Jurnal Riset Aplikasi Ilmu Data dan Sistem 1 (2), 185–196 DOI: 0000
Oktober 2026

Prediksi Beban Kerja Berdasarkan *Shift* Di Jembatan Timbang Pada PT. Wilmar Nabati Indonesia Menggunakan Metode *Long Short-Term Memory* (LSTM)

Ahmad Rafi Syaifudin, Atik Wintarti*, Ulfa Siti Nuraini
Program Studi Sarjana Sains Data, Universitas Negeri Surabaya, Indonesia

Abstrak

PT. Wilmar Nabati Indonesia menghadapi tantangan pengelolaan beban kerja di jembatan timbang akibat fluktuasi kedatangan armada angkutan yang tidak merata antar-*shift* operasional. Ketidakseimbangan ini berpotensi menimbulkan antrean panjang, inefisiensi logistik, dan pembengkakan biaya operasional. Pendekatan perencanaan konvensional berbasis statistik deskriptif dinilai tidak mampu menangkap pola non-linear dan ketergantungan temporal pada data kedatangan kendaraan. Penelitian ini bertujuan untuk mengidentifikasi karakteristik fluktuasi kedatangan armada berdasarkan *shift*, mengimplementasikan model *Long Short-Term Memory* (LSTM) dan *Bidirectional LSTM* (Bi-LSTM) dalam memprediksi beban kerja, serta membandingkan performa kedua model tersebut. Data yang digunakan merupakan catatan transaksi penimbangan di Jembatan Timbang 11 PT. Wilmar Nabati Indonesia periode Desember 2024 hingga Maret 2025. Prapemrosesan data mencakup rekayasa fitur berupa fitur *lag* historis hingga 24 jam sebelumnya, transformasi siklikal waktu berbasis fungsi sinus dan kosinus, serta normalisasi menggunakan MinMaxScaler. *Dataset* dibagi secara kronologis menjadi 80% data latih dan 20% data uji. Evaluasi model menggunakan metrik *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Error* (MAE), dan *Area Under the Curve* (AUC). Hasil analisis menunjukkan bahwa puncak kedatangan armada terjadi pada *Shift* Pagi sebesar 42,2% (5.270 truk), sedangkan puncak keberangkatan terjadi pada *Shift* Sore sebesar 46,6% (5.827 truk). Berdasarkan evaluasi performa, model Standard LSTM sedikit lebih unggul dibandingkan Bi-LSTM dengan nilai MSE sebesar 23,41, RMSE sebesar 4,84, MAE sebesar 3,45, dan AUC sebesar 0,852, yang termasuk kategori diskriminasi sangat baik. Kedua model memiliki keterbatasan dalam mengantisipasi lonjakan mendadak akibat faktor eksternal dan efek keterlambatan transisi *shift*. Penelitian ini membuktikan bahwa model LSTM mampu menjadi alat prediktif berbasis data yang andal untuk mendukung pengambilan keputusan operasional dan optimalisasi alokasi sumber daya di jembatan timbang industri pengolahan minyak sawit.

Kata Kunci *Long Short-Term Memory; Bidirectional LSTM; prediksi beban kerja; jembatan timbang; deret waktu; logistik industri*

Abstract

PT. Wilmar Nabati Indonesia faces challenges in managing workload at weighbridges due to uneven fluctuations in fleet arrivals between operational shifts. This imbalance has the potential to cause long queues, logistical inefficiencies, and operational cost overruns. Conventional planning approaches based on descriptive statistics are considered incapable of capturing non-linear patterns

*Corresponding author. Email: atikwintarti@unesa.ac.id or ulfanuraini@unesa.ac.id.

Received 16 Juli 2026; Revised 31 Oktober 2026; Accepted 16 November 2026

and temporal dependencies in vehicle arrival data. This study aims to identify the characteristics of fleet arrival fluctuations based on shifts, implement Long Short-Term Memory (LSTM) and Bidirectional LSTM (Bi-LSTM) models in predicting workload, and compare the performance of the two models. The data used are weighing transaction records at Weighbridge 11 of PT. Wilmar Nabati Indonesia for the period December 2024 to March 2025. Data preprocessing includes feature engineering in the form of historical lag features up to the previous 24 hours, cyclical time transformations based on sine and cosine functions, and normalization using MinMaxScaler. The dataset is divided chronologically into 80% training data and 20% test data. Model evaluation used Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE), and Area Under the Curve (AUC) metrics. The analysis showed that peak fleet arrivals occurred during the morning shift (42.2%) (5,270 trucks), while peak departures occurred during the afternoon shift (46.6%) (5,827 trucks). Based on the performance evaluation, the Standard LSTM model slightly outperformed the Bi-LSTM model with an MSE of 23.41, RMSE of 4.84, MAE of 3.45, and AUC of 0.852, which qualifies as very good discrimination. Both models have limitations in anticipating sudden surges due to external factors and the effects of shift transition delays. This study demonstrates that the LSTM model can be a reliable, data-driven predictive tool to support operational decision-making and optimize resource allocation at weighbridges in the palm oil processing industry.

Keywords *Long Short-Term Memory; Bidirectional LSTM; workload prediction; weighbridge; time series; industrial logistics*

1 Pendahuluan

Efisiensi rantai pasok merupakan faktor penting bagi perusahaan manufaktur untuk menjaga ketersediaan bahan baku, kontinuitas produksi, dan ketepatan distribusi produk. Pada kawasan industri berskala besar, jembatan timbang berfungsi sebagai titik validasi utama bagi kendaraan dan material yang masuk maupun keluar. Hambatan pada titik tersebut dapat meningkatkan waktu tunggu, memindahkan akumulasi pekerjaan ke periode berikutnya, dan menambah biaya operasional (Dubey dkk., 2021; Pratama, 2025).

