

## PENERAPAN MODEL *LONG SHORT-TERM MEMORY* (LSTM) UNTUK PREDIKSI WAKTU PROSES *BAGGING* BERDASARKAN FAKTOR OPERASIONAL PADA PT POS INDONESIA

### IMPLEMENTATION OF THE *LONG SHORT-TERM MEMORY* (LSTM) MODEL FOR *BAGGING* PROCESS TIME PREDICTION BASED ON OPERATIONAL FACTORS AT PT POS INDONESIA

Firna Ulfiani R<sup>a,1</sup>, Woro Isti Rahayu<sup>a,2</sup>, Kiki Mustaqim<sup>a,3</sup>, Suryo Edi Widodo<sup>a,4</sup>

<sup>a</sup> Prodi Sains Data, Universitas Logistik dan Bisnis Internasional, Jl. Sari Asih No. 54, Sarijadi, Kec. Sukasari, Kota Bandung, Jawa Barat, Indonesia 40151

<sup>1</sup> [firmaramadhani2121@gmail.com](mailto:firmaramadhani2121@gmail.com), <sup>2</sup> [woroisti@ulbi.ac.id](mailto:woroisti@ulbi.ac.id), <sup>3</sup> [kiki@ulbi.ac.id](mailto:kiki@ulbi.ac.id), <sup>4</sup> [suryoedywidodo@gmail.com](mailto:suryoedywidodo@gmail.com)

\*corresponding : [firmaramadhani2121@gmail.com](mailto:firmaramadhani2121@gmail.com)

Diterima: 15 Januari 2026, direvisi: 18 Februari 2026, disetujui: 07 Maret 2026, diterbitkan: 30 April 2026

#### ABSTRAK

Meningkatnya volume pengiriman akibat perkembangan *e-commerce* menjadikan proses *bagging* sebagai tahap penting dalam menjaga efisiensi operasional pada PT Pos Indonesia, perusahaan BUMN yang bergerak di bidang layanan pos dan logistik di Indonesia. Penelitian ini bertujuan untuk memprediksi durasi proses *bagging* berdasarkan faktor-faktor operasional menggunakan metode *Long Short-Term Memory* (LSTM). Data yang digunakan berupa data operasional harian yang meliputi volume kiriman, berat kiriman, jumlah staf, dan durasi proses *bagging*. Metodologi penelitian meliputi *preprocessing* data menggunakan *Min-Max Scaling*, uji stasioneritas menggunakan Augmented Dickey-Fuller (ADF), pembagian data menjadi *training* dan *testing*, pelatihan model LSTM, serta evaluasi performa menggunakan *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE), dan koefisien determinasi ( $R^2$ ). Hasil uji ADF menunjukkan bahwa data waktu *bagging* bersifat stasioner dengan nilai p-value sebesar 0,023. Model LSTM yang dikembangkan menghasilkan nilai MAE sebesar 32,51 detik, RMSE sebesar 41,78 detik, MAPE sebesar 6,15%, dan nilai  $R^2$  sebesar 0,89 yang menunjukkan performa prediksi yang baik. Hasil penelitian menunjukkan bahwa volume kiriman, berat kiriman, dan jumlah staf berpengaruh terhadap durasi proses *bagging*. Lonjakan volume kiriman sebesar 800–900 kiriman per hari terjadi hampir setiap hari sehingga meningkatkan durasi proses *bagging*. Pada kondisi dua staf, durasi *bagging* diperkirakan mencapai 773–774 menit per hari dan melebihi batas operasional perusahaan. Oleh karena itu, penambahan jumlah staf menjadi tiga orang direkomendasikan karena mampu menurunkan durasi proses *bagging* hingga sekitar 30–40% sehingga waktu operasional menjadi lebih efisien dan tetap berada dalam batas target kerja perusahaan. Temuan ini menunjukkan bahwa metode *Long Short-Term Memory* (LSTM) efektif digunakan untuk memodelkan dan memprediksi durasi proses *bagging* berdasarkan faktor operasional serta dapat dimanfaatkan sebagai dasar pengambilan keputusan operasional pada PT Pos Indonesia.

**Kata Kunci:** *Long Short-Term Memory* (LSTM), Prediksi Waktu *Bagging*, Time Series, Faktor Operasional, PT Pos Indonesia.

## ABSTRACT

*The increasing volume of shipments driven by the growth of e-commerce has made the bagging process an important stage in maintaining operational efficiency at PT Pos Indonesia, a state-owned company engaged in postal and logistics services in Indonesia. This study aims to predict the duration of the bagging process based on operational factors using the Long Short-Term Memory (LSTM) method. The data used consisted of daily operational data including shipment volume, shipment weight, number of staff, and bagging duration. The research methodology included data preprocessing using Min-Max Scaling, stationarity testing using the Augmented Dickey-Fuller (ADF) test, data splitting into training and testing sets, LSTM model training, and performance evaluation using Mean Absolute Error (MAE), Root Mean Square Error (RMSE), Mean Absolute Percentage Error (MAPE), and coefficient of determination ( $R^2$ ). The ADF test results indicated that the bagging time data were stationary with a p-value of 0.023. The developed LSTM model produced an MAE value of 32.51 seconds, RMSE of 41.78 seconds, MAPE of 6.15%, and an  $R^2$  value of 0.89, indicating good predictive performance. The results showed that shipment volume, shipment weight, and number of staff significantly influenced the duration of the bagging process. Shipment surges reaching 800–900 packages per day occurred almost every day, increasing the bagging duration. Under the condition of two staff members, the bagging duration was estimated to reach 773–774 minutes per day, exceeding the company's operational time limit. Therefore, increasing the number of staff to three people is recommended because it can reduce the bagging duration by approximately 30–40%, making operational time more efficient and within the company's target working hours. These findings indicate that the Long Short-Term Memory (LSTM) method is effective for modeling and predicting bagging process duration based on operational factors and can be utilized as a basis for operational decision-making at PT Pos Indonesia.*

**Keywords:** Long Short-Term Memory (LSTM), Bagging Time Prediction, Time Series, Operational Factors, PT Pos Indonesia.

## Pendahuluan

PT Pos Indonesia merupakan perusahaan Badan Usaha Milik Negara (BUMN) yang bergerak di bidang layanan pos dan logistik, yang menyediakan layanan pengiriman surat, paket, serta berbagai layanan logistik lainnya yang menjangkau seluruh wilayah Indonesia (Logistik et al., 2026). Sebagai salah satu penyedia layanan logistik nasional (Daya et al., n.d.), PT Pos Indonesia memiliki peran penting dalam mendukung sistem distribusi barang, terutama di tengah meningkatnya kebutuhan pengiriman akibat perkembangan *e-commerce* dan aktivitas perdagangan digital (Setianingrum et al., 2025).

