

Prediksi Penjualan Aerosol Menggunakan Algoritma ARIMA, LSTM Dan GRU

Nendi Sunendar¹, Harjono P. Putro², Rizki Hesananda³

^{1,2}Universitas Krisnadwipayana, Jatiwaringin, Jakarta,

³Universitas Siber Indonesia, Jakarta

Email: ¹sunendarnendi@gmail.com, ²harjono.unkris@gmail.com, ³hessananda@gmail.com

Abstract

The advancement of information technology has significantly enhanced operational efficiency by enabling companies to process data more effectively and make better decisions. In a highly competitive global market, distributors face major challenges, including shorter product life cycles and fluctuating customer demand. These factors impact stock and production management, necessitating more accurate predictive solutions to optimize production planning. This study aims to compare the performance of ARIMA, LSTM, and GRU models in sales forecasting using time series forecasting methods. ARIMA represents a traditional statistical approach, while LSTM and GRU, based on deep learning, are capable of capturing complex data patterns. The models are evaluated using MSE, RMSE, MAE, and MAPE metrics. The results indicate that LSTM outperforms other models with a MAPE of 10.76%, followed by ARIMA (11.23%) and GRU (11.47%). LSTM excels in identifying long-term trends and seasonal patterns, while GRU achieves nearly comparable accuracy with a shorter training time. ARIMA, despite its simplicity, struggles to handle non-linear patterns. These findings provide valuable insights for companies in selecting the most suitable predictive model to optimize supply chain management, enhance operational efficiency, and support more informed decision-making.

Keywords: Machine Learning, Sales Prediction, Time Series Data, ARIMA, LSTM, GRU.

Abstrak

Perkembangan teknologi informasi telah mendukung efisiensi operasional perusahaan melalui sistem informasi yang membantu dalam pengolahan data dan pengambilan keputusan yang lebih akurat. Dalam persaingan global, distributor menghadapi tantangan besar, seperti siklus hidup produk yang semakin pendek dan fluktuasi permintaan pelanggan. Hal ini berdampak pada pengelolaan stok dan produksi, yang menuntut solusi prediksi yang lebih akurat untuk mendukung perencanaan produksi yang optimal. Penelitian ini bertujuan untuk membandingkan performa ARIMA, LSTM, dan GRU dalam memprediksi penjualan menggunakan metode time series forecasting. ARIMA merupakan pendekatan statistik tradisional, sedangkan LSTM dan GRU berbasis deep learning, yang mampu menangkap pola data yang lebih kompleks. Model dievaluasi menggunakan metrik MSE, RMSE, MAE, dan MAPE. Hasil menunjukkan bahwa LSTM memberikan performa terbaik dengan MAPE 10,76%, diikuti oleh ARIMA (11,23%) dan GRU (11,47%). LSTM terbukti unggul dalam menangkap tren jangka panjang dan pola musiman, sementara GRU menunjukkan kinerja yang hampir setara dengan LSTM namun dengan waktu pelatihan yang lebih singkat. ARIMA, meskipun lebih sederhana, kurang efektif dalam menangani pola non-linear dalam data. Temuan ini memberikan wawasan bagi perusahaan dalam memilih model prediksi yang paling sesuai untuk mengoptimalkan rantai pasokan, meningkatkan efisiensi operasional, serta mendukung pengambilan keputusan yang lebih baik.

Kata Kunci: Pembelajaran Mesin, Prediksi Penjualan, Data Time Series, ARIMA,LSTM,GRU.

1. PENDAHULUAN

Kemajuan teknologi informasi dalam bidang komunikasi dan data telah berkembang pesat, memainkan peran penting dalam meningkatkan efisiensi operasional perusahaan. Sistem informasi kini menjadi elemen vital dalam mendukung pengolahan data dan penyediaan informasi strategis untuk pengambilan keputusan. Dalam era globalisasi dan persaingan bisnis yang semakin kompetitif, distributor menghadapi tantangan besar, seperti siklus hidup produk yang pendek dan fluktuasi permintaan pelanggan. Oleh karena itu, pengelolaan stok yang efisien menjadi prioritas utama guna menghindari kelebihan atau kekurangan persediaan yang dapat berdampak pada biaya operasional dan kepuasan pelanggan (Yavasani & Wang, 2023a). Di industri produk rumah tangga dan pengendalian hama, Aerosol Anti nyamuk adalah salah satu produk yang menghadapi tantangan dalam perencanaan persediaan dan distribusi akibat fluktuasi permintaan yang tinggi. Ketidakterpenuhan dalam prediksi permintaan dapat menyebabkan dua risiko utama yaitu; (1)Kelebihan stok, yang meningkatkan biaya penyimpanan dan risiko kedaluwarsa. (2)Kekurangan stok, yang berakibat pada kehilangan peluang penjualan. (3)Metode konvensional, seperti pendekatan statistik tradisional, sering kali mengalami keterbatasan dalam menangkap pola permintaan yang kompleks dan non-linear. Masing-masing model memiliki pendekatan yang berbeda dalam menganalisis data. ARIMA mengandalkan hubungan linier dalam data deret waktu, sementara LSTM dan GRU memanfaatkan teknik pembelajaran mendalam untuk menangkap pola yang lebih kompleks dan nonlinier.

