PREDIKSI KEBUTUHAN BAHAN BAKU PRODUKSI MENGGUNAKAN METODE LSTM DI DUA NAGA CORPORATION

Andhika Dias Fernanda[1], Nurmalitasari[2], Faulinda Ely Nastiti[3]

[123,] Sistem Informasi, Ilmu Komputer, Universitas Duta Bangsa Surakarta

Jln. Bhayangkara No.55, Tipes, Kec. Serengan, Kota Surakarta, Jawa Tengah 57154
[1]220101006@mhs.udb.ac.id, [2] nurmalitasari@udb.ac.id, [3] faulinda_ely@udb.ac.id

Abstract

Uncertain demand in contract manufacturing triggers volatility in raw material requirements, leading to procurement inefficiencies and high risks of stockouts and overstock. This study aims to implement Long Short-Term Memory (LSTM) architecture to predict upstream raw material demand at Dua Naga Corporation, filling a research gap in supply chain forecasting that is highly susceptible to extreme anomalies. Utilizing historical inventory data (December 2024–November 2025) under the CRISP-DM methodology, the scientific contribution of this study lies in integrating extreme smoothing preprocessing (15%–85% percentile clipping and 7-day moving average) into the LSTM model. This approach proved effective in reducing stochastic noise and mapping fundamental raw material trends, achieving a Weighted Mean Absolute Percentage Error (WMAPE) of 10.33% on test data with no indication of overfitting. A one-year projection forecasts a 16.2% surge in raw material demand. Practically, the model output is integrated into an interactive dashboard (Decision Support System/DSS), providing a data-driven foundation for corporate management to formulate precise procurement strategies, thereby achieving inventory efficiency and minimizing losses caused by stock shortages or accumulations.

Keywords : *Long Short-Term Memory, Time Series Forecasting, Raw Material Demand, Extreme Smoothing, CRISP-DM*

Abstrak

Ketidakpastian permintaan pada manufaktur kontrak memicu volatilitas kebutuhan bahan baku, yang berujung pada inefisiensi pengadaan serta tingginya risiko stockout dan overstock. Penelitian ini bertujuan mengimplementasikan arsitektur Long Short-Term Memory (LSTM) untuk memprediksi kebutuhan bahan baku hulu di Dua Naga Corporation, sekaligus mengisi celah riset pada prediksi rantai pasok yang rentan terhadap anomali ekstrem. Menggunakan data historis inventaris (Desember 2024–November 2025) dengan metodologi CRISP-DM, kontribusi ilmiah penelitian ini terletak pada integrasi teknik prapemrosesan extreme smoothing (clipping 15%–85% dan moving average 7 hari) pada model LSTM. Pendekatan tersebut terbukti efektif dalam mereduksi noise stokastik dan memetakan pola tren fundamental bahan baku, yang dibuktikan dengan capaian Weighted Mean Absolute Percentage Error (WMAPE) sebesar 10,33% pada data uji tanpa indikasi overfitting. Proyeksi satu tahun ke depan memperkirakan lonjakan kebutuhan bahan baku sebesar 16,2%. Secara praktis, luaran model diintegrasikan ke dalam dashboard interaktif (Sistem Pendukung Keputusan/DSS) guna memberikan landasan data-driven bagi manajemen perusahaan dalam merumuskan strategi pengadaan yang presisi, sehingga efisiensi inventaris tercapai dan kerugian akibat penumpukan maupun kekosongan stok dapat diminimalisir.

Kata kunci : *Long Short-Term Memory, prediksi deret waktu, kebutuhan bahan baku, extreme smoothing, CRISP-DM*

1. PENDAHULUAN

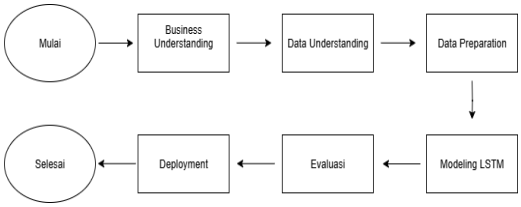
Akselerasi ekspansi sektor manufaktur kosmetik di Indonesia saat ini mencatatkan pertumbuhan yang massif memicu persaingan pasar yang sangat dinamis. Hal ini berdampak langsung pada operasional Dua Naga Corporation, sebuah perusahaan manufaktur kontrak (maklon), yang saat ini menghadapi masalah krusial dalam pengendalian persediaan bahan bakunya. Permasalahan utama yang terjadi adalah tingginya ketidakpastian pesanan pelanggan, yang menyebabkan fluktuasi kebutuhan bahan baku menjadi sangat tajam. Selama ini, perusahaan masih mengandalkan perhitungan manual dan statistik konvensional, seperti metode *Weighted Moving Average* untuk merencanakan stok barang [1]. Cara tersebut terbukti tidak akurat karena tidak mampu mengantisipasi lonjakan pesanan yang terjadi secara mendadak [2]. Ketidakmampuan dalam memprediksi kebutuhan material ini memicu dua kerugian besar bagi perusahaan: terjadinya kekosongan bahan (stockout) yang membuat proses produksi terhenti, serta penumpukan barang (overstock) yang menyebabkan pemborosan biaya gudang dan rusaknya kualitas bahan baku [3], [4].Analisis terkait kerugian operasional ini sangat relevan dengan prinsip pengendalian persediaan manufaktur secara terukur, di mana inefisiensi pengadaan dan penumpukan material akan meningkatkan beban biaya perusahaan secara drastis [5].

