

Implementasi Metode *Long Short-Term Memory* untuk *Prediksi Traffic* Transaksi

^{1*}David Satria Fahmi, ²Risa Helilintar, ³Rony Heri Irawan

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹davidsatriaf1@gmail.com, ²risa.helilintar@gmail.com, ³rony@unpkediri.ac.id

Penulis Korespondensi : David Satria Fahmi

Abstrak— Tingginya aktivitas transaksi produk digital pada ekosistem *e-commerce* menuntut efisiensi layanan yang optimal. Toko "Safa Shop" yang beroperasi di platform Shopee menghadapi kendala menentukan waktu siaga operasional akibat fluktuasi pesanan yang dinamis. Penelitian ini menerapkan algoritma *Long Short-Term Memory* (LSTM) untuk memprediksi volume transaksi per jam sebagai rekomendasi jadwal kerja bagi penjual. Model dilatih menggunakan data historis satu tahun dari Shopee, menghasilkan prediksi per jam untuk 24 jam ke depan. Tahapan penelitian meliputi pembersihan data, normalisasi, dan implementasi teknik *sliding window*. Evaluasi model menghasilkan nilai MAE sebesar 1,2890, RMSE sebesar 1,6900, dan MAPE sebesar 66,13% pada jam aktif. Pengujian fungsional dengan metode *Black Box Testing* menunjukkan seluruh modul sistem berjalan sesuai spesifikasi. Penelitian menyimpulkan bahwa LSTM mampu menyediakan dasar prediktif yang membantu penjual mengoptimalkan manajemen waktu operasional secara sistematis.

Kata Kunci— *E-commerce*, LSTM, Produk Digital, Sistem Prediksi, *Traffic* Transaksi

Abstract— High digital product transaction activity in the *e-commerce* ecosystem demands optimal service efficiency. "Safa Shop", operating on Shopee, faces challenges in determining standby times due to dynamic order fluctuations. This research implements *Long Short-Term Memory* (LSTM) to predict hourly transaction volumes as work schedule recommendations for sellers. The model was trained on one year of transaction history from Shopee, generating hour-by-hour predictions for the next 24 hours. Research stages include data cleaning, normalization, and sliding window implementation. Model evaluation yielded a Mean Absolute Error (MAE) of 1.2890, Root Mean Square Error (RMSE) of 1.6900, and Mean Absolute Percentage Error (MAPE) of 66.13% on active hours. Functional testing using *Black Box Testing* confirmed all system modules operated as specified. The research concludes that LSTM provides an effective predictive foundation to help sellers optimize operational time management.

Keywords— Digital Products, *E-commerce*, LSTM, Prediction System, Transaction Traffic

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Perkembangan teknologi informasi telah mendorong pergeseran pola konsumsi masyarakat menuju produk virtual pada platform *marketplace*. Sebagai salah satu sektor yang tumbuh pesat, perdagangan produk digital menuntut responsivitas layanan yang tinggi karena ekspektasi pelanggan terhadap kecepatan pengiriman. Namun, bagi toko "Safa Shop" yang beroperasi di platform Shopee, pemrosesan transaksi masih dilakukan secara manual oleh pemilik toko. Hal ini menimbulkan tantangan besar dalam mengelola waktu siaga (*standby*), mengingat kedatangan pesanan memiliki pola fluktuatif yang sulit diantisipasi tanpa dukungan alat analitik.

Ketidaksiapan penjual dalam menghadapi lonjakan pesanan pada jam-jam tertentu sering kali berujung pada keterlambatan respon dan pembatalan transaksi otomatis oleh sistem. Permasalahan ini menunjukkan urgensi adanya mekanisme peramalan yang mampu memberikan estimasi volume transaksi di masa depan. Dalam studi terkait, penggunaan model *deep learning* terbukti efektif dalam menangani data runtun waktu yang kompleks. Sebagai contoh, arsitektur LSTM dan GRU menunjukkan performa yang lebih unggul dibandingkan metode statistik konvensional seperti ARIMA dalam memprediksi pola penjualan yang fluktuatif [1]. Keunggulan LSTM juga terkonfirmasi pada prediksi penjualan komoditas fisik, di mana model tersebut mampu menghasilkan tingkat kesalahan yang lebih kecil dibandingkan algoritma *Artificial Neural Network* (ANN) standar [2].