Seiring dengan meningkatnya volume pengiriman akibat perkembangan *e-commerce* dan aktivitas logistik digital, perusahaan jasa pengiriman dituntut untuk meningkatkan efisiensi dan kecepatan dalam setiap tahapan operasional (Yulianto & Wulandari, 2025). Menurut (Process et al., 2019) proses distribusi pada PT Pos Indonesia terdiri dari tahapan *collecting*, *processing*, *transporting*, dan *delivery*, dimana tahap *processing* berperan dalam penyortiran dan pengelompokan kiriman sebelum diteruskan ke distribusi berikutnya. Sehingga, salah satu

tahapan penting dalam proses distribusi adalah *Bagging* merupakan proses penyortiran dan pengelompokan paket berdasarkan tujuan pengiriman sebelum diteruskan ke tahap distribusi berikutnya dalam sistem logistik pada PT Pos Indonesia. *Bagging* berperan penting dalam menentukan kelancaran proses distribusi, sehingga keterlambatan pada tahap ini dapat mempengaruhi keseluruhan waktu pengiriman. Pada operasional PT Pos Indonesia, proses ini menjadi bagian krusial dalam memastikan alur distribusi berjalan secara efektif dan tepat waktu.

Dalam praktiknya, proses *bagging* tidak bersifat konstan, melainkan sangat dipengaruhi oleh berbagai faktor operasional. Faktor tersebut meliputi volume kiriman harian yang fluktuatif, berat paket yang bervariasi, jumlah tenaga kerja yang tidak selalu tetap, serta kompleksitas jenis kiriman. Kombinasi faktor-faktor tersebut menyebabkan durasi proses *bagging* menjadi tidak stabil dan sulit diprediksi secara manual. Ketidakpastian ini dapat berdampak pada keterlambatan proses distribusi ke tahap selanjutnya, serta berpotensi menurunkan kualitas layanan secara keseluruhan. Oleh karena itu, diperlukan pendekatan berbasis data yang mampu memodelkan pola perubahan durasi proses *bagging* secara lebih akurat.

Dalam bidang analitik data dan manajemen operasional, peramalan (*forecasting*) merupakan teknik yang digunakan untuk memperkirakan nilai di masa depan berdasarkan data historis (Mubarok, 2025). Metode ini sangat penting dalam mendukung pengambilan keputusan, khususnya dalam pengelolaan sumber daya dan perencanaan operasional. Pemilihan metode peramalan harus disesuaikan dengan karakteristik data agar menghasilkan tingkat *error* yang rendah dan prediksi yang lebih akurat. Salah satu metode yang banyak digunakan dalam analisis data deret waktu (*time series*) adalah *Long Short-Term Memory* (LSTM). LSTM merupakan pengembangan dari *Recurrent Neural Network* (RNN) yang memiliki kemampuan untuk mempelajari ketergantungan jangka panjang dalam data sequential (Cahyani et al., 2023). Mekanisme utama LSTM adalah penggunaan *memory cell* dan *gate* (*input gate*, *forget gate*, dan *output gate*) yang memungkinkan model untuk menyimpan atau mengabaikan informasi tertentu sesuai relevansinya terhadap pola data (Rosyd et al., 2024). Kemampuan ini menjadikan LSTM sangat cocok untuk data yang memiliki pola waktu yang kompleks dan tidak linier.

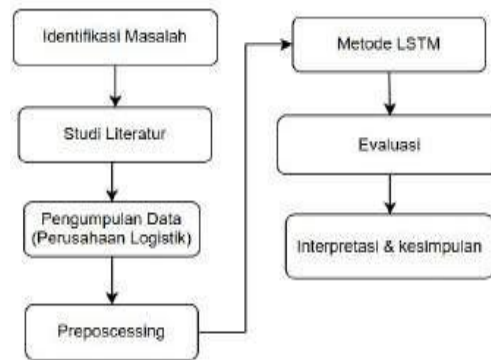
Penelitian sebelumnya menunjukkan bahwa LSTM telah banyak diterapkan dalam berbagai bidang seperti prediksi cuaca, prediksi penjualan, dan analisis deret waktu lainnya. Hasil penelitian tersebut menunjukkan bahwa performa LSTM sangat dipengaruhi oleh parameter model seperti *epoch*, *batch size*, serta karakteristik data yang digunakan (Tita Lattifia et al., 2022). Hal ini membuktikan bahwa LSTM memiliki fleksibilitas tinggi dalam memodelkan pola data historis dengan tingkat akurasi yang cukup baik. Meskipun metode

LSTM telah banyak digunakan dalam berbagai bidang penelitian, terdapat beberapa kesenjangan penelitian yang masih perlu diperhatikan dan menjadi dasar penting dalam penelitian ini. Pertama, sebagian besar penelitian berbasis LSTM masih berfokus pada domain seperti prediksi cuaca, keuangan, energi, dan penjualan. Penelitian yang mengaplikasikan LSTM dalam operasional logistik, khususnya pada proses *bagging* dalam industri jasa pengiriman, masih relatif terbatas. Padahal, sektor logistik memiliki karakteristik data yang sangat dinamis dan dipengaruhi oleh berbagai faktor operasional yang kompleks. Kedua, penelitian yang ada umumnya hanya berfokus pada prediksi satu variabel utama tanpa mempertimbangkan interaksi beberapa faktor operasional secara simultan. Dalam proses *bagging*, variabel seperti volume kiriman, berat paket, dan jumlah staf memiliki hubungan yang saling mempengaruhi terhadap durasi proses. Namun, integrasi variabel-variabel tersebut dalam satu model prediksi berbasis LSTM masih belum banyak dilakukan secara komprehensif. Ketiga, penelitian sebelumnya belum banyak mengeksplorasi penerapan LSTM sebagai alat pendukung pengambilan keputusan operasional secara langsung dalam perusahaan jasa pengiriman nasional seperti PT Pos Indonesia, terutama untuk optimasi waktu kerja dan distribusi tenaga kerja berdasarkan hasil prediksi. Dengan demikian, dapat disimpulkan bahwa terdapat kebutuhan penelitian yang lebih spesifik untuk mengembangkan model prediksi berbasis LSTM yang tidak hanya berfokus pada akurasi prediksi, tetapi juga mempertimbangkan faktor operasional secara menyeluruh dalam nyata proses *bagging*.

Berdasarkan kesenjangan penelitian tersebut, penelitian ini bertujuan untuk mengembangkan model LSTM yang mampu memprediksi durasi proses *bagging* berdasarkan faktor-faktor operasional secara lebih akurat. Model ini diharapkan dapat memberikan kontribusi dalam mendukung pengambilan keputusan operasional, khususnya dalam optimalisasi penggunaan sumber daya manusia dan waktu kerja.

### **Metode Penelitian**

Penelitian ini dilakukan melalui beberapa tahapan sistematis yang disusun secara berurutan untuk memastikan proses analisis berjalan secara terstruktur, mulai dari identifikasi permasalahan hingga diperolehnya hasil akhir berupa interpretasi dan kesimpulan. Adapun alur penelitian yang digunakan dalam studi ini dapat dilihat pada Gambar berikut.



