

Penerapan Model Long Short Term Memory Pada Jumlah Produksi Pupuk Di PT. Pelindo Gresik

Ro'iqotul Fathiyah Romdloni¹, Dian Yuliati², Nurissaidah Ulinnuha³

^{1,2,3} Program Studi Matematika, UIN Sunan Ampel Surabaya
Jl. Jend. A. Yani 117 Surabaya 60237, Indonesia
Korespondensi penulis : dian.yuliati@uinsa.ac.id

Submitted : 14 Oktober 2024

Accepted : 30 Juli 2025

Published : 30 Juli 2025

Abstrak

PT Pelindo Multi Terminal Petikemas Branch Gresik merupakan pelabuhan dengan aktivitas bongkar muat pupuk yang tinggi, sehingga membutuhkan sistem prediksi yang andal untuk mendukung efisiensi operasional. Penelitian ini menerapkan model Long Short-Term Memory (LSTM) untuk memprediksi jumlah produksi pupuk berdasarkan data bulanan tahun 2018–2023. Data dianalisis melalui tahapan normalisasi, pelatihan model, dan evaluasi menggunakan metrik MAPE, MSE, RMSE, dan MAE. Hasil terbaik diperoleh pada epoch ke-300 dengan nilai MAPE sebesar 18,60%, MSE sebesar 258.141.463,92, RMSE sebesar 19.745,11, dan MAE sebesar 14.533,75, yang menunjukkan tingkat akurasi prediksi yang baik. Penggunaan LSTM dinilai relevan karena mampu mengenali pola musiman dan fluktuasi jangka panjang dalam data deret waktu, yang umum terjadi dalam konteks industri pupuk. Keunikan penelitian ini terletak pada penerapan LSTM dalam skenario pelabuhan pupuk di Indonesia, yang masih jarang diteliti, serta evaluasi komprehensif terhadap performa model pada konteks industri logistik pelabuhan.

Kata Kunci: Pelindo, Pelabuhan, Produksi Pupuk, LSTM.

Abstract

PT Pelindo Multi Terminal Petikemas Branch Gresik is a port with high fertilizer unloading activity, requiring a reliable forecasting system to support operational efficiency. This study applies the Long Short-Term Memory (LSTM) model to predict fertilizer production volumes using monthly data from 2018 to 2023. The data were processed through normalization, model training, and evaluation using MAPE, MSE, RMSE, and MAE metrics. The best performance was achieved at epoch 300, with a MAPE of 18.60%, MSE of 258,141,463.92, RMSE of 19,745.11, and MAE of 14,533.75, indicating good predictive accuracy. LSTM is considered

relevant due to its ability to capture seasonal patterns and long-term dependencies, which are common in the fertilizer industry. The novelty of this study lies in the implementation of LSTM in the context of fertilizer logistics at an Indonesian port, which has been rarely explored, along with a comprehensive evaluation of its predictive performance.

Keywords: Pelindo, Port, Container, LSTM.

1. Pendahuluan

PT Pelindo Multi Terminal adalah subholding dari PT Pelabuhan Indonesia (Persero) yang mengelola berbagai terminal multipurpose di Indonesia, termasuk terminal petikemas. Cabang Gresik merupakan salah satu dari banyak cabang yang dikelola oleh PT Pelindo Multi Terminal yang berfokus pada operasi terminal petikemas dan layanan bongkar muat. Selaku pengelola terminal petikemas terbesar di Indonesia, PT Pelindo Multi Terminal Petikemas Branch Gresik memiliki tanggung jawab strategis dalam menjamin kelancaran dan efisiensi proses bongkar muat pupuk untuk mendukung tercukupinya ketersediaan pupuk di seluruh wilayah [1]. Pengelolaan bongkar muat pupuk di PT Pelindo Multi Terminal Petikemas Branch Gresik sangat penting dalam menjaga kelancaran rantai pasok pupuk nasional. Terdapat standarisasi dan integrasi jaringan antarterminal yang dilakukan oleh (Pelindo Terminal Petikemas) SPTP dengan tujuan proses bongkar muat pupuk dapat berjalan secara efisien dan terkoordinasi, sehingga meminimalisir

Ketidakpastian dalam kegiatan bongkar muat pupuk dapat disebabkan oleh beberapa tantangan, seperti fluktuasi cuaca, yang dapat mengganggu proses bongkar muat karena kondisi cuaca buruk dapat memperlambat atau bahkan menghentikan operasi. Selain itu, keterbatasan kapasitas penyimpanan di pelabuhan juga dapat menyebabkan penundaan, terutama ketika jumlah pupuk yang diimpor melebihi kapasitas fasilitas yang tersedia. Keterlambatan kapal atau masalah teknis pada alat bongkar muat seperti crane atau conveyor juga bisa menjadi faktor lain yang mempengaruhi ketepatan waktu operasi. Tidak hanya itu, kekurangan tenaga kerja atau perubahan regulasi terkait impor atau distribusi pupuk dapat meningkatkan ketidakpastian dan mempersulit perencanaan logistik secara efisien [2]. Kendala yang paling berpotensi di lapangan dalam bongkar pupuk dominan diakibatkan perubahan cuaca yang tidak menentu. PT Pelindo Multi Terminal Petikemas Gresik berperan penting dalam optimalisasi proses bongkar muat pupuk. PT. Pelindo Multi Terminal Petikemas Gresik telah mengimplementasikan langkah strategis untuk meningkatkan efisiensi operasional, salah satu inisiatif utama adalah penerapan sistem pemantauan digital untuk melakukan pengecekan pupuk secara rutin. Pendekatan berbasis teknologi ini memungkinkan perusahaan untuk memantau kondisi dan kuantitas pupuk dengan lebih akurat dan real-time. Hal ini tidak hanya meningkatkan efisiensi operasional, tetapi juga membantu dalam menjaga kualitas pupuk selama proses penyimpanan dan distribusi.

