

Perbandingan Performa Model Box-Jenkins dan *Machine Learning* pada Prediksi Tinggi Muka Air

<http://dx.doi.org/10.28932/jutisi.v12i2.10698>

Riwayat Artikel

Received: 24 Desember 2024 | Final Revision: 01 Juli 2026 | Accepted: 01 Juli 2026

Creative Commons License 4.0 (CC BY – NC)



Azanti Zuhriyani^{#1}, Meriza Immanuela Virgie^{#2}, Thufailah Ulfah Jaenudin^{#3}, Muhammad Rizqa Salas^{#4}, Azkiya Hafizhoh^{#5}, Muhammad Rizky Nurhambali^{#6}, Akbar Rizki^{#7}

[#]Program Studi Statistika dan Sains Data, Sekolah Sains Data, Matematika, dan Informatika, IPB University
Jl. Raya Dramaga Kampus IPB Dramaga, Bogor, 16680, Indonesia

¹azantizuhriyani@apps.ipb.ac.id

²virgiemeriza@apps.ipb.ac.id

³thufailahulfah@apps.ipb.ac.id

⁴muhrizqasalas@apps.ipb.ac.id

⁵hafizhohazkiya@apps.ipb.ac.id

⁶rizkynurhambali@apps.ipb.ac.id

⁷akbar.ritzki@apps.ipb.ac.id

✉Corresponding author: akbar.ritzki@apps.ipb.ac.id

Abstrak — Pintu Air Pasar Ikan yang terletak di kawasan Jakarta Utara merupakan area strategis yang rentan terhadap bencana banjir pesisir (rob). Tinggi muka air di kawasan ini dipengaruhi oleh kombinasi pasang surut, curah hujan tinggi, dan buruknya sistem drainase sehingga sering dijadikan sebagai indikator awal potensi banjir. Penelitian ini menggunakan data pengukuran harian tinggi muka air di pintu air pasar ikan dari 1 September hingga 24 Oktober 2024. Pola data menunjukkan bahwa data cukup fluktuatif dan terdapat pola musiman. Oleh karena itu, studi ini bertujuan untuk membandingkan performa metode klasik, yaitu seasonal autoregressive integrated moving average (SARIMA) dengan metode berbasis machine learning yaitu long short-term memory (LSTM). Hasil analisis menunjukkan bahwa model SARIMA terbaik adalah model ARIMA(1,0,3)×(1,2,1)₂₄ dengan mean absolute percentage error (MAPE) sebesar 10,88% dan root mean square error (RMSE) sebesar 25,45. Namun model ini memiliki kelemahan karena terdapat asumsi model yang tidak terpenuhi, yaitu asumsi normalitas dan kehomogenan ragam sisaan. Hasil pemodelan LSTM diperoleh bahwa model dengan kombinasi epoch 50 dan batch size 1 menghasilkan model LSTM terbaik dengan MAPE dan RMSE masing-masing sebesar 2,58% dan 5,60. Hasil prediksi metode LSTM lebih baik dibandingkan dengan metode SARIMA karena masih cukup mengikuti pola data aktual serta memiliki tren naik, sedangkan hasil peramalan metode SARIMA kurang bisa mengikuti pola tersebut serta tidak memenuhi asumsi.

Kata kunci— Deret Waktu; Long Short-Term Memory; Prediksi; SARIMA; Tinggi Muka Air.

A Comparative Study of Box–Jenkins and Machine Learning Model for Water Level Prediction

Abstract — The Pasar Ikan Water Gate, located in North Jakarta, is a strategic area that is prone to coastal flooding (rob). The water level in this area is influenced by a combination of tides, high rainfall, and poor drainage systems, making it a frequent early indicator of potential flooding. This study uses daily water level measurement data from the Fish Market Water Gate from September 1 to October 24, 2024. The data patterns show that the data is quite fluctuating and exhibits seasonal patterns. Therefore, this study aims to compare

the performance of the classical method, seasonal autoregressive integrated moving average (SARIMA), with the machine learning-based method, long short-term memory (LSTM). The analysis results show that the best SARIMA model is the $ARIMA(1,0,3) \times (1,2,1)_{24}$ model with a mean absolute percentage error (MAPE) of 10.88% and a root mean square error (RMSE) of 25.45. However, this model has weaknesses due to unmet model assumptions, namely the assumptions of normality and homogeneity of residual variance. The LSTM modeling results indicate that the model with a combination of 50 epochs and a batch size of 1 produces the best LSTM model with MAPE and RMSE of 2.58% and 5.60, respectively. The LSTM method's prediction results are better than the SARIMA method's because they still follow the actual data pattern and show an upward trend, whereas the SARIMA method's forecasting results fail to follow this pattern and do not meet the assumptions.

Keywords—Forecasting; Long Short-Term Memory; SARIMA; Time Series; Water Level.

I. PENDAHULUAN

DKI Jakarta khususnya Kota Jakarta Utara merupakan salah satu kawasan pesisir strategis yang dapat dioptimalkan untuk mendukung pelaksanaan pembangunan. Namun di sisi lain, DKI Jakarta sebagai kawasan pesisir juga merupakan kawasan yang sangat rawan terkena bencana seperti banjir pesisir atau rob, tsunami, dan gelombang badai yang dapat mengancam masyarakat sekitar pesisir [1]. Data Badan Penanggulangan Bencana Daerah (BPBD) DKI Jakarta menunjukkan bahwa pada tahun 2023, terdapat 1.258 kejadian bencana di Jakarta, dengan Jakarta Utara mencatat 379 kejadian, termasuk banjir. Penyebab utama banjir rob di wilayah pesisir adalah penurunan permukaan tanah dan naiknya permukaan air laut saat terjadi pasang [2]. Penelitian oleh Iman dkk [1] menunjukkan bahwa banjir pesisir cenderung lebih sering terjadi selama bulan Desember, Januari, Februari dan Juni, Juli, Agustus. Penelitian ini mengindikasikan bahwa nilai prediksi pasang ≥ 100 cm dengan tinggi muka air ≥ 220 cm dapat digunakan sebagai ambang batas untuk peringatan dini.