Akurasi model prediksi sangat dipengaruhi oleh pengaturan parameter internal seperti konfigurasi *hidden layer*, jumlah *epoch*, dan skenario *dropout* [3]. Selain pendekatan jaringan syaraf tiruan, algoritma *K-Nearest Neighbor* (K-NN) juga telah dieksplorasi untuk mengklasifikasikan tren penjualan pada kategori produk digital guna meminimalkan ketidakpastian stok [4]. Di sisi lain, penggunaan model *Prophet* yang dikembangkan oleh Meta menawarkan alternatif dalam menangkap dinamika musiman pada data penjualan harian [5]. Namun, mayoritas penelitian tersebut masih berfokus pada satuan waktu harian dan belum secara spesifik mengintegrasikan hasil prediksi per jam ke dalam sistem pendukung operasional UMKM digital.

Penelitian ini bertujuan untuk mengatasi celah tersebut dengan mengembangkan sistem prediksi *traffic* transaksi per jam menggunakan arsitektur LSTM. Dengan memanfaatkan data historis riil dari operasional toko di Shopee, penelitian ini tidak hanya berhenti pada pembentukan model AI, tetapi juga mengintegrasikannya ke dalam antarmuka aplikasi berbasis web. Melalui pendekatan ini, diharapkan penjual mendapatkan rekomendasi waktu siaga yang presisi, sehingga efisiensi pelayanan dapat ditingkatkan dan risiko kehilangan potensi penjualan dapat diminimalisasi.


II. METODE

A. Tahapan Penelitian

Penelitian ini dilaksanakan secara sistematis mengikuti model pengembangan *Waterfall* yang terdiri dari beberapa fase terintegrasi [6]. Tahapan dimulai dengan Identifikasi Masalah, yaitu melakukan observasi terhadap kendala operasional manual pada toko "Safa Shop". Langkah berikutnya adalah Pengumpulan Data, di mana dataset berupa riwayat transaksi produk digital selama satu tahun diambil dari platform Shopee. Data ini mencakup variabel waktu transaksi dan volume penjualan yang kemudian diproses sebagai data deret waktu (*time-series*).

Fase Analisis Kebutuhan dilakukan untuk menentukan spesifikasi perangkat lunak dan arsitektur model yang tepat guna menangani volatilitas data. Selanjutnya, pada tahap Perancangan, dilakukan pemodelan sistem menggunakan *Unified Modeling Language* (UML) dan desain basis data. Tahap Implementasi merupakan proses penerjemahan rancangan ke dalam baris kode program menggunakan bahasa Python dan *framework* Flask. Penelitian diakhiri dengan tahap Pengujian, yang meliputi validasi fungsionalitas sistem melalui *black-box testing* serta evaluasi akurasi prediksi menggunakan metrik statistik [7]. Seluruh prosedur ini dirancang

agar penelitian memiliki tingkat keterulangan (*reproducibility*) yang tinggi bagi peneliti selanjutnya.



Gambar 1. Diagram Alur Penelitian (*Waterfall*)

B. Metode *Long Short-Term Memory* (LSTM)

Metode *Long Short-Term Memory* (LSTM) dipilih karena kemampuannya yang sangat baik dalam mempelajari pola ketergantungan jangka panjang pada data sekuensial [8]. Berbeda dengan jaringan syaraf tiruan konvensional, LSTM memiliki struktur sel khusus yang dilengkapi dengan mekanisme gerbang (*gates*) untuk mengatur aliran informasi.