**Gambar 1. Alur Penelitian**


Penelitian ini menggunakan pendekatan kuantitatif dengan jenis *time series forecasting* berbasis metode LSTM yang dilakukan di PT Pos Indonesia (Persero). Data yang digunakan merupakan data operasional historis dengan total sebanyak 82.719 observasi, yang mencakup periode pengambilan data dari Januari 2024 hingga April 2025. Subjek penelitian berupa data operasional yang meliputi variabel volume kiriman, berat kiriman, jumlah staf, dan waktu *bagging*, yang digunakan untuk membangun model prediksi guna meningkatkan efisiensi proses operasional. Teknik pengumpulan data dilakukan melalui data sekunder dari sistem internal PT Pos Indonesia, yaitu dengan melakukan ekstraksi data dari aplikasi *Kibana* pada saat peneliti melaksanakan kerja praktik di perusahaan, sehingga data yang diperoleh merupakan data *real-time* operasional yang tersimpan dalam sistem monitoring internal perusahaan. Prosedur penelitian secara keseluruhan meliputi tahapan identifikasi masalah, studi literatur, pengumpulan data, *preprocessing* data, uji stasioneritas, pembangunan model LSTM, serta evaluasi model menggunakan metrik seperti *Mean Absolute Error* (MAE) dan *Mean Absolute Percentage Error* (MAPE) untuk mengukur tingkat akurasi prediksi model dalam menangkap pola data operasional. Sebelum pemodelan, data terlebih dahulu melalui tahapan *preprocessing*, yang mencakup:

- a. Penanganan *missing values*, dilakukan dengan metode imputasi atau penghapusan data kosong sesuai karakteristik data *time series*,
- b. Normalisasi data, menggunakan metode *Min-Max Scaling* untuk menyamakan skala antar variabel agar proses pelatihan LSTM lebih stabil dan optimal,
- c. Pembagian data (*train-test split*), dengan rasio pembagian yaitu dengan 80:20 untuk memastikan model diuji pada data yang belum pernah dilihat sebelumnya.
- d. Uji stasioneritas (*stationarity test*) menggunakan metode seperti *Augmented Dickey-Fuller* (ADF) test untuk mengetahui apakah data memiliki sifat stasioner atau memerlukan transformasi (seperti *differencing*) sebelum dimasukkan ke dalam model LSTM (Guo, 2023). Hipotesis pengujian sebagai berikut:

- $H_0$  : Waktu pengantongan data tidak stasioner
  - $H_1$  : Data waktu pengantongan stasioner
  - Variabel dengan p-value  $< 0,05$  (stasioner)
  - Variabel dengan p-value  $> 0,05$  (belum stasioner dan dapat dilakukan diferensiasi atau normalisasi)
- e. Membangun model LSTM

Pada penelitian ini, model LSTM dilatih menggunakan beberapa parameter utama untuk memperoleh performa prediksi yang optimal, yaitu *epoch* sebanyak 100, *batch size* sebesar 32, *optimizer Adam* dengan *learning rate* 0,001, serta 50 *neuron* pada layer LSTM. Parameter tersebut dipilih untuk membantu model mempelajari pola data operasional secara stabil dan akurat.

*Optimizer Adam* digunakan karena mampu mempercepat proses konvergensi dan menyesuaikan *learning rate* secara adaptif selama pelatihan model (Prasetyo et al., 2025). Selain itu, fungsi aktivasi *sigmoid* dan *tanh* digunakan pada mekanisme *gate* LSTM untuk mengatur informasi yang dipertahankan maupun diperbarui pada *cell state* (Adam & Sgd, 2025). Penggunaan 100 epoch memungkinkan model mempelajari pola historis data secara optimal, sedangkan *batch size* sebesar 32 membantu menjaga kestabilan proses pelatihan (Alfarizi & Lestarini, 2025). Jumlah 50 neuron dipilih karena mampu memberikan keseimbangan antara kemampuan model dalam menangkap pola temporal dan kompleksitas model sehingga risiko *overfitting* dapat dikurangi (Hawali, 2025).



**Gambar 2. Arsitektur LSTM**

Sumber: Hochreiter & Schmidhuber (1997), Gers et al. (2000)

Gambar 2 menunjukkan mekanisme kerja *Long Short-Term Memory* (LSTM) dalam satu langkah waktu. Secara arsitektural, LSTM terdiri dari tiga komponen utama, yaitu *cell state* ( $C_t$ ) sebagai memori jangka panjang, *hidden state* ( $h_t$ ) sebagai output pada setiap waktu, serta tiga *gate* yang mengatur aliran informasi, yaitu *forget gate*,

*input gate*, dan *output gate*(Y. Ashari et al., 2024).

Pada prosesnya, *input* saat ini ( $X_t$ ) dan *hidden state* sebelumnya ( $h_{t-1}$ ) menjadi masukan utama ke dalam sel LSTM. *Forget gate* berfungsi untuk menentukan informasi dari memori sebelumnya ( $C_{t-1}$ ) yang perlu dipertahankan atau dihapus melalui fungsi aktivasi *sigmoid*(Hermawan & Zuliarso, 2025). Selanjutnya, *input gate* berperan dalam mengontrol informasi baru yang akan disimpan, yang dikombinasikan dengan kandidat memori baru(Fahmi et al., n.d.). Hasil dari *forget gate* dan *input gate* kemudian digabungkan untuk memperbarui *cell state* menjadi ( $C_t$ ), yang merepresentasikan memori terbaru dari jaringan.(Wulandari & Aziz, 2025)

Kemudian, *output gate* menentukan informasi yang akan dikeluarkan sebagai *hidden state* ( $h_t$ ) berdasarkan kombinasi antara *cell state* yang telah diperbarui(Sungkar & Ratmawati, 2026). Dengan struktur ini, LSTM mampu mengatasi permasalahan *vanishing gradient* serta mempertahankan informasi penting dalam jangka panjang, sehingga sangat efektif digunakan pada data sekuensial seperti *time series forecasting*(Short et al., 2021). Secara umum model LSTM dapat dinyatakan melalui mekanisme berikut:

- a. *Forget gate*: mengontrol informasi lama yang dipertahankan. Gerbang ini menentukan informasi mana yang perlu dilupakan dari sel memori sebelumnya(Pradasyah & Baita, 2025)

$$f_t = \sigma (W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$f_t$  adalah untuk menunjukkan *forget gate vector* pada waktu ke- $t$ , yang berfungsi menentukan informasi mana dari memori sebelumnya yang akan dipertahankan atau dihapus.

$\sigma$  adalah fungsi aktivasi *sigmoid* yang menghasilkan nilai antara 0 hingga 1 :

Mendekati 0  $\rightarrow$  informasi diabaikan lalu mendekati 1  $\rightarrow$  informasi dipertahankan

$W_f$  adalah bobot (*weight*) pada *forget gate* yang dipelajari selama proses pelatihan model.

$[h_{t-1}, x_t]$  adalah Gabungan (*concatenation*) antara:

$h_{t-1}$  = *hidden state* dari waktu sebelumnya

$x_t$  = *input* pada waktu saat ini

$b_i$  adalah bias pada *forget gate* yang membantu model menyesuaikan *output* agar lebih fleksibel.