Untuk mengatasi keterbatasan metode peramalan tradisional, arsitektur Long Short-Term Memory (LSTM) terbukti memiliki keunggulan performa yang lebih baik. Keandalan metode ini didukung oleh beberapa penelitian terdahulu. Dalam konteks data fluktuatif di sektor bahan baku industri, Atharsyah dan Romli (2024) telah membuktikan bahwa arsitektur LSTM sangat optimal dalam memetakan pola prediksi pada harga komoditas seperti nikel [6]. Lebih lanjut terkait optimasi data deret waktu, Nugroho dan Haris (2024) mengkaji bahwa penanganan kualitas input melalui teknik prapemrosesan sangat krusial untuk meningkatkan akurasi prediksi model LSTM secara signifikan[7]. Dukungan terhadap metode ini juga terlihat pada penelitian Nugroho dan Hutahaean (2025) membuktikan bahwa LSTM mampu menangani fluktuasi data yang tajam untuk menghasilkan prediksi penjualan sepeda motor yang stabil [8]. Selanjutnya, penelitian Cahyani dkk. (2023) menunjukkan bahwa penggunaan Adam Optimizer pada algoritma LSTM berhasil meminimalkan tingkat kesalahan, yang dibuktikan dengan nilai Root Mean Squared Error (RMSE) terendah pada prediksi bahan pokok [9]. Di industri kosmetik, Fadilah dkk. (2024) juga telah memanfaatkan LSTM untuk memprediksi tren penjualan produk skincare dengan akurasi tinggi [10]. Meskipun metode ini terbukti andal, sebagian besar penelitian sebelumnya masih berfokus pada prediksi barang jadi (produk hilir) atau ekonomi makro [11], [12], [13].Tingkat urgensi dalam pengendalian persediaan produk hulu tergolong sangat signifikan. Sebagaimana dikemukakan dalam kajian manajemen rantai pasok, ketersediaan bahan baku spesifik merupakan faktor penentu utama dalam mempertahankan stabilitas aliran produksi [14]. Oleh karena itu, penelitian ini hadir untuk mengisi celah riset (research gap) dengan menerapkan model LSTM secara khusus untuk memprediksi kebutuhan bahan baku produksi (hulu) di lingkungan pabrik manufaktur.

Kendala substansial dalam memproyeksikan kebutuhan bahan baku di Dua Naga Corporation bersumber dari tingginya varians pada data transaksi historis yang terdistorsi oleh kemunculan anomali (outliers). Presensi noise berskala masif tersebut berpotensi mendegradasi tingkat akurasi pemodelan apabila data dieksekusi secara langsung ke dalam jaringan saraf tiruan. Merespons urgensi tersebut, studi ini bertujuan untuk mengimplementasikan algoritma LSTM—yang dilengkapi kapabilitas forget, input, dan output gate untuk mengekstraksi dependensi jangka panjang [15], [16] yang diintegrasikan bersama metode prapemrosesan Extreme Smoothing. Mekanisme stabilisasi ini mengkombinasikan reduksi nilai ekstrem (clipping 15%) dan penghalusan rata-rata bergerak 7 hari, yang direkayasa untuk mengeliminasi bias acak sehingga model dapat memetakan pola tren fundamental secara optimal. Keluaran (output) dari model prediktif ini selanjutnya akan direpresentasikan ke dalam sebuah dashboard visualisasi interaktif, yang difungsikan sebagai Sistem Pendukung Keputusan (Decision Support System/DSS) komprehensif bagi manajemen dalam merumuskan kebijakan pengadaan yang terukur dan efisien.

2. METODOLOGI PENELITIAN

Kerangka kerja yang digunakan dalam penelitian ini mengadopsi standar Cross-Industry Standard Process for Data Mining (CRISP-DM). Pendekatan ini dipilih karena memberikan alur yang terstruktur, komprehensif, dan teruji secara empiris dalam menyelesaikan permasalahan analisis data dan penemuan pengetahuan (knowledge discovery). Metodologi CRISP-DM diimplementasikan melalui enam tahapan sistematis yang bersifat iteratif guna menghasilkan model prediktif yang optimal bagi sistem pendukung keputusan [17], [18].



Gambar 1. Tahapan Penelitian

2.1. Pemahaman Bisnis (Business Understanding)

Tahap awal ini berfokus pada identifikasi tujuan bisnis dan penetapan parameter keberhasilan. Permasalahan utama yang diangkat adalah tingginya fluktuasi permintaan yang menyebabkan inefisiensi pengadaan bahan baku di Dua Naga Corporation, sehingga memicu risiko *stockout* dan *overstock*. Berdasarkan observasi dan wawancara dengan Supervisor Data Analyst, ditetapkan bahwa perusahaan membutuhkan sistem peramalan komputasional yang presisi untuk meredam volatilitas data historis. Solusi yang dirumuskan adalah pengembangan model Deep Learning berbasis LSTM yang diintegrasikan ke dalam sebuah dashboard visualisasi sebagai Sistem Pendukung Keputusan (DSS) strategis. Pemodelan berbasis komputasi pada level bahan mentah ini bersifat krusial, mengingat pendekatan dalam industri manufaktur makanan maupun kosmetik seringkali berpusat pada estimasi penjualan produk akhir, tanpa mengakomodasi dinamika fluktuasi kebutuhan bahan baku secara langsung [19].

2.2. Pemahaman Data (Data Understanding)

Pada tahap ini, dilakukan proses pengumpulan data dan eksplorasi karakteristik awal dataset. Data yang digunakan merupakan data sekunder berupa rekaman transaksi inventaris (outgoing stock) dari arsip digital basis data Dua Naga Corporation yang mencakup periode historis (Desember 2024 hingga November 2025). Dataset ini memuat empat atribut fundamental, yakni Tanggal, Kode Bahan Baku, Jenis Transaksi, dan Kuantitas (Qty) dalam satuan gram. Eksplorasi awal menemukan adanya distribusi anomali dan noise stokastik yang tinggi akibat lonjakan pemakaian material tertentu pada hari-hari operasional spesifik.

2.3. Persiapan Data (Data Preparation)

Tahap persiapan data merupakan fase krusial untuk memastikan kualitas input sebelum dieksekusi oleh algoritma jaringan saraf. Proses ini mencakup beberapa teknik pra-pemrosesan:

1.Pembersihan dan Pemfilteran

Menghilangkan data kosong (missing values) dan memfilter dataset hanya untuk transaksi pengeluaran ("OUT"), bertujuan untuk menangkap pola konsumsi riil bahan baku di lantai produksi, bukan riwayat pembelian dari pemasok

2.Agregasi Harian dan Stabilisasi Data (Extreme Smoothing)

Merangkum (resampling) data menjadi interval harian dan mengeliminasi hari non-operasional (hari Minggu). Total data aktif yang terekstraksi adalah 248 hari.Untuk mereduksi outliers, dilakukan pemotongan nilai ekstrem (clipping) pada ambang batas persentil 15% (bawah) dan 85% (atas). Data yang telah dipotong selanjutnya dihaluskan menggunakan *Moving Average* dengan jendela waktu 7 hari, yang dipilih untuk merepresentasikan satu siklus operasional mingguan pabrik, sehingga pola tren dapat diekstraksi tanpa menghilangkan fluktuasi harian yang penting.