Kondisi banjir rob paling sering tercatat di pintu air pasar-ikan, Jakarta Utara, yang kerap memasuki status Siaga II dibandingkan pintu air lainnya di DKI Jakarta. Hal tersebut dipengaruhi oleh faktor pasang surut air laut, yang berkontribusi pada fluktuasi tinggi muka air (TMA). Analisis TMA di pintu air ini menjadi lebih krusial karena berfungsi sebagai indikator langsung kondisi perairan yang dapat berpengaruh pada area di sekitar pintu air dan wilayah DKI Jakarta, khususnya Kota Jakarta Utara. Hasil penelitian oleh Syafitri dan Rochani [2], Jakarta Utara sangat rentan mengalami genangan banjir rob ketika pasang laut terjadi karena terletak pada ketinggian 0–300 cm di atas permukaan laut. Tinggi banjir rob di wilayah ini dapat mencapai hingga 100 cm dengan faktor utamanya adalah kenaikan permukaan air laut dan penurunan permukaan tanah. Oleh karena itu, penelitian lebih lanjut diperlukan untuk memprediksi TMA sehingga hasilnya dapat dijadikan acuan peringatan dini di wilayah pesisir utara Jakarta, khususnya di pintu air pasar ikan.

Data TMA yang didominasi oleh pengaruh cuaca seringkali memiliki pola musiman sehingga diperlukan metode peramalan yang mampu mengakomodasi pola tersebut. Salah satu metode yang dapat digunakan adalah *seasonal autoregressive integrated moving average* (SARIMA). Penggunaan metode SARIMA dalam peramalan data musiman sudah banyak digunakan oleh para peneliti sebelumnya, salah satunya yang dilakukan oleh Sa'adah dkk [3] yang menyatakan apabila pada data deret waktu terdapat observasi yang secara mencolok terlihat berbeda dengan observasi lain, maka dapat diindikasikan terdapat data *outlier* yang dapat memengaruhi kesesuaian model. Oleh karena itu, diperlukan metode peramalan yang mampu mengakomodasi adanya kejadian musiman dan *outlier* pada data yaitu menggunakan metode SARIMA dan deteksi *outlier*. Metode SARIMA sebagai metode konvensional mensyaratkan data harus stasioner melalui *differencing* atau transformasi agar model yang dipakai menjadi lebih akurat. Proses ini dapat mengakibatkan hilangnya informasi penting dan juga menambah kompleksitas dalam pemodelan.

Permasalahan yang muncul pada metode SARIMA tersebut dapat diatasi dengan metode berbasis *machine learning* yang tidak mensyaratkan kestasioneran data dan mampu menangkap pola *non-linear* maupun interaksi kompleks dalam data deret waktu. Salah satu metode berbasis *machine learning* adalah *long short-term memory* (LSTM). LSTM merupakan salah satu algoritma *deep learning* turunan dari *recurrent neural network* (RNN) yang dapat mengelola dan memprediksi data deret waktu [4]. Selain itu, LSTM dapat digunakan tanpa asumsi dan mampu mengelola data dengan jumlah yang relatif banyak [5]. Terdapat beberapa penelitian yang menggunakan metode LSTM sebagai model prediksi, salah satunya penelitian dalam peramalan jangka pendek tinggi muka air laut di Selat Sunda [5]. Penelitian tersebut dilakukan membandingkan dua metode *machine learning*, yaitu RNN dan LSTM dengan hasil LSTM lebih baik dibandingkan RNN. LSTM memiliki koefisien korelasi R^2 sebesar 0,97 dan nilai RMSE sebesar 0,04, serta terdapat nilai RNN pada penelitian sebelumnya yaitu memiliki koefisien korelasi R^2 sebesar 0,96 dan nilai RMSE sebesar 0,05 untuk prediksi selama 14 hari.

Oleh karena itu, penelitian ini bertujuan untuk membandingkan performa hasil peramalan metode SARIMA dan LSTM pada tinggi muka air (TMA) di pintu air pasar ikan. Hasil Peramalan TMA dalam penelitian ini diharapkan dapat membantu dan mendukung sistem peringatan dini di wilayah pesisir utara Jakarta sehingga dapat mengurangi risiko dan dampak banjir pesisir atau rob yang berpotensi terjadi. Sistem peringatan dini sebagai alat mitigasi dapat memberikan informasi lebih awal kepada masyarakat untuk mempersiapkan langkah antisipasi secara efektif.

II. METODE

A. Data

Data yang digunakan merupakan data TMA per jam di pintu air pasar ikan dari 1 September 2024 pukul 00.00 hingga 24 Oktober 2024 pukul 23.00. Zona waktu yang digunakan adalah waktu Indonesia bagian barat (WIB) atau GMT+7. Data tersebut terdiri dari 1.320 entri yang diambil dari situs resmi Badan Penanggulangan Bencana Daerah (BPBD) Provinsi DKI Jakarta, mengenai pemantauan TMA dan dapat diakses di bpbd.jakarta.go.id/waterlevel.

B. Metode Peramalan

Metode untuk memprediksi tinggi muka air (TMA) pada studi ini menggunakan dua pendekatan yaitu, metode statistika konvensional, SARIMA, dan metode berbasis *machine learning*, LSTM (*Long Short-Term Memory*). Pemodelan SARIMA dimulai dengan melakukan eksplorasi data dan menguji kestasioneran data baik dalam rata-rata maupun dalam ragam menggunakan uji ADF dan Fligner-Killeen. Proses *differencing* dan/atau transformasi Box-Cox akan dilakukan jika data tidak stasioner. Identifikasi model SARIMA dilakukan melalui plot ACF, PACF, dan EACF untuk menentukan kombinasi parameter optimal. Model yang telah diperoleh selanjutnya dilakukan pemeriksaan pada sisaannya berupa pemeriksaan kenormalan, kebebasan, kehomogenan, dan nilai tengah sisaan. Model terbaik dipilih berdasarkan nilai AIC terkecil dan diuji kembali untuk kemungkinan overfitting. Langkah terakhir pada pemodelan ini adalah proses validasi menggunakan data uji dan mengukur kebaikan model dengan menggunakan metrik RMSEP dan MAPE.

Sementara itu, tahapan pada pemodelan LSTM dimulai dengan melakukan normalisasi data menggunakan *min-max scaling*. Selanjutnya dilakukan pembentukan sekuens dengan *timestep* tertentu, penyusunan dataset untuk pelatihan model dan melakukan *hyperparameter tuning*. Model LSTM yang digunakan pada penelitian ini menggunakan *optimizer* ADAM. Evaluasi pemodelan dilakukan dengan menghitung nilai RMSE dan MAPE pada data uji. Prediksi terhadap TMA dilakukan dengan menggunakan model terbaik dari kedua metode yaitu SARIMA dan LSTM. Hasil ini peramalan dengan kedua metode ini selanjutnya dibandingkan untuk menentukan metode yang lebih akurat dalam peramalan tinggi muka air (TMA).