Secara teknis, proses komputasi di dalam sel LSTM melibatkan tiga komponen utama: *forget gate* yang memutuskan informasi masa lalu mana yang harus dibuang, *input gate* yang menyaring informasi baru untuk disimpan, dan *output gate* yang menentukan nilai sel yang akan diteruskan ke tahap berikutnya [9]. Melalui mekanisme ini, LSTM dapat meminimalkan masalah *vanishing gradient* dan memberikan hasil estimasi yang lebih stabil pada data transaksi yang memiliki pola fluktuatif [10].

Implementasi model dalam penelitian ini menggunakan konfigurasi arsitektur dan *hyperparameter* yang telah ditentukan melalui serangkaian eksperimen awal guna memperoleh keseimbangan antara akurasi dan efisiensi komputasi. Rincian lengkap konfigurasi yang digunakan disajikan pada Tabel 1 agar penelitian ini dapat direplikasi sepenuhnya.

Tabel 1. Konfigurasi *Hyperparameter* Model LSTM


Parameter	Nilai yang Digunakan	Keterangan
-----------	----------------------	------------

Arsitektur <i>Hidden Layer</i>	2 lapisan LSTM bertumpuk (<i>stacked</i>)	Lapisan 1: <i>return_sequences=True</i> (output seluruh sekuens ke lapisan 2) Lapisan 2: <i>return_sequences=False</i> (output satu vektor ke Dense)
Jumlah Unit per <i>Layer</i>	64 unit (lapisan 1), 64 unit (lapisan 2)	Jumlah unit identik pada kedua lapisan untuk mempertahankan kapasitas representasi fitur temporal
<i>Dropout Rate</i>	0,2	Diterapkan setelah setiap lapisan LSTM untuk mencegah <i>overfitting</i>
Panjang <i>Sliding Window</i>	168 jam (7 hari)	Mencakup satu siklus mingguan penuh sebagai konteks prediksi
Cakupan Prediksi	24 jam ke depan	Output berupa 24 nilai prediksi per jam
<i>Epoch</i>	25	Ditentukan berdasarkan titik konvergensi kurva <i>loss</i>
<i>Batch Size</i>	16	Menjaga stabilitas pembaruan gradien pada dataset berukuran sedang
<i>Learning Rate</i>	Adaptif (optimizer <i>Adam</i>)	<i>Adam</i> menyesuaikan <i>learning rate</i> secara otomatis per parameter
Fungsi Kerugian	<i>Mean Squared Error (MSE)</i>	Memberikan penalti lebih besar pada deviasi ekstrem
<i>Framework</i>	<i>TensorFlow/Keras</i>	Implementasi menggunakan bahasa Python

C. Desain Sistem

Rancangan sistem aplikasi dibangun untuk menjembatani model cerdas dengan kebutuhan praktis pengguna. Arsitektur sistem didefinisikan melalui dua perspektif utama:


1. *Use Case Diagram*: Menggambarkan interaksi antara aktor (Admin/Penjual) dengan fitur-fitur utama sistem, seperti modul autentikasi (*login*), fungsi unggah laporan penjualan dalam format Excel, tampilan visualisasi grafik prediksi, tampilan riwayat hasil prediksi serta fitur cetak laporan dalam format PDF.



Gambar 2. *Use Case Diagram* Sistem Prediksi

2. Desain Database: Struktur penyimpanan data menggunakan sistem manajemen basis data relasional MySQL. Basis data ini dirancang untuk menyimpan riwayat hasil prediksi serta

detail rekomendasi status siaga per jam secara terstruktur, guna memudahkan pemantauan tren operasional jangka panjang [6].