- b. *Input gate*: mengontrol informasi baru yang disimpan. Gerbang ini memutuskan informasi baru apa yang akan disimpan dalam sel memori (Pradasyah & Baita, 2025)

$$i_t = \sigma (W_o \cdot [h_{t-1}, x_t] + b_o) \quad (2)$$

$i_t$  adalah untuk menentukan seberapa besar informasi baru disimpan ke dalam *cell state*  
 $\sigma$  adalah untuk mengubah hasil menjadi rentang 0–1 dimana 0 = ditolak, 1 = diterima penuh

$W_i$  adalah parameter yang dipelajari model dan mengatur pengaruh *input* terhadap *gate*  
 $[h_{t-1}, x_t] = h_{t-1}$  *output hidden state* sebelumnya *input* pada waktu saat ini  $x_t$   
keduanya digabung (*concatenate*)

$b_i$  adalah nilai tambahan untuk menyesuaikan hasil perhitungan agar lebih fleksibel

- c. *Output gate*: mengontrol informasi yang dikeluarkan sebagai *output* sehingga menentukan bagian mana dari memori jangka panjang (*cell state*) yang akan dipakai sebagai *output* saat ini untuk diteruskan ke waktu berikutnya (Pradasyah & Baita, 2025).

$$o_t = \sigma (W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3)$$

$o_t$  adalah untuk meenentukan seberapa besar informasi baru disimpan ke dalam *cell state*

$\sigma$  adalah untuk meengubah hasil menjadi rentang 0–1 dimana 0 = ditolak, 1 = diterima penuh

$W_o$  adalah parameter yang dipelajari model dan mengatur pengaruh *output* terhadap *gate*  
 $[h_{t-1}, x_t] = h_{t-1}$  *output hidden state* sebelumnya *input* pada waktu saat ini  $x_t$   
keduanya digabung untuk menentukan keputusan *output*

$b_o$  adalah nilai tambahan untuk menyesuaikan hasil perhitungan agar lebih fleksibel

Validasi model dalam penelitian ini dilakukan menggunakan pendekatan pembagian data berbasis waktu (*time series split*), yaitu dengan membagi data menjadi data latih (*training set*) dan data uji (*testing set*) secara berurutan tanpa melakukan pengacakan (Akbar & Ariany, 2026). Hal ini dilakukan karena karakteristik data yang digunakan merupakan data deret waktu sehingga urutan temporal harus tetap dipertahankan agar tidak terjadi kebocoran informasi (*data leakage*) (Ismanto et al., 2026). Data pada periode awal digunakan sebagai data latih untuk membangun model *Long Short-Term Memory* (LSTM), sedangkan data pada periode akhir digunakan sebagai data uji untuk mengevaluasi kemampuan model dalam melakukan prediksi terhadap data yang belum pernah dilihat sebelumnya. Selain itu, untuk memastikan kestabilan performa model, dilakukan juga evaluasi menggunakan beberapa metrik kesalahan, yaitu MAE merupakan ukuran rata-rata *error* absolut yang paling mudah diinterpretasikan karena langsung menggambarkan rata-rata kesalahan prediksi model (Hodson, 2022). MAPE merupakan metrik yang umum digunakan dalam *forecasting* karena mampu menunjukkan tingkat

kesalahan dalam bentuk persentase sehingga mudah diinterpretasikan nilai MAPE di bawah 10% termasuk kategori “sangat baik”(Badulescu, 2020). RMSE lebih sensitif terhadap kesalahan besar dibandingkan MAE karena menggunakan kuadrat *error* dalam perhitungannya(Hodson, 2022).  $R^2$  metrik informatif dalam evaluasi model regresi karena mampu menunjukkan tingkat kecocokan model terhadap data aktual secara lebih jelas ketika mendekati 1 menunjukkan hubungan yang sangat kuat antara hasil prediksi dan data aktual(Chicco et al., 2021).

Dengan demikian, metode validasi ini tidak hanya menguji kemampuan model dalam mengenali pola historis, tetapi juga mengukur tingkat akurasi prediksi model pada data aktual di masa depan(Alfarizi & Lestarini, 2025).

## Hasil dan Pembahasan

Permasalahan operasional terkait waktu proses *bagging* di PT Pos Indonesia (Persero) dianalisis menggunakan pendekatan kuantitatif berbasis *time series forecasting* dengan metode *Long Short-Term Memory* (LSTM). Pendekatan ini dirancang untuk memodelkan dan memprediksi durasi waktu *bagging* berdasarkan data historis operasional, yang meliputi volume kiriman, berat kiriman, jumlah staf, dan waktu proses *bagging*. Dalam penelitian ini, metode LSTM digunakan untuk menangkap pola ketergantungan data waktu (*sequential data*) guna menghasilkan prediksi yang lebih akurat terhadap kinerja operasional.

### 1. Hasil Uji Stasioneritas Menggunakan *Augmented Dickey-Fuller* (ADF)

Tabel 1. Hasil Uji Stasioneritas

NO	Variabel	Nilai p-Value	Interpretasi
1	Waktu <i>Bagging</i>	0,023	Stasioner

Nilai p-value sebesar 0,012 pada variabel Waktu *Bagging* menunjukkan bahwa hasil uji *Augmented Dickey-Fuller* (ADF) berada di bawah tingkat signifikansi 0,05. Hal ini berarti hipotesis nol ( $H_0$ ) yang menyatakan data tidak stasioner ditolak, sehingga waktu pengantongan data dinyatakan stasioner. Kondisi ini menunjukkan bahwa pola waktu pengantongan data relatif stabil dari waktu ke waktu dan tidak memiliki tren yang terlalu kuat. Dengan demikian, data tersebut dinilai layak digunakan pada tahap pemodelan *time series* menggunakan metode LSTM karena pola historisnya dapat dipelajari dengan lebih baik oleh model.

## 2. Hasil Sistematika Manual LSTM

Sebagai sampel berikut contoh perhitungan manual LSTM model dengan satu kali iterasi. pada data perusahaan logistik :

$$\text{Volume Kiriman} = 9$$

$$\text{Berat Kiriman (Kg)} = 8.56$$

$$\text{Banyak Staf} = 2$$

$$X_t = \text{waktu bagging}$$

$$\text{Bobot (semua): } W = 0.5$$

$$\text{Bias } \textit{forget gate} = 1$$

$$\text{Bias } \textit{input gate} = 0.5$$

$$\text{Bias } \tilde{C}_t \text{ (candidate memory)} = 0$$

$$\text{Bias } \textit{output gate} = 0.5$$

$$X_t = \frac{\text{Volume Kiriman} + \text{Berat kirirman}}{\text{Banyak Staf}}$$

$$\frac{9+8.56}{2} = 8,78$$

a) Menghitung *Forget*

$$\begin{aligned} f_t &= \sigma (W_f \cdot [h_{t-1}, x_t] + b_i) \\ &= \sigma ((0,5 \cdot 8,78) + (0,5 \cdot 0) + 1) \\ &= \sigma (4,39 + 0 + 1) \\ &= \sigma (5,39) \\ &= 0,9955 \end{aligned}$$