PT. Pelindo Multi Terminal Petikemas Gresik memang tidak bertanggung jawab langsung atas pengelolaan stok pupuk, karena itu merupakan tanggung jawab produsen atau distributor pupuk. Namun, sebagai operator pelabuhan, Pelindo berperan dalam mengoptimalkan proses bongkar muat dan penyimpanan sementara di pelabuhan. Dengan mengadopsi metode prediktif, mereka dapat menganalisis tren kedatangan barang dan kapasitas penyimpanan yang tersedia. Informasi ini membantu Pelindo dalam menentukan jadwal bongkar muat yang tepat dan menghindari kendala seperti penyimpanan penuh di gudang pelabuhan. Dengan begitu, operasional logistik tetap berjalan lancar dan pupuk dapat segera didistribusikan ke tujuan akhir tanpa penundaan,

Dalam upaya meningkatkan akurasi prediksi dan mengatasi ketidakpastian dalam kegiatan bongkar muat, terdapat metode *machine learning* yang dapat membantu mengatasi hal tersebut. Salah satu pendekatan yang diimplementasikan adalah *Long Short-Term Memory* (LSTM), sebuah jenis arsitektur jaringan saraf tiruan yang khusus dirancang untuk menganalisis dan memprediksi pola dalam data deret waktu.

Long Short Term Memory (LSTM) adalah jenis jaringan saraf rekurensial (RNN) yang mampu menangani masalah pengolahan data misalnya dalam memprediksi dalam urutan data [3]. Penerapan LSTM pada data historis bongkar muat pupuk, dapat dimodelkan pola-pola kompleks dalam data dan secara akurat dalam pengolahan data jumlah bongkar muat di masa depan [4].

Terdapat penelitian-penelitian terdahulu terkait dengan metode prediksi, diantaranya penelitian [5] dengan menggunakan metode *Long Short Term Memory* untuk prediksi tingkat temperatur di kota Semarang diperoleh informasi bahwa nilai evaluasi yang diperoleh yaitu, evaluasi RMSE sebesar 0,725 dan MAPE sebesar 1,896016%. Kemudian penelitian [6] dengan menggunakan metode *Recurrent Neural Network* (RNN) untuk prediksi harga kelapa sawit diperoleh hasil akhir dengan nilai evaluasi MAPE sebesar 4,84%. Selanjutnya penelitian [7] dengan metode regresi linier untuk prediksi penjualan mobil Toyota di industri otomotif Indonesia diperoleh nilai MAPE sebesar 12,47% dan nilai RMSE sebesar 3360,26.

Dari penelitian terdahulu didapatkan informasi bahwa nilai MAPE yang lebih tinggi dalam penelitian [7] menunjukkan bahwa metode regresi linier memiliki performa yang kurang baik dalam prediksi data deret waktu dibandingkan dengan metode RNN dan LSTM. Perbandingan ini menunjukkan bahwa LSTM memberikan hasil prediksi yang lebih akurat pada beberapa kasus, terutama dalam prediksi yang melibatkan data yang memiliki pola temporal.


Berdasarkan dari penelitian terdahulu dan permasalahan yang telah dipaparkan, Penelitian ini memilih metode LSTM dikarenakan dari keunggulan LSTM yang terletak pada kemampuannya untuk menangani data berurutan dengan baik. Artinya, LSTM dapat memproses informasi yang datang secara berurutan, seperti waktu, teks, atau data audio, yang merupakan kasus yang umum terjadi di banyak aplikasi seperti prediksi

harga saham, analisis sentimen, atau terjemahan bahasa [8]. Selain itu, LSTM juga dapat menangkap pola jangka panjang dalam data, itu berarti dapat mempertimbangkan hubungan antara data yang dipisahkan oleh interval waktu yang signifikan [9]. Hal ini membuatnya sangat berguna dalam memodelkan dan memprediksi tren jangka panjang atau pola yang kompleks dalam data [10]. Disamping kemampuannya untuk menangani data berurutan, keunggulan lain dari LSTM adalah fleksibilitasnya dalam menangani berbagai jenis data. Hal ini termasuk data numerik, kategorikal, teks, atau bahkan gambar, karena arsitektur LSTM dapat diadaptasi untuk memproses dan memahami berbagai format data dengan baik [11].

Tujuan dari penelitian ini untuk mengevaluasi kinerja metode LSTM dalam pengolahan data jumlah produksi pupuk pada kegiatan bongkar muat pupuk di PT. Pelindo Multi Terminal Petikemas Branch Gresik. Dengan penelitian ini diharapkan dengan hasil prediksi LSTM dapat membantu dalam mengoptimasi jumlah kegiatan bongkar muat pupuk serta dapat meningkatkan efisiensi pada kegiatan bongkar muat pupuk pada PT Pelindo Multi Terminal Petikemas Branch Gresik.

2. Metode Penelitian

Jenis data yang digunakan dalam analisis ini adalah data sekunder yang langsung diambil pada PT Pelindo Multi Terminal Petikemas Branch Gresik. Data yang digunakan adalah data jumlah barang pupuk dalam rentang tahun 2018-2023. Berikut tahapan dan diagram alir penelitian yang dilakukan:



Gambar 1 Diagram Alir Penelitian

Berikut penjelasan tiap langkah-langkah LSTM:

1. Mulai: Penelitian dimulai dengan mengumpulkan data historis terkait bongkar muat pupuk.
2. Data Historis Bongkar Muat Pupuk: Data yang digunakan adalah data historis aktivitas bongkar muat pupuk. Data ini menjadi bahan dasar untuk proses analisis lebih lanjut.
3. Memasukkan Data: Data historis yang sudah dikumpulkan kemudian dimasukkan ke dalam sistem untuk diproses lebih lanjut.
4. Normalisasi Data: Data yang telah dimasukkan dilakukan normalisasi untuk menyamakan skala variabel sehingga dapat diproses oleh model dengan lebih efektif.
5. Analisis Statistika Deskriptif: Data yang telah dinormalisasi kemudian dianalisis secara statistik untuk memahami distribusi, pola, dan tren dalam data tersebut.
6. Membagi Data: Setelah analisis, data dibagi menjadi dua bagian: data uji dan data latih. Data latih digunakan untuk melatih model, sedangkan data uji digunakan untuk mengevaluasi performa model.
7. Melatih Data: Pada tahap ini, data latih digunakan untuk melatih model LSTM. Model ini merupakan jenis Recurrent Neural Network (RNN) yang sering digunakan untuk memprediksi data deret waktu.
8. Model LSTM: Model LSTM yang telah dilatih siap untuk diuji dengan data uji.