Gambar 3. Desain *Entity Relationship Diagram* (ERD)

III. HASIL DAN PEMBAHASAN

A. Analisis Performa Model LSTM

Fase pengujian kinerja dilakukan menggunakan dataset uji yang mencakup 20% dari total populasi data transaksi tahunan. Evaluasi terhadap model *Long Short-Term Memory* (LSTM) dilakukan melalui perhitungan metrik regresi standar untuk menjamin presisi estimasi. Berdasarkan hasil pengolahan data, model menghasilkan nilai *Mean Absolute Error* (MAE) sebesar 1,2890, *Root Mean Square Error* (RMSE) sebesar 1,6900, dan *Mean Absolute Percentage Error* (MAPE) sebesar 66,13%. Nilai MAPE dihitung secara eksklusif pada 1.291 jam aktif dari total 1.719 jam data uji (428 jam bernilai nol atau 24,9% dikecualikan), sesuai konvensi standar evaluasi model *time-series* dengan komponen nilai nol.

Secara interpretatif, nilai MAE sebesar 1,2890 menunjukkan bahwa rata-rata penyimpangan prediksi per jam adalah sekitar 1,29 pesanan dari angka transaksi riil, sebuah margin yang kecil secara absolut dalam konteks operasional UMKM. Nilai MAPE sebesar 66,13% tampak tinggi, namun hal ini merupakan konsekuensi matematis yang lazim pada data transaksi dengan volume rendah, bukan indikasi model yang buruk. Analisis distribusi data menunjukkan bahwa sebagian besar jam aktif hanya berisi 1–3 pesanan, sehingga selisih 1 pesanan saja setara dengan 33–100% error relatif pada masing-masing titik data tersebut. Fenomena ini menyebabkan rata-rata MAPE tertarik ke atas secara signifikan, meskipun selisih absolutnya tetap kecil. Oleh karena itu, metrik MAE dan RMSE menjadi indikator akurasi yang lebih representatif untuk konteks data ini. Tingkat akurasi yang belum sepenuhnya optimal ini juga dipengaruhi oleh adanya beberapa titik data dengan lonjakan transaksi yang ekstrem (*outliers*) akibat tingginya volatilitas karakteristik produk digital di platform Shopee.


Tabel 2. Hasil Evaluasi Akurasi Model LSTM

Metrik Evaluasi	Nilai Uji (Error)	Keterangan
<i>Mean Absolute Error</i> (MAE)	1,2890	Rata-rata selisih prediksi $\approx$ 1,29 pesanan per jam
<i>Root Mean Square Error</i> (RMSE)	1,6900	Sensitivitas terhadap deviasi ekstrem $\approx$ 1,69 pesanan per jam
<i>Mean Absolute Percentage Error</i> (MAPE)	66,13%	Rata-rata kesalahan relatif pada 1.291 jam aktif (transaksi > 0); tinggi karena mayoritas jam hanya berisi 1–3 pesanan, di mana selisih 1 unit = 33–100% error relatif

B. Analisis Proses Pelatihan *Deep Learning*

Fase pelatihan (*training*) model dilakukan secara bertahap untuk memastikan arsitektur jaringan mampu menangkap pola temporal dari jendela waktu 168 jam yang digunakan sebagai masukan. Penggunaan fungsi kerugian *Mean Squared Error* (MSE) selama proses pelatihan terbukti efektif dalam memberikan penalti yang signifikan terhadap kesalahan prediksi besar, sehingga memaksa model untuk lebih sensitif terhadap pola lonjakan *traffic* [10].

Selama 25 *epoch* pelatihan dengan *batch size* 16, model menunjukkan pola konvergensi yang stabil. Penggunaan pengoptimal *Adam* berperan krusial dalam menyesuaikan *learning rate* secara dinamis, sehingga meminimalkan hambatan dalam mencapai nilai *local minima* pada kurva *loss* [9]. Selain itu, penerapan lapisan *Dropout* sebesar 0,2 mampu menjaga model dari risiko *overfitting*. Hal ini terlihat dari konsistensi nilai *error* antara data latih dan data uji yang tidak mengalami disparitas tajam. Karakteristik sel LSTM yang memiliki gerbang memori memungkinkan sistem untuk mempertahankan informasi pola transaksi pada jam-jam sibuk di masa lalu dan mengabaikan fluktuasi acak (*noise*) yang tidak relevan, sehingga menghasilkan prediksi yang lebih generalis terhadap tren transaksi di masa depan [8].