Pada perhitungan *forget gate* diperoleh nilai sebesar 0,9955. Nilai ini menunjukkan bahwa hampir seluruh informasi dari kondisi sebelumnya dipertahankan oleh model. Dalam konteks prediksi waktu *bagging*, kondisi tersebut mengindikasikan bahwa pola historis sebelumnya masih dianggap sangat relevan untuk memprediksi kondisi saat ini, sehingga model tidak banyak “melupakan” informasi terdahulu.

b) Menghitung *Input Gate* :

$$\begin{aligned} i_t &= \sigma (W_i \cdot [h_{t-1}, x_t] + b_i) = \sigma ((0,5 \cdot 8,78) + (0,5 \cdot 0) + 0,5) \\ &= \sigma (4,39 + 0 + 0,5) \\ &= \sigma (5,39) \\ &= 0,9925 \end{aligned}$$

Pada *input gate* diperoleh nilai sebesar 0,9925. Nilai ini menandakan bahwa

informasi baru yang masuk, yaitu hasil kombinasi volume kiriman, berat kiriman, dan jumlah staf, diterima hampir sepenuhnya oleh model untuk memperbarui memori sel. Artinya, data operasional pada waktu tersebut dianggap memiliki pengaruh kuat terhadap prediksi waktu *bagging*.

c) Menghitung *Output Gate*

$$\begin{aligned} o_t &= \sigma (W_o \cdot [h_{t-1}, x_t] + b_o) = \sigma ((0,5 \cdot 8,78) + (0,5 \cdot 0) + 0) \\ &= \sigma(4,89) \\ &= 0,9998 \end{aligned}$$

Sementara itu, *output gate* menghasilkan nilai sebesar 0,9998 yang berarti hampir seluruh informasi dari memori sel diteruskan menjadi *output hidden state*. Hal ini menunjukkan bahwa model memberikan respons yang sangat kuat terhadap kondisi *input* yang diberikan, sehingga informasi yang telah diproses dianggap penting untuk menghasilkan prediksi waktu *bagging* pada tahap berikutnya.

Hasil perhitungan tersebut menunjukkan bagaimana mekanisme pada metode LSTM bekerja dalam menentukan informasi mana yang dipertahankan, diperbarui, dan dikeluarkan pada proses prediksi waktu *bagging*. Nilai yang dihasilkan pada setiap *gate* berada pada rentang 0–1 karena menggunakan fungsi aktivasi *sigmoid* ( $\sigma$ ). Secara keseluruhan, nilai *gate* yang mendekati 1 menunjukkan bahwa model LSTM menganggap data *input* pada kondisi tersebut memiliki keterkaitan yang kuat dengan pola sebelumnya (Saepulrohman & Pratama, 2023). Sehingga, kombinasi volume kiriman dan berat kiriman terhadap jumlah staf signifikan dalam proses prediksi waktu *bagging*, sehingga informasi lama maupun informasi baru sama-sama dipertahankan secara optimal oleh model.

### 3. Hasil Evaluasi Model LSTM

Tabel 2. Hasil Evaluasi Model LSTM

NO	Metrik	Nilai	Interpretasi
1	MAE	32,51 detik	Rata-rata selisih prediksi cukup kecil
2	RMSE	41,78 detik	<i>Error</i> lebih sensitif terhadap <i>outlier</i> , masih tergolong baik
3	MAPE	6,15%	Tingkat kesalahan relatif rendah
4	$R^2$	0,89	Model mampu menjelaskan 89% variasi data

Berdasarkan tabel 2 hasil evaluasi model, dapat diketahui bahwa model LSTM yang digunakan memiliki performa prediksi yang baik dalam memprediksi waktu *bagging*. Nilai MAE sebesar 32,51 detik menunjukkan bahwa rata-rata selisih antara hasil prediksi dan data aktual relatif kecil. Jika dibandingkan dengan rata-rata waktu *bagging* sekitar 9 menit atau 540 detik, maka nilai *error* tersebut hanya sekitar 6% dari total waktu proses. Hal ini menunjukkan bahwa hasil prediksi model cukup mendekati kondisi sebenarnya sehingga kesalahan prediksi masih dalam batas yang dapat diterima.

Nilai RMSE sebesar 41,78 detik menunjukkan bahwa model masih memiliki beberapa kesalahan prediksi yang lebih besar pada kondisi tertentu, terutama ketika terjadi lonjakan data operasional. Jika dibandingkan dengan rata-rata waktu *bagging* sekitar 9 menit atau 540 detik, maka nilai RMSE tersebut hanya sekitar 7,74% dari total waktu proses.

$$\text{Persentase error} = \frac{RMSE}{\text{Data Aktual}} = \frac{41,78 \text{ detik}}{540 \text{ detik}} \times 100\% \approx 7,74\%$$

Persentase tersebut menunjukkan bahwa tingkat *error* model masih relatif kecil dibandingkan keseluruhan durasi proses *bagging* sehingga performa model masih tergolong baik. Selain itu, nilai RMSE lebih besar dibandingkan MAE sebesar 32,51 detik dengan selisih sekitar 9,27 detik. Perbedaan ini menunjukkan adanya beberapa *error* yang lebih besar pada titik data tertentu. Kondisi tersebut sesuai dengan teori evaluasi *forecasting* bahwa RMSE lebih sensitif terhadap *outlier* atau lonjakan data karena proses perhitungannya menggunakan kuadrat *error*. Menurut (Hodson, 2022), RMSE akan memberikan nilai lebih besar terhadap kesalahan prediksi yang ekstrem dibandingkan MAE sehingga metrik ini lebih efektif untuk mendeteksi fluktuasi *error* pada data *time series*. Dengan demikian, hasil evaluasi menunjukkan bahwa model LSTM cukup stabil dan tetap mampu mempertahankan performa prediksi yang baik meskipun terdapat variasi data operasional pada beberapa periode tertentu.


Selanjutnya, nilai MAPE sebesar 6,15% menunjukkan tingkat kesalahan relatif yang sangat rendah. Berdasarkan teori evaluasi *forecasting* yang dikemukakan oleh (Badulescu, 2020), nilai MAPE di bawah 10% termasuk kategori “sangat baik”. Hasil ini menunjukkan bahwa model LSTM mampu menghasilkan prediksi dengan tingkat akurasi yang tinggi terhadap data aktual. Nilai MAPE yang rendah juga

menandakan bahwa model mampu mempertahankan konsistensi prediksi pada berbagai kondisi data operasional.

Pada nilai koefisien determinasi  $R^2$  sebesar 0,89, dapat diartikan bahwa model mampu menjelaskan sekitar 89% variasi data waktu *bagging*, sedangkan sisanya sebesar 11% dipengaruhi oleh faktor lain di luar model. Sejalan dengan teori koefisien determinasi menurut (Chicco et al., 2021), nilai  $R^2$  yang mendekati 1 menunjukkan hubungan yang sangat kuat antara hasil prediksi dan data aktual. Oleh karena itu, model LSTM dinilai efektif dalam menangkap pola data operasional dan mampu digunakan sebagai model prediksi waktu *bagging* pada proses pengolahan kiriman.