Operasional Jembatan Timbang 11 PT Wilmar Nabati Indonesia berlangsung selama 24 jam dan dibagi ke dalam tiga *shift*, yaitu pagi, sore, dan malam. Volume kendaraan pada setiap *shift* tidak selalu seimbang. Kedatangan yang terkonsentrasi pada jam tertentu meningkatkan beban petugas dan fasilitas, sedangkan keterlambatan penyelesaian proses penimbangan dapat meneruskan beban kerja ke *shift* selanjutnya. Dengan demikian, penggunaan rata-rata historis saja belum cukup untuk menggambarkan hubungan nonlinier dan ketergantungan waktu pada arus kendaraan.

Pemanfaatan data transaksi memungkinkan beban kerja diperkirakan melalui pendekatan deret waktu. Dalam penelitian ini, beban kerja didefinisikan secara operasional sebagai jumlah kendaraan yang diproses pada setiap interval satu jam. Permasalahan beban kerja menghasilkan target bernilai kontinu, sehingga permasalahan utama termasuk permasalahan regresi. Permasalahan regresi dapat diselesaikan dengan pendekatan *machine learning*, salah satunya yakni *Recurrent Neural Network* (RNN)

Recurrent Neural Network (RNN) mampu memproses data sekuensial melalui *hidden state*, tetapi dapat mengalami *vanishing gradient* ketika dependensi jangka panjang harus dipelajari. Akibatnya, model sering kali gagal menangkap pola atau konteks dari data sekuensial yang memiliki rentang waktu sangat panjang. *Long Short-Term Memory* mampu menyelesaikan keterbatasan

tersebut melalui mekanisme gerbang yang mengatur informasi yang dipertahankan, diperbarui, dan dikeluarkan dari sel memori (Hochreiter dan Schmidhuber, 1997; Gers dkk., 2000). LSTM telah digunakan dalam berbagai masalah prediksi lalu lintas dan logistik karena mampu memodelkan pola temporal yang tidak linier (Ramadhan dan Saputra, 2024; Wang dan Chen, 2025).

Bidirectional LSTM (Bi-LSTM) memperluas LSTM dengan memproses urutan pada arah maju dan mundur (Schuster dan Paliwal, 1997). Arah maju *forward* membaca data mulai awal hingga akhir untuk memahami konteks masa lalu, sedangkan arah mundur *backward* membaca data dari akhir kembali ke awal untuk memahami konteks masa depan. Hasilnya kemudian digabungkan agar model memiliki pemahaman konteks yang utuh dari kedua sisi. Ganmbaran ini dapat menghasilkan representasi konteks yang lebih kaya, tetapi juga meningkatkan jumlah parameter dan biaya komputasi. Pada peramalan operasional yang bersifat maju, manfaat pemrosesan dua arah perlu diuji secara empiris. Arsitektur yang lebih kompleks tidak selalu menghasilkan kesalahan prediksi yang lebih rendah, terutama ketika data terbatas atau representasi input belum menyediakan urutan waktu yang panjang.

Penelitian ini memiliki tiga tujuan. Pertama, mengidentifikasi karakteristik fluktuasi kedatangan dan keberangkatan kendaraan berdasarkan jam dan *shift*. Kedua, membangun model Standard LSTM dan Bi-LSTM dengan fitur *lag* serta fitur waktu siklikal. Ketiga, membandingkan performa kedua model berdasarkan *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolut Error* (MAE), dan *Area Under the Curve* (AUC) sebagai analisis tambahan. Kontribusi praktis penelitian adalah menyediakan estimasi beban per jam yang dapat menjadi informasi pendukung dalam perencanaan petugas dan kesiapan fasilitas jembatan timbang.

2 Metode

2.1 Alur Penelitian

Alur penelitian terdiri atas pengumpulan data transaksi, validasi atribut waktu, agregasi jumlah kendaraan per jam, perbaikan kesenjangan deret waktu, rekayasa fitur, pembagian data kronologis, transformasi data, pelatihan model menggunakan LSTM dan Bi-LSTM dengan metrik evaluasi komparatif. Gambar 1 menyajikan urutan implementasi penelitian.

2.2 Pengumpulan dan Definisi Data

Data penelitian merupakan data primer transaksi penimbangan pada Jembatan Timbang 11 PT Wilmar Nabati Indonesia. Periode pengamatan dimulai pada 27 Desember 2024 dan berakhir pada 31 Maret 2025 dengan data sejumlah 12502 baris dengan 36 fitur. Setiap transaksi menyediakan informasi waktu penimbangan masuk dan penimbangan keluar yang digunakan untuk membentuk arus kendaraan per jam.

Variabel dependen penelitian adalah volume kendaraan per jam, yaitu hasil agregasi jumlah transaksi pada setiap interval satu jam. Variabel independen meliputi fitur *lag* historis, jam kedatangan, *shift* operasional, fitur siklikal waktu, dan durasi waktu tunggu. Durasi waktu tunggu digunakan pada analisis deskriptif awal, sedangkan target utama pemodelan adalah jumlah kendaraan per jam.

Pembagian *shift* mengikuti aturan operasional perusahaan sebagaimana dirangkum pada Tabel 1. Label numerik dipertahankan sebagai salah satu fitur model.