Metode yang digunakan dalam penelitian ini adalah metode SARIMA dan LSTM yang dianalisis dengan bantuan R dan python mengikuti prosedur berikut:

1. Melakukan eksplorasi data untuk melihat pola dari data deret waktu menggunakan plot deret waktu dan plot ACF.
2. Membagi data menjadi dua set data: data latih dan data uji.
3. Melakukan pemodelan SARIMA dengan tahapan yang disajikan pada Gambar 1.
 - a. Uji stasioneritas data
 - i. Uji stasioneritas data dalam rata-rata melalui eksplorasi plot deret waktu dan uji *augmented dickey-fuller* (ADF). Data dianggap stasioner dalam rata-rata jika *p-value* kurang dari taraf nyata yang digunakan, dengan hipotesis H_0 : data tidak stasioner dalam rata-rata dan H_1 : data stasioner dalam rata-rata.
 - ii. Uji stasioneritas data dalam ragam menggunakan uji formal Fligner-Killeen. Data dianggap stasioner dalam ragam jika *p-value* kurang dari taraf nyata yang digunakan, dengan hipotesis H_0 : ragam homogen dan H_1 : ragam tidak homogen.
 - b. *Differencing* musiman dan non-musiman apabila data tidak stasioner dalam rata-rata, jika data tidak stasioner dalam ragam, maka dilakukan transformasi Box-Cox.
 - c. Identifikasi model dilakukan dengan menggunakan plot *autocorrelation function* (ACF), *partial autocorrelation function* (PACF), dan *extended autocorrelation function* (EACF) untuk menentukan kombinasi parameter musiman dan non-musiman sehingga didapat beberapa kandidat model terbaik.
 - d. Diagnostik model yang dilakukan dengan uji formal.
 - i. Uji formal yang digunakan untuk memeriksa normalitas sisaan adalah uji Kolmogorov-Smirnov (KS), Shapiro-Wilk, dan Anderson-Darling. Asumsi terpenuhi jika sisaan menyebar normal dengan *p-value* lebih besar dari taraf nyata yang digunakan, dengan hipotesis H_0 : sisaan menyebar normal dan H_1 : sisaan tidak menyebar normal.
 - ii. Uji Ljung-Box digunakan untuk menguji kebebasan sisaan, dan uji kehomogenan ragam digunakan untuk memeriksa apakah ragam sisaan homogen. Asumsi terpenuhi jika sisaan saling bebas dan ragam sisaan homogen dengan *p-value* lebih besar dari taraf nyata yang digunakan. Hipotesis untuk uji kebebasan sisaan adalah H_0 : sisaan saling bebas dan H_1 : sisaan tidak saling bebas. Sementara itu, hipotesis untuk uji kehomogenan ragam adalah H_0 : ragam sisaan homogen dan H_1 : ragam sisaan tidak homogen.
 - iii. Uji-t juga digunakan untuk memeriksa apakah nilai tengah sisaan sama dengan nol, dengan hipotesis H_0 : nilai tengah sisaan sama dengan 0 dan H_1 : nilai tengah sisaan tidak sama dengan 0. Asumsi terpenuhi jika nilai tengah sisaan sama dengan nol ketika *p-value* lebih besar dari taraf nyata yang digunakan.
 - iv. Pemilihan model terbaik berdasarkan nilai *Akaike Information Criterion* (AIC) terkecil dan signifikansi parameter model.

- e. *Overfitting* pada model dengan menambahkan orde p dan q pada model yang terpilih. Jika model hasil *overfitting* memiliki nilai AIC dan signifikansi parameter yang tidak lebih baik, maka model awal tetap digunakan. Sebaliknya, jika model hasil *overfitting* lebih baik dari model awal, maka model tersebut digunakan, dan diagnostik model dilakukan kembali.

$$AIC = \ln\left(\frac{1}{T} \sum_{t=1}^T e_t^2\right) + \frac{2p}{T} \quad (1)$$


Keterangan:

T : Banyaknya data pengamatan

p : Jumlah parameter

e_t^2 : Kuadrat sisaan

- f. Model terbaik yang telah ditentukan kemudian divalidasi menggunakan data uji. Hal ini bertujuan untuk mengevaluasi performa model dalam melakukan peramalan.



Gambar 1. Tahapan pemodelan SARIMA

4. Melakukan Pemodelan LSTM dengan tahapan yang disajikan pada Gambar 2,
- a. Normalisasi data menggunakan metode *min-max scaling* untuk mengurangi rentang nilai antar sampel [6].

$$X_{sc} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2)$$

- b. Pembentukan sekuens dengan parameter *timestep*.
- c. Penyusunan set data berdasarkan sekuens terpilih.
- d. Definisikan fungsi model LSTM yang terdiri dari LSTM dan *dense layer*, banyaknya neuron, *input*, *loss function* berupa MSE dan pengoptimal *adaptive momentum* (ADAM) [7]. Dua *layer* LSTM digunakan untuk menangkap pola dan merangkum informasi, *layer dropout* untuk mencegah *overfitting*, dan *layer dense* untuk prediksi akhir [8]. Model dikompilasi dengan *optimizer* ADAM untuk penyesuaian bobot yang efisien dan *loss function* *mean squared error* (MSE) untuk mengukur akurasi prediksi.
- e. *Hyperparameter* tuning model meliputi banyaknya *epoch* dan *batch size*. Digunakan empat *epoch* dan tiga *batch size* pada penelitian ini, yaitu 10, 25, 50, 100 untuk *epoch* dan 1, 16, 32 untuk *batch size*. Penentuan nilai *epoch* dan *batch size* didasarkan secara subjektif untuk *epoch* 25 yang digabungkan dengan nilai *epoch* 10, 50, 100 serta *batch size* 1 berdasarkan penelitian yang dilakukan sebelumnya [9], [10].
- f. Pembentukan ulang model berdasarkan data latih dan *hyperparameter* terbaik yang diperoleh dari tuning.