#### 4. Hasil Prediksi Waktu *Bagging* Terhadap Faktor Operasional

Gambar di bawah ini di dapat bahwa model LSTM mampu memprediksi waktu *bagging*, dengan pola prediksi yang mengikuti tren data aktual. Meskipun terjadi beberapa selisih saat lonjakan nilai, secara umum model dapat memprediksi waktu *bagging* dengan akurasi yang memadai.




**Gambar 3. Hasil Perbandingan Data Aktual dan Prediksi**

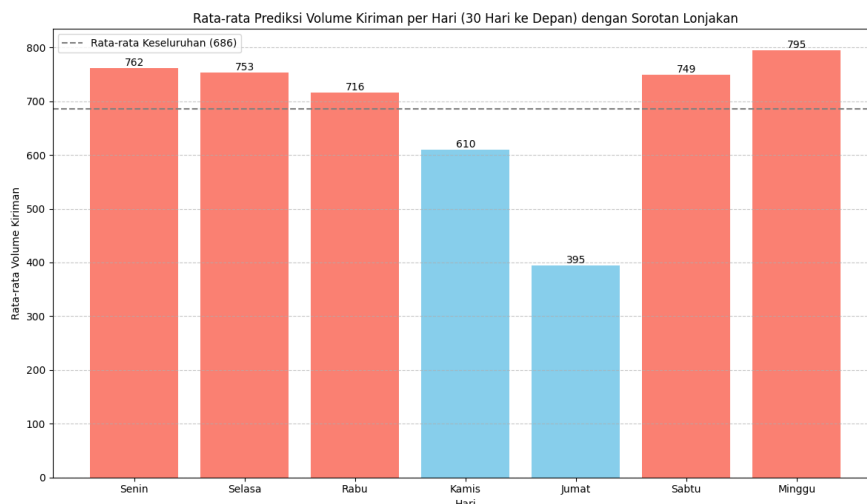
Gambar 3 di atas menunjukkan grafik perbandingan antara nilai aktual dan nilai prediksi waktu *bagging* yang dihasilkan oleh model *Long Short-Term Memory* (LSTM). Sumbu horizontal (X) merepresentasikan waktu atau tanggal pengamatan, sedangkan sumbu vertikal (Y) menunjukkan durasi waktu *bagging* yang diukur dalam satuan detik. Garis berwarna biru menggambarkan data aktual, yaitu waktu *bagging* yang terjadi

secara nyata di lapangan. Sementara itu, garis berwarna oranye menunjukkan hasil prediksi yang dihasilkan oleh model LSTM berdasarkan pola data historis. Dari grafik tersebut dapat dilihat bahwa pola prediksi mengikuti tren data aktual dengan cukup baik, meskipun terdapat beberapa titik yang menunjukkan perbedaan atau selisih nilai.

Perbedaan antara nilai aktual dan prediksi terlihat pada beberapa fluktuasi ekstrem, terutama pada kondisi tertentu ketika terjadi lonjakan waktu *bagging*. Hal ini menunjukkan bahwa model masih mengalami kesulitan dalam memprediksi kondisi yang bersifat tidak stabil atau memiliki variasi tinggi. Namun secara umum, model mampu menangkap pola utama dari data aktual sehingga dapat dikatakan memiliki performa prediksi yang cukup baik. Kesesuaian antara kedua garis tersebut juga mengindikasikan bahwa model LSTM mampu mempelajari pola temporal dari data *time series* , sehingga dapat digunakan sebagai alat bantu dalam memperkirakan waktu proses *bagging* di masa mendatang.

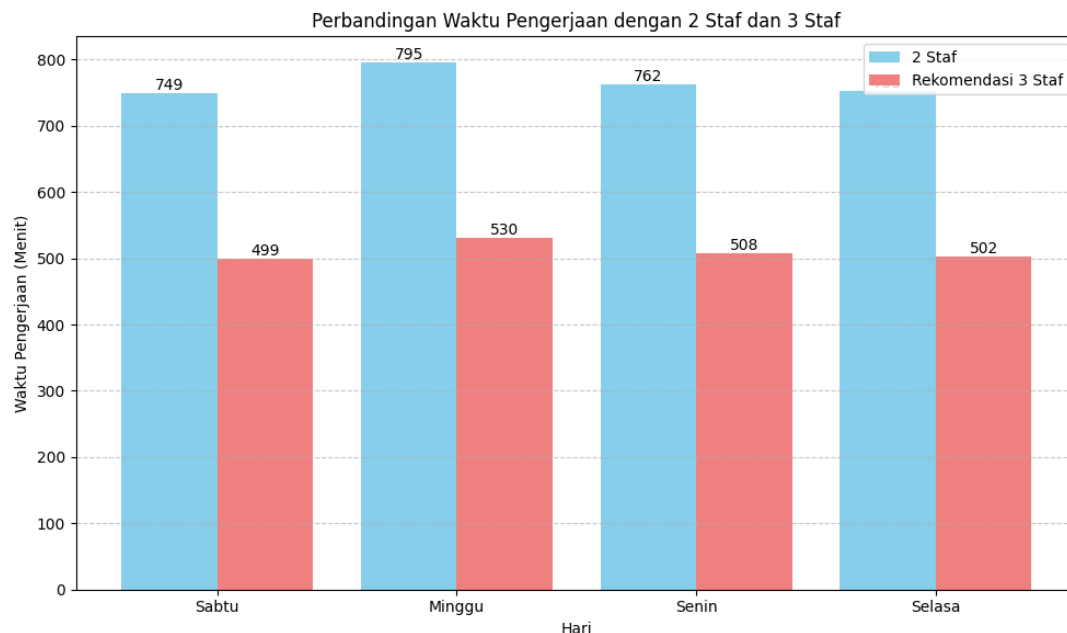


**Gambar 4. Pola Lonjakan Volume Kiriman 30 Hari Kedepan**



**Gambar 5. Pola Lonjakan Volume Kiriman Dalam 1 Minggu**

Berdasarkan gambar 5 hasil prediksi 30 hari kedepan, terjadi lonjakan hampir terjadi setiap hari kecuali Kamis dan Jumat yang turun ke 300–400 kiriman, oleh karena itu dibutuhkan penambahan jumlah staf yang bertugas dalam menghadapi lonjakan volume kiriman untuk pencapaian target jam kerja di perusahaan logistik tersebut.



**Gambar 6. Pola Perbandingan Waktu Pengerjaan 2 dan 3 Staf**

Gambar 6 menunjukkan perbandingan waktu penyelesaian proses *bagging* antara penggunaan 2 staf dan rekomendasi 3 staf pada beberapa hari pengamatan. Hasil analisis menunjukkan bahwa penambahan jumlah staf memberikan dampak yang signifikan terhadap penurunan waktu proses *bagging*, dengan rata-rata efisiensi sekitar 30–40%. Hal ini menunjukkan bahwa peningkatan kapasitas tenaga kerja berkontribusi dalam mempercepat alur kerja melalui pembagian tugas yang lebih seimbang, sehingga beban kerja individu menjadi lebih ringan dan proses dapat berjalan lebih paralel.