9. Pengujian Model: Model LSTM diuji menggunakan data uji untuk melihat seberapa baik model dalam melakukan prediksi.
10. Evaluasi Model: Setelah pengujian, dilakukan evaluasi terhadap performa model untuk mengetahui tingkat akurasi prediksi dan identifikasi kesalahan yang mungkin terjadi.
11. Denormalisasi Data: Hasil prediksi yang awalnya dinormalisasi dikembalikan ke skala aslinya agar lebih mudah diinterpretasi.
12. Prediksi: Setelah data dinormalisasi, hasil prediksi aktivitas bongkar muat pupuk dapat diperoleh.
13. Selesai: Proses penelitian selesai setelah mendapatkan hasil prediksi yang diharapkan.

3. Landasan Teori

3.1 Bongkar Muat Logistik

Bongkar muat logistik adalah proses pengangkutan barang dari satu tempat ke tempat lain yang melibatkan kegiatan memuat barang ke dalam kendaraan pengangkut di titik asal dan membongkar barang dari kendaraan pengangkut di titik tujuan. Proses ini menjadi bagian penting dalam logistik, karena memungkinkan pengiriman barang secara efektif dan efisien dari sumber ke tujuan akhir.

3.2 Rantai Pasok Pupuk

Rantai pasok pupuk mengacu pada serangkaian kegiatan dan proses yang terjadi dari tahap produksi pupuk hingga sampai ke tangan konsumen akhir [12]. Berikut adalah penjelasan mengenai beberapa tahapan dalam rantai pasok pupuk:

3.2.1 Produksi

Setelah pupuk diproduksi, langkah selanjutnya adalah pengemasan. Pupuk dikemas dalam kemasan yang sesuai, baik itu kemasan besar untuk penggunaan komersial atau kemasan kecil untuk konsumen akhir. Proses ini bisa dilakukan di pabrik pupuk yang besar atau fasilitas produksi yang lebih kecil [13].

3.2.2 Pengemasan

Setelah pupuk diproduksi, langkah selanjutnya adalah pengemasan. Pengemasan adalah tahap yang sangat penting dalam rantai pasok pupuk karena memungkinkan pengiriman produk pupuk yang berkualitas ke konsumen dengan cara yang efektif dan efisien [14].

3.2.3 Distribusi

Pupuk kemudian didistribusikan ke berbagai daerah atau wilayah. Distribusi ini melibatkan transportasi pupuk dari pabrik produksi ke gudang

penyimpanan pelabuhan di berbagai lokasi. Dalam sistem distribusi pupuk, transportasi adalah langkah penting untuk mengangkut produk dari pabrik produksi ke gudang penyimpanan pelabuhan di berbagai lokasi [15].

3.2.4 Bongkar Muat

Proses bongkar muat adalah tahap yang sangat penting dalam sistem distribusi pupuk. Proses ini melibatkan beberapa tahapan, seperti pengangkutan dari kapal, pengawasan kualitas, penyimpanan sementara, dan distribusi lanjutan. Proses bongkar muat yang efektif dan efisien sangat penting dalam memastikan kualitas produk pupuk dan memenuhi kebutuhan konsumen [16].

3.2.5 Distribusi Akhir

Setelah bongkar muat, pupuk siap untuk didistribusikan ke konsumen akhir, yang bisa berupa petani, produsen pertanian, atau pabrik-pabrik yang menggunakan pupuk sebagai bahan baku. Proses distribusi ini melibatkan beberapa langkah, termasuk pengaturan logistik, pengiriman, dan manajemen inventaris [17].

3.3 Min-max Normalization

Normalisasi adalah proses penskalaan nilai pada data bertujuan nilai data berada pada range tertentu. Bentuk dari normalisasi data ini adalah *Min-max Normalization*. Proses normalisasi ini menggunakan cara transformasi linier terhadap data aslinya. Hal ini dilakukan seperti pada Persamaan (1) [18]

$$X' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Keterangan:

X' = Hasil normalisasi

x = Nilai x (asli)

$\min(x)$ = Nilai minimal untuk variabel x

$\max(x)$ = Nilai maksimal untuk variabel x

3.4 Fungsi Aktivasi

Fungsi aktivasi secara khusus digunakan pada jaringan saraf tiruan agar dapat mempelajari pola-pola kompleks pada data. Keakuratan prediksi jaringan syaraf tiruan bergantung pada jumlah lapisan yang digunakan dan yang lebih penting lagi pada jenis fungsi aktivasi yang digunakan. Secara spesifik, tidak ada jumlah pasti yang dapat digunakan untuk hasil dan akurasi yang lebih baik dari jaringan saraf. Jika fungsi aktivasi tidak digunakan dalam jaringan saraf maka *output layer* hanya akan menjadi fungsi linier sederhana. Meskipun persamaan linear sederhana dan mudah untuk diselesaikan tetapi

kompleksitasnya terbatas dan tidak memiliki kemampuan untuk mempelajari dan mengenali pemetaan kompleks dari data [19].

3.5 Recurrent Neural Network (RNN)

Recurrent Neural Network (RNN) adalah jenis jaringan saraf tiruan yang dirancang untuk memproses data berurutan, seperti deret waktu atau teks. Berbeda dengan jaringan saraf tradisional, RNN memiliki koneksi yang melingkar sehingga informasi dapat mengalir dari satu langkah waktu ke langkah berikutnya. Ini memungkinkan RNN untuk menyimpan informasi tentang urutan data sebelumnya, membuatnya sangat efektif untuk tugas-tugas seperti pemodelan bahasa, pengenalan suara, dan prediksi deret waktu [20].

Namun, RNN standar sering menghadapi masalah dalam mengingat informasi jangka panjang karena masalah *vanishing gradient*. Untuk mengatasi hal ini, varian seperti *Long Short-Term Memory* (LSTM) dan *Gated Recurrent Unit* (GRU) telah dikembangkan. Varian ini menggunakan mekanisme yang disebut "*gates*" untuk mengontrol aliran informasi, memungkinkan RNN mempertahankan informasi relevan untuk waktu yang lebih lama. Berikut rumus perhitungan RNN:[21]

Rumus perhitungan *hidden state* (h):

$$h_t = \sigma(W_{hi}x_t + W_{hh}h_{t-1} + b_h) \quad (2)$$

Keterangan:

- h_t = State tersembunyi (*hidden state*) di waktu t.
- σ = Fungsi aktivasi (sigmoid).
- x_t = Vektor *input* pada waktu ke – t.
- h_{t-1} = Vektor *output* dari sel pada waktu sebelumnya (t-1).
- b_h = Bias, nilai yang ditambahkan untuk menyesuaikan output.
- W_{hi} = Bobot yang diterapkan pada x_i (input di waktu t).
- W_{hh} = Bobot yang diterapkan pada state tersembunyi sebelumnya ($h_t - 1$).