3.Transformasi dan Normalisasi

Menerapkan transformasi logaritmik natural (Log1p) untuk menekan rentang distribusi, yang dilanjutkan dengan penskalaan fitur menggunakan MinMaxScaler ke rentang [0, 1].Normalisasi ini bertujan agar rentang nilai data menjadi seragam, sehingga mempercepat

dan menstabilkan proses perhitungan saat model LSTM dilatih.berikut rumus MinMaxScaler:

$$x_{scaled} = \frac{X - x_{min}}{x_{max} - x_{min}}$$

Keterangan:
X = Nilai asli data
x_{min} = Nilai minimum dari dataset
x_{max} = Nilai maksimum dari dataset

4.Pembentukan Sekuens (Windowing)

Data deret waktu direstrukturisasi menggunakan metode sliding window dengan look-back 30 hari. Dataset kemudian dipartisi menjadi 80% data latih (training set) dan 20% data uji (testing set). Mekanisme restrukturisasi sekuens dan partisi data seperti ini telah terbukti sangat diandalkan dalam memetakan ketergantungan temporal pada data yang rentan terhadap volatilitas ekstrem, seperti pada peramalan harga komoditas beras di level makro [20].

2.4. Pemodelan (Modeling)

Pemodelan peramalan dieksekusi menggunakan arsitektur LSTM. Konfigurasi jaringan dibangun dengan menempatkan 50 unit neuron pada lapisan memori LSTM untuk mencegah terjadinya overfitting, diterapkan teknik regularisasi *Dropout* dengan rasio pemotongan sebesar 20%. Model dikompilasi menggunakan fungsi kerugian Mean Squared Error (MSE) dan dioptimasi menggunakan algoritma Adam Optimizer. Proses pelatihan (training) dijalankan menggunakan parameter batch size bernilai 1. Selain itu, fungsi Early Stopping diterapkan dengan patience 15 untuk menghentikan iterasi secara otomatis apabila tidak terjadi penurunan nilai validasi (val_loss), sehingga bobot model terbaik dapat dipertahankan. Persamaan matematis untuk setiap gerbang adalah sebagai berikut:

Forget Gate: $f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f)$
Input Gate: $i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i)$
Cell State Update: $\tilde{c}_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c)$
Final Cell State: $\tilde{c}_t = f_t * c_{t-1} + i_t * \tilde{c}_t$
Output Gate: $o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o)$
Hidden State: $h_t = o_t * \tanh(c_t)$

Keterangan:

- Gerbang Utama (Gates):
  1. f_t:(Forget Gate)Menentukan informasi status sel sebelumnya yang akan dibuang atau dipertahankan
  2. i_t: Mengatur informasi baru yang akan disimpan ke dalam status sel.
  3. o_t: Mengontrol bagian status sel yang akan dikeluarkan sebagai *hidden state* saat ini.
- Variabel Status dan Input:
  1. x_t : Mewakili vector input pada langkah waktu saat ini
  2. h_{t-1} : Mewakili *hidden state* atau output Langkah waktu sebelumnya
  3. h_t : : Mewakili *hidden state* atau output Langkah waktu saat ini
  4. c_{t-1} : Mewakili status sel dari langkah waktu sebelumnya yang menyimapn memori jangka panjang
  5. c_t : Mewakili status sel yang telah diperbarui pada Langkah waktu saat ini
  6. $\tilde{c}_t$: Mewakili kandidat nilai baru yang akan ditambah ke dalam status sel
- Parameter Matematis:
  1. w (*Weights*): Matriks bobot untuk setiap mekanisme gerbang (seperti w_f,w_i, w_o, w_c) yang dipelajari selama proses pelatihan
  2. b (*Bias*) : Vektor bias untuk setiap gerbang yang digunakan untuk menggeser fungsi aktivasi
  3. σ (*Sigmoi*d) : Fungsi aktivasi yang memetakan nilai ke dalam rentang 0 hingga 1 untuk menentukan probabilitas informasi yang lewat
  4. $tanh$ (*Hyperbolic Tangent*) : Fungsi aktivasi yang memetakan nilai ke dalam rentang -1 hingga 1 untuk membantu meregulasi jaringan
  5. $*$: Operasi perkalian elemen demi elemen (*element-wise multiplication*)

2.5 Evaluasi (Evaluation)

Model yang telah dilatih kemudian dievaluasi menggunakan data uji untuk mengukur tingkat akurasi prediksi. Karena data sebelumnya melalui proses transformasi logaritmik, nilai prediksi dikembalikan ke skala asli melalui inversi fungsi eksponensial (Expm1) sebelum tingkat kesalahan dihitung. Evaluasi performa model diukur menggunakan tiga metrik statistik, yaitu Root Mean Squared Error (RMSE), Mean Absolute Percentage Error (MAPE), dan secara khusus Weighted Mean Absolute Percentage Error (WMAPE) yang memberikan pembobotan lebih adil pada fluktuasi data skala besar. Evaluasi performa model dilakukan untuk mengukur tingkat akurasi prediksi dengan menggunakan metrik statistik sebagai berikut:

Weighted Mean Absolute Percentage Error (WMAPE):

$$WMAPE = \frac{\sum | Aktual - Prediksi |}{\sum Aktual} \; x \; 100\%$$

Keterangan:
$Aktual\ (A)$: Nilai data
$Prediksi\ (P)$: Nilaiperkiraan yang di hasilkan model.
$Selisih\ A$bsolut $(\sum | Aktual - Prediksi |)$: Jarak antara nilai prediksi (tanpa nilai negatif).

2.6 Dashboard (Deployment)

Pada fase final, model yang telah tervalidasi diimplementasikan untuk memproyeksikan kebutuhan bahan baku satu tahun ke depan. Luaran model diintegrasikan ke dalam dashboard visualisasi interaktif yang menyajikan analisis tren dan rekapitulasi kebutuhan top 10 material dengan lonjakan tertinggi. Representasi visual ini bertujuan untuk memudahkan pemangku kepentingan dalam melakukan interpretasi hasil prediktif secara intuitif dan berbasis data (data-driven).

3. HASIL DAN PEMBAHASAN

3.1 Business Understading (Pemahaman Bisnis)

Tahap awal berfokus pada identifikasi inefisiensi pengadaan bahan baku akibat fluktuasi permintaan yang sangat dinamis. Parameter keberhasilan ditetapkan pada pengembangan model prediktif berbasis LSTM yang mampu meredam volatilitas data historis guna mendukung pengambilan keputusan manajerial dalam meminimalisir risiko *stockout* dan *overstock*.