Efisiensi ini terjadi karena pada kondisi 2 staf, sistem kerja lebih rentan mengalami *bottleneck*, di mana satu atau kedua pekerja harus menangani volume pekerjaan yang lebih besar secara simultan. Kondisi ini meningkatkan waktu tunggu (*waiting time*) dan memperpanjang *cycle time* secara keseluruhan. Sebaliknya, dengan 3 staf, pekerjaan dapat didistribusikan lebih merata sehingga proses *sorting*, *handling*, dan pengemasan dapat dilakukan secara lebih paralel dan mengurangi penumpukan pada satu titik proses.

Meskipun demikian, masih terdapat variasi waktu pada setiap hari pengamatan, terutama pada hari dengan lonjakan volume kiriman. Selisih atau fluktuasi ini terjadi

karena peningkatan jumlah kiriman tidak hanya berdampak pada beban kerja, tetapi juga meningkatkan kompleksitas operasional seperti variasi ukuran paket, kebutuhan penanganan khusus, serta waktu transisi antar tahapan proses. Pada kondisi tersebut, meskipun jumlah staf ditingkatkan menjadi 3 orang, sistem tetap mendekati batas kapasitas operasionalnya sehingga efisiensi tidak selalu meningkat secara linier.

Hasil penelitian ini menunjukkan bahwa model *Long Short-Term Memory* (LSTM) mampu memberikan performa prediksi yang baik dalam memodelkan durasi proses *bagging* berdasarkan faktor operasional. Kemampuan LSTM dalam mempelajari pola data *time series* yang kompleks memungkinkan model menangkap hubungan temporal antara volume kiriman, berat kiriman, jumlah staf, dan durasi *bagging*. Mekanisme *memory cell* serta *gate* pada LSTM membantu model mempertahankan informasi penting dari periode sebelumnya sehingga pola perubahan durasi *bagging* dapat dipelajari secara efektif. Hal ini dibuktikan melalui hasil evaluasi model dengan nilai MAE sebesar 32,51 detik, RMSE sebesar 41,78 detik, MAPE sebesar 6,15%, dan nilai  $R^2$  sebesar 0,89 yang menunjukkan bahwa model mampu menjelaskan sekitar 89% variasi data aktual.

Nilai *error* yang relatif rendah menunjukkan bahwa model mampu mengikuti pola data aktual dengan cukup baik. Rendahnya tingkat kesalahan tersebut dipengaruhi oleh tahapan *preprocessing* seperti normalisasi menggunakan *Min-Max Scaling* dan pembagian data *time series* secara berurutan sehingga pola historis tetap terjaga. Selain itu, penggunaan variabel operasional yang relevan membantu model mengenali hubungan antara beban kerja dan durasi proses *bagging* secara lebih akurat. Walaupun masih terdapat selisih prediksi pada kondisi lonjakan kiriman, model tetap mampu menangkap pola utama data operasional sehingga dapat digunakan sebagai alat bantu prediksi dalam mendukung pengambilan keputusan operasional.

Hasil penelitian ini juga sejalan dengan penelitian sebelumnya yang menyatakan bahwa metode LSTM efektif digunakan dalam prediksi data *time series*. Penelitian oleh (M. L. Ashari & Sadikin, 2020)) menunjukkan bahwa LSTM mampu menghasilkan prediksi dengan tingkat *error* yang rendah pada data transaksi penjualan. Selain itu, penelitian (Cahyani et al., 2023) juga menyatakan bahwa LSTM memiliki performa yang baik pada data multivariat yang bersifat fluktuatif. Kesamaan hasil tersebut menunjukkan bahwa kemampuan LSTM dalam mempelajari ketergantungan jangka panjang dapat diterapkan tidak hanya pada bidang penjualan dan cuaca, tetapi juga pada operasional logistik seperti proses *bagging* di PT Pos Indonesia.

Dengan demikian, penambahan staf terbukti efektif dalam meningkatkan efisiensi dan menurunkan waktu proses *bagging* secara keseluruhan, namun efektivitas tersebut bersifat kondisional. Artinya, penambahan staf paling optimal pada kondisi beban kerja normal hingga menengah, sementara pada kondisi lonjakan ekstrem, diperlukan kombinasi strategi lain seperti optimalisasi alur kerja atau penyesuaian sistem penjadwalan untuk menjaga stabilitas waktu proses agar tetap berada dalam batas operasional yang ditetapkan, yaitu 18 jam dalam dua shift kerja. Selain itu, hasil prediksi model LSTM dapat dimanfaatkan sebagai dasar pengambilan keputusan dalam pengaturan tenaga kerja dan perencanaan operasional logistik secara lebih optimal.

## Simpulan

Berdasarkan hasil penelitian, metode *Long Short-Term Memory* (LSTM) berhasil diterapkan untuk memprediksi durasi proses pengantongan berdasarkan faktor operasional berupa volume kiriman, berat kiriman, dan jumlah staf pada PT Pos Indonesia. Model yang dikembangkan mampu menghasilkan kinerja prediksi yang baik sehingga dapat digunakan untuk membantu perencanaan operasional logistik. Penelitian ini menunjukkan bahwa peningkatan volume pengiriman berpengaruh terhadap peningkatan durasi proses pengantongan, sedangkan penambahan jumlah staf mampu meningkatkan efisiensi waktu proses secara signifikan. Penelitian ini juga menunjukkan bahwa metode LSTM dapat diterapkan pada prediksi proses pengantongan logistik berdasarkan faktor operasional multivariat yang masih jarang didiskusikan pada penelitian sebelumnya. Temuan ini memberikan kontribusi dalam penerapan metode *deep learning* pada proses operasional logistik, khususnya sebagai dasar pengambilan keputusan dalam pengaturan tenaga kerja dan optimalisasi proses pengantongan agar tetap berada dalam batas waktu operasional perusahaan.

Untuk penelitian berikutnya, disarankan agar model prediksi LSTM dikembangkan dengan memasukkan lebih banyak variabel operasional, seperti waktu kedatangan kiriman, distribusi jenis paket, serta faktor eksternal seperti musim atau periode promosi yang dapat memengaruhi lonjakan volume. Selain itu, penggunaan data historis yang lebih panjang dan beragam akan meningkatkan akurasi prediksi pola kiriman. Penelitian juga dapat membandingkan LSTM dengan metode lain, misalnya *Random Forest*, *Gradient Boosting*, atau ARIMA, untuk menilai keunggulan relatif masing-masing model. Implementasi sistem prediksi secara *real-time* yang terintegrasi dengan sistem operasional perusahaan logistik lainnya juga menjadi arah pengembangan penting, sehingga alokasi staf dapat dilakukan secara dinamis sesuai kondisi harian. Dengan demikian, penelitian lanjutan tidak hanya memperkuat validitas

model, tetapi juga memberikan kontribusi praktis bagi optimalisasi manajemen logistik.

