

## PERBANDINGAN MODEL SARIMA, LSTM, DAN PROPHET DALAM PREDIKSI VOLUME BONGKAR-MUAT KAPAL

### COMPARISON OF SARIMA, LSTM, AND PROPHET MODELS IN SHIP LOADING AND UNLOADING VOLUME PREDICTION

**Rizka Britania**

Fakultas Teknik, Universitas Bina Nusantara, Indonesia.

Correspondence author: rizka.britania@binus.ac.id

#### ABSTRACT

*Accurately predicting ship loading and unloading volumes at ports is essential for optimizing operations and strategic planning. This study compares three time series forecasting models: SARIMA, LSTM, and Prophet, to predict ship loading and unloading volumes at Tanjung Priok, Indonesia's busiest port. The dataset covers the period from January 2017 to August 2025 in monthly increments. Hyperparameter tuning was performed on each model to determine the optimal hyperparameter values. Model performance was evaluated on the testing dataset using the Mean Absolute Percentage Error (MAPE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), and accuracy metrics. Based on these four metrics, SARIMA had the best performance with an accuracy rate of 87.97%, followed by the LSTM model at 85.38%, and the Prophet model at 69.40%. SARIMA can capture seasonal patterns and trends in loading and unloading data, making it useful for decision-making related to ship scheduling, crane allocation, and dock management. This study emphasizes the importance of selecting a model based on the characteristics of the data and demonstrates that traditional statistical models, such as SARIMA, are competitive with deep learning models for time series with strong seasonality.*

**Keywords:** Forecasting; LSTM; Ship loading and unloading; SARIMA; Prophet.

#### ABSTRAK

Prediksi volume bongkar-muat kapal di pelabuhan merupakan hal penting untuk optimalisasi operasional dan perencanaan strategis. Penelitian ini bertujuan membandingkan tiga model forecasting time series; SARIMA, LSTM, dan Prophet dalam memprediksi volume bongkar-muat kapal di pelabuhan tersibuk di Indonesia, Tanjung Priok. Dataset mencakup periode Januari 2017 hingga Agustus 2025 dalam satuan waktu bulanan. Pada setiap model dilakukan hyperparameter tuning untuk memperoleh nilai hyperparameter terbaik. Evaluasi performa model dilakukan pada testing dataset menggunakan metrik Mean Absolute Percentage Error (MAPE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan akurasi. Berdasarkan keempat metric tersebut, SARIMA memiliki performa terbaik dengan tingkat akurasi sebesar 87,97%, diikuti oleh model LSTM sebesar 85,38%, dan model Prophet sebesar 69,40%. SARIMA mampu menangkap pola musiman dan tren pada data bongkar muat, sehingga sesuai untuk mendukung pengambilan keputusan terkait penjadwalan kapal, alokasi crane, dan manajemen dermaga. Penelitian ini menekankan pentingnya pemilihan model berdasarkan karakteristik data, serta menunjukkan bahwa model statistik tradisional seperti SARIMA tetap kompetitif dibandingkan model deep learning pada time series dengan musiman yang kuat.

**Kata Kunci:** Bongkar-muat kapal; LSTM; SARIMA; Prediksi; Prophet.

## PENDAHULUAN

Indonesia merupakan negara yang terdiri dari banyak pulau, sehingga transportasi laut memegang peranan penting dalam mobilitas barang dan orang. Distribusi barang dengan menggunakan jalur laut merupakan kebutuhan logistik yang besar. Pelabuhan memiliki peran yang penting dalam mendukung rantai logistik terkait hal tersebut. Efisiensi pelabuhan dapat menentukan kelancaran dan stabilitas rantai pasok. Tidak hanya sebagai titik keluar-masuk barang, pelabuhan juga menjadi tempat aktivitas bongkar-muat, sehingga pelabuhan dituntut mampu untuk menangani fluktuasi volume bongkar muat dengan cepat dan akurat.

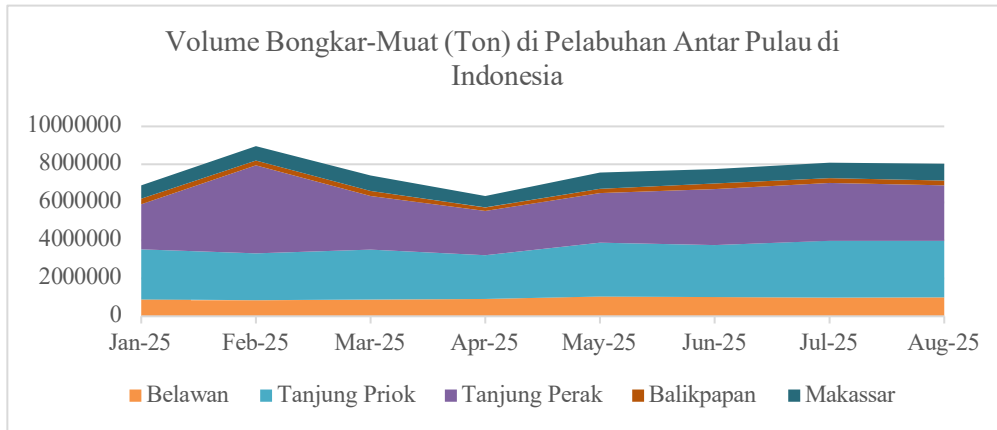
Kemampuan prediksi aktivitas bongkar muat kapal merupakan hal yang penting di pelabuhan. Informasi yang akurat ini dapat memudahkan pengelola pelabuhan untuk melakukan perencanaan kapasitas dan persiapan secara optimal, seperti kesiapan area, alokasi sumber daya manusia, kesiapan alat, maupun pengaturan jadwal kapal. Perencanaan yang buruk akibat tidak adanya prediksi yang baik, dapat menyebabkan banyak kerugian seperti penumpukan antrian kapal, penumpukan barang, peningkatan biaya logistik, serta penurunan kualitas layanan pelabuhan. Oleh karena itu, prediksi volume bongkar muat merupakan kebutuhan penting untuk meningkatkan efisiensi operasional dan mendukung perencanaan dan pengambilan keputusan jangka panjang.