Rumus perhitungan *output* (y):

$$y_t = \sigma(W_{xy}h_t + b_y) \quad (3)$$

Keterangan:

- y_t = Vektor *output* pada waktu ke – t.
- W_{xy} = Bobot yang diterapkan pada *hidden state* sebelumnya (h_t).

h_t = State tersembunyi (*hidden state*) di waktu t .

b_y = Bias, nilai yang ditambahkan untuk menyesuaikan output

3.6 Long Short Term Memory (LSTM)

Long Short-Term Memory (LSTM) adalah jenis jaringan saraf tiruan yang dirancang untuk menangani data berurutan, seperti data waktu. LSTM mampu menangkap pola jangka panjang dalam data dan membuat prediksi yang lebih akurat dibandingkan dengan jaringan saraf tiruan tradisional. Model LSTM dapat menyaring data atau informasi memacu struktur gates untuk dapat mempertahankan informasi yang berhubungan dan mengubah keadaan dari sel memori. Struktur gerbang tersebut mencakup *input gate*, *forget gate*, dan *output gate* [22].

LSTM memiliki beberapa lapisan tersembunyi yang berfungsi ketika informasi mengalir, setiap informasi yang relevan disimpan dan yang tidak relevan dibuang pada tiap sel. Struktur gerbang pada LSTM merupakan salah satu bentuk dari RNN yang sering digunakan untuk menghindari masalah pada penumpukan pada gradien atau ketergantungan jangka panjang dalam memproses ataupun melakukan prediksi terhadap data deret waktu. RNN cenderung memiliki penumpukan pada gradien yang menyebabkan nilai gradien saling bertabrakan sehingga terdapat nilai gradien yang tidak jelas dan dapat menghilangkan nilai akumulasinya sehingga diperlukan LSTM untuk menghindari hal tersebut terjadi [23].

Berikut adalah rumus dasar untuk menghitung LSTM:[24]

Rumus perhitungan *input gate* (i):

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (4)$$

Keterangan:

i_t = Vektor *input gate* pada waktu t .

c_t = Vektor *state cell* pada waktu ke - t .

W_{xi} = Bobot yang diterapkan pada input x_t .

W_{ci} = bobot yang dikalikan dengan cell state sebelumnya $c_t - 1$.

$h_t - 1$ = Vektor *output* dari sel pada waktu sebelumnya ($t-1$).

$c_t - 1$ = *Cell state* di waktu sebelumnya

b_i = Bias untuk *input gate*

Rumus perhitungan *forget gate* (f):

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{co}c_{t-1} + b_o) \quad (5)$$

Keterangan:

- f_t = Vektor *forgot gate* pada waktu ke – t.
 W_{xf} = Bobot yang diterapkan pada input x_t .
 W_{hf} = Bobot yang diterapkan pada *hidden state* sebelumnya (h_{t-1}).
 W_{co} = Bobot yang diterapkan pada *cell state* sebelumnya (c_{t-1}).
 b_o = Bias untuk *forgot gate*.

Rumus perhitungan *output gate* (o):

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (6)$$

Keterangan:

- o_t = Vektor *output gate* pada waktu ke – t
 W_{xo} = Bobot yang diterapkan pada input x_t .
 W_{ho} = Bobot yang diterapkan pada *hidden state* sebelumnya (h_{t-1}).
 W_{cf} = Bobot yang diterapkan pada *cell state* sebelumnya (c_{t-1}).
 b_f = Bias untuk *output gate*.

Rumus perhitungan *candidate state* (g):

$$g_t = \tanh(W_{xg}x_t + W_{hg}h_{t-1} + b_g) \quad (7)$$

Keterangan:

- g_t = Vektor *candidate state* pada waktu ke – t
 W_{xg} = Bobot yang diterapkan pada input x_t .
 W_{hg} = Bobot yang diterapkan pada *hidden state* sebelumnya (h_{t-1}).
 b_g = Bias untuk *candidate state*.
Tanh = Fungsi aktivasi tanh yang membatasi output dalam rentang -1 hingga 1.

Rumus perhitungan sel memori (c):

$$c_t = f_t c_{t-1} + i_t g_t \quad (8)$$

Rumus perhitungan *output* (h):

$$h_t = o_t \tanh(c_t) \quad (9)$$

Rumus perhitungan sigmoid (σ):

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (10)$$

Keterangan:

$\sigma(x)$ = Fungsi sigmoid

x = Input ke fungsi

e = Basis logaritma (2.71828)

3.7 Arsitektur Jaringan LSTM

Model yang digunakan dalam penelitian ini terdiri dari dua lapisan LSTM dengan masing-masing 100 unit *neuron*, diikuti oleh lapisan *dropout* sebesar 20% untuk mencegah overfitting. Lapisan pertama LSTM diatur dengan *return_sequences=True*, yang memungkinkan keluaran dari setiap unit disalurkan ke lapisan berikutnya. Setelah itu, terdapat lapisan LSTM kedua yang mengembalikan output akhir dari urutan. Model ini diakhiri dengan satu lapisan *dense (fully connected)* yang berfungsi menghasilkan satu nilai prediksi. Struktur jaringan secara umum dapat digambarkan sebagai berikut:

```
#Struktur jaringan
Input Layer → LSTM (100 units, return_sequences=True) → Dropout (0.2) →
LSTM (100 units) → Dropout (0.2) → Dense (1 unit) → Output
```

Gambar 2 Struktur jaringan LSTM

Optimizer yang digunakan adalah Adam, dengan fungsi loss *mean_squared_error*. Model dilatih pada epoch sebanyak 100, 200, dan 300 untuk mengevaluasi pengaruh jumlah epoch terhadap akurasi model.