3.2 Data Understanding (Pemahaman Data)

Eksplorasi awal terhadap 68.603 baris data menunjukkan adanya fluktuasi acak yang tinggi serta nilai pencilan (outliers) akibat lonjakan penggunaan bahan baku secara drastis pada hari operasional tertentu.

3.3 Persiapan Data (Data Preparation)

Pada tahap pra-pemrosesan ini sangat penting untuk menentukan tingkat akurasi dan stabilitas model prediksi yang akan dihasilkan.

3.3.1 Pembersihan dan Pemfilteran Data

Tahap awal pemrosesan hasil melibatkan kurasi dataset melalui eliminasi entri yang tidak lengkap (missing values) guna menjamin validitas analisis. Selanjutnya, dilakukan ekstraksi data secara selektif yang difokuskan secara eksklusif pada catatan transaksi pengeluaran (outgoing stock), sehingga dihasilkan basis data yang representatif untuk pemodelan prediksi stok.

	Tanggal	Kode	Jenis	Qty
1	2024-12-10 00:00:00	CSF0001CSF	OUT	9800.0
2	2024-12-10 00:00:00	DRG0001DRG	OUT	350.0
3	2024-12-20 00:00:00	TRB0001TRB	OUT	1400.0
4	2024-12-26 00:00:00	UFP0001UFP	OUT	8.5
5	2024-12-26 00:00:00	OJE0001OJE	OUT	70.0
...	...	...	...	...
62917	2025-11-05 00:00:00	EUV0001EUV	OUT	375000.0
62918	2025-11-05 00:00:00	XGC0001XGC	OUT	200.0
62919	2025-11-05 00:00:00	ONM0001ONM	OUT	30.3
62920	2025-11-05 00:00:00	VUE0001VUE	OUT	150000.0
62921	2025-11-05 00:00:00	RWT0001RWT	OUT	5000.0

```
Total data setelah filter OUT: 62,921
```

Gambar 2. Tahap Pembersihan Dan Pemfilteran Data

3.3.2 Agregasi Harian dan Stabilisasi Data (Extreme Smoothing)

Dataset diolah melalui teknik agregasi harian (resampling) untuk memetakan fluktuasi kebutuhan bahan baku secara kronologis, dengan mengabaikan periode non-operasional untuk mempertahankan relevansi data aktif. Tahapan ini di lakukan untuk meminimalisir dampak anomali data, diimplementasikan mekanisme Extreme Smoothing melalui pemotongan nilai ekstrem (clipping) pada ambang batas persentil 15% dan 85%, yang kemudian diikuti dengan penerapan Simple Moving Average berbasis jendela waktu 7 hari. Prosedur ini terbukti efektif dalam mereduksi noise stokastik dan menstabilkan varians data, sehingga menghasilkan input yang lebih optimal bagi arsitektur LSTM dalam menangkap pola tren fundamental.

	Tanggal	Qty
1	2025-01-08 00:00:00	1151711.431429
2	2025-01-09 00:00:00	1387752.777857
3	2025-01-10 00:00:00	1502139.547143
4	2025-01-11 00:00:00	1630606.265
5	2025-01-13 00:00:00	1796150.155714
...	...	...
244	2025-10-31 00:00:00	2772145.258571
245	2025-11-01 00:00:00	2607220.258571
246	2025-11-03 00:00:00	2079750.392143
247	2025-11-04 00:00:00	2578712.088143
248	2025-11-05 00:00:00	2613129.916714

Gambar 3. Tahap Agresi Harian Dan Stabilitas Data

3.3.3 Transformasi dan Normalisasi

Tahapan ini di lakukan untuk mengoptimalkan distribusi data, diaplikasikan fungsi logaritmik natural (Log1p) yang bertujuan untuk menekan rentang varians serta menstabilkan fluktuasi nilai yang tajam pada data kebutuhan bahan baku. Setelah distribusi data mencapai tingkat stabilitas yang diinginkan, dilakukan prosedur normalisasi menggunakan metode MinMaxScaler. Teknik ini mentransformasikan seluruh fitur ke dalam rentang standar [0, 1], sehingga menghilangkan dominasi numerik dari variabel tertentu dan mempercepat konvergensi algoritma saat fase pelatihan model LSTM. Implementasi kedua teknik prapemrosesan ini memastikan bahwa setiap input memiliki skala yang seragam, yang secara signifikan meningkatkan kemampuan jaringan saraf dalam mengenali pola-pola sekuensial yang kompleks.

	Tanggal	Qty_Asli	Log_Qty	Scaled_Qty
1	2025-01-08 00:00:00	1151711.431429	13.95676	0.173727
2	2025-01-09 00:00:00	1387752.777857	14.143197	0.276856
3	2025-01-10 00:00:00	1502139.547143	14.222402	0.320669
4	2025-01-11 00:00:00	1630606.265	14.304463	0.366062
5	2025-01-13 00:00:00	1796150.155714	14.401157	0.419549
...	...	...	...	...
244	2025-10-31 00:00:00	2772145.258571	14.835132	0.659607
245	2025-11-01 00:00:00	2607220.258571	14.773796	0.625678
246	2025-11-03 00:00:00	2079750.392143	14.547759	0.500644
247	2025-11-04 00:00:00	2578712.088143	14.762801	0.619596
248	2025-11-05 00:00:00	2613129.916714	14.77606	0.626931

Gambar 4. Tahap Transformasi dan Normalisasi

3.3.4 Pembentukan Sekuens (Windowing)

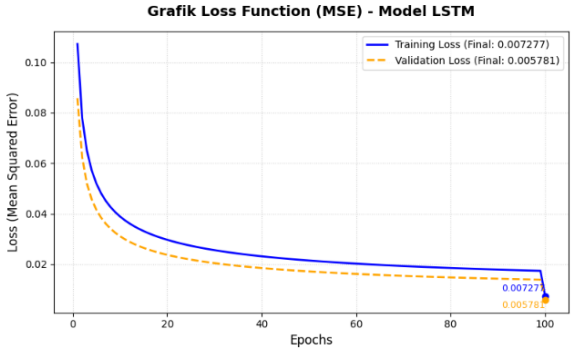
Setelah proses normalisasi selesai, data direstrukturisasi ke dalam format sekuensial menggunakan teknik sliding window dengan parameter look-back selama 30 hari. Prosedur ini mentransformasi data deret waktu menjadi struktur pembelajaran terawasi (supervised learning), di mana observasi pada rentang waktu sebelumnya digunakan sebagai fitur input untuk memprediksi nilai kebutuhan bahan baku pada satu langkah waktu berikutnya. Mekanisme windowing ini krusial bagi arsitektur LSTM untuk mengekstraksi ketergantungan temporal dan pola siklus dalam aktivitas inventaris perusahaan. Selanjutnya, dataset yang telah terbentuk dibagi secara sistematis ke dalam dua partisi, yakni data latih (training set) sebesar 80% dan data uji (testing set) sebesar 20%. Proporsi ini ditetapkan untuk memberikan volume informasi yang memadai bagi model dalam mempelajari bobot internal pada fase pelatihan, sekaligus menyediakan basis validasi yang objektif untuk mengukur kemampuan generalisasi model terhadap data baru, guna memastikan hasil prediksi yang akurat dan terhindar dari indikasi overfitting.