Aktivitas bongkar-muat kapal di pelabuhan dipengaruhi oleh banyak faktor. Prediksi volume bongkar-muat merupakan hal yang penting untuk membantu dalam efisiensi aktivitas ini. Diperlukan kajian untuk dapat mengetahui model prediksi

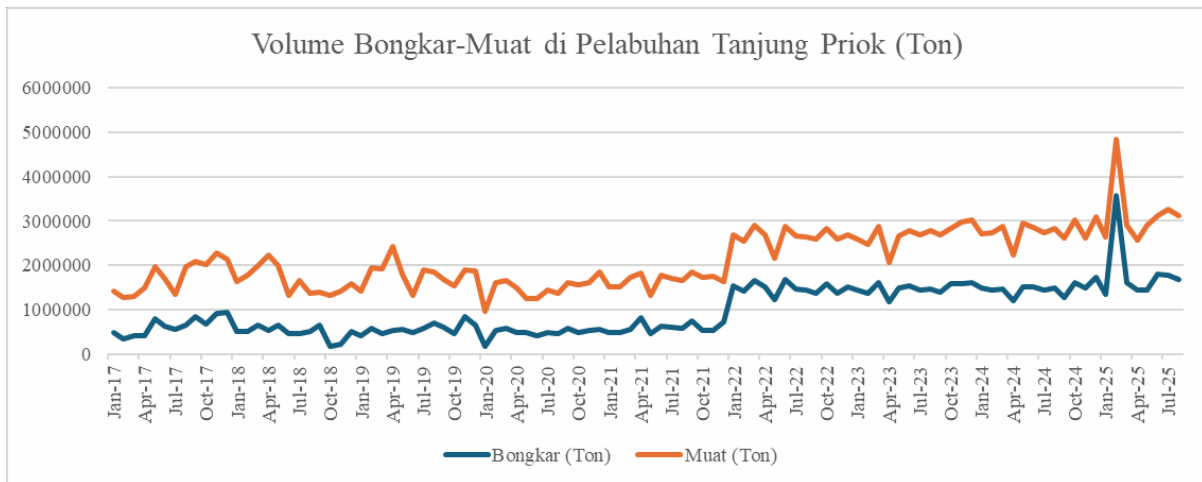
yang akurat, namun hal ini sulit didapatkan karena beberapa hal. Tingginya ketidakpastian volume bongkar-muat dapat dilihat dari data yang menunjukkan pola yang tidak stabil, seperti adanya fluktuasi musiman, tren naik-turun dalam periode tertentu, serta lonjakan yang dipengaruhi kondisi ekonomi, cuaca, dan kebijakan tertentu.

Indonesia memiliki beberapa pelabuhan, seperti Tanjung Priok, Tanjung Perak, Makassar, Belawan, dan Balikpapan. Tanjung Priok merupakan salah satu gerbang utama perdagangan nasional dan distribusi antar pulau di Indonesia. Gambar 1 menunjukkan perbandingan volume bongkar-muat Tanjung Priok dibanding keempat pelabuhan antarpulau lainnya di tahun 2025. Dari gambar tersebut dapat dilihat bahwa Tanjung Priok relatif selalu menempati posisi pertama sebagai pelabuhan dengan volume bongkar-muat tertinggi.

Selain skala operasionalnya yang besar, kompleksitas aktivitas bongkar muat di Tanjung Priok juga cukup tinggi dibanding pelabuhan lain karena melibatkan berbagai jenis komoditas, variasi ukuran kapal, dan aktivitas ekspor-impor. Gambar 2 menunjukkan volume bongkar-muat untuk pelabuhan Tanjung Priok Jakarta pada tahun 2025. Kompleksitas pola yang dimiliki historis tersebut menunjukkan diperlukannya model prediksi *time series* yang mampu mengenali pola tren, seasonality, dan error secara baik. Kompleksitas ini menunjukkan diperlukannya model prediksi berbasis *time series* untuk memprediksi volume bongkar-muat di pelabuhan ini.



Gambar 1. Perbandingan volume bongkar-muat di lima pelabuhan antarpulau di Indonesia



Gambar 2. Volume bongkar-muat pelabuhan Tanjung Priok, Jakarta

Model prediksi *time series* sudah semakin berkembang seiring dengan kemajuan teknik komputasi. Saat ini terdapat beberapa teknik *forecasting* yang dapat digunakan untuk model *time series*, mulai dari model statistik klasik seperti SARIMA, hingga model berbasis *machine learning* seperti LSTM dan Prophet. Masing-masing model memiliki kekuatan dan kelemahan dalam menangani pola yang dikandung data, seperti pola musiman, tren non-linear, hingga data dengan volatilitas yang tinggi.

Terdapat beberapa penelitian terdahulu yang memiliki objek kajian di pelabuhan. Topik yang digunakan cukup beragam seperti analisis *dwelling time* kapal, prediksi volume bongkar-muat kapal, jumlah penumpang, dan jumlah kapal. Metode yang digunakan juga bervariasi,

mulai dari metode statistik klasik, hingga metode *deep learning*.

Ricardianto, dkk (2018) melakukan kajian terkait analisis *dwelling time* dan bongkar muat peti kemas di Pelabuhan Tanjung Priok menggunakan metode *qualitative descriptive*. Hasil penelitiannya menunjukkan adanya korelasi positif yang tinggi diantara keduanya dengan rata-rata *dwelling time* sebesar 5.5 hari. Munim, ZH dkk. (2023) melakukan penelitian prediksi throughput container pada beberapa pelabuhan besar di Asia, seperti Shanghai, Busan dan Nagoya menggunakan ARIMA, SARIMA, HWES, dan Prophet. Penelitian ini menunjukkan bahwa SARIMA merupakan metode yang cukup kompetitif dibandingkan metode lainnya. Lee, GC, dkk (2024) melakukan kajian serupa pada pelabuhan di Singapura. Pada

penelitiannya, dibandingkan beberapa model seperti SARIMAX, LSTM, Prophet, dan tree-based model. Hasil penelitian menunjukkan bahwa SARIMAX unggul pada throughput musiman. Di Zhang & X. Li, dkk. (2024) melakukan penelitian yang berujung mengusulkan kerangka hybrid (*deep learning + decomposition*) dan menunjukkan perbaikan pada pelabuhan di Cina. Oh, dkk (2022) membandingkan model ARIMA, Prophet, dan Neural Prophet untuk memprediksi throughput container pada pelabuhan Pohang. Hasilnya menunjukkan Neural Prophet memiliki performa terbaik. Jiang, F, dkk (2021) menggunakan model *deep learning* untuk menganalisis *throughput container* di pelabuhan Qingdao, China. Hasil penelitiannya menunjukkan bahwa model *deep learning* yang digunakan dapat memberikan akurasi yang baik dan sesuai dengan karakteristik pelabuhan kajian. Penelitian terkait *throughput container* juga dilakukan oleh Li, M (2024) pada pelabuhan Tianjin. Model ARIMA yang digunakan dinilai sesuai dengan data yang ada dan memberikan akurasi yang baik. Xiao, dkk (2025) melakukan analisis terkait *container throughput* pada dua pelabuhan di China dengan menggunakan model hybrid *decomposition-reconstruction ensemble method*. Hasil penelitian menunjukkan performa yang unggul dihasilkan model *hybrid* tersebut dibandingkan model tradisional. Saber, dkk (2025) menggunakan metode *hybrid machine learning* untuk memprediksi waktu kedatangan kapal di pelabuhan. Dilakukan integrasi beberapa model seperti Extra Trees, AutoGluon Tabular, and LightGBM, dan Random Forest Regressor (RFR). Model tersebut dapat memberikan error MAPE yang sangat kecil sejumlah 0.25%.