1.1 ARIMA (*AutoRegressive Integrated Moving Average*)

ARIMA merupakan model statistik yang digunakan untuk menganalisis dan memprediksi data deret waktu dengan pola linier. Model ini terdiri dari tiga komponen utama:

1. AutoRegressive (AR): Ketergantungan nilai saat ini terhadap nilai sebelumnya dengan koefisien regresi tertentu.
2. Integrated (I): Diferensiasi untuk menghilangkan tren dan membuat data menjadi stasioner.
3. Moving Average (MA): Hubungan antara observasi saat ini dengan error dari lag sebelumnya.

Rumus umum ARIMA dituliskan sebagai:

$$Y_t = c + \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{j=1}^q \theta_j \epsilon_{t-j} + \epsilon_t \quad (1)$$

Di mana:

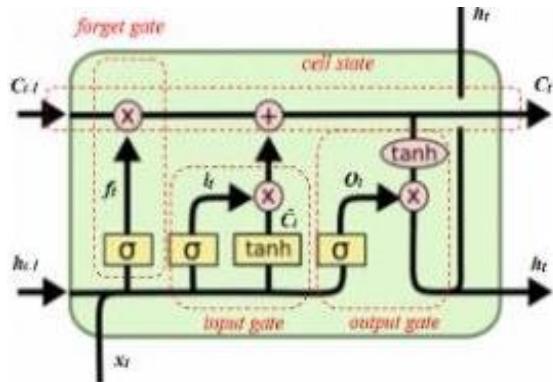
- Y_t adalah nilai yang diprediksi pada waktu t ,
- ϕ adalah parameter AR,
- θ adalah parameter MA,
- ϵ_t adalah error residual.

ARIMA digunakan untuk data yang memiliki tren jangka panjang dan tidak terlalu dipengaruhi oleh hubungan nonlinier yang kompleks (Si, Nadarajah, Zhang, & Xu, 2024).

1.2 LSTM (Long Short-Term Memory)

Neural network (NN) sederhana hanya terdiri dari input, model network, dan output untuk regresi linier dan klasifikasi. Pengembangan selanjutnya adalah model one to many, di mana output sebelumnya digunakan sebagai input untuk proses berikutnya.

Model ini kemudian berkembang menjadi Recurrent Neural Network (RNN), yang memproses input dengan melibatkan data sebelumnya. RNN menggunakan multi-layer dan perulangan dalam

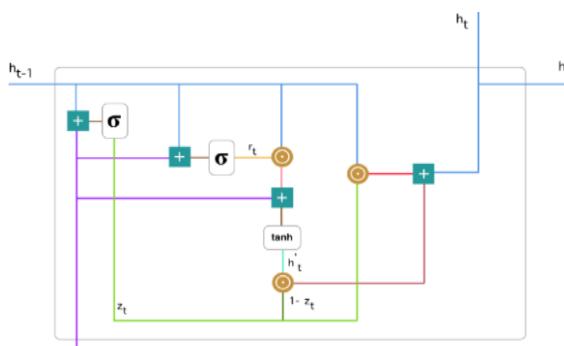


Gambar 1. Struktur LSTM

Gambar 2 menunjukkan struktur LSTM. Untuk menangani data time series atau deret waktu, LSTM menghubungkan informasi sebelumnya dengan informasi berikutnya secara efektif dan mampu menyimpan data dalam jangka waktu yang panjang. Pertama, menghitung nilai sigmoid dan tanh. Kedua, mengubah data menjadi masalah supervised learning, yang mempelajari fungsi pemetaan dari input ke output. Data yang digunakan berbentuk time series, dengan output hari kemarin dilambangkan ($t-1$) dan hari ini (t). Ketiga, menerapkan min-max scaling untuk normalisasi. Keempat, menghapus variabel yang tidak diperlukan. Kelima, membagi data menjadi data latih dan data uji. Keenam, memodelkan LSTM dengan memilih jumlah neuron, hidden layer, dan epoch yang sesuai. Selanjutnya, menghitung nilai forget gate, input gate, memperbaiki memory cell, menghitung output gate, dan nilai output akhir. Terakhir, mengevaluasi model LSTM yang dikembangkan (Yavasani & Wang, 2023b).

1.3 GRU (Gated Recurrent Unit)

GRU adalah versi perbaikan dari algoritma *Recurrent Neural Network* (RNN). Diperkenalkan oleh untuk mengatasi masalah gradien hilang dari RNN standar. GRU juga dapat dianggap sebagai variasi pada LSTM karena keduanya dirancang serupa dan dalam beberapa kasus, menghasilkan hasil yang sama bagusnya. Untuk mengatasi masalah gradien hilang GRU menggunakan *update gate* dan *reset gate*. Pada dasarnya, ini adalah dua vektor yang memutuskan informasi apa yang harus diteruskan ke output.