	Awal_Window (t-30)	t-29	t-28	...	Akhir_Window (t-1)	Target (t)
1	0.173727	0.276856	0.320669	...	0.805392	0.845844
2	0.276856	0.320669	0.366062	...	0.845844	0.866584
3	0.320669	0.366062	0.419549	...	0.866584	0.902754
4	0.366062	0.419549	0.456607	...	0.902754	0.928085
5	0.419549	0.456607	0.362196	...	0.928085	0.932989
...	...	...	...	...	...	...
164	0.356584	0.297576	0.312489	...	0.41201	0.41201
165	0.297576	0.312489	0.435862	...	0.41201	0.44146
166	0.312489	0.435862	0.558168	...	0.44146	0.607713
167	0.435862	0.558168	0.615563	...	0.607713	0.577886
168	0.558168	0.615563	0.74481	...	0.577886	0.510454

Gambar 5. Tahapan Pembentukan Sekuens

3.4 Pemodelan (Modeling)

Model prediktif dikembangkan melalui integrasi lapisan LSTM dengan konfigurasi 50 neuron fungsional guna mengekstraksi dependensi temporal pada data stok. Stabilitas model dioptimalkan melalui penerapan *Dropout* 20% untuk memitigasi overfitting, serta algoritma Adam Optimizer dan Mean Squared Error (MSE) sebagai metrik minimalisasi deviasi. Meskipun mekanisme early stopping telah diintegrasikan sebagai langkah preventif terhadap overfitting, model tetap melakukan iterasi hingga batas maksimum 100 epoch. Hal ini menunjukkan bahwa proses optimasi mencapai titik konvergensi pada tahap akhir pelatihan, sehingga diperoleh bobot model yang paling representatif berdasarkan tren minimalisasi *loss* pada dataset validasi.



Gambar 6. Pemodelan

3.5 Evaluasi

Fase evaluasi dilakukan untuk mengukur tingkat akurasi dan kemampuan generalisasi model LSTM yang telah dilatih. Pengujian statistik dilakukan dengan membandingkan nilai prediksi terhadap nilai aktual pada testing set (20% data) yang tidak terlibat dalam fase pelatihan.

3.5.1 Analisis Metrik Kesalahan

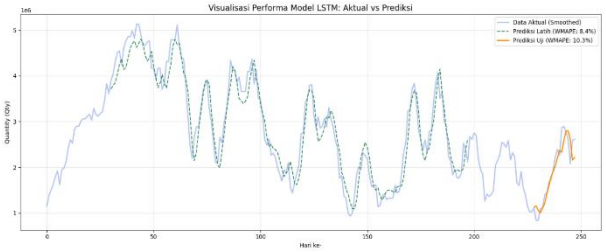
Performa model diukur menggunakan dua metrik utama, yaitu Root Mean Squared Error (RMSE) dan Weighted Mean Absolute Percentage Error (WMAPE). Hasil pengujian menunjukkan nilai kesalahan sebagai berikut:

TABEL I. EVALUASI ANALSISI METRIK KESALAHAN

Dataset	RMSE (Skala Asli)	MAPE	WMAPE
Train	308,054.90	9.76%	8.43%

Berdasarkan table 1 nilai *Weighted Mean Absolute Percentage Error* (WMAPE) pada data latih sebesar 8,43%. Berdasarkan kriteria industri peramalan, capaian tersebut mengindikasikan bahwa model memiliki performa prediksi yang sangat baik membuktikan bahwa *model Long Short-Term Memory* (LSTM) yang dikembangkan memiliki kemampuan generalisasi yang tinggi dan berhasil memitigasi risiko overfitting. Keberhasilan ini secara kritis sangat bergantung pada teknik Extreme Smoothing yang mampu meredam anomali pesanan sebelum diumpankan ke jaringan saraf. Temuan ini sejalan dengan Nugroho dan Haris (2024) mengenai urgensi kualitas prapemrosesan. Lebih lanjut, jika penelitian Cahyani dkk. (2023) dan Fadilah dkk. (2024) berfokus pada prediksi produk hilir (barang jadi), hasil ini secara eksplisit mengonfirmasi bahwa arsitektur LSTM dan Adam Optimizer sama tangguhnya saat diterapkan pada sektor hulu (kebutuhan bahan baku), yang notabene memiliki volatilitas dan noise stokastik yang jauh lebih kompleks.