Penelitian untuk pelabuhan di Indonesia, masih sedikit yang membahas prediksi volume bongkar-muat. Kebanyakan penelitian berfokus pada prediksi jumlah penumpang kapal yang masuk/keluar, maupun prediksi jumlah

kapal yang datang/pergi. Negara, RIP (2021) melakukan penelitian untuk memprediksi jumlah penumpang kapal di pelabuhan Pantai Baru dengan metode Sarima dan *Winter's Exponential Smoothing*. Hasilnya menunjukkan bahwa model SARIMA menunjukkan performa yang lebih baik. Riung, Nainggolan, dan Langi (2024) juga menggunakan model SARIMA untuk jumlah penumpang kapal laut di Pelabuhan Melonguane Kabupaten Kepulauan Talaud. Model SARIMA juga digunakan oleh Khoiriyah, dkk (2023) untuk memprediksi jumlah penumpang kapal di pelabuhan Balikpapan. Rismawati, dkk (2023) melakukan kajian untuk memprediksi jumlah penumpang kapal di Pelabuhan Soekarno Hatta, Makassar pada 2023, dengan metode LSTM. Hasilnya, model LSTM dapat memberikan prediksi dengan akurasi yang cukup baik. Fernando, dan Mailoa (2024) menggunakan metode *triple exponential smoothing* untuk memprediksi jumlah penumpang berangkat di Pelabuhan Tanjung Perak.

Perbandingan model SARIMA dengan Prophet dikaji oleh Cintani, dkk (2025) dalam penelitian terkait prediksi jumlah penumpang di pelabuhan Balikpapan. Hasil yang diperoleh menunjukkan model SARIMA memberikan akurasi lebih baik dibandingkan model Prophet. Ratmoko, dan Zuliarso (2025) membandingkan model SARIMA dan LSTM pada prediksi *throughput container* di pelabuhan Tanjung Emas, Semarang. Model SARIMA terbukti memberikan performa yang lebih baik. Fesalbon (2024) menggunakan model LSTM untuk memprediksi penumpang kapal pada dua pelabuhan di Filipina. Model tersebut dapat memberikan akurasi yang cukup baik pada dua pelabuhan yang dikaji.

Dari penjelasan di atas dapat dilihat bahwa masih terdapat ruang penelitian yang cukup besar untuk objek kajian prediksi volume bongkar-muat kapal di Indonesia, karena sebagian besar penelitian terdahulu tidak berfokus pada hal ini. Model SARIMA sering digunakan pada penelitian

terkait prediksi yang berkaitan dengan pelabuhan di Indonesia, dan terbukti memberikan hasil yang baik, namun dari hasil penelitian di luar Indonesia yang dijelaskan di atas, model *deep learning* (terutama LSTM / BiLSTM) banyak memberikan akurasi lebih baik bila data memiliki pola nonlinier atau dependensi jangka panjang. Beberapa penelitian menunjukkan LSTM unggul atas SARIMA/Prophet dalam kondisi tertentu. Hal ini menunjukkan bahwa model prediksi bersifat unik, dan tidak general. Performanya bergantung pada karakteristik data yang dimiliki. Oleh karena itu diperlukan kajian untuk melakukan perbandingan yang objektif terkait performansi model-model tersebut. Terdapat beberapa metrik evaluasi yang dapat digunakan seperti MAPE, MAE, dan MSE untuk menguji model. Melalui penelitian ini, dapat ditentukan model mana yang paling akurat dan sesuai dengan karakteristik bongkar-muat di Pelabuhan Tanjung Priok, Jakarta, Indonesia.

Penelitian ini bertujuan untuk menentukan model prediksi volume bongkar-muat di Pelabuhan Tanjung Priok, Jakarta. Dibandingkan tiga model; SARIMA, LSTM, dan Prophet. SARIMA dipilih karena merupakan model statistik klasik yang efektif menangkap pola musiman dan linier. LSTM dipilih karena merupakan salah satu model *deep learning* yang mampu mempelajari pola kompleks dan dependensi jangka panjang (*long-term dependencies*). Prophet model merupakan model prediksi *decomposable* yang fleksibel terhadap tren non-linear, *holiday effects*, dan ketidakteraturan data. Dengan mengkaji ketiga model ini, penelitian dapat mempelajari bagaimana karakteristik data mempengaruhi performa masing-masing model. Model terbaik dipilih berdasarkan akurasi yang dilihat dari metrik evaluasi seperti MAPE, MAE, RMSE, dan MSE. Penentuan model terbaik ini diharapkan dapat membantu pihak pengelola pelabuhan dalam perencanaan kapasitas, alokasi SDM, kesiapan peralatan, dan

pengambilan keputusan operasional lainnya.

Penelitian ini memiliki kontribusi secara praktikal dan teoritis. Secara praktikal, penelitian ini dapat membantu pihak pelabuhan memperoleh model terbaik untuk memprediksi volume bongkar-muat yang akurat sehingga akan membantu dalam aktivitas operasional maupun rencana strategis, seperti perencanaan kapasitas lapangan, penjadwalan kapal, alokasi tenaga kerja dan peralatan, dan evaluasi kinerja logistik. Secara teoritis, penelitian ini memperkaya literatur *forecasting* khususnya pada sektor maritim dan logistik Indonesia karena sebagian besar penelitian *forecasting* di Indonesia masih berfokus pada data ekonomi umum, energi, atau produksi komoditas. Penelitian yang membahas model prediksi khusus pada aktivitas bongkar-muat kapal masih cukup terbatas.