Gambar 2. Sel GRU

Menghitung *update gate* Z_t untuk langkah waktu t menggunakan rumus berikut :

$$Z_t = \sigma(W^z x_t + U^z h_{t-1}) \quad (2)$$

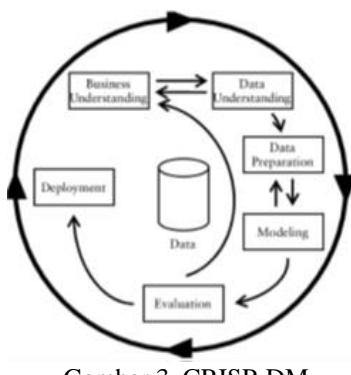
Ketika x_t dimasukkan ke unit jaringan, itu dikalikan dengan bobotnya sendiri $W^{(z)}$. Hal yang sama berlaku untuk h_{t-1} yang menyimpan informasi untuk unit $t-1$ sebelumnya dan dikalikan dengan bobotnya sendiri $U^{(z)}$. Kedua hasil ditambahkan bersama-sama dan fungsi aktivasi sigmoid diterapkan untuk mendapatkan hasil antara 0 dan 1. *Update gate* membantu model untuk menentukan berapa banyak informasi masa lalu (dari langkah waktu sebelumnya) yang perlu diteruskan ke masa depan. Itu sangat kuat karena model dapat memutuskan untuk menyalin semua informasi dari masa lalu dan menghilangkan risiko masalah gradien menghilang.

1.4 CRISP-DM

Penelitian ini menggunakan metode CRISP-DM (Cross-Industry Standard Process for Data Mining) sebagai framework utama dalam pemodelan, yang mencakup enam tahapan utama: Pemahaman Bisnis, Pemahaman Data, Persiapan Data, Pemodelan, Evaluasi, dan Penerapan Model. Tahapan ini mencakup berbagai aktivitas seperti eksplorasi data, identifikasi pola, pemilihan atribut yang relevan, serta pengolahan dan validasi hasil prediksi. Setelah model dievaluasi, model terbaik akan diimplementasikan untuk membantu dalam proses pengambilan keputusan bisnis (Ali & Rizki Rinaldi, 2023). Penelitian ini berkontribusi pada bidang peramalan penjualan dengan mengeksplorasi penerapan model pembelajaran mesin dalam skenario bisnis nyata. Dengan membandingkan metode statistik tradisional dengan teknik deep learning, penelitian ini memberikan wawasan mengenai kelebihan dan keterbatasan setiap pendekatan. Temuan ini diharapkan dapat membantu perusahaan dalam memilih model peramalan yang paling sesuai (Sastya & Nugraha, 2023).

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan Cross-Industry Standard Process for Data Mining (CRISP-DM) yang terdiri dari enam tahap utama, yaitu pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan penerapan hasil. Model prediksi yang digunakan dalam penelitian ini bertujuan untuk mengoptimalkan permintaan produk sehingga produksi dapat disesuaikan dengan kebutuhan distributor (Hasanah, Soim, & Handayani, 2021). Tahapan CRISP-DM (Cross-Industry Standard Process for Data Mining) merupakan metode yang digunakan dalam penelitian ini untuk mengelola data dan menghasilkan prediksi yang akurat. Berikut adalah penjelasan lebih rinci mengenai setiap tahapannya beserta sub-tahapan yang terlibat (Saputra, Atina, & Nastiti, 2024):



Gambar 3. CRISP-DM

Gambar 3 menampilkan flow metodologi CRISP-DM, berikut merupakan detail untuk setiap step metodologi pada penelitian ini.

2.1 Pemahaman terhadap Bisnis (*Business Understanding*)

Pada tahap pemahaman bisnis, penelitian berfokus pada tantangan yang dihadapi perusahaan dalam memenuhi kebutuhan distributor akibat fluktuasi permintaan. Kondisi ini sering kali menyebabkan kelebihan atau kekurangan produksi, yang berdampak pada efisiensi rantai pasokan. Oleh karena itu, penelitian ini bertujuan untuk membangun model prediksi yang akurat untuk membantu perusahaan dalam mengelola produksi secara lebih efektif. Pada tahapan ini akan dilakukan observasi ke tempat yang dijadikan objek penelitian kemudian mencari kondisi bisnis diperusahaan. Dalam hal ini dapat menentukan tujuan dari penelitian.

2.3 Pemahaman Terhadap Data (*Data Understanding*)

Pada tahapan proses pengumpulan data, data tersebut dipelajari dan dipahami lebih lanjut. Data yang dibutuhkan dalam penelitian ini adalah data permintaan dari distributor periode Januari 2019 – November 2023. Data yang digunakan terdiri dari tanggal, nama produk, total permintaan. Tahapan ini bertujuan untuk memahami karakteristik dataset yang digunakan dalam penelitian.