- g. Model LSTM terbaik kemudian dievaluasi berdasarkan nilai RMSE dengan rumus pada persamaan (3) dan nilai akurasi nilai MAPE pada persamaan (4).

RMSE mengukur seberapa dekat hasil prediksi model dengan nilai sebenarnya. Semakin rendah nilai RMSE, semakin kecil kesalahan prediksi yang dihasilkan, yang menunjukkan bahwa model memiliki tingkat akurasi yang lebih tinggi [11].

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

dengan:

n : jumlah total observasi.
 y_i : nilai sebenarnya dari observasi ke-i.
 y^i : nilai prediksi dari observasi ke-i.


MAPE menghitung kesalahan rata-rata dalam persentase yang memberikan gambaran tentang besarnya kesalahan relatif terhadap skala nilai sebenarnya. Nilai MAPE yang rendah menunjukkan bahwa prediksi memiliki tingkat akurasi yang tinggi dalam persentase. Kedua metrik ini berguna dalam konteks model prediksi karena memberikan informasi tentang kualitas dan keandalan prediksi yang dibuat model [11].

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - y^i}{y_i} \right| \quad (4)$$

dengan:

n : jumlah total observasi.
 y_i : nilai sebenarnya dari observasi ke-i.
 y^i : nilai prediksi dari observasi ke-i.

5. Mengevaluasi performa model SARIMA dan LSTM untuk prediksi TMA dengan menggunakan MAPE dan RMSE.
6. Interpretasi hasil dan membuat simpulan.




Gambar 2. Tahapan pemodelan LSTM

III. HASIL DAN PEMBAHASAN

A. Eksplorasi Data

Penelitian ini menggunakan data TMA per jam untuk menganalisis risiko banjir rob atau peristiwa ekstrem lainnya. Data TMA secara keseluruhan dibagi menjadi dua set data, yaitu data latih dan data uji dengan proporsi 80% dan 20% yang didasarkan pada karakteristik pola fluktuasi data. Data latih mencakup 1056 periode dari tanggal 1 September 2024 pukul 00.00 hingga 9 Oktober 2024 pukul 10.00, sedangkan data uji terdiri 264 periode. Berdasarkan Gambar 3 terindikasi pola musiman yang dihasilkan dari data deret waktu TMA di pintu pasar ikan dengan pola fluktuasi yang berulang dalam periode tertentu. Pola yang dihasilkan cenderung stasioner, dengan rata-rata data yang stabil di antara 180 cm hingga 200 cm.


Tinggi muka air terendah dan tertinggi berada pada ketinggian 124 cm dan 247 cm yang terjadi pada tanggal 27 September 2024 pukul 03.00 dan 20 Oktober 2024 pukul 11.00. Ketinggian muka air di pintu pasar ikan selaras dengan pasang surut air laut yang terjadi di Jakarta. Berdasarkan data dari website pasanglaut.com/id/jakarta/tanjung-priok pada tanggal 27 September 2024 pasang surut tinggi terjadi pada pukul 03.25 dan pada tanggal 20 Oktober 2024 pasang naik tinggi terjadi pada pukul 11.28. Hal ini menunjukkan bahwa adanya fluktuasi TMA yang cukup tajam di beberapa titik diakibatkan oleh faktor eksternal, salah satunya karena siklus pasang surut air laut.



Gambar 3. Plot data latih dan data uji TMA di pintu pasar ikan

B. Pemodelan SARIMA


Pemodelan diawali dengan memeriksa kestasioneran data melalui plot deret waktu dan plot ACF. Gambar 3 menunjukkan pola data deret waktu dari data TMA pintu pasar ikan yang memiliki pola musiman dengan ditandai adanya fluktuasi yang teratur. Didukung dengan plot ACF pada Gambar 4(a) yang menunjukkan hubungan antar lag dalam deret waktu memiliki pola sinus dengan nilai ACF yang cukup besar dan menurun perlahan mendekati nilai nol di beberapa lag awal. Melalui uji ADF, didapat p -value sebesar 0,01 lebih kecil dari $\alpha = 0,05$ sehingga tolak H_0 yang artinya cukup bukti untuk menyatakan bahwa data stasioner atau data tidak memiliki akar unit (*unit root*) untuk data non-musimannya. Data yang tidak memiliki akar unit berarti memiliki statistik seperti rata-rata, ragam, dan autokorelasi yang tidak berubah seiring waktu [10]. Terdapat perbedaan hasil analisis berdasarkan visualisasi plot dengan uji ADF. Pada visualisasi, data tampak stasioner dalam rataaan, tetapi tidak stasioner dalam ragam karena memiliki pola musiman yang signifikan.



Gambar 4. Plot data TMA (a) ACF (b) Box-Cox

Berdasarkan Gambar 4(b), plot Box-Cox menunjukkan *rounded value* (λ) *optimum* sebesar 1,96 dengan selang kepercayaan 95% yang berkisar antara 1,61 hingga 2,35. Selang kepercayaan tersebut tidak memuat nilai satu sehingga disimpulkan bahwa data awal TMA tidak memiliki kestasioneran dalam ragam atau variansi yang tidak konstan [12]. Untuk mengatasi permasalahan tersebut dilakukan transformasi Box-Cox [13] yang mendapatkan nilai λ mendekati satu yaitu, sebesar 1,02. Hal ini menunjukkan kestasioneran data dalam ragam sudah berhasil untuk ditangani.


Data TMA yang tidak stasioner dalam rataaan diperlukan *differencing* pada pola musimannya. Untuk mencapai stasioneritas dalam analisis deret waktu, diperlukan derajat *differencing* d , yang diasumsikan telah tercapai ketika fungsi autokorelasi menurun dengan cepat. Dalam praktiknya, nilai d biasanya 0, 1, atau 2. Untuk menentukan nilai ini, cukup dilakukan inspeksi terhadap sekitar 20 autokorelasi pertama dari data asli serta dari *differencing* pertama dan kedua jika diperlukan [14]. Pada Gambar 5(a), 5(b) dan 5(c) terlihat bahwa kestasioneran data belum teratasi setelah dilakukan *differencing* pertama karena belum terlihat cut off lag yang jelas sehingga perlu dilakukan *differencing* kembali yang kedua kalinya untuk mengatasi ketidakstasioneran data musiman dalam rataaan.