## MATERI DAN METODE

### *Forecasting*

*Forecasting* merupakan proses memprediksi nilai di masa depan berdasarkan data historis yang dimiliki. Terdapat beberapa karakteristik dalam *forecasting*, salah satunya adalah tidak selalu akurat 100%. Walaupun memiliki degree of error, *forecasting* tetap perlu dilakukan untuk memberikan gambaran di masa depan dan mempersiapkannya di masa sekarang. *Forecasting* dapat digunakan dalam berbagai bidang, termasuk ekonomi, keuangan, produksi, dan manajemen operasional. Tujuan utama *forecasting* adalah mengurangi ketidakpastian dan mendukung pengambilan keputusan yang lebih baik.

Untuk memperoleh akurasi prediksi yang baik, diperlukan metode *forecasting* yang tepat. Dilihat dari pendekatannya, terdapat dua jenis metode *forecasting*; kualitatif dan kuantitatif. Metode *forecasting* kualitatif penilaian subjektif, pendapat ahli, dan pengalaman untuk memprediksi nilai masa depan. Metode

*forecasting* kuantitatif menggunakan data historis dan teknik matematis, statistik, maupun *machine learning* dalam perhitungannya.

Pada metode *forecasting* kuantitatif, terdapat tiga pendekatan berkaitan dengan cara variabel target tersebut diprediksi, yaitu *time series forecasting*, *causal forecasting*, dan simulasi. *Time series forecasting* adalah metode *forecast* yang menggunakan nilai variabel tersebut di periode waktu lampau. Pada *time series forecasting*, penentuan metode didasarkan pada pola data yang dikandung. Terdapat setidaknya empat pola data pada *time series data*; stasioner, *trend*, *curvilinear*, dan *seasonal with linear trend*.

Saat ini, teknik *time series forecasting* sudah berkembang dengan cepat, sehingga menghasilkan berbagai metode yang beragam. Teknik perhitungan matematis sederhana seperti pada metode *moving average*, dan *exponential smoothing* mudah diterapkan namun memiliki keterbatasan dalam menangkap pola kompleks. Teknik statistik seperti pada metode ARIMA, dan SARIMA mampu memodelkan tren, musiman, dan residual dalam data historis dengan lebih baik dibandingkan teknik matematis sederhana. Perkembangan teknik komputasi memungkinkan adanya pendekatan *deep learning* melalui *machine learning* seperti pada metode LSTM, dan *neural network* yang dapat menangkap pola non-linear yang kompleks dan interaksi jangka panjang dalam data.

Model statistik klasik seperti ARIMA dan variasinya seperti SARIMA banyak digunakan untuk memodelkan data dengan komponen tren dan musiman dan sering menjadi dasar dalam penelitian terkait perbandingan model prediksi. Model prediksi berbasis *machine learning* seperti Long Short-Term Memory (LSTM) dapat menangkap pola non-linear dan ketergantungan jangka panjang yang tidak dapat diakomodasi oleh model statistik klasik. Model Prophet memiliki kelebihan fleksibilitas dalam memodelkan tren dan komponen musiman di dalam data.

### **Model SARIMA (Seasonal AutoRegressive Integrated Moving Average)**

Model SARIMA merupakan pengembangan dari model ARIMA, dimana model ini dapat digunakan untuk menganalisis data *time series* yang memiliki komponen musiman (*seasonality*). ARIMA dibentuk atas tiga komponen utama; *autoregressive* (AR) yang menangkap hubungan antara nilai saat ini dan nilai masa lampau, *differencing* (I) yang mengatasi *non-stationarity*, dan *moving average* (MA) yang mengakomodasi *error* masa lampau. Dalam banyak kasus, seperti pada data operasional pelabuhan, terdapat pola musiman seperti pola bulanan, tahunan, atau siklus tertentu. SARIMA menambahkan komponen *seasonality* (P,D,Q,s) untuk memodelkan pola tersebut sehingga mampu menangkap struktur periodik dalam data.


Model SARIMA memiliki kelebihan, diantaranya adalah sangat efektif untuk data dengan pola musiman yang kuat, modelnya transparan dan interpretatif karena setiap parameter AR, I, MA menggambarkan aspek struktural data, dan cukup stabil untuk data linier. Adapun beberapa kelemahan Model SARIMA adalah kurang sesuai untuk pola data *non-linear* atau yang sangat fluktuatif, pembentukan modelnya membutuhkan proses identifikasi parameter yang kompleks (p,q,d dan P,Q,D,s), termasuk pengecekan *stationarity*, ACF, dan PACF, dan kurang responsif karena tidak secara otomatis menangani perubahan tren jika struktur data berubah tiba-tiba.

### **Model LSTM (Long Short Term Memory)**

Long Short-Term Memory (LSTM) adalah model *machine learning* yang pertama kali diperkenalkan oleh Hochreiter dan Schmidhuber (1997). LSTM merupakan salah satu jenis dari model *Recurrent Neural Network* (RNN). Namun, tidak seperti RNN yang memiliki masalah *vanishing gradient*, LSTM menggunakan

cell state dan gating mechanisms (input gate, forget gate, output gate) yang memungkinkan model “mengingat” dan “melupakan” informasi penting secara selektif. Cell state pada LSTM merupakan jalur memori yang berperan membawahi informasi penting dari satu tahap ke tahap selanjutnya. Nilai cell state diperbaharui berdasarkan input baru dan informasi sebelumnya. Aliran informasi yang mengalir dimodifikasi melalui gating system (input, forget, output gates), sehingga memungkinkan gradien tetap

stabil selama proses *backpropagation* dan terhindar dari *vanishing gradient problem*. Gambar 3 menunjukkan *repeating modul* pada LSTM berdasarkan (D Li, 2022). Proses yang ada pada LSTM ini membuat LSTM unggul pada data dengan pola *non-linear* yang kompleks dan pada data yang sangat dinamis seperti aktivitas bongkar muat kapal. LSTM dapat menangkap interaksi antara *trend*, *seasonality*, fluktuasi acak, dan *hidden pattern* yang tidak tertangkap model statistik.



Gambar 3. *Repeating modul pada LSTM*  
(D Li, 2023)

Dibandingkan SARIMA dan Prophet, LSTM dapat menangani pola non-linear dengan baik. Model ini efektif pada data yang memiliki *long-term dependencies* seperti pola mingguan, bulanan, dan kejadian temporer. Adapun tantangan yang dimiliki untuk menggunakan model ini adalah diperlukannya dataset yang cukup besar agar model dapat berjalan dengan baik, dibutuhkannya waktu komputasi lebih lama saat *tuning hyperparameter*, sifat model yang sulit dipahami (*black box*), dan rentan mengalami *overfitting* jika data terbatas atau tahap *preprocessing* tidak dilakukan dengan baik.