3.8 Denormalization

Mean Squared Error (MSE) adalah ukuran statistik yang digunakan untuk mengukur rata-rata dari kuadrat perbedaan antara nilai yang diprediksi oleh model dan nilai yang sebenarnya [26]. Berikut rumus perhitungan MSE. Proses denormalisasi data digunakan untuk dapat mengembalikan hasil keluaran dari jaringan agar nilai keluaran dapat kembali berada pada range sebelumnya seperti pada Persamaan 2. Penelitian ini menggunakan *min-max normalization* seperti penjelasan pada bagian sebelumnya. Rumus denormalisasi data terdapat pada Persamaan 2 [21].

$$X = X'(\max(x) - \min(x)) + \min(x) \quad (11)$$

3.9 Mean Squared Error (MSE)

Mean Squared Error (MSE) adalah ukuran statistik yang digunakan untuk mengukur rata-rata dari kuadrat perbedaan antara nilai yang diprediksi oleh model dan nilai yang sebenarnya [26]. Berikut rumus perhitungan MSE:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

Keterangan:

n = Jumlah data

y_i = Nilai aktual pada waktu ke - i

$\hat{y}$ = Nilai prediksi pada waktu ke - i

3.10 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) adalah metrik yang digunakan untuk mengukur akurasi model prediksi. MAPE menunjukkan rata-rata kesalahan absolut sebagai persentase dari nilai aktual. Berikut rumus perhitungan MAPE:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (13)$$

3.11 Root Mean Squared Error (RMSE)

Root Mean Squared Error (RMSE) adalah salah satu metrik evaluasi yang paling umum digunakan untuk mengukur perbedaan antara nilai yang diprediksi oleh model dengan nilai sebenarnya. RMSE mengukur akar kuadrat dari rata-rata kuadrat kesalahan. Karena kesalahan dikuadratkan sebelum dirata-ratakan, RMSE memberikan bobot yang lebih besar pada kesalahan yang besar. Ini membuatnya sangat sensitif terhadap outlier atau kesalahan prediksi yang signifikan. Semakin kecil nilai RMSE, semakin baik kinerja model dalam memprediksi data [27].

Rumus untuk menghitung *Root Mean Squared Error (RMSE)* adalah sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (14)$$

3.12 Mean Absolute Error (MAE)

Mean Absolute Error (MAE) adalah metrik lain yang digunakan untuk mengukur rata-rata besarnya kesalahan antara nilai yang diprediksi dan nilai sebenarnya. Berbeda dengan RMSE, MAE menghitung rata-rata dari nilai absolut kesalahan, yang berarti MAE kurang sensitif terhadap outlier dibandingkan RMSE. MAE memberikan gambaran yang lebih langsung tentang rata-rata besar kesalahan yang dapat diharapkan dalam unit yang sama dengan variabel yang diprediksi. Semakin kecil nilai MAE, semakin akurat model tersebut [23].

Rumus untuk menghitung *Mean Absolute Error (MAE)* adalah sebagai berikut

$$\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (15)$$

4 Hasil dan Pembahasan

a. Analisis Deskriptif

Data yang digunakan dalam analisis ini adalah data jumlah produksi pupuk dalam rentang tahun 2018-2023. *Google colab* sebagai *software* pemrograman. Berikut sampel data pupuk tahun 2023:

Tabel 1 Data Sampel Pupuk 2023

Bulan ke -	Jumlah Produksi
1	111636
2	29178
3	164631
4	87906
5	58518
6	69609
7	98391
8	86481
9	110208
10	27399
11	123654
12	120927

Pada sampel data tahun 2023 dapat diketahui:

Tabel 2 Deskriptif Data Pupuk 2023

Jumlah	Rata-rata	Min	Max
1088538	90711,5	27399	164631

Tahapan dalam pemrosesan data dengan menggunakan data sampel dari data pupuk tahun 2023 adalah sebagai berikut:

b. Normalisasi Data

Dilakukan tahap normalisasi data dengan *min-max scaler*. Proses normalisasi bertujuan untuk mengubah skala data sehingga berada dalam rentang tertentu, biasanya 0 hingga 1. Berikut sampel data yang telah dinormalisasi:

Tabel 3 Sampel Data Normalisasi

Data Normalisasi
0.01296345
1
0.44091028
0.22676198
0.30758132

c. Pembagian Data

Pembagian data *training* dan data *testing*, dengan 80% data untuk data training dan 20% data untuk *testing*.


Model yang digunakan adalah model LSTM (Long Short-Term Memory) dengan dua lapisan LSTM dan satu lapisan *Dense* untuk prediksi regresi. Model ini diawali dengan

LSTM pertama berukuran 100 unit dan diatur untuk mengembalikan seluruh urutan, diikuti oleh lapisan *Dropout* sebesar 20% untuk mencegah *overfitting*. LSTM kedua juga memiliki 100 unit dan hanya mengembalikan nilai akhir, diikuti oleh *Dropout* 20%. Lapisan *output Dense* berfungsi memprediksi satu nilai (jumlah produksi). Penerapan algoritma *Long-Short Term Memory* (LSTM) pada penelitian ini menggunakan uji coba nilai *epoch* 100,200, dan 300 *epoch* dan ‘Adam’ digunakan sebagai optimizernya

d. Pelatihan (*Training*) Model LSTM

Pada tahap pelatihan model proses iteratif di mana model menggunakan data pelatihan untuk mengoptimalkan bobot-bobotnya guna meminimalkan fungsi *loss* yang telah ditetapkan. Model dilatih dengan hingga *epoch* yang diinginkan tercapai dengan *batch size* sebesar 2. Pada setiap *epoch*, model memperbarui bobotnya berdasarkan gradien dari fungsi *loss* memungkinkan pembaruan bobot yang lebih sering dan lebih akurat untuk dataset kecil.

Melalui tahap ini, model belajar pola dan hubungan dalam data sehingga dapat membuat prediksi yang akurat pada data baru yang belum pernah dilihat sebelumnya.



Gambar 3 Grafik MAPE a,b,c dengan Epoch 100,200,300

Berikut grafik pelatihan data dengan *epoch* yang berbeda:

e. Denormalisasi Data

Tahap denormalisasi data adalah proses untuk mengembalikan hasil prediksi yang telah dinormalisasi ke skala atau nilai aslinya. Normalisasi biasanya dilakukan pada awal proses untuk menyamakan skala berbagai fitur data agar lebih mudah diproses oleh model, terutama dalam algoritma machine learning seperti LSTM.