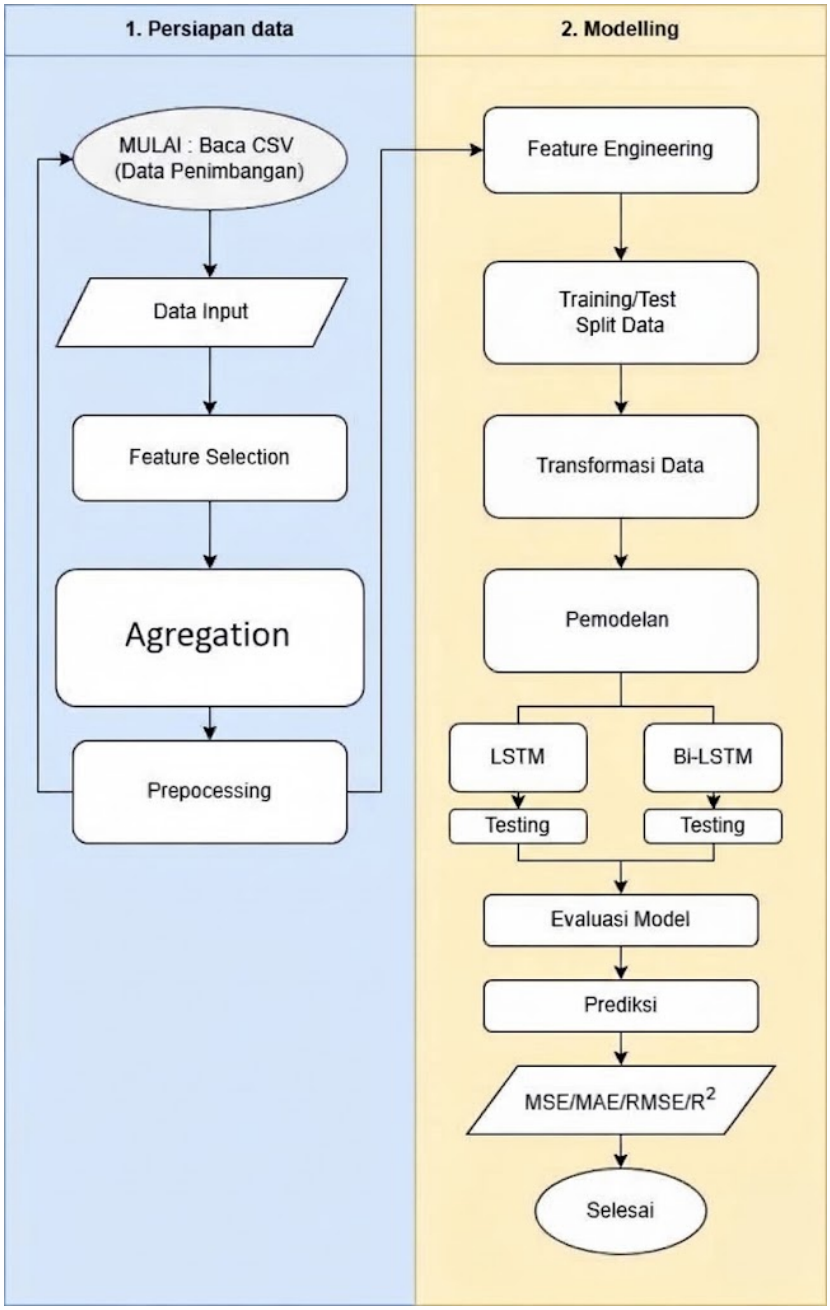

Gambar 1: Alur Penelitian

Tabel 1: Ketentuan Pelabelan *Shift*

No	Jam *Shift*	Jenis *Shift*	Label
1	08:00–15:59	Pagi	1
2	16:00–23:59	Sore	2
3	00:00–07:59	Malam	3

2.3 Pra-pemrosesan Data

Kolom waktu dikonversi ke tipe *datetime* untuk memastikan transaksi dapat diurutkan secara kronologis. Observasi dengan format waktu tidak valid diperiksa sebelum proses agregasi. Transaksi kemudian dikelompokkan berdasarkan interval satu jam sehingga diperoleh jumlah kendaraan per jam. Hasil data yang telah diproses menjadi 2056 baris dan 32 fitur.

Indeks waktu kontinu dibentuk untuk seluruh periode penelitian. Jam yang tidak memiliki catatan transaksi tetap dipertahankan melalui *reindexing*(proses membangun kembali struktur indeks pada database atau sistem pencarian). Jumlah kendaraan pada interval kosong diisi dengan nol, sedangkan label *shift* ditentukan kembali berdasarkan jam operasional. Langkah ini diperlukan agar selisih waktu antarbaris selalu satu jam dan fitur *lag* tidak melompati interval yang hilang.

2.4 Rekayasa Fitur dan Pembagian Data

Fitur historis dibentuk menggunakan 24 nilai *lag* jumlah kendaraan. Untuk waktu target t, fitur tersebut dituliskan sebagai

$$\mathbf{x}_t^{\text{lag}} = [y_{t-1}, y_{t-2}, \ldots, y_{t-24}], \tag{1}$$

dengan y_{t-k} menyatakan jumlah kendaraan pada k jam sebelum waktu prediksi. Penggunaan 24 *lag* dimaksudkan untuk merepresentasikan pola satu siklus harian.

Jam, hari dalam minggu, dan bulan memiliki karakteristik siklikal. Oleh karena itu, masing-masing indeks waktu ditransformasikan ke pasangan sinus dan kosinus:

$$s_z = \sin\left(2\pi \frac{z}{P}\right), \qquad c_z = \cos\left(2\pi \frac{z}{P}\right), \tag{2}$$

dengan z merupakan indeks waktu dan P adalah panjang siklus, yaitu 24 untuk jam, 7 untuk hari dalam minggu, dan 12 untuk bulan. Transformasi tersebut mempertahankan kedekatan siklikal, misalnya antara pukul 23.00 dan 00.00.