### Model Prophet

Model Prophet merupakan model *forecasting* yang dikembangkan oleh Facebook (Ensafi, dkk, 2022). Model ini berbasis *decomposable additive* yang mendekomposisi data *time series* menjadi tiga komponen utama: *trend*, *seasonality*, dan *holiday/event*. Prophet dapat bekerja

dengan sangat baik pada data yang memiliki pola musiman yang fleksibel, tren non-linear, atau perubahan tren mendadak (*trend changepoint*). Model ini menggunakan kombinasi *piecewise linear trend* dan *fourier series* untuk memodelkan komponen *seasonality*, sehingga cocok untuk data yang mengalami perubahan pola musiman dari tahun ke tahun, seperti yang sering terjadi pada volume bongkar muat di pelabuhan

Model Prophet memiliki beberapa kelebihan, diantaranya adalah (1) mudah digunakan dan secara otomatis menangani *missing values*, *outlier*, dan perubahan tren, (2) fleksibel untuk data dengan pola *seasonality* yang kompleks, termasuk musiman harian, mingguan, dan tahunan, (3) cocok untuk data operasional yang tidak selalu stasioner atau tidak mengikuti pola linier. Beberapa kelemahan yang dimiliki model ini adalah (1) kurang optimal untuk pola jangka panjang yang sangat non-linear, jika dibandingkan dengan model *deep learning* seperti LSTM, (2) performanya

bergantung pada pemilihan *hyperparameters*, terutama jumlah *changepoints* yang memengaruhi fleksibilitas tren.

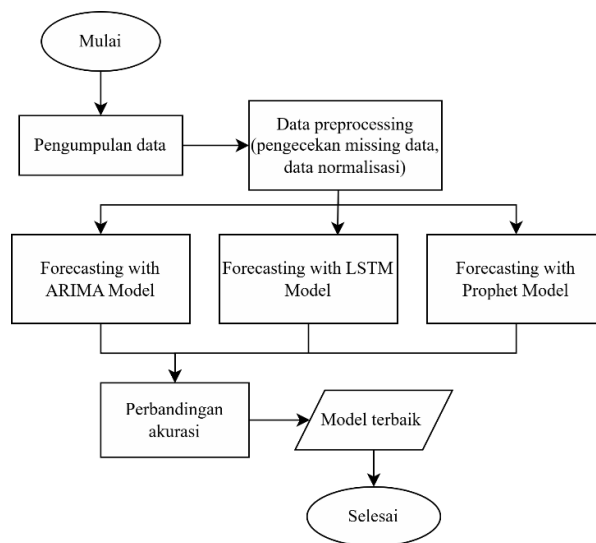
### Metodologi Penelitian

Penelitian ini bertujuan mengkaji tiga model *forecasting* untuk memprediksi volume bongkar-muat kapal di Pelabuhan Tanjung Priok, Jakarta. Ketiga model tersebut adalah SARIMA, LSTM, dan Prophet. Dilakukan *hyperparameter tuning* pada pembentukan ketiga model tersebut. Model dengan MAPE terkecil dipilih sebagai model terbaik. Gambar 4 menunjukkan *flowchart* penelitian.

Penelitian ini menggunakan data volume bongkar-muat kapal di Pelabuhan Tanjung Priok, Indonesia. Data ini diperoleh dari situs Badan Pusat Statistik Indonesia yang dapat diakses pada <https://www.bps.go.id/id/statistics-table/2/NjgjMg==/bongkar-muat-barang-angkutan-laut-antar-pulau-di-pelabuhan->

utama--ton-.html. Data yang digunakan merupakan data *time series*, dari Januari 2017 hingga Desember 2025. Nilai volume merupakan jumlah dari volume bongkar dan volume muat. Terdapat 105 entri data yang terdiri dari dua kolom, yaitu bulan dan volume barang (ton).

Tahap selanjutnya adalah mempersiapkan data untuk diolah lebih lanjut. Pada tahap ini dilakukan pengecekan data kosong, dan normalisasi data. Pengecekan melalui python menunjukkan tidak terdapat data kosong, sehingga tidak diperlukan data imputasi ataupun data *cleaning*. Gambar 5 menunjukkan proses pengecekan data kosong pada python dengan hasil tidak ada data yang kosong. Normalisasi dilakukan untuk meningkatkan akurasi model. Tahapan *pre-processing* yang terakhir adalah membagi data menjadi dataset *training* (70%), *validasi* (15%), dan *testing* (15%).



Gambar 4. *Flowchart* Penelitian

```
# Memeriksa data yang kosong
missing_values = df.isnull().sum()
print(missing_values)
```

---

```
Month          0
Barang (Ton)   0
dtype: int64
```

Gambar 5. Pengecekan *missing data*

## HASIL PENELITIAN DAN PEMBAHASAN

### Model SARIMA

Pengolahan data untuk model SARIMA dilakukan dengan bahasa pemrograman Python pada *Google Colaboratory*. Digunakan fitur auto arima untuk mencari parameter (p,d,q)(P,D,Q) terbaik. Metrik evaluasi yang digunakan adalah MAPE, MSE, RMSE, R<sup>2</sup>, MAE. Pemeriksaan *stationarity* dilakukan dengan *adfuller*. Identifikasi pola AR dan MA dilihat dari nilai ACF dan PACF. Dilakukan *cross validation* pada data training untuk menyeleksi nilai parameter terbaik saat auto arima menjalankan prosesnya. Metric yang digunakan pada *cross validation* ini adalah MAE. *Seasonal period* yang digunakan adalah 12. Setelah model terbaik diperoleh dari data training, model tersebut digunakan pada gabungan data training dan validasi sebagai final model. Gambar 6 menunjukkan final model SARIMA yang dihasilkan. Model SARIMA yang optimal adalah SARIMA (0,1,1) yang berarti tidak terdapat komponen autoregressive, dilakukan *data differencing* satu kali, dan terdapat satu komponen moving average. Final model tersebut selanjutnya digunakan

pada set data test untuk diuji performansinya. Gambar 7 menunjukkan *forecast* yang dihasilkan pada test data. Dari gambar tersebut dapat dilihat bahwa hasil prediksi cukup dapat mengikuti nilai aktual data.