Namun, setelah model menghasilkan prediksi, nilai yang dihasilkan masih dalam bentuk yang sudah dinormalisasi. Oleh karena itu, diperlukan denormalisasi agar hasil prediksi bisa dikembalikan ke bentuk aslinya yang sesuai dengan skala atau satuan data awal. Berikut sampel data denormalisasi:

Tabel 4 Sampel Data Denormalisasi

Data Denormalisasi
79606.07
70783.89
76212.445
110908.6
94902.46

f. Evaluasi Model

Tahap evaluasi model adalah tahap dimana terjadi penilaian hasil kinerja suatu model dari *machine learning*. Dalam penelitian ini, kinerja model dievaluasi menggunakan rumus MAPE dan MSE. Berikut hasil dari evaluasi model yang telah dilakukan:

Tabel 5 Hasil Evaluasi Model

<i>Epoch</i>	MAPE	MSE	RMSE	MAE	Kategori
100	36,41%	593439051,97	24997.74	19717.85	Cukup
200	29,05%	384163879,52	19762.56	15989.67	Cukup
300	18,60%	258141463,92	19745.11	14533,75	Akurat

Berdasarkan hasil evaluasi model dengan menggunakan empat metrik utama, yaitu MAPE, MSE, RMSE, dan MAE, terlihat bahwa performa model meningkat secara konsisten seiring bertambahnya epoch. Pada epoch ke-100, nilai MAPE sebesar 36,41% yang tergolong dalam kategori *cukup*. Nilai MSE dan RMSE juga masih cukup tinggi, masing-masing sebesar 593.439.051,97 dan 24.997,74, menunjukkan bahwa model masih menghasilkan kesalahan prediksi yang relatif besar. Selain itu, nilai MAE sebesar 19.717,85 juga mengindikasikan rata-rata kesalahan absolut yang cukup tinggi.


Selanjutnya, pada epoch ke-200, terjadi penurunan nilai kesalahan secara signifikan. Nilai MAPE menurun menjadi 29,05% namun masih berada dalam kategori *cukup*. Begitu pula dengan nilai MSE dan RMSE yang menurun menjadi 384.163.879,52 dan 19.762,56. Nilai MAE juga turun menjadi 15.989,67, menandakan peningkatan akurasi prediksi model.

Peningkatan performa paling optimal terlihat pada epoch ke-300. Pada titik ini, nilai MAPE turun menjadi 18,60%, yang telah masuk dalam kategori *akurat*. Selain itu, MSE dan RMSE terus menurun hingga masing-masing sebesar 258.141.463,92 dan 19.745,11. MAE juga menunjukkan hasil terbaik dengan nilai 14.533,75. Penurunan pada seluruh metrik error ini menunjukkan bahwa model menjadi semakin stabil dan mampu menghasilkan prediksi yang lebih presisi terhadap data aktual.

Dengan demikian, dapat disimpulkan bahwa model dengan epoch ke-300 memberikan performa terbaik dibandingkan epoch lainnya, baik dari segi kesalahan absolut maupun persentase kesalahan, dan layak dijadikan model akhir dalam penelitian ini. Selain itu, dibandingkan dengan model regresi linier atau metode prediktif klasik seperti ARIMA, LSTM memiliki keunggulan dalam mengenali pola musiman dan tren jangka panjang yang sering muncul dalam data deret waktu produksi pupuk. Hal ini terbukti dari nilai $MAPE < 20\%$ yang menandakan tingkat prediksi yang akurat. Sebagai perbandingan, penelitian sebelumnya [7] menggunakan regresi linier dan memperoleh MAPE sebesar 12,47%, namun tidak mampu menangkap fluktuasi musiman yang kompleks seperti yang terjadi pada data ini. Dengan mempertimbangkan ketidakpastian operasional dan pola musiman dalam logistik pelabuhan, pendekatan berbasis LSTM memberikan fleksibilitas dan keakuratan yang lebih tinggi. Dari hasil evaluasi tersebut dapat diketahui dengan pemodelan data dengan algoritma LSTM baik digunakan untuk mengolah data jumlah produksi muatan pupuk. Hasil evaluasi dengan LSTM bisa digunakan sebagai gambaran awal pengolahan data jumlah kegiatan bongkar pupuk.

g. Prediksi

Tahap prediksi adalah proses di mana model yang telah dilatih digunakan untuk memperkirakan nilai atau hasil yang diinginkan berdasarkan data uji. Pada penelitian ini, tujuan dari prediksi adalah untuk memproyeksikan aktivitas bongkar muat pupuk selama 6 bulan ke depan. Setelah melakukan berbagai percobaan dengan beberapa *epoch*, pada epoch ke-300 model menghasilkan Mean Absolute Percentage Error (MAPE) yang kecil. Karena MAPE pada epoch tersebut menunjukkan tingkat kesalahan prediksi yang rendah, maka hasil dari epoch ke-300 digunakan sebagai hasil prediksi terbaik dalam penelitian ini. Berikut grafik data asli dan data hasil prediksi:



Gambar 4 Data Hasil Pediksi

Berikut Tabel 6 yang menunjukkan hasil dari prediksi aktivitas bongkar muat pupuk dalam 6 bulan kedepan:

Tabel 6 Hasil Prediksi

Bulan Ke-	Jumlah Produksi
1	56333.832031
2	70514.101562
3	94870.156250
4	90111.781250
5	72169.804688
6	79737.460938

Berdasarkan Tabel 6 Hasil Prediksi, terlihat bahwa jumlah produksi bongkar muat pupuk diprediksi mengalami fluktuasi selama enam bulan ke depan. Pada bulan pertama, diprediksi sebanyak 56.333,83 ton, dengan peningkatan signifikan pada bulan kedua menjadi 70.514,10 ton. Puncak produksi terjadi di bulan ketiga dengan jumlah 94.870,16 ton, sebelum turun kembali di bulan keempat menjadi 90.111,78 ton dan bulan kelima sebesar 72.169,80 ton. Pada bulan keenam, produksi diprediksi naik lagi menjadi 79.737,46 ton. Tren ini menunjukkan adanya fluktuasi yang mungkin dipengaruhi oleh faktor-faktor seperti musim atau permintaan pasar. Peningkatan yang signifikan di bulan ketiga menunjukkan kebutuhan akan persiapan tambahan dalam hal kapasitas penyimpanan dan pengaturan bongkar muat di pelabuhan, sementara penurunan di bulan keempat dan kelima memberikan peluang untuk menyesuaikan operasi. Prediksi ini sangat penting bagi pengelola pelabuhan dalam memastikan kelancaran operasional, terutama untuk mengantisipasi lonjakan produksi dan mencegah penumpukan barang di gudang.

