Short-Term Memory (LSTM) pada PT Unilever Abstrak,” *Manaj. Inform. dan Komun.*, vol. 6, no. 1, pp. 252–260, 2025, doi: 10.35870/jmik.v6i1.1190.
- [27] Firmansyah, D. P. Rini, and Sukemi, “Klasifikasi Data Penderita Skizofrenia Menggunakan CNN-LSTM dan Cnn-Gru pada Data Sinyal EEG 2D,” *J. JTİK (Jurnal Teknol. Inf. dan Komunikasi)*, vol. 7, no. 4, pp. 642–650, 2023, doi: 10.35870/jtik.v7i4.1072.