Gambar 4. Grafik Loss Model (Training vs Validation Loss)

C. Implementasi Antarmuka dan Dampak Operasional

Penerapan model yang telah tervalidasi kemudian diintegrasikan ke dalam lingkungan produksi berbasis web menggunakan *framework* Flask. Antarmuka sistem dirancang untuk memberikan informasi yang intuitif bagi penjual melalui dua komponen utama visualisasi hasil prediksi:

1. Visualisasi Tren Transaksi: Hasil komputasi model ditampilkan dalam bentuk grafik garis yang memetakan fluktuasi volume pesanan untuk 24 jam ke depan. Grafik ini memungkinkan penjual untuk melihat secara visual kapan puncak beban transaksi akan terjadi.



Gambar 5. Grafik Tren Prediksi Traffic 24 Jam

2. Tabel Rekomendasi Operasional: Sebagai pendukung grafik, sistem menyajikan tabel detail yang mengonversi angka prediksi menjadi instruksi status siaga. Sistem secara otomatis memberikan label "Pesanan Tinggi" untuk estimasi volume transaksi di atas ambang batas, serta label "Pesanan Rendah" untuk periode sepi.

Jam Prediksi	Prediksi Transaksi	Status Prediksi	Keterangan Aksi
00:00 09 Mar 2026	0 Pesanan	Pesanan Rendah	Boleh Istirahat atau Lakukan Tugas Lain
01:00 09 Mar 2026	0 Pesanan	Pesanan Rendah	Boleh Istirahat atau Lakukan Tugas Lain
02:00 09 Mar 2026	0 Pesanan	Pesanan Rendah	Boleh Istirahat atau Lakukan Tugas Lain
03:00 09 Mar 2026	1 Pesanan	Pesanan Rendah	Boleh Istirahat atau Lakukan Tugas Lain
04:00 09 Mar 2026	1 Pesanan	Pesanan Rendah	Boleh Istirahat atau Lakukan Tugas Lain
05:00 09 Mar 2026	2 Pesanan	Pesanan Rendah	Boleh Istirahat atau Lakukan Tugas Lain
06:00 09 Mar 2026	3 Pesanan	Pesanan Tinggi	Siaga Lonjakan Pesanan & Pantau Notifikasi
07:00 09 Mar 2026	4 Pesanan	Pesanan Tinggi	Siaga Lonjakan Pesanan & Pantau Notifikasi

Gambar 6. Tabel Detail Prediksi dan Rekomendasi Status Siaga

Implementasi sistem ini membawa dampak signifikan pada efisiensi operasional "Safa Shop". Penjual tidak lagi bersiaga secara spekulatif, melainkan berdasarkan pedoman data. Dengan memfokuskan sumber daya pada jam yang diprediksi sibuk, penjual dapat menjaga kecepatan respon layanan (*fast response*) yang menjadi parameter krusial reputasi toko di Shopee [11].

D. Pengujian Sistem

Pengujian fungsional pada sistem ini dilakukan menggunakan metode *Black Box Testing*. Pengujian ini berfokus pada spesifikasi fungsional perangkat lunak untuk memastikan bahwa setiap masukan (*input*) yang diberikan oleh pengguna akan menghasilkan keluaran (*output*) yang

sesuai dengan perancangan awal, tanpa perlu meninjau struktur kode internal. Ringkasan hasil pengujian fungsional terhadap modul-modul utama sistem disajikan pada Tabel 3.