5 Kesimpulan

Penelitian ini berhasil menerapkan model *Long Short-Term Memory* (LSTM) untuk memprediksi jumlah produksi pupuk pada kegiatan bongkar muat di PT Pelindo Multi Terminal Petikemas Branch Gresik. Berdasarkan hasil evaluasi terhadap beberapa parameter epoch (100, 200, dan 300), ditemukan bahwa model LSTM dengan epoch ke-

300 memberikan performa terbaik dengan Model terbaik diperoleh pada epoch ke-300, dengan hasil evaluasi menunjukkan nilai *Mean Absolute Percentage Error (MAPE)* sebesar 18,60%, *Mean Squared Error (MSE)* sebesar 258.141.463,92, *Root Mean Squared Error (RMSE)* sebesar 19.745,11, dan *Mean Absolute Error (MAE)* sebesar 14.533,75.. Hasil ini menunjukkan bahwa LSTM efektif dalam memproses data deret waktu dan mampu menghasilkan prediksi yang akurat. Namun demikian, penelitian ini memiliki keterbatasan pada jumlah data historis yang terbatas (2018–2023), serta belum mempertimbangkan faktor eksternal seperti cuaca, permintaan pasar, atau volume kapal.

Keunggulan LSTM dibandingkan metode klasik seperti regresi linier terletak pada kemampuannya dalam mengenali pola musiman dan tren jangka panjang, yang sangat penting dalam konteks logistik pelabuhan yang dinamis. Dengan akurasi prediksi yang baik, model ini dapat dijadikan alat bantu dalam pengambilan keputusan operasional seperti perencanaan bongkar muat, pengelolaan kapasitas gudang, hingga antisipasi lonjakan permintaan.

Refleksi dari hasil ini menunjukkan bahwa penerapan metode *machine learning* dalam bidang logistik bukan hanya sekadar upaya teknis, tetapi juga bagian dari strategi efisiensi dan optimasi. Pemodelan seperti ini sangat relevan untuk diterapkan dalam industri pelabuhan modern yang dituntut serba cepat dan presisi.

Pada penelitian selanjutnya, disarankan agar dilakukan eksplorasi model seperti Holt-Winters, serta mempertimbangkan variabel eksternal seperti cuaca, volume kapal, atau permintaan pasar yang dapat mempengaruhi fluktuasi produksi pupuk. Selain itu, penambahan rentang data historis dan fitur tambahan juga dapat meningkatkan generalisasi dan ketahanan model dalam berbagai kondisi.

Daftar Pustaka

- [1] R. Amalia, A. G. Kamaludin, and A. A. Tabah, "Efektivitas Pengiriman Barang di Terminal Peti Kemas (TPK) Koja," *Jurnal Manajemen Bisnis Transportasi dan Logistik*, vol. 6, no. 1, p. 73, Jul. 2020, doi: 10.54324/j.mbt.v6i1.445.
- [2] Sulistyowati and S. A. Wijaya, "Faktor-Faktor Yang Mempengaruhi Kecepatan Bongkar Muat Peti Kemas Di Pt. Ipc Terminal Peti Kemas Area Pontianak," *Jurnal Ekonomika45*, vol. 10, no. 1, 2022, doi: 10.30640/ekonomika45.v10i1.651.
- [3] M. Mukhlis, A. Kustiyo, A. Suharso, B. Jaya, J. Dramaga, and K. Bogor, "Peramalan Produksi Pertanian Menggunakan Model Long Short-Term Memory," *BINA INSANI ICT JOURNAL*, vol. 8, no. 1, pp. 22–32, 2021, doi: 10.51211/biict.v8i1.1492.
- [4] A. S. Bayangkari Karno, "Analisis Data Time Series Menggunakan LSTM (Long Short Term Memory) Dan ARIMA (Autocorrelation Integrated Moving Average) Dalam Bahasa Python.," *Ultima InfoSys : Jurnal Ilmu Sistem Informasi*, vol. 11, no. 1, pp. 1–7, Jul. 2020, doi: 10.31937/si.v9i1.1223.
- [5] R. Akbar, R. Santoso, and B. Warsito, "Prediksi Tingkat Temperatur Kota Semarang Menggunakan Metode Long Short-Term Memory (LSTM)," *Jurnal Gaussian*, vol. 11, no. 4, pp. 572–579, Feb. 2023, doi: 10.14710/j.gauss.11.4.572-579.