3.5.2 Validasi Visual dan Proyeksi Tren



Gambar 7. Validasi Visual

Visualisasi hasil peramalan pada gambar 7 menunjukkan bahwa kurva prediksi mampu mengikuti pola fluktuasi data aktual yang telah melalui proses Extreme Smoothing. Meskipun terdapat volatilitas pada data inventaris harian, mekanisme gerbang (gates) pada arsitektur LSTM efektif dalam menangkap ketergantungan temporal jangka panjang.

```
5. PROYEKSI BISNIS (1 Tahun Kedepan):
   - Rata-rata Historis : 65,453,737 Qty / bulan
   - Rata-rata Prediksi : 76,036,958 Qty / bulan
   - Kesimpulan Tren    : NAIK 📈 (Sebesar 16.2%)

6. ANALISIS TREN BAHAN BAKU (Top 10 Kenaikan Tertinggi):
   - Status Analisis    : Berhasil dihitung (Gradien/Slope Matematika Sederhana)
   - Keterangan         : Diurutkan berdasarkan perhitungan nilai gradien pada agregasi penggunaan bulanan.

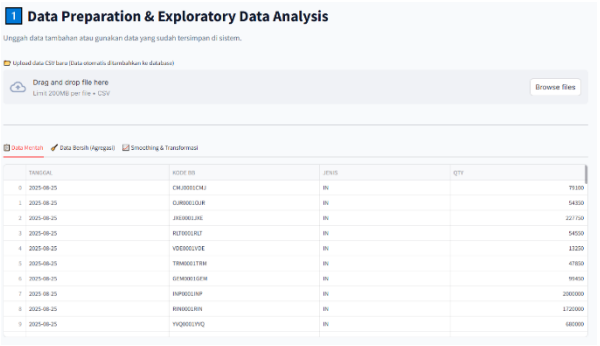
   Kode_BB  Tren_Slope  Total_Pakai_Setahun
HOU0001HOU   355496.86            2851110.0
DCM0001DCM   115316.61            5787385.0
OQF0001OQF    81375.00            1137250.0
CEJ0001CEJ    54180.00             466800.0
HTR0001HTR    41949.78            1290141.5
DTQ0001DTQ    27650.00              38350.0
VZR0001VZR    13603.65            6133400.5
FIU0001FIU    13167.20             448276.0
RDA0001RDA    12069.92             915542.8
RXB0001RXB    10496.17             349817.8
```

Gambar 8. Proyeksi Tren

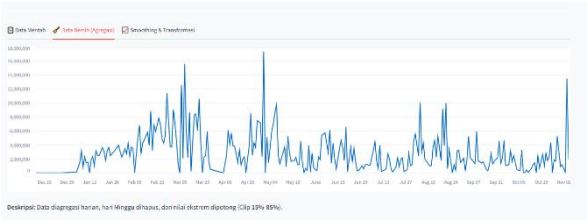
Secara agregat, hasil proyeksi bisnis untuk satu tahun ke depan menunjukkan adanya potensi kenaikan kebutuhan bahan baku sebesar 16,2% dibandingkan rata-rata historis. Rata-rata kebutuhan bulanan diprediksi meningkat dari 65,4 juta unit menjadi 76 juta unit. Analisis tren menggunakan gradien/slope matetmatika sederhana yang berhasil mengidentifikasi bahan baku dengan kode HOU0001HOU sebagai material dengan lonjakan pemakaian tertinggi (tren kenaikan 355.496 per periode). Hasil ini memberikan validasi bahwa model tidak hanya akurat secara statistik, tetapi juga relevan secara fungsional untuk mendukung strategi pengadaan bahan baku di Dua Naga Corporation.

3.6 Deployment

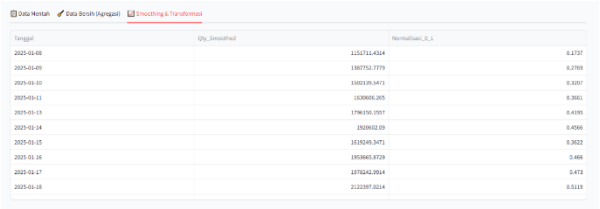
Tahap akhir implementasi diwujudkan melalui integrasi model LSTM ke dalam platform berbasis web menggunakan framework Streamlit. Sistem ini dirancang untuk mengotomatisasi seluruh alur analitik secara *real-time*, mencakup proses pengunggahan data mutasi stok mentah, prapemrosesan otomatis, hingga eksekusi algoritma prediksi sekuensial. Luaran analisis disajikan melalui visualisasi grafik proyeksi kebutuhan bahan baku dan tabel estimasi stok masa depan yang dapat diunduh untuk kebutuhan manajerial. Secara praktis, sistem ini berfungsi sebagai Decision Support System (DSS) yang memfasilitasi manajemen Dua Naga Corporation dalam merumuskan strategi pengadaan bahan baku yang presisi, efisien, dan berbasis data untuk memitigasi risiko inefisiensi inventaris.



Gambar 9. Input Data Dan Data Mentah



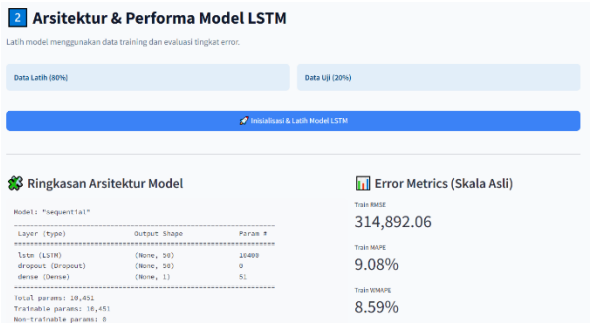
Gambar 10. Data Bersih (Agregasi)



Gambar 11. Smoothing & Transformasi

3.6.1 Arsitektur Model dan Nilai Loss

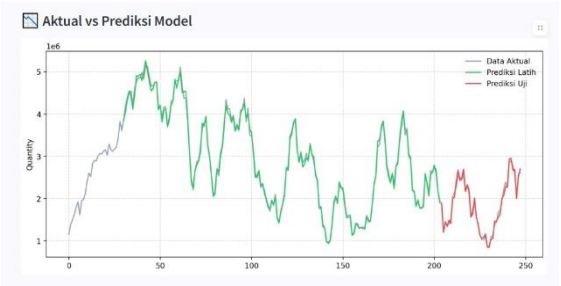
Pada tahap *deployment*, sistem menampilkan arsitektur yang terdiri dari *layer* LSTM, *Dropout*, dan *Dense* beserta nilai Final Training *Loss* dan Final Validation *Loss* dalam bentuk Mean Squared Error (MSE). Berdasarkan hasil implementasi diperoleh nilai Training *Loss* sebesar 0.007277 dan Validation *Loss* sebesar 0.005781.



Gambar 12. Arsitektur Model

3.6.2 Performa Model dan Visualisasi Prediksi

Sistem menampilkan performa model menggunakan nilai RMSE, MAPE, dan WMAPE pada data pelatihan dan pengujian. Hasil evaluasi menunjukkan nilai Train RMSE sebesar 314,892.06 dan Test RMSE sebesar 251,298.82, sedangkan nilai Train MAPE sebesar 9.08% dan Test MAPE sebesar 10.83%. Selain itu, sistem juga menampilkan grafik perbandingan data aktual dan hasil prediksi yang menunjukkan bahwa model mampu mengikuti pola data penggunaan bahan baku dengan cukup baik.