Komposisi input terdiri atas 24 fitur *lag* jumlah kendaraan, enam fitur siklikal (sinus dan kosinus untuk jam, hari dalam minggu, dan bulan), satu fitur jam, serta satu label *shift*, sehingga totalnya 32 fitur. Setelah 24 baris awal yang tidak memiliki *lag* lengkap dihapus, diperoleh 2.039 sampel. Sebanyak 1.631 sampel pertama digunakan sebagai data latih dan 408 sampel terakhir sebagai data uji. Pemisahan dilakukan secara kronologis tanpa pengacakan untuk menjaga urutan waktu.

Fitur dan target ditransformasi menggunakan MinMaxScaler. Parameter minimum dan maksimum dihitung hanya dari data latih, kemudian transformasi yang sama diterapkan pada data uji. Tahap ini menghindari kebocoran informasi dari periode pengujian ke proses pelatihan. Bentuk input model adalah $[\text{sampel}, 1, 32]$, yaitu satu langkah waktu dengan 32 fitur.

2.5 Model LSTM dan Bidirectional LSTM

Standard LSTM terdiri atas dua lapisan LSTM bertumpuk dengan 100 unit pada setiap lapisan. Lapisan pertama mengembalikan urutan, karena lapisan pertama ini berada di bawah lapisan LSTM kedua (bertumpuk) maka harus meneruskan seluruh rangkaian data waktu ke lapisan di atasnya. Sedangkan lapisan kedua menghasilkan representasi akhir. *Dropout* 0,2 diberikan setelah setiap lapisan LSTM dan diikuti lapisan *Dense*(1) untuk menghasilkan prediksi regresi. Lapisan Dense berfungsi sebagai pemeta akhir yang mengubah fitur-fitur urutan data dari LSTM menjadi satu nilai prediksi kontinu

Bi-LSTM diawali lapisan bidirectional berukuran 128 unit, diikuti *dropout* 0,3, lapisan LSTM 128 unit, *dropout* 0,3, lapisan LSTM 64 unit, dan *Dense*(1). Kedua model dikompilasi menggunakan *optimizer* Adam dan fungsi *loss* MSE, kemudian dilatih selama 50 *epoch* dengan *batch size* 32.

Pada sebuah unit LSTM, proses pembaruan *forget gate*, *input gate*, kandidat sel, status sel, *output gate*, dan *hidden state* dirumuskan sebagai berikut (Hochreiter dan Schmidhuber, 1997):

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f), \tag{3}$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i), \tag{4}$$

$$\widetilde{C}_t = \tanh(W_C x_t + U_C h_{t-1} + b_C), \tag{5}$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \widetilde{C}_t, \tag{6}$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o), \tag{7}$$

$$h_t = o_t \odot \tanh(C_t). \tag{8}$$

Bi-LSTM memproses input melalui jalur maju dan mundur, jalur maju *forward* dan mundur *backward* mengacu pada arah urutan pembacaan data deret waktu *time-series* atau teks dari dua dimensi temporal yang berlawanan, kemudian menggabungkan representasi dari kedua arah sebelum diteruskan ke lapisan berikutnya (Schuster dan Paliwal, 1997).

2.6 Evaluasi Model

Prediksi yang masih berada pada skala normalisasi dikembalikan ke satuan jumlah kendaraan per jam menggunakan *inverse transform*. Evaluasi utama menggunakan *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), dan *Mean Absolute Error* (MAE):

$$\text{MSE} = \frac{1}{n}\sum_{i=1}^{n}(y_i - \widehat{y}_i)^2, \tag{9}$$

$$\text{RMSE} = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \widehat{y}_i)^2}, \tag{10}$$

$$\text{MAE} = \frac{1}{n}\sum_{i=1}^{n}|y_i - \widehat{y}_i|. \tag{11}$$

Nilai yang lebih kecil menunjukkan kesalahan prediksi yang lebih rendah. RMSE dan MAE memiliki satuan kendaraan per jam.

Analisis ROC-AUC digunakan sebagai evaluasi tambahan dengan mengubah target aktual menjadi kategori beban rendah dan tinggi berdasarkan median jumlah kendaraan. Nilai prediksi kontinu digunakan sebagai skor diskriminasi. AUC tidak menggantikan metrik regresi karena target utama penelitian tetap berupa nilai kontinu. Analisis ini hanya menunjukkan kemampuan model dalam mengurutkan interval beban relatif tinggi dibandingkan interval beban rendah (Fawcett, 2006).

2.7 Skenario Pengujian

Kedua model menggunakan pembagian data, fitur, skala target, jumlah epoch, *batch size*, *optimizer*, dan fungsi *loss* yang sama. Dengan rincian pada pembagian data jumlah baris yang digunakan

sejumlah 2039 setelah lag (dengan training set sebanyak 1.631 data dan testing set sebanyak 408 data) dengan menggunakan 24 fitur lag dan 6 fitur siklis waktu. Keduanya juga sama menggunakan MinMaxScaler dengan skala (0,1) dan jumlah epoch keduanya sejumlah 50. Perbedaan utama terletak pada susunan lapisan rekuren, jumlah unit, *dropout*, dan jumlah parameter. Perbandingan dilakukan pada data uji yang sama sehingga selisih performa dapat dikaitkan dengan konfigurasi arsitektur.