A	B	C	D	E	F	G	H	I
MT_NO	MT_DATE	INV_NO	INV_NAME	INV_QTY	INV_UOM	MT_Lineno	MT_DO	MT_SL
1	5006290756	10/4/2019	40027070	HIT AEROSOL EXPERT SWEET FLOWER	144 EA	1	8541192	SL01
2	5006290757	10/4/2019	40027070	HIT AEROSOL EXPERT SWEET FLOWER	240 EA	1	8541200	SL01
3	5006292393	10/4/2019	40027070	HIT AEROSOL EXPERT SWEET FLOWER	12 EA	4	8541234	SL01
4	5006292397	10/4/2019	40027070	HIT AEROSOL EXPERT SWEET FLOWER	156 EA	17	8541236	SL01
5	5006292397	10/4/2019	40027034	HIT AEROSOL EXPERT BLOSSOM	360 EA	18	8541236	SL01
6	5006292397	10/4/2019	40027069	HIT AEROSOL EXPERT BLOOMING TEA	492 EA	66	8541236	SL01
7	5006292397	10/4/2019	40027070	HIT AEROSOL EXPERT SWEET FLOWER	48 EA	67	8541236	SL01
8	5006292397	10/4/2019	40027071	HIT AEROSOL EXPERT CITRUS	420 EA	68	8541236	SL01
9	5006292397	10/4/2019	40027071	HIT AEROSOL EXPERT CITRUS	312 EA	15	8541270	SL01
10	5006294496	10/5/2019	40027069	HIT AEROSOL EXPERT BLOOMING TEA	1536 EA	1	8541270	SL01
11	5006294496	10/5/2019	40027071	HIT AEROSOL EXPERT CITRUS	240 EA	6	8541296	SL01
12	5006294525	10/5/2019	40027034	HIT AEROSOL EXPERT BLOSSOM	4608 EA	19	8541296	SL01
13	5006295116	10/5/2019	40027034	HIT AEROSOL EXPERT BLOSSOM	12 EA	34	8541386	SL01
14	5006295116	10/5/2019	40027069	HIT AEROSOL EXPERT BLOOMING TEA	24 EA	33	8541386	SL01
						

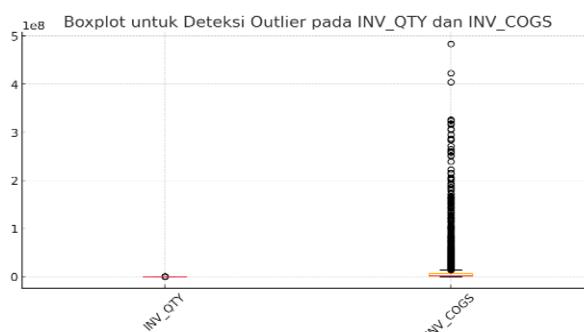
Gambar 4. Dataset

2.4 Persiapan Data (*Data Preparation*)

Tahap pengolahan data mencakup proses pembersihan data dengan menghapus atau mengisi nilai yang hilang. Selain itu, dilakukan normalisasi menggunakan MinMaxScaler untuk menyamakan rentang nilai fitur sehingga data lebih seragam. Setelah melakukan eksplorasi awal terhadap dataset, berikut hasilnya:

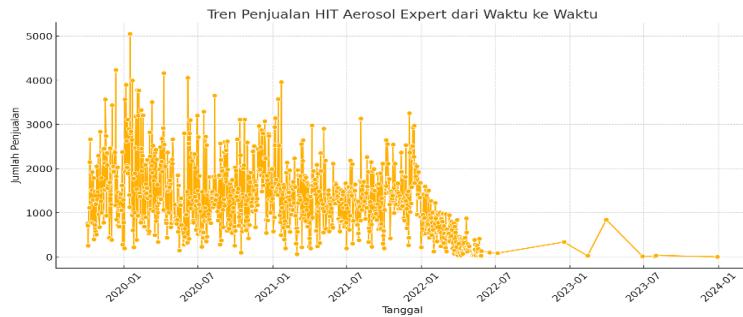
Struktur Dataset: Dataset memiliki 17.049 baris dan 13 kolom. Beberapa kolom relevan untuk analisis, yaitu INV_NAME (Nama produk), INV_QTY (Jumlah unit produk), INV_COGS (Biaya perolehan barang), MT_DATE (Tanggal transaksi).

Missing Values: Tidak ada missing values dalam dataset. Semua kolom memiliki jumlah data yang lengkap. *Tipe Data:* Kolom MT_DATE (tanggal) masih dalam format string (object), yang perlu dikonversi menjadi format datetime untuk analisis time series. Kolom INV_QTY dan INV_COGS dalam format numerik (int64), sehingga bisa langsung digunakan untuk analisis prediksi penjualan. Deteksi outlier dan normalisasi data untuk memastikan kualitas data sebelum digunakan dalam pemodelan.



Gambar 5. Boxplot untuk Deteksi Outlier pada INV_QTY dan INV_COGS

Dikolom INV_QTY (Jumlah Barang Terjual) Terdapat 2.686 outlier yang berada di luar batas normal distribusi data. Ini menunjukkan adanya transaksi dalam jumlah besar yang mungkin memerlukan penyesuaian atau segmentasi data. Tindakan yang dilakukan untuk mengatasi outlier tersebut dengan cara: (1) Menghapus outlier jika dianggap sebagai anomali (misalnya, kesalahan input data). (2) Melakukan transformasi data (misalnya log-transform) untuk menangani skewness. (3) Memperlakukan data secara terpisah untuk transaksi besar dan kecil dalam analisis.