- [6] A. Aulia, A. M. Elhanafi, and H. Dafitri, "Implementasi Algoritma Gated Recurrent Unit Dalam Melakukan Prediksi Harga Kelapa Sawit Dengan Memanfaatkan Model Recurrent Neural Network (RNN)," *Prosiding Snastikom*, vol. 1, 2021.
- [7] Ilham Amansyah, Jamaludin Indra, and Ayu Ratna Juwita, "Prediksi Penjualan Kendaraan Menggunakan Regresi Linear Studi Kasus pada Industri Otomotif di Indonesia," vol. 4, pp. 1199–1216, 2024.
- [8] A. D. Milniadi and N. O. Adiwijaya, "Analisis Perbandingan Model Arima Dan Lstm Dalam Peramalan Harga Penutupan Saham (Studi Kasus : 6 Kriteria Kategori Saham Menurut Peter Lynch)," *SIBATIK JOURNAL: Jurnal Ilmiah Bidang Sosial, Ekonomi, Budaya, Teknologi, dan Pendidikan*, vol. 2, no. 6, pp. 1683–1692, May 2023, doi: 10.54443/sibatik.v2i6.798.
- [9] A. Awaludin and T. Oktarina, "Application of the LSTM Algorithm in Predicting Urea Fertilizer Production at IIB Plant PT. Pupuk Sriwidjaja Palembang," *Jurnal Sains Komputer & Informatika*, vol. 7, no. 2, p. 1015, 2023.
- [10] A. Primawati, I. S. Sitanggang, A. Annisa, and D. A. Astuti, "Perbandingan Kinerja LSTM dan Prophet untuk Prediksi Deret Waktu (Studi Kasus Produksi Susu Sapi Harian)," *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, vol. 9, no. 3, p. 428, Dec. 2023, doi: 10.26418/jp.v9i3.72031.
- [11] Yudi Widhiyasa, Transmissia Semiawan, Ilham Gibran Achmad Mudzakir, and Muhammad Randi Noor, "Penerapan Convolutional Long Short-Term Memory untuk Klasifikasi Teks Berita Bahasa Indonesia," *Jurnal Nasional Teknik Elektro dan Teknologi Informasi*, vol. 10, no. 4, pp. 354–361, Nov. 2021, doi: 10.22146/jnteti.v10i4.2438.
- [12] M. Butar Butar, "Perancangan Sistem Informasi Pengolahan Data Distribusi Pupuk Menggunakan Metode E-Supply Chain Management (Studi Kasus : Pt. Gudang Penyangga Dairi)," 2019.
- [13] L. Yuliana, "Manajemen Rantai Pasok Produksi Rak Piring Aluminium Di Depok (Studi Kasus Pada Pd. Sumber Jaya Aluminium)," *Jurnal Riset Bisnis*, vol. 3, no. 2, 2020, doi: 10.35814/jrb.v3i2.789.
- [14] A. D. W. P and N. I. Safutra, "Pelatihan Teknik Pengemasan Pupuk Organik Cair dan Pestisida Nabati untuk Menjaga Viabilitas Bakteri Pada Kelompok Seraton di Desa Tonasa," *Idea Pengabdian Masyarakat*, vol. 2, no. 03, pp. 169–174, May 2022, doi: 10.53690/ipm.v2i03.130.
- [15] I. P. C. P. Adnyana and M. S. Mohktar, "Pengawasan Distribusi Pupuk Bersubsidi Di Kota Padang," *SOCA: Jurnal Sosial Ekonomi Pertanian*, p. 201, Apr. 2019, doi: 10.24843/soca.2019.v13.i02.p05.
- [16] A. Palapa, "Upaya Pencegahan Kecelakaan Kerja pada MV. Mochtar Prabu Mangkunekagara Dalam Proses Bongkar Muat Pupuk," *KALAOs : Kalao's Maritime Journal*, vol. 3, no. 2, pp. 46–60, 2022, doi: 10.69754/kalaos.v3i2.73.
- [17] U. Maman, I. Aminudin, and E. Novriana, "Efektifitas Pupuk Bersubsidi Terhadap Peningkatan Produktivitas Padi Sawah," *JURNAL AGRIBISNIS TERPADU*, vol. 14, no. 2, p. 176, Dec. 2021, doi: 10.33512/jat.v14i2.13268.
- [18] D. Prasetyawan and R. Gatra, "Algoritma K-Nearest Neighbor untuk Memprediksi Prestasi Mahasiswa Berdasarkan Latar Belakang Pendidikan dan Ekonomi," *JISKA*

- (*Jurnal Informatika Sunan Kalijaga*), vol. 7, no. 1, pp. 56–67, Jan. 2022, doi: 10.14421/jiska.2022.7.1.56-67.
- [19] K. O. Putra, G. W. Nurcahyo, and J. Santony, “). Penerapan Jaringan Syaraf Tiruan Dengan Algoritma Backpropagation Untuk Memprediksi Kunjungan Poliklinik (Studi Kasus Di Rumah Sakit Otak Dr. Drs. M. Hatta Bukittinggi),” *JSR : Jaringan Sistem Informasi Robotik*, vol. 2, no. 1, pp. 86–90, Mar. 2018, doi: 10.58486/jsr.v2i1.30.
 - [20] K. Shankar *et al.*, “An Automated Hyperparameter Tuning Recurrent Neural Network Model for Fruit Classification,” *Mathematics*, vol. 10, no. 13, Jul. 2022, doi: 10.3390/math10132358.
 - [21] A. E. Ibor, F. A. Oladeji, O. B. Okunoye, and O. O. Ekabua, “Conceptualisation of Cyberattack prediction with deep learning,” *Cybersecurity*, vol. 3, no. 1, Dec. 2020, doi: 10.1186/s42400-020-00053-7.
 - [22] A. Rolangon, A. Weku, and G. A. Sandag, “Perbandingan Algoritma LSTM Untuk Analisis Sentimen Pengguna Twitter Terhadap Layanan Rumah Sakit Saat Pandemi Covid-19,” *TelKa*, vol. 13, no. 01, pp. 31–40, May 2023, doi: 10.36342/teika.v13i01.3063.
 - [23] R. Luthfiansyah and B. Wasito, “Penerapan Teknik Deep Learning (Long Short Term Memory) dan Pendekatan Klasik (Regresi Linier) dalam Prediksi Pergerakan Saham BRI,” 2023. doi: 10.46806/jib.v12i2.1059.
 - [24] J. Cahyani, S. Mujahidin, and T. P. Fiqar, “Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional,” *Jurnal Sistem dan Teknologi Informasi (JustIN)*, vol. 11, no. 2, p. 346, Jul. 2023, doi: 10.26418/justin.v11i2.57395.
 - [25] T. O. Hodson, T. M. Over, and S. S. Foks, “Mean Squared Error, Deconstructed,” *J Adv Model Earth Syst*, vol. 13, no. 12, Dec. 2021, doi: 10.1029/2021MS002681.
 - [26] F. Indra Sanjaya and D. Heksaputra, “Prediksi Rerata Harga Beras Tingkat Grosir Indonesia dengan Long Short Term Memory,” vol. 7, no. 2, pp. 163–174, 2020, doi: 10.35957/jatisi.v7i2.388.
 - [27] J. Hasil *et al.*, “Analisis Antrian dan Waktu Tunggu Terminal Peti Kemas Semarang,” *Jurnal Teknik Perkapalan*, vol. 11, no. 3, p. 1, 2023.