Gambar 5. Plot setelah differencing pertama (a) Plot deret waktu, (b) Plot ACF, dan (c) Plot PACF

Setelah dilakukan *differencing* kedua dilakukan identifikasi model, pada model SARIMA notasi yang digunakan untuk mengidentifikasi model yaitu (p, d, q) sebagai notasi non-musiman dan (P, D, Q) sebagai notasi musiman. Berdasarkan plot ACF pada Gambar 6(b) untuk pola musimannya terlihat cut off pada lag ke-24 untuk data pola musimannya sehingga dipilih ordo $Q = 1$, sementara plot PACF pada Gambar 6(c) tidak terlihat ordo P yang terbentuk karena cenderung *tails off*. Untuk ordo D didapat dari hasil seberapa banyak dilakukannya differencing musiman yang dilakukan, pada penelitian ini dilakukan sebanyak dua kali. Oleh karena itu, didapat komponen musimannya adalah $ARIMA(0,2,1)_{24}$.

Pada Gambar 6(d) disajikan plot EACF untuk melihat komponen non-musimannya yang menghasilkan beberapa ordo (p, q) dari pola segitiga yang terbentuk, yaitu $ARMA(1,3)$, $ARMA(1,4)$, $ARMA(2,3)$, $ARMA(2,4)$. Sehingga di dapat empat komponen non-musimannya dengan ordo $d = 0$ karena tidak dilakukan differencing sama sekali. Empat kandidat model yang akan diuji, yaitu model $ARIMA(1,0,3) \times (0,2,1)_{24}$, $ARIMA(1,0,4) \times (0,2,1)_{24}$, $ARIMA(2,0,3) \times (0,2,1)_{24}$, dan $ARIMA(2,0,4) \times (0,2,1)_{24}$.



Gambar 6. Plot setelah differencing kedua (a) Plot Deret Waktu, (b) Plot ACF, (c) Plot PACF, dan (d) Plot EACF

Dilakukan identifikasi model terbaik dengan mempertimbangkan nilai AIC dan signifikansi parameter dari ke-4 kandidat model. Hasilnya didapatkan bahwa nilai AIC masing-masing model secara berurutan adalah 17.072,14; 17.073,55; 17.073,23;

dan 17.075,64. Parameter yang signifikan secara keseluruhan hanya terdapat pada model pertama, yaitu model $ARIMA(1,0,3) \times (0,2,1)_{24}$ yang disajikan pada Tabel 1. Oleh karena itu, model tersebut ditetapkan sebagai model terbaik karena memiliki nilai AIC terkecil dengan keseluruhan parameter signifikan. Setelah mendapatkan model terbaik dilakukan uji formal untuk mengevaluasi asumsi-asumsi pada sisaan model. Pada Tabel 2 didapatkan hasil bahwa terdapat dua asumsi yang tidak terpenuhi, yaitu normalitas dan kehomogenan ragam sisaan.

TABEL 1
ESTIMASI PARAMETER MODEL $ARIMA(1,0,3) \times (0,2,1)_{24}$ PADA TARAF NYATA 5% ($\alpha = 0,05$)

Model	Parameter	Estimasi	P-value	Keputusan	Signifikansi	AIC
$ARIMA(1,0,3) \times (0,2,1)_{24}$	AR1	0,7346	< 0,05	Tolak H_0	Ya	17.072,14
	MA1	-0,1855	< 0,05	Tolak H_0	Ya	
	MA2	0,1004	< 0,05	Tolak H_0	Ya	
	MA3	0,1288	< 0,05	Tolak H_0	Ya	
	SMA1	-0,9999	< 0,05	Tolak H_0	Ya	

TABEL 2
HASIL UJI FORMAL TERHADAP SISAAN MODEL $ARIMA(1,0,3) \times (0,2,1)_{24}$

Aspek yang Diuji	Uji Formal	P-value	Keputusan	Simpulan
Normalitas Sisaan	Kolmogorov-Smirnov	$2,2 \times 10^{-16}$	Tolak H_0	Sisaan tidak menyebar normal
Autokorelasi Sisaan	Ljung-Box	0,9283	Terima H_0	Tidak ada autokorelasi
Homoskedastisitas Sisaan	Ljung-Box	$2,2 \times 10^{-16}$	Tolak H_0	Sisaan tidak homogen
Nilai Tengah Sisaan sama dengan nol	Uji-t	0,6532	Terima H_0	Nilai tengah sama dengan nol

Terdapat tujuh kandidat model yang dihasilkan dari proses *overfitting*, yaitu model $ARIMA(2,0,3) \times (0,2,1)_{24}$, $ARIMA(1,0,2) \times (0,2,1)_{24}$, $ARIMA(1,0,4) \times (0,2,1)_{24}$, $ARIMA(0,0,3) \times (0,2,1)_{24}$, $ARIMA(1,0,3) \times (0,2,2)_{24}$, $ARIMA(1,0,3) \times (1,2,1)_{24}$, dan $ARIMA(1,0,3) \times (0,2,0)_{24}$. Didapatkan nilai AIC dan signifikansi parameter secara berurutan dari ke-7 model tersebut adalah 17.073,23; 17.082,72; 17.073,55; 17.167,26; 16.921,28; 16.960,45; dan 17.937,34. Parameter yang signifikan secara keseluruhan terdapat pada model ke-2, ke-4 dan ke-6. Berdasarkan nilai AIC dan signifikansi parameter didapatkan bahwa model $ARIMA(1,0,3) \times (1,2,1)_{24}$ hasil *overfitting* lebih baik dari model $ARIMA(1,0,3) \times (0,2,1)_{24}$ karena memiliki parameter yang signifikan secara keseluruhan yang disajikan pada Tabel 3 dan nilai AIC yang lebih kecil, yaitu 16.960,45. Oleh karena itu, dipilih model hasil *overfitting* sebagai model terbaik yang akan digunakan pada penelitian ini.