3 Hasil dan Pembahasan

3.1 Karakteristik Fluktuasi Kendaraan Berdasarkan *Shift*

Distribusi kendaraan berdasarkan jam dan *shift* ditunjukkan pada Gambar 2. Aktivitas kedatangan meningkat pada *shift* pagi dan mencapai puncak lokal sekitar pukul 13.00. Puncak berikutnya terlihat sekitar pukul 19.00 pada *shift* sore. Keberangkatan cenderung terjadi lebih lambat dan lebih terkonsentrasi pada *shift* sore.

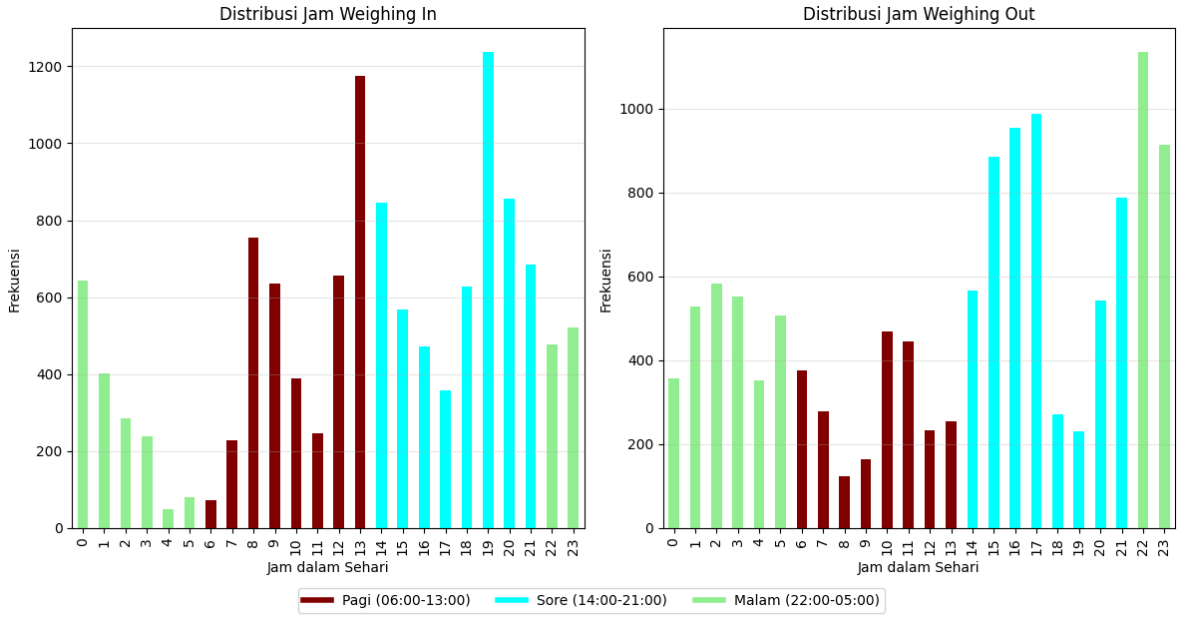

Gambar 2: Karakteristik Fluktuasi Distribusi Berdasarkan *Shift* pada WB 11

Perbedaan waktu antara puncak kedatangan dan keberangkatan menunjukkan adanya waktu pemrosesan dan potensi akumulasi kendaraan. Dengan demikian, beban pada *shift* sore tidak hanya berasal dari kendaraan yang datang pada periode tersebut, tetapi juga dari kendaraan yang prosesnya belum selesai pada *shift* sebelumnya.

Komposisi pada Gambar 3 menunjukkan bahwa 42,2% kedatangan atau 5.270 truk terjadi pada *shift* pagi. Sementara itu, 46,6% keberangkatan atau 5.827 truk terjadi pada *shift* sore. Aktivitas *shift* malam lebih rendah, tetapi tetap relevan karena fasilitas beroperasi sepanjang hari dan dapat menerima kendaraan tertunda atau pengiriman mendesak.

Deret waktu lengkap pada Gambar 4 memperlihatkan kombinasi siklus berulang dan lonjakan tidak teratur. Pola berulang mendukung penggunaan *lag* harian dan fitur waktu siklikal.

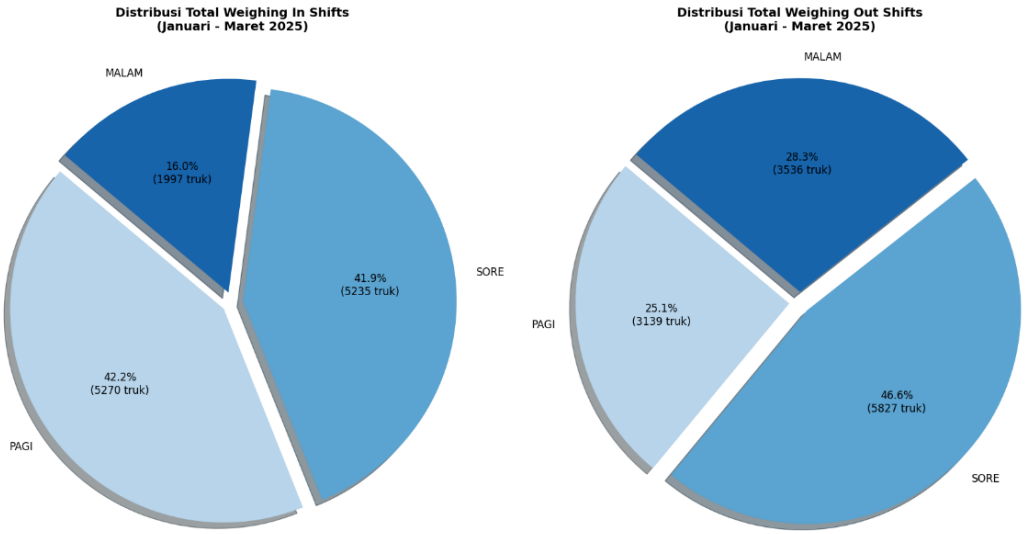

Gambar 3: Visualisasi Distribusi Armada Di WB 11

Sebaliknya, lonjakan yang tidak teratur menunjukkan adanya pengaruh eksternal yang belum direpresentasikan oleh fitur historis.