### Daftar Pustaka

- Adam, P. O., & Sgd, D. A. N. (2025). *Perbandingan optimizer adam, rmsprop, dan sgd dalam prediksi kepribadian berbasis openface*. 9(5), 8157–8164.
- Akbar, M. A., & Ariany, F. (2026). *Komparasi Algoritma Naive Bayes dan K-Nearest Neighbor untuk Analisis Sentimen Pengguna Dompok Digital pada Google Play Store*. 7(4), 2335–2348. <https://doi.org/10.47065/bits.v7i4.9285>
- Alfarizi, M., & Lestarini, D. (2025). *Predicting Cryptocurrency Prices Using Machine Learning : A Case Study on Bitcoin*. 9(6), 3612–3621.
- Ashari, M. L., & Sadikin, M. (2020). *Prediksi Data Transaksi Penjualan Time Series Menggunakan Regresi Lstm*. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 9(1), 1. <https://doi.org/10.23887/janapati.v9i1.19140>
- Ashari, Y., Suhendar, A., Sains, F., Yogyakarta, U. T., & Info, A. (2024). *IMPLEMENTASI ALGORITMA LONG SHORT-TERM MEMORY ( LSTM ) UNTUK MEMREDIKSI HARGA BERAS DI JAWA*. 5(3), 624–636. <https://doi.org/10.46576/djtechno>
- Badulescu, Y. (2020). *Evaluating demand forecasting models using multi-criteria decision-making approach*. <https://doi.org/10.1108/JAMR-05-2020-0080>
- Cahyani, J., Mujahidin, S., & Palyus, T. (2023). *Implementasi Metode Long Short Term Memory ( LSTM ) untuk Memprediksi Harga Bahan Pokok Nasional*. 11(2), 346–357. <https://doi.org/10.26418/justin.v11i2.57395>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). *The coefficient of determination R-squared is more informative than SMAPE , MAE , MAPE , MSE and RMSE in regression analysis evaluation*. 1–24. <https://doi.org/10.7717/peerj-cs.623>
- Daya, M., Di, S., & Digitalisasi, E. R. A. (n.d.). *PT POS INDONESIA TRANSFORMATION AND INNOVATION IN*. 2(2), 292–299.
- Fahmi, A., Syarif, A. M., Irawan, C., Widjajanto, B., & Mulyanto, E. (n.d.). *No Title*.
- Guo, Z. (2023). *Research on the Augmented Dickey-Fuller Test for Predicting Stock Prices and Returns*. 0, 101–106. <https://doi.org/10.54254/2754-1169/44/20232198>

- Hawali, M. L. (2025). *Pemilihan Neuron LSTM dan LSTM Bayesian Optimization Untuk Prediksi Curah Hujan Bulanan Berbasis Iklim*. 15(2), 376–382.
- Hermawan, T., & Zuliarso, E. (2025). *Perbandingan Metode Recurrent Neural Network ( RNN ) dan Long Short-Term Memory ( LSTM ) untuk Prediksi Curah Hujan*. 7(2), 1450–1463. <https://doi.org/10.47065/bits.v7i2.8099>
- Hodson, T. O. (2022). *Root-mean-square error ( RMSE ) or mean absolute error ( MAE ): when to use them or not*. 2, 5481–5487.
- Ismanto, E., Dalimunthe, A. G., Iqbal, M., & Addinunnisa, F. (2026). *Analisis Komparatif Model Machine Learning dan Deep Learning pada Peramalan Harga Saham Time Series*. 2(1), 131–139.
- Logistik, P. T., Indonesia, U. P., & Barat, J. (2026). , *Wiku Larutama*. 19(01), 34–57.
- Mubarok, A. S. (2025). *Analisis Peramalan dalam Manajemen Operasi*.
- Pradasyah, A., & Baita, A. (2025). *Comparative Study of Support Vector Regression and Long Short-Term Memory for Stock Price Prediction*. 9(4).
- Prasetyo, Y., Faris, M., Fatih, A., Iqbal, M. J., Zida, A., Isnaini, M., Rizki, A. M., & Anyar, G. (2025). *ANALISIS PERBANDINGAN OPTIMIZER SGD DAN ADAM PADA MODEL CNN*. 9(1), 1348–1354.
- Process, D., Strategy, O., Delivering, F., Package, D., At, D., Surabaya, N., & Office, P. (2019). *Proses Distribusi Dan Strategi Optimasi Pengiriman Paket Dan Dokumen Dalam Negeri Pada Kantor Pos Besar Surabaya Utara 60000 Distribution Process And Optimization Strategy For Delivering Domestic Package And Document At North Surabaya Post Office*. 3(1), 37–49.
- Rosyd, A., Purnamasari, A. I., & Ali, I. (2024). *PENERAPAN METODE LONG SHORT TERM MEMORY ( LSTM ) DALAM MEMPREDIKSI HARGA SAHAM PT BANK CENTRAL ASIA*. 8(1), 501–506.
- Saepulrohman, A., & Pratama, S. Z. (2023). *Prediksi Arah Harga Bitcoin Berdasarkan Manipulasi Metode Long Short-Term Memory ( LSTM )*. 3(1), 15–24.
- Setianingrum, N., Isfian, N. A., Rahayu, M., & Isnaini, M. F. (2025). *Jurnal Penelitian Nusantara Analisis Kinerja PT . Pos Indonesia ( Studi Kasus Pengiriman Paket Pos di*

*Kota Bondowoso ) Menulis : Jurnal Penelitian Nusantara. 1, 582–587.*

Short, L., Memory, T., Setiawan, D., & Stefani, K. (2021). 264 *Dhanny Setiawan, Kezia Stefani, Yusup Jauhari S., Carel Anthony F.P. Sistem Analisis Harga Saham Menggunakan Algoritma Long Short Term Memory.* 264–279.

Sungkar, A. A., & Ratmawati, D. E. (2026). *ANALISIS SENTIMEN APLIKASI JAKONE MOBILE MENGGUNAKAN LONG SHORT-TERM MEMORY ( LSTM ) DAN LATENT DIRICHLET ALLOCATION ( LDA ).* 10(4).

Tita Lattifia, Putu Wira Buana, & NI Kadek Dwi Rusjyanthi. (2022). Model Prediksi Cuaca Menggunakan Metode LSTM. *JITTER-Jurnal Ilmiah Teknologi dan Komputer*, 3(1).

Wulandari, H. S., & Aziz, R. Z. A. (2025). *Implementasi Model LSTM , CNN + LSTM Hybrid , dan Transformer untuk Prediksi Cuaca Harian Berbasis Data Multivariat.* 7(2), 1005–1016. <https://doi.org/10.47065/bits.v7i2.7655>

Yulianto, E., & Wulandari, A. (2025). Dampak Perkembangan E-Commerce Terhadap Industri. *Jurnal Pengabdian Indonesia (JPI)*, 1(2), 352–365.