TABEL 3
ESTIMASI PARAMETER MODEL $ARIMA(1,0,3) \times (1,2,1)_{24}$ PADA TARAF NYATA 5% ($\alpha = 0,05$)

Model	Parameter	Estimasi	P-value	Keputusan	Signifikansi	AIC
$ARIMA(1,0,3) \times (1,2,1)_{24}$	AR1	0,7529	< 0,05	Tolak H_0	Ya	16.960,45
	MA1	-0,1298	< 0,05	Tolak H_0	Ya	
	MA2	0,1359	< 0,05	Tolak H_0	Ya	
	MA3	0,1319	< 0,05	Tolak H_0	Ya	
	SAR1	-0,3439	< 0,05	Tolak H_0	Ya	
	SMA1	-0,9999	< 0,05	Tolak H_0	Ya	


TABEL 4
HASIL UJI DIAGNOSTIK (FORMAL) TERHADAP SISAAN MODEL *OVERFITTING* $ARIMA(1,0,3) \times (1,2,1)_{24}$

Aspek yang Diuji	Uji Formal	P-value	Keputusan	Kesimpulan
Normalitas Sisaan	Kolmogorov-Smirnov	$2,2 \times 10^{-16}$	Tolak H_0	Sisaan tidak menyebar normal
Autokorelasi Sisaan	Ljung-Box	0,8823	Terima H_0	Tidak ada autokorelasi
Homoskedastisitas Sisaan	Ljung-Box	$2,2 \times 10^{-16}$	Tolak H_0	Sisaan tidak homogen
Nilai Tengah Sisaan sama dengan nol	Uji-t	0,7178	Terima H_0	Nilai tengah sama dengan nol

Uji diagnostik dilakukan kembali terhadap model hasil *overfitting* untuk mengevaluasi asumsi-asumsi pada sisaan model yang disajikan pada Tabel 4. Terdapat dua asumsi yang tidak terpenuhi yaitu, normalitas sisaan dan homoskedastisitas ragam sisaan. Pelanggaran asumsi normalitas dapat diabaikan karena data TMA cukup besar, yaitu sebanyak 1320 data. Seperti halnya dalam penelitian sebelumnya yang memiliki jumlah observasi sebanyak 520 data dimana data tersebut juga cukup besar sehingga tidak memenuhi asumsi normalitas sisaan dapat diabaikan [15]. Pelanggaran asumsi homoskedastisitas tidak ditangani lebih lanjut dalam penelitian ini.

Kemudian model $ARIMA(1,0,3) \times (1,2,1)_{24}$ digunakan untuk memprediksi data TMA yang menghasilkan nilai RMSE sebesar 25,45 dan nilai MAPE sebesar 10,88% pada data uji. Nilai ini menunjukkan bahwa model memiliki rata-rata kesalahan prediksi yang cukup rendah sehingga dapat dianggap layak untuk digunakan dalam memprediksi data TMA. Suatu model dapat dikatakan mempunyai kinerja yang sangat bagus jika nilai MAPE berada di bawah 10%, mempunyai kinerja yang bagus jika nilai MAPE berada di antara 10%–20%, mempunyai kinerja yang cukup jika nilai MAPE berada di antara 20%–50%, dan mempunyai kinerja yang tidak akurat jika nilai MAPE lebih dari 50% [16].

Berdasarkan Gambar 7, model SARIMA dicobakan terhadap data uji untuk memprediksi tinggi muka air (TMA). Grafik tersebut menunjukkan bahwa hasil prediksi kurang mengikuti pola data asli meskipun di beberapa titik pola prediksi mengikuti pola pergerakan data aktualnya. Hal ini sesuai dengan nilai MAPE yang didapatkan lebih besar dari 10% yang mencerminkan bahwa model SARIMA kurang mampu menggambarkan dinamika pola musiman dan fluktuasi yang terjadi pada data TMA dengan baik.



Gambar 7. Plot perbandingan data uji prediksi dengan data uji aktual TMA di pintu pasar ikan menggunakan model SARIMA

C. Pemodelan LSTM


Pemodelan LSTM diawali dengan normalisasi data menggunakan metode *min-max scaling* pada rentang 0 sampai 1 untuk mempercepat proses pembelajaran dan meminimalkan risiko *vanishing gradient* [7], [9]. Selanjutnya menentukan jumlah *timestep* atau langkah yang akan dijadikan input sebesar 24 ($t = 24$), artinya model akan menerima 24 data berurutan untuk memprediksi nilai berikutnya dalam konteks penelitian ini adalah selama 24 jam atau sama dengan satu hari kedepan. Selanjutnya membangun model dengan beberapa layer, yaitu layer LSTM pertama dan kedua dengan jumlah 128 unit, 32 unit, *layer dropout* dengan rasio 0,5, serta *layer dense* dengan satu unit neuron. Model dikompilasi dengan pengoptimal ADAM dan *loss function* MSE.

Pada penelitian ini dilakukan percobaan dengan kombinasi parameter berupa peningkatan *epoch* 10, 25, 50, dan 100 serta *batch size* 1, 16, 32 untuk melihat pengaruh dari jumlah parameter terhadap hasil prediksi. Hasil percobaan ditampilkan pada Tabel 5 yang menunjukan bahwa kombinasi terbaik terdapat pada *epoch* = 50, *batch size* = 1 dengan $t = 24$ karena memiliki nilai akurasi yang paling baik. Peningkatan jumlah *epoch* dan *batch size* cenderung tidak menghasilkan nilai prediksi yang lebih baik dan signifikan. Hal ini mungkin terjadi karena model telah mencapai titik konvergensi pada jumlah *epoch* yang relatif rendah. Selain itu, *batch size* memengaruhi kecepatan pembelajaran model, di mana *batch size* yang lebih kecil cenderung mempercepat proses konvergensi [17]. Dengan demikian, parameter yang dipilih mampu mengoptimalkan performa model tanpa perlu peningkatan parameter yang berlebihan.

Model dengan kombinasi terbaik kemudian akan digunakan untuk meramal data uji TMA. Sebelum dilakukan peramalan, data ditransformasi balik terlebih dahulu, kemudian dibandingkan dengan data TMA aktualnya. Pada Gambar 8, data uji hasil prediksi yang menggunakan model LSTM membentuk garis yang mengikuti pola data asli dengan baik. Model ini mampu menangkap pola musiman dengan akurasi yang baik, yaitu dengan MAPE data uji sebesar 2,58% dan RMSE data uji sebesar 6,09 sehingga cukup untuk memprediksi TMA selama 1 minggu ke depan dengan kombinasi parameter *epoch* = 50, *batch size* = 1, dengan $t = 24$.