3.2 Hasil Pemodelan LSTM dan Bi-LSTM

Hasil evaluasi pada data uji disajikan pada Tabel 2. Standard LSTM menghasilkan nilai terendah pada seluruh metrik regresi. RMSE sebesar 4,838 menunjukkan bahwa besarnya penyimpangan prediksi berada pada kisaran empat hingga lima kendaraan per jam. MAE sebesar 3,451 menunjukkan rata-rata selisih absolut sekitar tiga hingga empat kendaraan per jam.

Tabel 2: Hasil Evaluasi Performa Model LSTM

No.	Metriks Evaluasi	Nilai Model LSTM	Nilai Model Bi-LSTM
	Mean Squared Error (MSE)	23.406863	23.730392
	Root Mean Squared Error (RMSE)	4.838064	4.871385
	Mean Absolute Error (MAE)	3.450980	3.465686
	Area Under The Curve (AUC)	0.851660	0.847717

Selisih RMSE antara kedua model hanya 0,033 kendaraan per jam dan selisih MAE hanya 0,015 kendaraan per jam. Perbedaan ini menunjukkan bahwa performa keduanya sangat berdekatan. Oleh karena itu, hasil penelitian tidak mendukung klaim bahwa Bi-LSTM secara substantif lebih baik daripada Standard LSTM pada dataset ini.

Hasil prediksi kedua model menunjukkan kecenderungan mengikuti pola umum data, tetapi masih memiliki keterbatasan ketika terjadi lonjakan mendadak. Sesuai pembahasan pada naskah sumber, keterbatasan tersebut berkaitan dengan faktor eksternal yang tidak tersedia pada fitur historis serta efek keterlambatan transisi *shift*.