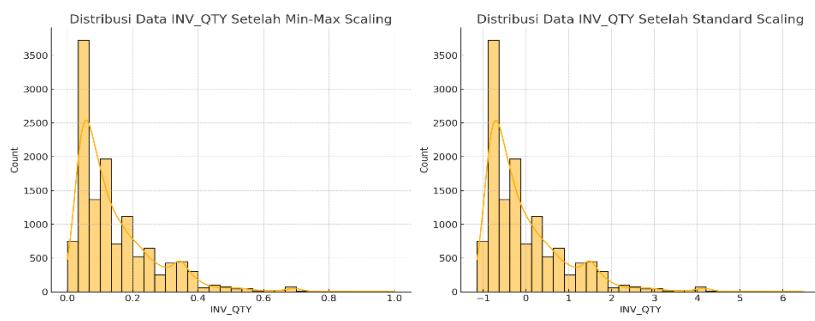


Gambar 6. Visualisasi tren penjualan Aerosol

Grafik menunjukkan tren pada volume tinggi dengan fluktuasi signifikan, menunjukkan permintaan yang stabil. Namun, sejak 2021, terjadi penurunan yang dapat disebabkan oleh perubahan strategi bisnis, faktor musiman, atau kondisi eksternal seperti pandemi. Pada 2023-2024, penjualan turun drastis dengan hanya beberapa transaksi, mengindikasikan perubahan signifikan dalam distribusi atau permintaan pasar. Pola ini menunjukkan adanya tren musiman, dan analisis lebih lanjut menggunakan model prediktif seperti ARIMA atau LSTM dapat membantu memahami pola dan merencanakan strategi bisnis ke depan.

Selanjutnya melakukan normalisasi data menggunakan dua metode:

1. Min-Max Scaling – Menyesuaikan data dalam rentang 0 hingga 1, cocok untuk model yang sensitif terhadap skala seperti LSTM dan GRU.
2. Standard Scaling – Mengonversi data menjadi distribusi dengan mean = 0 dan standard deviation = 1, ideal untuk algoritma berbasis statistik seperti ARIMA.



Gambar 7. Distribusi Data INV_QTY

Sebelah kiri adalah grafik untuk Min-Max Scaling, data telah diubah ke dalam rentang 0 hingga 1, membuatnya lebih seragam untuk model seperti LSTM dan GRU. Grafik sebelah kanan adalah Standard Scaling, data memiliki mean = 0 dan standar deviasi = 1, yang lebih cocok untuk model berbasis statistik seperti ARIMA. Selanjutnya, dataset dibagi menjadi data latih sebesar 80% dan data uji sebesar 20%. Langkah-langkah ini dilakukan agar model yang digunakan dapat belajar dari pola historis secara lebih optimal.

2.5 Pemodelan (*Modeling*)

Pemodelan dilakukan dengan menggunakan tiga algoritma prediksi, yaitu ARIMA, LSTM, dan GRU. Model ARIMA digunakan untuk analisis deret waktu dengan pendekatan statistik yang mengasumsikan linearitas dalam data. Model LSTM, yang merupakan bagian dari jaringan saraf tiruan berbasis Recurrent Neural Network (RNN), digunakan untuk menangkap pola temporal jangka panjang dan pendek dalam data deret waktu. Sementara itu, model GRU, yang merupakan variasi dari LSTM dengan jumlah parameter yang lebih sedikit, diterapkan sebagai alternatif yang lebih ringan secara komputasi tetapi tetap efektif dalam menangani data berurutan. Setiap model dilatih menggunakan dataset yang telah diproses, dan hasil prediksinya dibandingkan untuk menentukan model terbaik.

Model ARIMA dinotasikan sebagai ARIMA(p, d, q), dengan parameter p (AutoRegressive Order): Jumlah lag dari variabel target yang digunakan sebagai prediktor. d (Degree of Differencing): Jumlah transformasi differencing yang dibutuhkan agar data menjadi stasioner. q (Moving Average Order): Jumlah lag dari error model yang digunakan dalam prediksi. Menentukan Parameter ARIMA adalah p ditentukan dengan melihat plot PACF (Partial AutoCorrelation Function). Jika PACF mengalami cutoff setelah beberapa lag, maka nilai p bisa diambil dari jumlah lag sebelum cutoff. q ditentukan dengan melihat plot ACF (AutoCorrelation Function). Jika ACF mengalami cutoff setelah beberapa lag, maka nilai q bisa diambil dari jumlah lag sebelum cutoff. d ditentukan dengan Augmented Dickey-Fuller Test (ADF Test). Jika data tidak stasioner, lakukan differencing hingga menjadi stasioner, dan nilai d adalah jumlah differencing yang dilakukan.