TABEL 5
NILAI AKURASI KOMBINASI PARAMETER


Jumlah Epoch	Batch Size	Train MAPE (%)	Train RMSE	Test MAPE (%)	Test RMSE
10	1	2,25	6,27	2,88	6,72
	16	3,15	7,38	4,54	10,37
	32	3,63	8,48	5,84	12,49
25	1	2,31	5,73	2,59	6,13
	16	2,78	6,82	3,12	7,33
	32	2,98	7,12	3,35	7,82
50	1	2,20	5,46	2,58	6,09
	16	2,60	6,37	2,83	6,37
	32	2,52	6,18	2,65	6,18
100	1	2,19	5,44	2,77	6,62
	16	2,54	6,22	2,74	6,47
	32	2,52	6,18	2,65	6,21



Gambar 8. Plot perbandingan data uji prediksi dengan data uji aktual TMA di pintu pasar ikan menggunakan model LSTM

D. Evaluasi Model

Prediksi TMA untuk satu minggu kedepan dilakukan menggunakan model terbaik dari kedua metode yaitu SARIMA dan LSTM. Pada Gambar 9 terlihat bahwa kedua model tidak ada yang bisa memprediksi data aktual secara akurat. Namun, plot dengan model LSTM jauh lebih baik untuk memprediksi TMA dibandingkan dengan model SARIMA. Hal tersebut dapat dilihat dari garis putus-putus (data prediksi) model LSTM pada Gambar 9(a) lebih mendekati pola garis ungu (data aktual) dengan tren naik, sedangkan plot dengan model SARIMA pada Gambar 9(b) meski terdapat titik-titik yang sesuai dengan pola data aktual, terlihat ada beberapa garis prediksi yang jauh dari garis data aktualnya dan tidak terlihat tren naik ataupun turun.



Gambar 9. Plot prediksi TMA di pintu pasar ikan pada 1 minggu ke depan menggunakan (a) LSTM dan (b) SARIMA

Selanjutnya, kedua model dievaluasi menggunakan nilai MAPE dan RMSE yang disajikan pada Tabel 6. Hasil prediksi selama satu minggu ke depan menunjukkan model SARIMA memiliki nilai MAPE (9,23%), tidak jauh berbeda dengan model

LSTM (9,20%). Hal ini mengartikan bahwa rata-rata kesalahan prediksi model SARIMA terhadap data aktualnya adalah sebesar 9,23%. Nilai RMSE pada model LSTM (6,07) lebih kecil dibanding model SARIMA (20,85) yang artinya rata-rata kesalahan prediksi model LSTM adalah sebesar 6,07 cm dari data aktualnya. Namun, model SARIMA memerlukan beberapa asumsi yang harus terpenuhi, yakni normalitas sisaan, kehomogenan ragam sisaan, autokorelasi sisaan, serta nilai tengah sisaan sama dengan nol. Sebaliknya, LSTM tidak memerlukan asumsi apapun yang harus dipenuhi. Oleh karena itu model LSTM dianggap sebagai model yang lebih baik untuk memprediksi data pada penelitian ini.

TABEL 6
PERBANDINGAN HASIL NILAI AKURASI HASIL PREDIKSI MODEL SARIMA DAN LSTM

Model	MAPE (%)	RMSE
SARIMA	9,23	20,85
LSTM	9,20	6,07

TMA dijadikan rujukan untuk mengkategorikan status siaga di pintu pasar ikan. Status siaga pintu pasar ikan pada Tabel 7 yang dikutip dari poskobanjir.dsdadki.web.id menjadi acuan peringatan dini ketika tinggi muka air memasuki rataian siaga I (bahaya), siaga II (waspada tinggi), siaga III (waspada rendah), dan normal. Rataan tinggi muka air pada model terbaik dapat diprediksi dari banjir pesisir ataupun risiko kerusakan akibat pasang air laut yang tinggi karena berada pada status siaga II dan III yaitu, di antara 170-200 cm. Ketika tinggi muka air melewati ambang kritis (> 250 cm) atau memasuki status Siaga I, hal ini mengindikasikan adanya potensi banjir besar atau risiko serius yang mungkin terjadi. Dari Gambar 9 terlihat bahwa data prediksi tertinggi mencapai 220 cm di mana pada data prediksi ini dapat memperlihatkan tinggi muka air memasuki status siaga II, sedangkan untuk data aktual yang tercatat tidak terlalu jauh dengan nilai data prediksinya, yaitu data aktual tertinggi sebesar 230 cm.

TABEL 7
STATUS SIAGA PINTU PASAR IKAN BERDASARKAN TINGGI MUKA AIR

Status	Tinggi muka air (cm)
Siaga I	> 250
Siaga II	200
Siaga III	170
Normal	< 170

Model prediksi yang dihasilkan mampu menunjukkan rata-rata tinggi muka air yang jauh dari ambang kritis. Hasil ini mengindikasikan kondisi aman dan meminimalkan risiko banjir pesisir atau rob. Namun, ketika tinggi muka air mendekati atau melampaui ambang kritis, status siaga dapat digunakan untuk mengarahkan respons yang cepat dan tepat, seperti peringatan dini, evakuasi, atau langkah preventif lainnya. Dengan demikian, penggunaan model prediksi dan klasifikasi status siaga secara efektif dapat mengurangi dampak bencana serta meningkatkan kesiapsiagaan dalam pengelolaan sumber daya air.

IV. SIMPULAN

Hasil penelitian ini didapatkan perbedaan yang cukup signifikan antara metode klasik (SARIMA) dan metode machine learning (LSTM) dalam memprediksi TMA di pintu air Pasar Ikan. Terdapat pola data cukup fluktuatif serta terdapat pola tren musiman. Model SARIMA terbaik yang diperoleh ialah $ARIMA(1,0,3) \times (1,2,1)_{24}$ dengan nilai RMSE sebesar 25,45 dan MAPE 10,88%. Hasil akurasi tersebut dapat dikatakan cukup baik untuk metode klasik, tetapi model ini tidak memenuhi asumsi normalitas dan kehomogenan ragam sisaan sehingga hasil prediksinya kurang presisi.

Pada metode LSTM dengan parameter optimal ($epoch = 50$, $batch\ size = 1$, $t = 24$) memberikan hasil prediksi TMA yang lebih baik, dengan nilai RMSE sebesar 5,60 serta MAPE sebesar 2,58%. Metode LSTM tidak memerlukan pengujian asumsi seperti normalitas atau kehomogenan ragam sisaan seperti pada metode klasik. Hal ini menjadikan LSTM lebih fleksibel dan cocok untuk penelitian ini, terutama dalam memodelkan data TMA yang fluktuatif dan membentuk pola musiman dengan akurasi yang sangat baik.