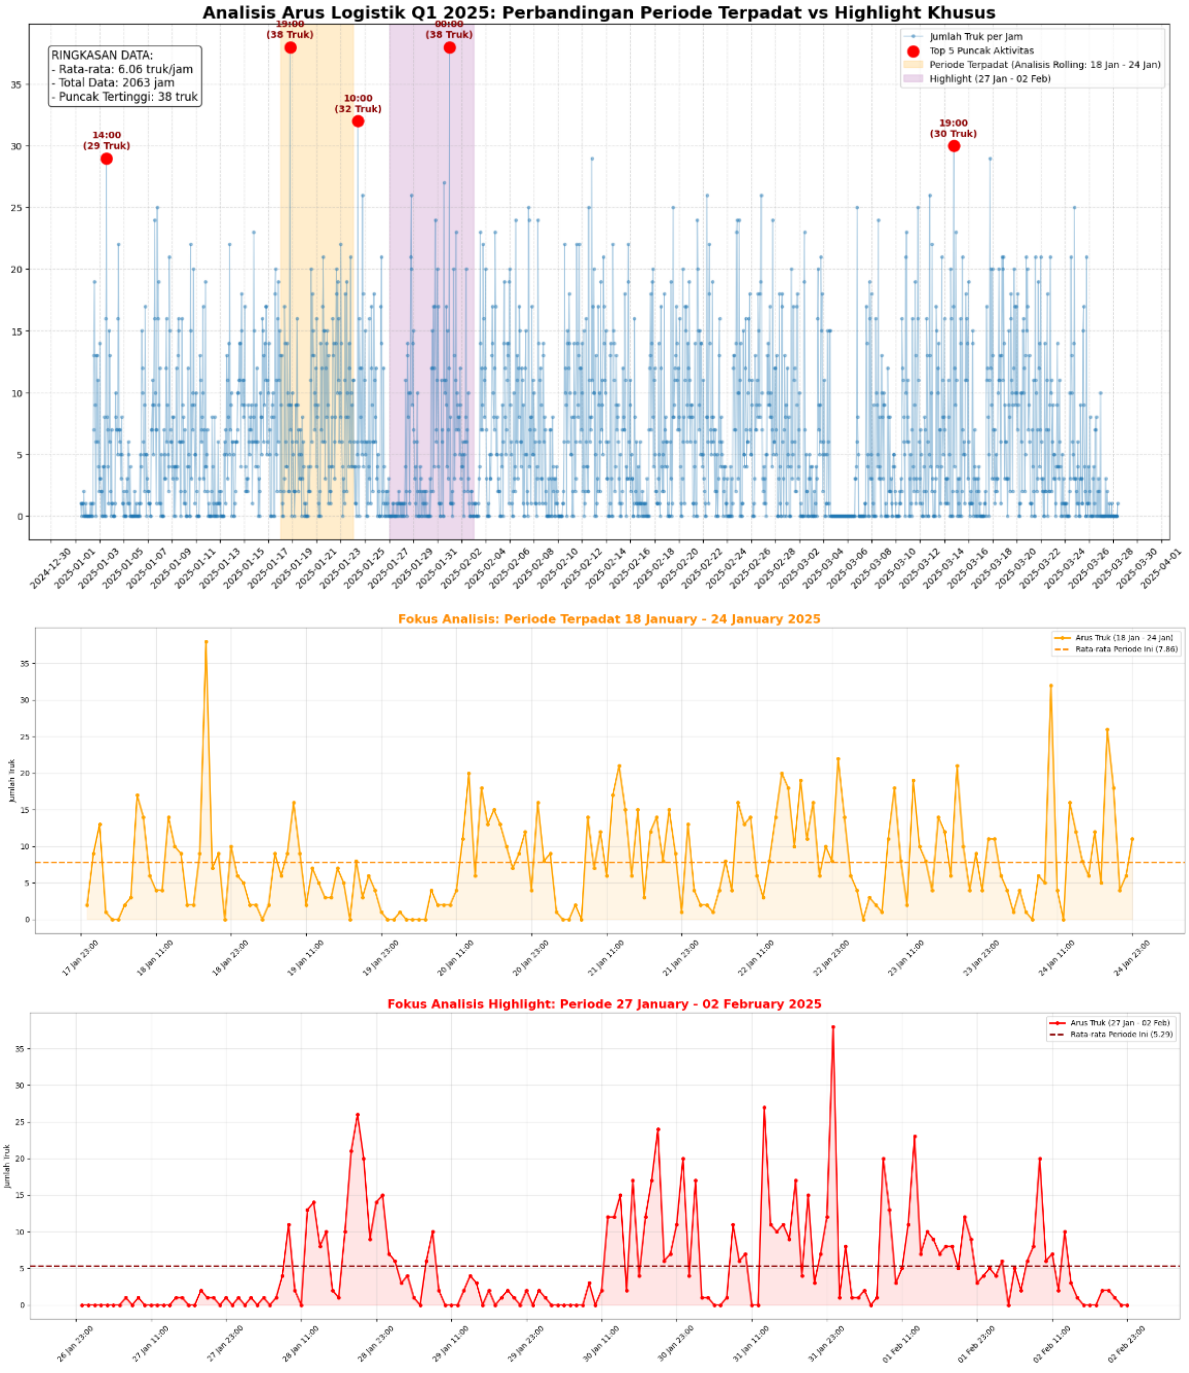

Gambar 4: Time Series Plot

3.3 Analisis Komparatif Arsitektur

Berdasarkan hasil perbedaan pada model LSTM dan Bi-LSTM pada gambar 4 dan tabel 2. Standard LSTM menggunakan 133.701 parameter, sedangkan Bi-LSTM menggunakan 411.457 parameter. Dengan demikian, Bi-LSTM memiliki lebih dari tiga kali jumlah parameter Standard LSTM, tetapi menghasilkan kesalahan yang sedikit lebih tinggi. Hasil ini menunjukkan bahwa kompleksitas model tidak otomatis meningkatkan generalisasi.

Salah satu faktor yang dapat menjelaskan hasil tersebut adalah bentuk input [sampel, 1, 32]. Dua puluh empat informasi historis ditempatkan sebagai fitur dalam satu langkah waktu, bukan sebagai 24 langkah sekuensial. Akibatnya, lapisan rekuren hanya menerima urutan dengan panjang satu dan tidak memproses perubahan 24 jam secara eksplisit dari langkah ke langkah. Pada representasi tersebut, jalur mundur Bi-LSTM memiliki konteks temporal tambahan yang terbatas untuk dimanfaatkan.

Jumlah sampel juga relatif kecil dibandingkan kompleksitas Bi-LSTM. Model dengan parameter lebih banyak memiliki kapasitas representasi yang tinggi, tetapi membutuhkan data yang cukup untuk memperoleh keuntungan generalisasi. Standard LSTM yang lebih sederhana memberikan hasil sedikit lebih stabil pada periode pengamatan yang tersedia. Namun, karena eksperimen hanya menggunakan satu pembagian kronologis dan tidak melaporkan pengulangan beberapa *seed*, perbedaan kecil tersebut tidak boleh ditafsirkan sebagai keunggulan mutlak.

3.4 Analisis Diskriminasi Beban Kerja

Standard LSTM menghasilkan AUC 0,8517 dan Bi-LSTM menghasilkan AUC 0,8477. Berdasarkan skala kategori yang digunakan dalam naskah sumber, kedua nilai tersebut berada pada kategori kemampuan diskriminasi sangat baik, dengan nilai Standard LSTM sedikit lebih tinggi.

AUC dalam penelitian ini harus dibaca sebagai analisis tambahan. Kategori tinggi dan rendah dibentuk dari median target kontinu, bukan berasal dari label operasional resmi perusahaan. Oleh karena itu, AUC tidak menunjukkan akurasi klasifikasi kondisi kritis dan tidak dapat digunakan sebagai pengganti RMSE atau MAE.

3.5 Implikasi Operasional dan Keterbatasan

Hasil prediksi dapat digunakan sebagai estimasi jumlah kendaraan yang perlu dilayani pada setiap jam. Informasi tersebut dapat membantu menyiapkan petugas pada *shift* pagi yang menerima proporsi kedatangan terbesar dan pada *shift* sore yang menangani proporsi keberangkatan terbesar serta potensi pekerjaan tertunda. Prediksi sebaiknya diperlakukan sebagai informasi pendukung, bukan sebagai sistem penjadwalan otomatis.

Penelitian memiliki beberapa keterbatasan. Pertama, periode data sekitar tiga bulan belum merepresentasikan variasi musiman tahunan, hari raya, penghentian produksi, atau perubahan jadwal pemasok. Kedua, input menggunakan 24 *lag* sebagai fitur dalam satu langkah waktu sehingga urutan temporal tidak diproses secara eksplisit oleh lapisan rekuren. Ketiga, data belum mencakup jadwal pemasok, hari libur, cuaca, kondisi lalu lintas, jenis muatan, kapasitas layanan, dan jadwal produksi. Keempat, penelitian hanya menggunakan data latih dan data uji tanpa subset validasi terpisah, sehingga pengembangan model dan evaluasi akhir perlu dipisahkan lebih tegas pada penelitian selanjutnya. Kelima, AUC diperoleh dari kategorisasi berbasis median dan tidak merepresentasikan ambang beban kritis yang ditentukan perusahaan.