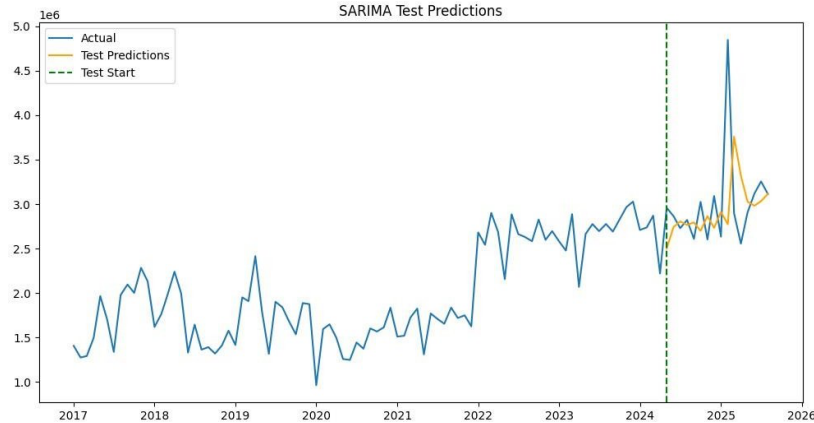
### Model LSTM

Pembentukan model LSTM dilakukan pada *Google Colaboratory* menggunakan bahasa pemrograman python. Pada model LSTM yang dilatih, dilakukan *hyperparameter tuning*. Jumlah layer yang di-tuning adalah 1 dan 2. Jumlah node yang digunakan pada setiap layer di-tuning dengan jumlah min 32 dan max 160 pada layer 1, dan min 32 dan max 128 pada layer 2. Step yang digunakan pada pemilihan node ini adalah 32. Epoch yang digunakan adalah 80 dengan batch size sejumlah 16. Tabel 1 menunjukkan detail *tuning* tersebut. Setelah diperoleh nilai *hyperparameter* terbaik, digunakan test dataset untuk menguji model yang terbentuk. Gambar 8 menunjukkan hasil prediksi dari model tersebut pada set data training, validasi, dan test. Dari gambar tersebut terlihat bahwa model dapat memberikan prediksi yang relatif mengikuti nilai aktual.

```
final_model.summary()
```

SARIMAX Results						
Dep. Variable:	y			No. Observations:	88	
Model:	SARIMAX(0, 1, 1)	Log Likelihood	-1223.515			
Date:	Wed, 19 Nov 2025	AIC	2451.031			
Time:	05:57:07	BIC	2455.963			
Sample:	01-01-2017	HQIC	2453.017			
			-04-01-2024			
Covariance Type: opg						
	coef	std err	z	P> z	[0.025	0.975]
ma.L1	-0.4612	0.095	-4.852	0.000	-0.648	-0.275
sigma2	9.321e+10	8.78e-14	1.06e+24	0.000	9.32e+10	9.32e+10
Ljung-Box (L1) (Q):	0.14	Jarque-Bera (JB):	5.73			
Prob(Q):	0.71	Prob(JB):	0.06			
Heteroskedasticity (H):	0.93	Skew:	-0.30			
Prob(H) (two-sided):	0.85	Kurtosis:	4.10			

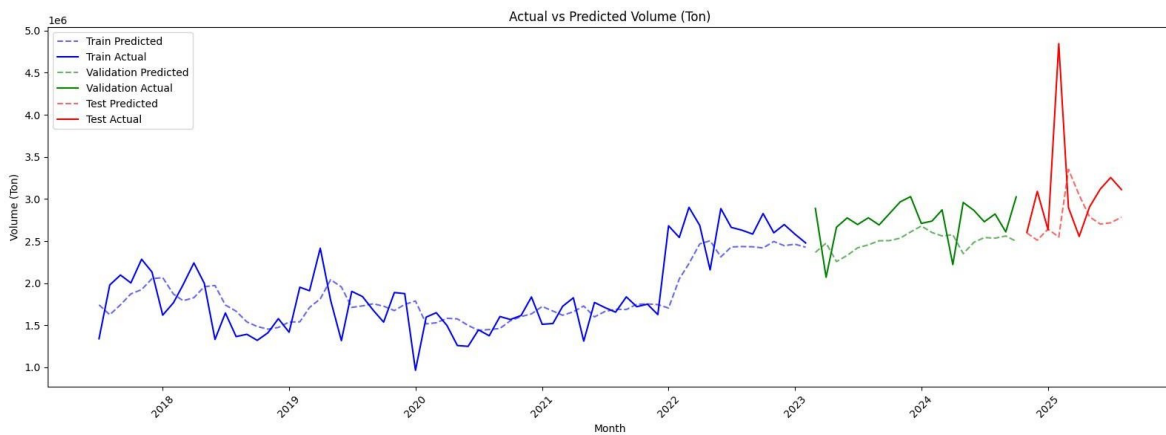
Gambar 6. Model SARIMA terbaik



Gambar 7. Prediksi pada test data model SARIMA

Tabel 1. Nilai *hyperparameter tuning* untuk model LSTM

<i>Hyperparameter</i>	<i>Rentang Tuning</i>	<i>Nilai terbaik</i>
<i>lag / window size</i>	3–12 bulan	6
<i>num_layers</i>	1 atau 2 LSTM layer	1
<i>units_layer1</i>	32–160	64
<i>units_layer2</i>	32–128	128
<i>dropout1</i>	0.0–0.4	0.3
<i>dropout2</i>	0.0–0.4 (jika layer 2 aktif)	0.1
<i>Learning rate (Adam)</i>	1e-4 – 1e-2	0.007