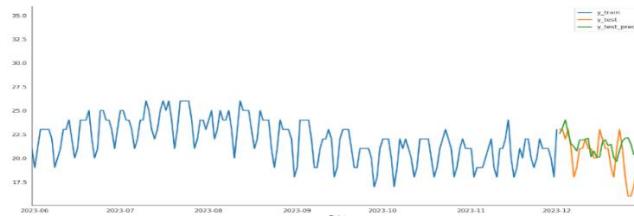
LSTM merupakan jenis Recurrent Neural Network (RNN) yang memiliki gate mechanism untuk mengontrol aliran informasi. Parameter utama dalam LSTM meliputi:

Units: Jumlah neuron dalam setiap lapisan LSTM, menentukan kapasitas model. Batch Size: Jumlah sampel dalam satu iterasi training. Epochs: Jumlah iterasi training penuh pada seluruh dataset. Learning Rate: Kecepatan pembaruan bobot dalam proses optimasi.

Dropout: Teknik regulasi untuk menghindari overfitting. Menentukan Parameter LSTM dengan cara; Grid Search atau Bayesian Optimization dapat digunakan untuk mencari kombinasi terbaik dari hyperparameter. Eksperimen dengan jumlah neurons (units), biasanya dimulai dari 50 hingga 200. Dropout berkisar antara 0.2 – 0.5 untuk mencegah overfitting. Batch size dan epochs dapat diuji dengan nilai umum seperti 32, 64 untuk batch size dan 10, 50, 100 untuk epochs.

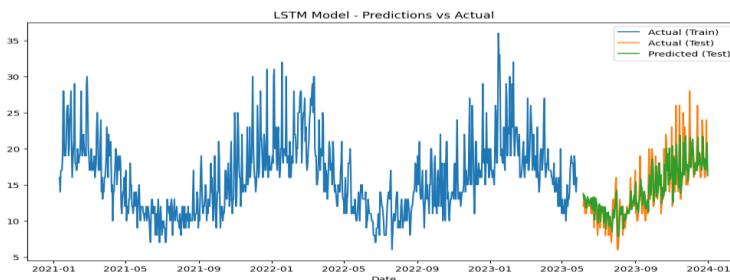
GRU adalah variasi dari LSTM dengan lebih sedikit parameter, sehingga lebih cepat dalam proses training. Parameter utama GRU mirip dengan LSTM: Units: Jumlah neuron dalam lapisan GRU. Batch Size: Ukuran batch yang digunakan dalam training. Epochs: Jumlah iterasi training penuh. Learning Rate: Kecepatan pembelajaran. Dropout: Regulasi model. Menentukan Parameter GRU: Sama seperti LSTM, Grid Search atau Bayesian Optimization dapat digunakan. Jumlah units dapat diuji dari 50 hingga 200 untuk melihat pengaruh terhadap akurasi. Dropout sekitar 0.2 – 0.5 untuk menghindari overfitting.

Batch size dan epochs diuji dengan nilai seperti 32, 64, 128 untuk batch size dan 10, 50, 100 untuk epochs. Hyperparameter tuning ARIMA dengan auto_arima untuk mencari nilai optimal (p, d, q) dan komponen musiman (P, D, Q, s). Tuning LSTM dan GRU menggunakan Grid Search untuk mencari kombinasi terbaik dari: Neurons (jumlah unit), Dropout rate, Learning rate, Batch size, Epochs



Gambar 8. Plot hasil prediksi ARIMA

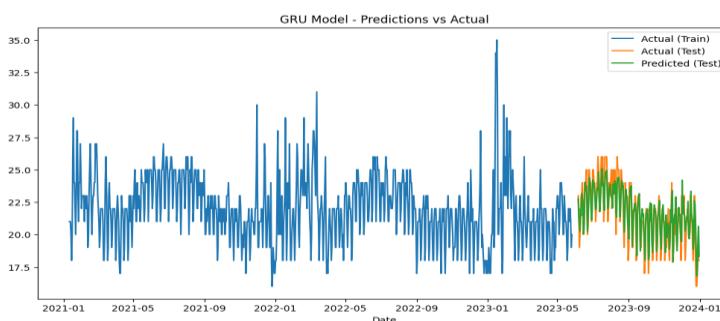
Berdasarkan Gambar 8 diatas, model memprediksi penjualan Blooming Tea akan meningkat secara bertahap. Peningkatan penjualan Blooming Tea yang diprediksi mungkin disebabkan oleh kinerja penjualan yang baik pada beberapa bulan sebelumnya dan faktor musiman. Tren sedikit meningkat disebabkan oleh permintaan yang stabil.



Gambar 9. Plot hasil prediksi LSTM

Plot di atas menunjukkan prediksi penjualan dibandingkan dengan data aktual. Pada data latih, prediksi model LSTM (garis biru) mengikuti tren data aktual (garis hijau) dengan cukup baik. Ada beberapa periode di mana prediksi sedikit menyimpang dari data aktual, tetapi secara keseluruhan akurasi model cukup tinggi. Sedangkan Pada data uji prediksi model LSTM (garis biru) masih mengikuti tren data aktual (garis hijau), tetapi akurasinya sedikit menurun dibandingkan dengan data latih. Ada beberapa periode di mana prediksi model menyimpang secara signifikan dari data aktual. Model LSTM mampu memprediksi penjualan dengan cukup akurat, terutama pada data latih.

Beberapa faktor yang dapat menyebabkan penurunan akurasi pada data uji mungkin mengandung pola yang berbeda dari data latih, sehingga model tidak dapat memprediksinya dengan tepat. Model mungkin overfitting pada data latih, sehingga performanya menurun pada data baru.