4 Kesimpulan

Fluktuasi kendaraan di Jembatan Timbang 11 menunjukkan ketidakseimbangan antar-*shift*. Proporsi kedatangan terbesar terjadi pada *shift* pagi sebesar 42,2% atau 5.270 truk, sedangkan proporsi keberangkatan terbesar terjadi pada *shift* sore sebesar 46,6% atau 5.827 truk. Perbedaan waktu antara kedatangan dan keberangkatan menunjukkan bahwa proses pelayanan dan akumulasi pekerjaan dapat memindahkan beban ke periode berikutnya.

Standard LSTM dan Bi-LSTM dibangun menggunakan 24 fitur *lag*, enam fitur waktu siklikal, jam, dan label *shift*. Standard LSTM menghasilkan MSE 23,406863, RMSE 4,838064, MAE 3,450980, dan AUC 0,851660. Nilai tersebut sedikit lebih baik dibandingkan Bi-LSTM dengan MSE 23,730392, RMSE 4,871385, MAE 3,465686, dan AUC 0,847717. Dengan jumlah parameter yang lebih rendah, Standard LSTM menjadi konfigurasi yang lebih efisien untuk representasi data yang digunakan.

Perbedaan performa kedua model relatif kecil sehingga tidak cukup untuk menyimpulkan keunggulan arsitektur secara umum. Model masih kesulitan menangkap lonjakan mendadak karena hanya menggunakan informasi historis dan kalender. Penelitian selanjutnya disarankan menggunakan rentang data lebih panjang, memisahkan data untuk melatih data dan uji data, validasi, dan uji, menyusun 24 jam historis sebagai urutan multilangkah, menjalankan eksperimen berulang, serta menambahkan jadwal pemasok, hari libur, cuaca, lalu lintas, jenis muatan, dan kondisi produksi.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Program Studi Sarjana Sains Data Universitas Negeri Surabaya serta seluruh pihak yang telah memberikan dukungan dan masukan selama pelaksanaan penelitian ini.

Daftar Pustaka

Adere, E. M. (2022). A new dynamic network intrusion detection system using combined deep learning approach. *Security and Communication Networks*, 2022:1–17.

Almansobi, A., Bakar, A. A., dan Hamdan, A. R. (2024). Predictive analytics for truck arrival and wait times in logistics using deep learning: A review. *Journal Of Advanced Research In Dynamical And Control Systems*, 16(1):45–59.

Astuti, R. dan Nugroho, A. (2020). Optimasi rantai pasok hilir pada industri pengolahan minyak goreng. *Jurnal Manajemen Dan Operasional Industri*.

Dubey, R. dkk. (2021). Big data analytics and artificial intelligence pathway to operational performance under imperfect information: An empirical investigation. *International Journal of Production Economics*, 226:107647.

Fawcett, T. (2006). An introduction to roc analysis. *Pattern Recognition Letters*, 27(8):861–874.

Gers, F. A., Schmidhuber, J., dan Cummins, F. (2000). Learning to forget: Continual prediction with lstm. *Neural Computation*, 12(10):2451–2471.

Hochreiter, S. dan Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8):1735–1780.

Pratama, A. (2025). Analisis optimalisasi arus logistik dan sistem antrean kendaraan pada pt wilmar nabati indonesia: Studi kasus sistem antrian truk.

Ramadhan, A. dan Saputra, R. (2024). Pengujian long-short term memory (lstm) pada prediksi trafik lalu lintas menggunakan multi server. *Jurnal Sistem Informasi dan Teknologi*, 11(2):88–95.

Ratten, V. dan Jones, P. (2021). Sustainability and the roundtable on sustainable palm oil (rspo): Corporate social responsibility in the palm oil industry. *Journal Of Cleaner Production*.

Saputra, A. (2022). *Pengantar Deep Learning: Konsep Dan Implementasi Algoritma Long Short-Term Memory*. Penerbit Informatika.

Schuster, M. dan Paliwal, K. K. (1997). Bidirectional recurrent neural networks. *IEEE Transactions on Signal Processing*, 45(11):2673–2681.

Setyawan, B. dkk. (2022). Implementasi enterprise resource planning (erp) dalam pemantauan stok real-time di industri manufaktur. *Jurnal Sistem Informasi Bisnis*, 12(1):45–58.

Setyawan, B. dan Kusuma, H. (2022). Analisis performa arsitektur lstm dalam memprediksi beban kerja operasional pada industri manufaktur. *Jurnal Manajemen Industri Dan Logistik*, 6(1):30–42.

Stergiopoulos, L. dan Vlahogianni, E. I. (2024). Deep learning for predicting wait times in freight logistics using cyclical time features. *Transportation Research Part C: Emerging Technologies*, 158:104421.

Suryadi, K. (2021). Workload forecasting for industrial weighing station based on shift patterns. *International Journal Of Industrial Engineering And Management*, 12(3):142–155.

Tambunan, T. (2021). *Profil Industri Agribisnis: Pengolahan CPO Dan Produk Turunannya Di Indonesia*. Penerbit Ekonomi Kreatif.

Wang, J. dan Chen, L. (2025). Actual truck arrival prediction at a container terminal with the truck appointment system based on the long short-term memory and transformer model. *Journal of Marine Science and Engineering*, 13(1):405.