Gambar 8. Hasil prediksi pada model LSTM

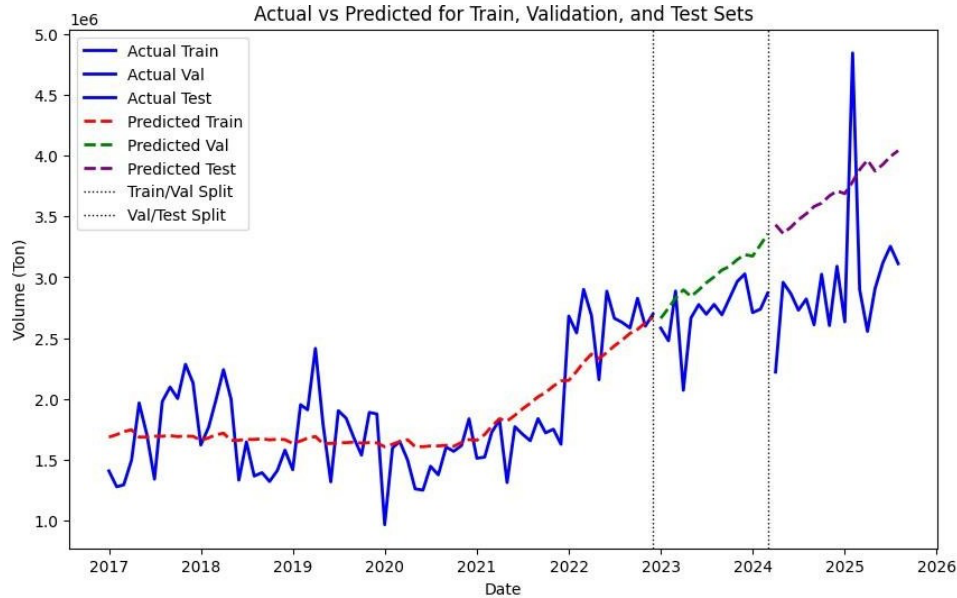
### Model Prophet

Untuk model Prophet, terdapat tiga *hyperparameter* yang *di-tuned*, yaitu *changepoint prior scale*, *seasonality prior scale*, *seasonality mode*. *Changepoint prior scale* mengontrol seberapa fleksibel model dalam menyesuaikan tren saat terjadi perubahan tiba-tiba. *Seasonality prior scale* mengontrol kekuatan *seasonality* pada model. *Seasonality mode* membantu model

menangkap pola *seasonality* dengan benar. Tabel 2 menunjukkan nilai yang *di-tuned* dan hasil nilai terbaik. Gambar 9 menunjukkan hasil prediksi pada model Prophet untuk seluruh set data. Dari gambar dapat dilihat bahwa model relatif lebih sulit buruk dibanding model SARIMA dan LSTM.

**Tabel 2. Nilai *hyperparameter tuning* untuk model Prophet**

<i>Hyperparameter</i>	<i>Rentang Tuning</i>	<i>Nilai terbaik</i>
<i>Changepoint Prior Scale</i>	0.01, 0.1, 0.5	0.1
<i>Seasonality prior scale</i>	0.01, 0.1, 1.0	0.01
<i>Seasonality Mode</i>	<i>additive, multiplicative</i>	<i>multiplicative</i>



Gambar 9. Hasil prediksi pada model Prophet

### Perbandingan Performa Model

Ketiga model yang digunakan, SARIMA, LSTM, dan Prophet, memiliki kelemahan dan kelebihan masing-masing. Berdasarkan penelitian terdahulu, model *forecasting* untuk volume bongkar-muat relatif unik dan tergantung pada karakteristik data. Tabel 3 menunjukkan perbandingan akurasi ketiga model untuk data volume bongkar-muat di Pelabuhan Tanjung Priok, Jakarta. Dari tabel tersebut, dapat dilihat bahwa model SARIMA memberikan akurasi terbaik sehingga cocok untuk digunakan dalam memprediksi volume bongkar-muat di pelabuhan Tanjung Priok.

SARIMA memberikan hasil terbaik. Hal ini dikarenakan data volume bongkar-muat yang digunakan memiliki pola musiman dan tren yang relatif stabil, sehingga SARIMA mampu menangkap tren jangka panjang dan musiman dengan baik. LSTM juga memberikan performa yang mendekati. LSTM cenderung lebih

fleksibel menangkap non-linearitas jangka pendek, tetapi pada dataset ini musiman dan tren linear lebih dominan, sehingga LSTM sedikit kalah dari SARIMA. Jika terjadi perubahan tren non-linear di masa depan, LSTM lebih optimal digunakan. Prophet memiliki performa terburuk. Hal ini dapat disebabkan karena model Prophet lebih sensitif terhadap *seasonality multiplicative* atau *changepoint* sehingga jika tidak *tuned* dengan baik, prediksi bisa bias. Selain itu, terdapat kemungkinan dataset terlalu pendek untuk Prophet menangkap tren tahunan dengan baik.

Kebaruan penelitian ini terletak pada pembuktian bahwa model statistik klasik masih dapat mengungguli model *deep learning* dalam karakteristik operasional tertentu. LSTM dikenal memiliki kemampuan dalam memodelkan pola non-linear yang kompleks, namun hasil empiris menunjukkan bahwa SARIMA menghasilkan akurasi peramalan yang lebih tinggi pada penelitian ini. Karakteristik data deret waktu yang memiliki pola musiman

yang kuat, tren yang relatif stabil, serta jumlah data yang terbatas memberikan keunggulan pada model SARIMA. Temuan ini menunjukkan bahwa performa model forecasting tidak hanya ditentukan oleh kompleksitas model, namun juga kesesuaian antara karakteristik data dan asumsi model yang digunakan. Hasil

penelitian ini juga memberikan implikasi praktis bagi otoritas pelabuhan dan perencana logistik bahwa model yang lebih sederhana seperti SARIMA tetap efektif dan efisien secara komputasional untuk prediksi volume bongkar muat jangka pendek hingga menengah.

**Tabel 3. Perbandingan performa model prediksi**

<i>Metric</i>	<b>SARIMA</b>	<b>LSTM</b>	<b>Prophet</b>
MSE	3.97E+11	6.65E+11	8.23E+11
MAE	393,830.98	524,023.44	871,474.53
MAPE	12.03%	14.62%	30.60%
Akurasi	87.97%	85.38%	69.40%

### **KESIMPULAN DAN IMPLIKASI**

Hasil evaluasi menunjukkan bahwa model SARIMA (87.97%) memberikan akurasi tertinggi dibandingkan LSTM (85.38%) dan Prophet (69.40%) pada test dataset. Model SARIMA merupakan model terbaik untuk memprediksi volume bongkar-muat Pelabuhan Tanjung Priok, Jakarta. Untuk jangka panjang, jika terjadi perubahan tren nonlinear, LSTM dapat digunakan. Hasil penelitian ini diharapkan dapat membantu perencanaan operasional pelabuhan, dan pengambilan keputusan strategis.

Penelitian ini memiliki beberapa keterbatasan yang dapat menjadi ruang kebaruan untuk penelitian-penelitian selanjutnya. Analisis pada penelitian ini hanya menggunakan satu dataset volume bongkar-muat pelabuhan, yaitu pada pelabuhan Tanjung Priok, Jakarta. Hal ini menunjukkan keterbatasan dalam generalisasi ke pelabuhan lain. Selain itu, penelitian ini hanya mencakup variabel volume bongkar muat tanpa mempertimbangkan faktor eksternal seperti cuaca, harga BBM, atau kondisi perdagangan nasional/internasional, hanya membandingkan tiga model dengan keterbatasan *hyperparameter tuning* yang dilakukan. Penelitian selanjutnya dapat

ditingkatkan melalui beberapa hal seperti menyertakan faktor eksternal seperti cuaca, harga BBM, jadwal kedatangan kapal, atau indeks perdagangan global untuk meningkatkan akurasi prediksi. Meningkatkan jumlah data historis juga diekspektasi dapat membantu model menemukan pola time series yang dimiliki. Penelitian selanjutnya juga dapat menggunakan model prediksi *hybrid* atau model *machine learning* yang lebih *advanced*, dan melakukan *hyperparameter tuning* dengan lebih kompleks.