Gambar 13. Visualisasi Prediksi

3.6.3 Tampilan Kesimpulan Eksekutif

Sistem menampilkan kesimpulan eksekutif secara otomatis yang berisi ringkasan preprocessing data, konfigurasi model, hasil evaluasi, dan proyeksi bisnis untuk periode mendatang. Berdasarkan hasil *forecasting,* diperoleh tren kenaikan penggunaan bahan baku sebesar 16.2% dibandingkan rata-rata historis bulanan sehingga informasi tersebut dapat digunakan sebagai pendukung pengambilan keputusan perusahaan.



Gambar 14. Kesimpulan Eksekutif

3.6.4 Tampilan Tabel Kenaikan Tren Tertinggi

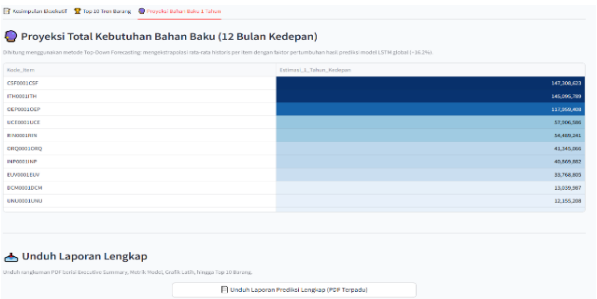
Pada tahapan ini sistem menampilkan tabel *Top 10 Tren Bahan Baku* peningkatan tertinggi berdasarkan perhitungan nilai gradien (*slope*) dari agregasi penggunaan bulanan. Atribut yang ditampilkan mencakup Kode_Item sebagai identifikasi unik material, Slope yang merepresentasikan laju pertumbuhan permintaan empiris, serta Total_Pakai_Setahun sebagai akumulasi volume penggunaan. Analisis *slope* ini secara efektif mengidentifikasi bahan baku dengan peningkatan kebutuhan paling signifikan dari waktu ke waktu.



Gambar 15. Tabel Top 10 Bahan Baku

3.6.5 Proyeksi Kebutuhan Bahan Baku

Tahap akhir ini menggunakan model LSTM untuk memprediksi kebutuhan bahan baku pada periode mendatang. Proyeksi ini dibangun berdasarkan pola historis yang telah melalui tahapan prapemrosesan data yang bersifat menyeluruh, meliputi extreme smoothing, transformasi logaritmik, dan normalisasi. Secara manajerial, proyeksi peningkatan kebutuhan material secara agregat sebesar 16,2% menuntut pergeseran strategi perusahaan dari reaktif menjadi proaktif. Identifikasi material dengan lonjakan tren tertinggi, seperti HOU0001HOU , mengharuskan manajemen mengambil langkah taktis seperti merekalibrasi *safety* stock lebih awal, dan menginisiasi negosiasi pembelian bervolume besar (*bulk order*) dengan pemasok. Dengan demikian, *dashboard* visualisasi ini berfungsi lebih dari sekadar instrumen pendukung keputusan strategis berbasis data (*data-driven decision making*), melainkan sebagai solusi langsung untuk mengoptimalisasi perencanaan pengadaan serta memitigasi kerugian operasional akibat *stockout* maupun *overstock*.



Gambar 16. Proyeksi Kebutuhan Bahan Baku

4. Kesimpulan dan Saran

Hasil penelitian yang telah di lakukan menyimpulkan bahwa implementasi model LSTM terbukti sangat efektif dalam memetakan serta memprediksi kebutuhan bahan baku di Dua Naga Corporation dengan tingkat akurasi yang tinggi. Melalui prosedur prapemrosesan yang sistematis, mencakup Extreme Smoothing dan normalisasi MinMaxScaler, model mampu mereduksi noise stokastik sehingga menghasilkan input yang stabil bagi jaringan saraf. Hasil evaluasi menunjukkan nilai Weighted Mean Absolute Percentage Error (WMAPE) sebesar 10,33% pada data uji, di mana konsistensi performa ini didukung oleh penggunaan *Dropout* 20% dan mekanisme Early Stopping yang secara signifikan berhasil memitigasi risiko overfitting serta meningkatkan kemampuan generalisasi model terhadap data baru.

Secara strategis, hasil proyeksi bisnis mengungkap adanya potensi kenaikan kebutuhan bahan baku sebesar 16,2% untuk periode mendatang, dengan identifikasi tren lonjakan spesifik pada material tertentu seperti kode HOU0001HOU. Temuan ini diintegrasikan ke dalam sistem pendukung keputusan (Decision Support System) berbasis platform Streamlit yang mampu mengotomatisasi seluruh alur analitik secara *real-time*. Kehadiran perangkat manajerial ini memberikan kontribusi praktis yang krusial bagi manajemen perusahaan dalam merumuskan kebijakan pengadaan yang lebih presisi, sehingga efisiensi inventaris dapat diminimalisir melalui perencanaan stok yang berbasis pada data prediktif yang valid.

Sebagai upaya pengembangan di masa depan, disarankan untuk mengintegrasikan variabel eksternal seperti dinamika musiman atau tren pasar, serta melakukan komparasi performa model secara langsung dengan varian arsitektur *Learning* tingkat lanjut lainnya, seperti *Bidirectional* LSTM (Bi-LSTM) atau *Gated Recurrent Unit* (GRU). Perbandingan ini krusial untuk mengevaluasi tidak hanya dari segi akurasi (metrik WMAPE), tetapi juga dari tingkat efisiensi beban komputasi (waktu konvergensi) pada dataset manufaktur yang bervolatilitas tinggi. Terakhir, sinkronisasi sistem secara langsung dengan basis data ERP perusahaan sangat direkomendasikan untuk mewujudkan ekosistem manajemen rantai pasok yang sepenuhnya otomatis, responsif, dan terintegrasi secara menyeluruh.

5. UCAPAN TERIMA KASIH

Ungkapan terima kasih penulis haturkan kepada segenap pihak yang telah memfasilitasi terselenggaranya penelitian ini hingga selesai. Apresiasi mendalam secara khusus diberikan kepada jajaran dosen pembimbing atas dedikasi intelektual, arahan teknis, serta masukan konstruktif yang telah mempertajam substansi penelitian ini. Penulis juga menyampaikan penghargaan kepada segenap manajemen dan staf PT Dua Naga Corporation sebagai penyedia dataset primer yang sangat krusial bagi keberhasilan pemodelan LSTM ini. Harapan penulis, temuan dalam studi ini mampu menjadi referensi strategis dalam peningkatan efisiensi rantai pasok di sektor manufaktur nasional.