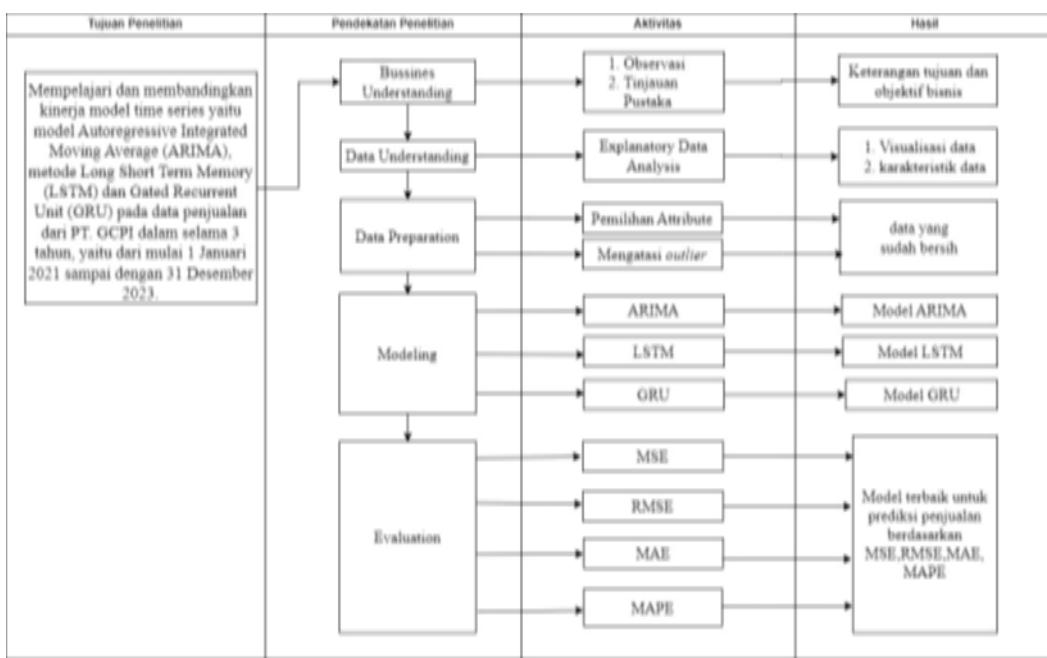
Gambar 10. Plot hasil prediksi GRU

Visualisasi diatas, terlihat bahwa model GRU mampu mengikuti tren dan pola musiman yang ada dalam data, meskipun terdapat beberapa perbedaan antara prediksi dan data aktual, terutama pada titik-titik dengan fluktuasi yang tinggi. Meskipun model menunjukkan performa yang cukup baik dalam mengenali pola utama data, terdapat peluang untuk meningkatkan akurasi dengan penyesuaian **hyperparameter** atau

penambahan fitur tambahan. Secara keseluruhan, model GRU menunjukkan potensi yang baik untuk prediksi penjualan, namun evaluasi lebih lanjut diperlukan untuk meningkatkan presisi hasil prediksi.

2.6 Evaluasi (Evaluation)

Evaluasi model dilakukan dengan menggunakan beberapa metrik, yaitu Mean Square Error (MSE), Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE). MSE digunakan untuk mengukur rata-rata kuadrat kesalahan antara nilai aktual dan prediksi. MAE mengukur rata-rata kesalahan absolut yang terjadi pada prediksi. RMSE, yang merupakan akar kuadrat dari MSE, memberikan indikasi seberapa jauh prediksi dari nilai aktual. MAPE mengukur persentase kesalahan absolut rata-rata dibandingkan dengan nilai aktual. Model yang memiliki nilai kesalahan terkecil dianggap sebagai model terbaik untuk memprediksi permintaan produk.



Gambar 11 Kerangka Pemikiran

Gambar tersebut merupakan diagram alur penelitian yang menjelaskan langkah-langkah dalam menganalisis dan membandingkan kinerja model ARIMA, LSTM, dan GRU dalam memprediksi penjualan. Diagram ini terdiri dari empat kolom utama: Tujuan Penelitian, Pendekatan Penelitian, Aktivitas, dan Hasil.

1. Tujuan Penelitian, Penelitian ini bertujuan untuk mempelajari dan membandingkan kinerja model prediksi time series, yaitu ARIMA, LSTM, dan GRU, dalam menganalisis data penjualan perusahaan selama tiga tahun, dari 1 Januari 2021 hingga 31 Desember 2023. Tujuan ini bertujuan untuk meningkatkan akurasi peramalan penjualan guna mendukung pengambilan keputusan bisnis.
2. Pendekatan Penelitian, Diagram ini mengadopsi metodologi CRISP-DM (Cross-Industry Standard Process for Data Mining)
3. Aktivitas, Setiap tahap dalam pendekatan penelitian mencakup aktivitas spesifik.
 - a. Business Understanding: Observasi dan tinjauan pustaka untuk memahami tujuan bisnis.
 - b. Data Understanding: Exploratory Data Analysis (EDA) dilakukan untuk mengidentifikasi pola dan karakteristik data.