Tabel 3. Hasil Pengujian Fungsional (Black Box Testing)

No.	Fitur / Modul	Skenario Pengujian	Hasil yang Diharapkan	Hasil Pengujian
1.	Autentikasi	Memasukkan <i>username</i> dan <i>password</i> yang benar.	Sistem mengizinkan akses dan mengarahkan pengguna ke halaman <i>Dashboard</i> .	Berhasil
2.	Autentikasi	Memasukkan <i>username</i> atau <i>password</i> yang salah.	Sistem menolak akses dan menampilkan pesan <i>error</i> "Username atau Password salah!".	Berhasil
3.	Validasi Upload	Menekan tombol "Proses Data" tanpa memilih berkas <i>file</i> .	Sistem memunculkan <i>alert</i> peringatan "Pilih file Excel terlebih dahulu!".	Berhasil
4.	Validasi Upload	Mengunggah tipe berkas selain format Excel (.xlsx).	Sistem memblokir pemilihan fail di luar ekstensi .xlsx pada penjelajah berkas (<i>file explorer</i>).	Berhasil
5.	Pemrosesan Data	Mengunggah fail .xlsx yang format kolomnya tidak sesuai dengan standar laporan Shopee.	Sistem menghentikan proses dan menampilkan pesan "Gagal membaca format file".	Berhasil
6.	Pemrosesan Data	Mengunggah fail valid, namun total riwayat transaksi kurang dari 168 jam.	Sistem menolak proses dan memberikan <i>alert error</i> terkait kekurangan jumlah data untuk metode LSTM.	Berhasil
7.	Prediksi Traffic	Mengunggah fail valid (≥ 168 jam) dan memprosesnya.	Sistem berhasil melakukan komputasi dan menampilkan grafik serta tabel rekomendasi 24 jam ke depan.	Berhasil
8.	Cetak PDF	Menekan tombol "Cetak Hasil ke PDF" pada halaman Dashboard.	Sistem memanggil fungsi cetak bawaan peramban (<i>browser</i>) yang memuat grafik dan tabel dengan rapi.	Berhasil
9.	Manajemen Riwayat	Menekan tombol "Lihat" pada salah satu baris data riwayat prediksi.	Sistem menampilkan <i>pop-up modal</i> berisi grafik, tabel prediksi, dan tombol cetak PDF spesifik untuk riwayat tersebut.	Berhasil
10.	Manajemen Riwayat	Menekan tombol "Hapus" pada salah satu baris data riwayat prediksi.	Sistem memunculkan dialog konfirmasi, lalu menghapus data terkait dari basis data secara permanen.	Berhasil
11.	Logout	Menekan menu "Keluar (Logout)" pada bilah navigasi samping.	Sistem menghapus sesi aktif dan mengembalikan pengguna ke halaman <i>Login</i> .	Berhasil

Berdasarkan hasil pengujian pada Tabel 3, seluruh fungsionalitas utama dari aplikasi berbasis *web* ini telah berjalan dengan baik tanpa adanya *bug* atau *error* penanganan, termasuk keberhasilan sistem dalam memvalidasi dan mencegah kesalahan *input* dari pengguna. Dengan

demikian, sistem ini dinyatakan fungsional dan siap dioperasikan secara penuh untuk mendukung kebutuhan *forecasting* operasional toko.

IV. KESIMPULAN

Penelitian ini berhasil mengimplementasikan algoritma *Long Short-Term Memory* (LSTM) untuk memprediksi *traffic* transaksi per jam pada toko "Safa Shop" di platform Shopee, menghasilkan rekomendasi penjadwalan siaga berbasis data yang terstruktur. Model dilatih menggunakan data historis satu tahun dengan arsitektur dua lapisan LSTM (64 unit per lapisan), *sliding window* 168 jam, dan menghasilkan prediksi 24 jam ke depan. Evaluasi model menunjukkan nilai MAE sebesar 1,2890 dan RMSE sebesar 1,6900, merepresentasikan deviasi rata-rata satu hingga dua pesanan per jam dari data aktual, margin yang dinilai masih dapat diterima untuk keperluan penjadwalan tenaga kerja pada konteks UMKM digital. Nilai MAPE sebesar 66,13% mencerminkan karakteristik matematis data bervolume rendah dan bukan indikasi kegagalan model, sehingga MAE dan RMSE menjadi acuan akurasi yang lebih representatif. Ke depan, peningkatan performa dapat dilakukan melalui perluasan dataset historis, penambahan fitur eksternal seperti data promosi dan hari libur (*multivariate forecasting*), serta eksplorasi arsitektur alternatif seperti GRU atau *Transformer*.