Daftar Pustaka:

[1] R. E. Erlinda, U. Yudatama, and E. R. Arumi, “Implementasi Sistem Peramalan Pengadaan Kebutuhan Bahan Baku Pangan Dengan Metode Weighted Moving Average,” Jurnal Teknologi Informasi dan Ilmu Komputer, vol. 9, no. 2, 2022, doi: 10.25126/jtiik.2022924700.

[2] M. Fadila, R. A. Dalimunthe, and S. R. M. Azmi, “Prediksi Stok Bahan Baku Roti Pada Toko Karya Bakery Kecamatan Lima Puluh Dengan Metode Single Moving Average,” DECODE: Jurnal Pendidikan Teknologi Informasi, vol. 4, no. 2, pp. 593–608, 2024.

[3] M. H. Satria and S. Dewi, “Analisis Sistem Manajemen Persediaan Dengan Metode Economic Order Quantity (EOQ),” Venus: Jurnal Publikasi Rumpun Ilmu Teknik, vol. 2, no. 1, pp. 145–157, 2024.

[4] Nuraeni, N., & Santoso, B. (2024). Peranan Manajemen Persediaan Bahan Baku terhadap Penjadwalan Produksi PT XYZ. Jurnal Bisnis dan Manajemen (JURBISMAN), 2(2), 379-394.

[5] R. D. P. Rawi et al., “Analisis Pengendalian Persediaan Bahan Baku Dengan Menggunakan Metode Economic Order Quantity,” Jurnal Akuntansi dan Pajak, vol. 23, no. 1, 2022, doi: 10.29040/jap.v23i1.5667.

[6] M. Atharsyah and M. A. Romli, "Implementasi Model LSTM, GRU,

BiLSTM, dan BiGRU dalam Prediksi Harga Nikel," Jurnal Informatika dan Rekayasa Elektronik (JIRE), vol. 7, no. 2, 2024. doi.org/10.36595/jire.v7i2.1317.

[7] A. Nugroho and M. Haris, "Analisis Efektivitas Teknik Imputasi pada LSTM untuk Meningkatkan Kualitas Data pada Peramalan Curah Hujan," Jurnal Informatika dan Rekayasa Elektronik (JIRE), vol. 7, no. 2, 2024, doi: 10.36595/jire.v7i2.1172.

[8] Y. A. Nugroho and H. A. Hutahaean, "Pengembangan Model Deep Learning LSTM dan CNN untuk Peramalan Penjualan Sepeda Motor di Indonesia," Jupiter: Publikasi Ilmu Keteknikan Industri, Teknik Elektro dan Informatika, vol. 3, no. 2, pp. 94–104, 2025.

[9] J. Cahyani, S. Mujahidin, and T. P. Fiqar, "Implementasi Metode Long Short Term Memory (LSTM) untuk Memprediksi Harga Bahan Pokok Nasional," Jurnal Sistem dan Teknologi Informasi (JUSTIN), vol. 11, no. 2, 2023, doi: 10.26418/justin.v11i2.57395.

[10] M. Fadilah, Y. Setiawan, and F. Z. Rahmanti, "Sistem Peramalan Penjualan Produk Skincare Favorit Menggunakan Long Short-Term Memory (LSTM) Studi Kasus Toko Kayrabeauty," Jurnal Tugas Akhir Fakultas Informatika, Universitas Telkom, 2024.

[11] S. Putri and M. Sadikin, "Prediksi Penjualan Produk Untuk Mengestimasi Kebutuhan Bahan Baku Menggunakan Perbandingan Algoritma LSTM dan ARIMA," Format Jurnal Ilmiah Teknik Informatika, vol. 10, no. 2, 2021, doi: 10.22441/format.2021.v10.i2.007.

[12] R. Firdaus, H. Mukhtar, and Awaluddin, "Prediksi Indeks Harga Produsen Pertanian Karet di Indonesia Menggunakan Metode LSTM," Jurnal FASILKOM, vol. 13, no. 1, 2023, doi: 10.37859/jf.v13i01.4851.

[13] S. Suranti and S. Sitohang, "Implementasi Neural Network dengan Metode LSTM untuk Prediksi Penjualan Chintari Cake and Cookies," COMASIE, vol. 13, no. 3, 2025, doi: 10.33884/comasiejournal.v13i3.10535.

[14] Langi, M. Wullur, and A. B. H. Jan, "Peramalan Pengendalian Persediaan Bahan Baku Gula Aren," Jurnal EMBA: Jurnal Riset Ekonomi, Manajemen, Bisnis dan Akuntansi, vol. 13, no. 1, pp. 545–558, 2025.

[15] S. P. Afrisia, F. M. Hana, and W. C. Wahyudin, "Implementasi Metode Long Short Term Memory (LSTM) pada Chatbot Kesehatan Mental Mahasiswa," Sainteks: Jurnal Ilmiah Penelitian dan Pembelajaran, vol. 21, no. 2, pp. 107–116, 2024. doi: 10.30595/sainteks.v21i2.23869

[16] P. Rizkha Ambadar et al., "Implementation of LSTM Method on Tidal Prediction in Semarang Region," Journal of Applied Informatics and Computing, vol. 9, no. 2, 2025, doi: 10.30871/jaic.v9i2.8932.

[17] R. Wahid and A. Witanti, "Implementasi Algoritma LSTM untuk Prediksi Kebutuhan Bahan Baku Restoran di Bale Raos Kraton Yogyakarta," INTECOMS: Journal of Information Technology and Computer Science, vol. 8, no. 1, 2025, doi: 10.31539/cf163j95.

[18] P. C. Bangun, P. Juanta, and M. F. Nizam, "Predictive Analysis of Raw Material Stock at Puri Food and Healthy Using the Long Short-Term Memory (LSTM) Method," Jurnal Sisfokom, vol. 14, no. 4, 2025, doi: 10.32736/sisfokom.v14i4.2458.

[19] C. Billan and U. Ependi, "Oil and Gas Production Forecasting Based on LSTM Model: A Case Study of PT Pertamina Hulu Rokan Zone 4," Journal of Information Systems and Informatics, vol. 7, no. 4, 2025, doi: 10.63158/journalisi.v7i4.1285.

[20] Anggun and R. E. S., "Penerapan Metode Long Short Term Memory untuk Memprediksi Harga Beras di Indonesia," JINACS: Journal of Informatics and Computer Science, vol. 6, no. 3, 2024.