Setelah dilakukan prediksi TMA selama satu minggu ke depan menggunakan kedua metode tersebut, prediksi model SARIMA cenderung menghasilkan estimasi yang jauh lebih tinggi dari nilai ekstrem, baik saat TMA mencapai nilai tertinggi maupun terendah. Hal ini menunjukkan bahwa meskipun model mampu menangkap pola musiman secara umum, akurasi prediksi masih perlu ditingkatkan terutama dalam memodelkan fluktuasi ekstrem pada data. Metode LSTM menunjukkan tren kenaikan yang konsisten dan pola prediksinya mendekati pola data aktual. Keakuratan prediksi ini memperkuat potensi penerapan LSTM dalam pengembangan sistem peringatan dini untuk mitigasi risiko banjir pesisir, terutama di kawasan Jakarta Utara. Integrasi model LSTM dan mekanisme validasi pemodelan secara berkelanjutan ke dalam sistem peringatan dini berbasis waktu nyata (*real-time*) dengan dukungan data sensor otomatis dan visualisasi prediksi yang responsive

diharapkan dapat dilakukan di waktu yang akan datang sehingga hasil penelitian ini dapat bermanfaat secara nyata untuk Masyarakat dan lingkungan.

DAFTAR PUSTAKA

- [1] Iman, A. Rizky, Ardiansyah, and W. N. Pratama, "Penentuan Nilai Ambang Batas dalam Prakiraan Potensi Banjir Pesisir di Utara Jakarta," *Bul. Meteorol. Klimatol. Dan Geofis.*, vol. 5, no. 4, pp. 35–43, 2024.
- [2] A. W. Syafitri and A. Rochani, "Analisis Penyebab Banjir Rob di Kawasan Pesisir Studi Kasus: Jakarta Utara, Semarang Timur, Kabupaten Brebes, Pekalongan," *J. Kaji. Ruang*, vol. 1, no. 1, pp. 16–28, 2021.
- [3] A. F. Sa'adah and D. Ispriyanti, "Prediksi Tinggi Pasang Air Laut di Kota Semarang dengan Menggunakan Metode Seasonal Autoregressive Integrated Moving Average (SARIMA) dan Deteksi Outlier," *J. GAUSSIAN*, vol. 3, no. 3, pp. 273–282, 2014.
- [4] Ainurrochman, D. P. Adi, and A. B. Gumelar, "Deteksi Emosi Wicara pada Media On-Demand menggunakan SVM dan LSTM," *J. Rekayasa Sist. Dan Teknol. Inf.*, vol. 4, no. 5, pp. 799–804, 2020.
- [5] A. W. Ramadhan, D. Adytia, D. Saepudin, S. Husrin, and A. Adiwijaya, "Forecasting of Sea Level Time Series using RNN and LSTM Case Study in Sunda Strait," *Lontar Komput. J. Ilm. Teknol. Inf.*, vol. 12, no. 3, p. 130, 2021.
- [6] R. Julian and M. R. Pribadi, "Peramalan Harga Saham Pertambangan pada Bursa Efek Indonesia (BEI) menggunakan Long Short Term Memory (LSTM)," *J. Tek. Inform. Dan Sist. Inf.*, vol. 8, no. 3, pp. 1570–1580, 2021.
- [7] L. Yang and A. Shami, "On Hyperparameter Optimization of Machine Learning Algorithms: Theory and Practice," *Neurocomputing*, vol. 415, pp. 295–316, 2020.
- [8] T. A. Faisal Muhammad and M. I. Irawan, "Implementasi Long Short-Term Memory (LSTM) untuk Prediksi Intensitas Curah Hujan (Studi Kasus: Kabupaten Malang)," *J. Sains Dan Seni ITS*, vol. 12, no. 1, pp. A34–A39, 2023.
- [9] S. Supriyade, G. Firmansyah, H. Akbar, and B. Tjahjono, "Analysis of Time Series Water Level Data Prediction Using Deep Learning Method at the Water Gate of DKI Jakarta Water Resources Office," *J. Indones. Soc. Sci.*, vol. 4, no. 09, pp. 753–762, 2023.
- [10] Namora and J. E. Riwurohi, "Prediction of Water Levels on Peatland using Deep Learning," *J. Rekayasa Sist. Dan Teknol. Inf.*, vol. 6, no. 2, pp. 234–239, 2022.
- [11] I. C. Azhari and T. Haryanto, "Modeling of Hyperparameter Tuned RNN-LSTM and Deep Learning for Garlic Price Forecasting in Indonesia," *J. Inform. Telecommun. Eng.*, vol. 7, no. 2, pp. 502–513, 2024.
- [12] M. B. Pamungkas and A. Wibowo, "Aplikasi Metode ARIMA Box-Jenkins untuk Meramalkan Kasus DBD di Provinsi Jawa Timur," *Indones. J. Public Health*, vol. 13, no. 2, p. 183, 2019.
- [13] V. T. N. Uyen and N. H. Son, "Improving accuracy of surface roughness model while turning 9XC steel using a Titanium Nitride-coated cutting tool with Johnson and Box-Cox transformation," *AIMS Mater. Sci.*, vol. 8, no. 1, pp. 1–17, 2021.
- [14] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, and G. M. Ljung, *Time Series Analysis: Forecasting and Control*, 5th ed. New Jersey: Wiley, 2016.
- [15] F. Salsabila, R. A. Fatharani, T. A. Taqiyuddin, and M. Irfan, "Aplikasi Model ARCH/GARCH dalam Peramalan Laju Inflasi Bulanan Indonesia," *J. Sains Mat. Dan Stat.*, vol. 8, no. 1, p. 34, 2022.
- [16] C. Fiarni, H. Kurniawan, and F. H. Mulyono, "Perancangan Integrated Demand Forecast untuk Manajemen Informasi Sistem Pelayanan Kegawatdaruratan," *J. Telematika*, vol. 16, no. 1, pp. 10–17, 2021.
- [17] B. A. Septian and U. T. Kartini, "Pemodelan Peramalan Beban Jangka Pendek untuk Subsistem Krian Gresik menggunakan Deep Learning LSTM-NN," *J. Tek. ELEKTRO*, vol. 12, no. 2, pp. 1–5, 2023.