DAFTAR PUSTAKA

- [1] N. Sunendar, H. P. Putro, and R. Hesandana, "Prediksi Penjualan Aerosol Menggunakan Algoritma ARIMA, LSTM Dan GRU," *INSOLOGI: Jurnal Sains dan Teknologi*, vol. 4, no. 1, pp. 113–126, Feb. 2025, doi: 10.55123/insologi.v4i1.4868.
- [2] I. N. Hasanah, A. Lasarudin, and W. Hasyim, "Penerapan Data Mining untuk Prediksi Penjualan Produk Terlaris Menggunakan Metode ANN dan LSTM," *Jurnal Ilmu Komputer (JUIK)*, vol. 5, no. 2, pp. 141–154, Jul. 2025, doi: 10.31314/juik.v5i2.4180.
- [3] N. L. Chusna, D. M. R. Tari, and A. Khumaidi, "Konfigurasi Hyperparameter Long Short Term Memory untuk Optimalisasi Prediksi Penjualan," *Faktor Exacta*, vol. 15, no. 4, pp. 290–300, Jan. 2023, doi: 10.30998/faktorexacta.v15i4.15286.
- [4] B. Susilo, N. A. Ramdhan, and O. S. Bachri, "Penerapan Algoritma K-Nearest Neighbor untuk Prediksi Penjualan Produk Digital," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1466–1476, Sep. 2024, doi: 10.57152/malcom.v4i4.1517.
- [5] K. Hidayat, W. Witanti, and E. Ramadhan, "Analisis Tren dan Prediksi Penjualan Restoran Menggunakan Model Time Series Prophet," *METIK JURNAL*, vol. 9, no. 2, pp. 457–467, Aug. 2025, doi: 10.47002/metik.v9i2.1101.
- [6] B. Zuhri and N. H. Harani, *Aplikasi Rekrutmen Karyawan Dengan Algoritma Artificial Neural Network (ANN) Dan Framework Flask*. Penerbit Buku Pedia, 2023. [Online]. Available: <https://books.google.co.id/books?id=yeCuEAAAQBAJ>

- [7] Rianto and P. I. Santosa, *Data Preparation untuk Machine Learning & Deep Learning*. Penerbit Andi, 2025. [Online]. Available: <https://books.google.co.id/books?id=Y5U9EQAAQBAJ>
- [8] A. A. Anandari, G. Harsono, and A. F. Wadjdi, *Long Short-Term Memory Recurrent Neural Network (LSTM-RNN) Aplikasi Penginderaan Jauh untuk Kelautan & Perikanan Laut Tangkap*. CV Jejak (Jejak Publisher), 2024. [Online]. Available: <https://books.google.co.id/books?id=9j0eEQAAQBAJ>
- [9] N. Yudistira, *Deep Learning: Teori, Contoh Perhitungan, dan Implementasi*. Deepublish, 2024. [Online]. Available: <https://books.google.co.id/books?id=G6cTEQAAQBAJ>
- [10] D. Utomo and T. F. Utomo, *Deep Learning Dasar Teori dan Implementasi dengan Python dan Keras: Diandra Kreatif*. Penalicious, 2025. [Online]. Available: <https://books.google.co.id/books?id=nqmQEQAQBAJ>
- [11] N. Sriminarti, Y. P. Yustisi, and R. I. Hariman, *Buku Ajar E-Commerce*. PT. Sonpedia Publishing Indonesia, 2024. [Online]. Available: <https://books.google.co.id/books?id=3v8REQAAQBAJ>