### **UCAPAN TERIMAKASIH**

Terimakasih kepada Pelabuhan Tanjung Priok dan seluruh responden yang telah membantu penelitian ini mengenai Perbandingan Model Prediksi Sarima, LSTM, dan Prophet dalam Prediksi Volume Bongkar-Muat Kapal di Pelabuhan Tanjung Priok.

### **DAFTAR PUSTAKA**

Cintani, M., dkk. (2025). Evaluation of the SARIMA and Prophet Models in Forecasting Ship Passenger Numbers at Balikpapan Port. *Jambura Journal of Mathematics*, 7(2), 120–128.

- <https://doi.org/10.37905/jjom.v7i2.31606>
- D. Li, "Feature Selection Based on Stock Prediction Model," J. Phys. Conf. Ser., vol. 2386, no. 1, 2022, doi: 10.1088/1742-6596/2386/1/012021
- Ensafi, Y., dkk. (2022). Time-series forecasting of seasonal items sales using machine learning – A comparative analysis. International Journal of Information Management Data Insights. 2 (1). <https://doi.org/10.1016/j.jjime.2022.100058>
- Fesalbon, D. (2024). Forecasting Ferry Passenger Flow Using Long-Short TermMemory Neural Networks. International Journal of Scientific Research and Engineering Development, 7(3), <https://doi.org/10.48550/arXiv.2405.02098>
- Fernando, Z., & Mailoa, E. (2024). Implementasi *Time series* Dalam Prediksi Jumlah Keberangkatan Penumpang di Pelabuhan Tanjung Perak. Jutisi : Jurnal Ilmiah Teknik Informatika Dan Sistem Informasi, 13(2), 1296-1303. doi:<http://dx.doi.org/10.35889/jutisi.v13i2.1998>
- Jiang, F., Xie, G., dan Wang, S. Forecasting Port Container Throughput with Deep Learning Approach. The 5th International Conference on Computer Science and Application Engineering (CSAE 2021), October 19-21, 2021, Sanya, China, DOI: <https://doi.org/10.1145/3487075.3487173>
- Khoiriyah, N. S., dkk. (2023). Peramalan Jumlah Penumpang Kapal di Pelabuhan Balikpapan dengan SARIMA. Jurnal Statistika dan Komputasi. 2(2):76-82. Doi: 10.32665/statkom.v2i2.2303.
- Lee, G.-C., & Bang, J.-Y. (2024). *Forecasting* Container Throughput of Singapore Port Considering Various Exogenous Variables Based on SARIMAX Models. *Forecasting*, 6 (3), 748-760. <https://doi.org/10.3390/forecast6030038>
- Li, M. (2024). Port Throughput Forecast Based on ARIMA Model-Take Tianjin Port as an Example. Highlights in Science, Engineering and Technology, 105, 11-17. <https://doi.org/10.54097/dv0kzs60>
- Munim, Z. H., dkk. (2023). *Forecasting* container throughput of major Asian ports using the Prophet and hybrid *time series* models. The Asian Journal of Shipping and Logistics, 39 (2), 67-66. <https://doi.org/10.1016/j.ajsl.2023.02.004>.
- Negara, R. I. P. (2021). Peramalan Jumlah Penumpang Kapal di Pelabuhan Pantai Baru dengan Metode Sarima Dan Winter's Exponential Smoothing. Jurnal Statistika Terapan (ISSN 2807-6214), 1(1), 63-78.
- Oh, J.H., dkk. (2022). Throughput Prediction of Pohang Port using *Time series* Data: Application of SARIMA, Prophet and Neural Prophet. Korea Trade Review. 47 (6). 291-305. <https://doi.org/10.22659/KTRA.2022.47.6.291>
- Ratmoko, H., & Zuliarso, E. (2025). Time Series Forecasting for Container Throughput Using SARIMA and LSTM: A Case Study of Tanjung Emas Port, Semarang. Maritime Park: Journal of Maritime Technology and Society, 4(3), 232-242. <https://doi.org/10.62012/mp.vi.45866>
- Ricardianto, P., Suhalis, A., Siarit, D. P. (2018). Integrasi antara Dwelling Time dan Bingkar Muat Peti Kemas Pelabuhan Tanjung Priok. Jurnal Manajemen Transportasi & Logistik. 5(3). doi: 10.54324/j.mtl.v5i3.265
- Rismawati, Alwi, W., Sauddin, A., & Adiatma. (2024). Peramalan Jumlah Penumpang Kapal Laut Menggunakan Metode *Time series Machine learning*

- di PT Pelabuhan Indonesia (Persero) Regional 4 (Studi Kasus Pada Pelabuhan Soekarno Hatta Makassar). *Jurnal MSA (Matematika Dan Statistika Serta Aplikasinya)*, 12(2), 68–78.  
<https://doi.org/10.24252/msa.v12i2.51076>.
- Riung, R., Nainggolan, N., & Langi, Y.A.R. (2024). Peramalan Jumlah Penumpang Kapal Laut di Pelabuhan Melonguane Kabupaten Kepulauan Talaud Menggunakan Metode SARIMA. *Jurnal MIPA (JM)*. Vol. 13 No. 2. DOI: <https://doi.org/10.35799/jm.v13i2.55741>
- Saber, dkk. (2025). High-accuracy prediction of vessels' estimated time of arrival in seaports: A hybrid machine learning approach. *Maritime Transport Research*. Vol 8. <https://doi.org/10.1016/j.martra.2025.100133>
- Xiao, Y., dkk. (2025). Analyzing and Forecasting Container Throughput With a Hybrid Decomposition-Reconstruction-Ensemble Method: A Study of Two China Ports. *Journal of Forecasting*. 44(4). <https://doi.org/10.1002/for.3253>
- Zhang, D., dkk. (2024). A novel hybrid deep-learning framework for medium-term container throughput forecasting: an application to China's Guangzhou, Qingdao and Shanghai hub ports. *Marit Econ Logist* 26, 44–73. <https://doi.org/10.1057/s41278-024-00284-2>