- c. Data Preparation: Pemilihan atribut yang relevan dan penanganan outlier untuk memastikan data bersih sebelum pemodelan.
 - d. Modeling: Menerapkan model ARIMA, LSTM, dan GRU guna menghasilkan prediksi penjualan.
 - e. Evaluation: Menggunakan metrik MSE, RMSE, MAE, dan MAPE untuk menilai akurasi setiap model.
4. Hasil, Setiap tahap aktivitas menghasilkan output yang mendukung penelitian.

Diagram diatas memberikan gambaran sistematis tentang proses penelitian yang bertujuan untuk mengidentifikasi model prediksi terbaik dalam membantu pengambilan keputusan strategis terkait produksi, distribusi, dan manajemen stok.

3. HASIL DAN PEMBAHASAN

3.1 Implementasi dan Pengujian Model Prediksi

Pada bagian ini, implementasi dan pengujian terhadap model prediksi yang telah dibangun dilakukan untuk memperoleh hasil yang akurat dan dapat digunakan dalam pengambilan keputusan bisnis. Proses ini mencakup persiapan data, pemilihan model yang sesuai, serta evaluasi dan validasi prediksi yang dihasilkan guna memastikan kehandalan dan efektivitasnya. Model yang digunakan dalam penelitian ini harus dapat menangkap pola dan tren historis dengan baik agar hasil prediksi dapat dijadikan acuan dalam pengambilan keputusan strategis. Pengujian dilakukan menggunakan metode CRISP-DM, yang merupakan pendekatan sistematis dalam data mining yang terdiri dari enam tahap utama: pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan penerapan model. Dengan pendekatan ini, perusahaan dapat menyesuaikan model dengan kebutuhan spesifik mereka dan mengoptimalkan strategi bisnis berdasarkan hasil analisis data.

Dengan penerapan model prediksi yang tepat, PT. Godrej Consumer Product Indonesia (GCPI) dapat mengelola rantai pasokan dengan lebih efisien, meningkatkan perencanaan produksi, serta memastikan ketersediaan produk di pasar sesuai dengan permintaan. Selain itu, model ini juga dapat membantu mengidentifikasi peluang pertumbuhan dan strategi penjualan yang lebih efektif untuk meningkatkan daya saing perusahaan dalam industri.

3.2 Business Understanding

Pada tahap ini, dilakukan observasi terhadap sistem penjualan yang digunakan oleh PT. GCPI, termasuk sistem distribusi produk HIT Aerosol Expert yang memiliki masa kadaluarsa dua tahun. Data penjualan dikumpulkan dari sistem berbasis web yang digunakan oleh distributor dan dianalisis untuk memahami pola dan tren penjualan. Hal ini penting untuk memastikan bahwa model yang digunakan bisa benar-benar mencerminkan kondisi nyata di pasar dan memberikan hasil yang relevan. Produk yang didistribusikan oleh PT. GCPI mencakup beberapa varian, yaitu Blooming Tea, Citrus, Sweet Flower, dan Lily Blossom. Setiap produk memiliki pola penjualan yang berbeda dan dipengaruhi oleh faktor musiman. Oleh karena itu, analisis yang dilakukan dalam penelitian ini berfokus pada pola penjualan setiap produk untuk memahami fluktuasi serta faktor-faktor yang mempengaruhi permintaan di pasar.

Analisis lebih lanjut juga dilakukan terhadap faktor eksternal yang mungkin berkontribusi terhadap fluktuasi permintaan, seperti promosi, perubahan harga, dan kondisi ekonomi makro. Dengan mempertimbangkan faktor-faktor ini, model prediksi dapat dikembangkan secara lebih akurat sehingga perusahaan dapat mengoptimalkan perencanaan produksi dan distribusi.

Selain itu, strategi pemasaran yang tepat dapat dikembangkan berdasarkan hasil analisis ini. Sebagai contoh, produk dengan pola permintaan musiman tinggi dapat dipromosikan pada periode tertentu untuk memaksimalkan penjualan, sementara produk dengan fluktuasi rendah dapat dikelola dengan strategi persediaan yang lebih stabil. Dengan adanya pendekatan ini, PT. GCPI dapat meningkatkan efisiensi rantai pasokan serta memastikan ketersediaan produk sesuai dengan kebutuhan pasar, sehingga mampu meningkatkan kepuasan pelanggan dan profitabilitas perusahaan.

3.3 Data Understanding

Analisis eksplorasi data (EDA) dilakukan untuk memahami karakteristik data penjualan produk dari Januari 2020 hingga Desember 2023. Berikut adalah statistik deskriptif dari dataset:

Tabel 1. Statistik Deskriptif Data Penjualan

Produk	Mean	Std Dev	Min	25%	50%	75%	Max
BloomingTea	21.89	2.49	16	20	22	23	35
Citrus	15.76	4.91	6	12	15	19	36
SweetFlower	16.68	5.45	3	13	16	20	37
LilyBlossom	24.31	2.80	17	22	24	26	39

Hasil EDA menunjukkan bahwa data memiliki tren meningkat dengan fluktuasi musiman yang cukup besar. Variabilitas ini perlu diperhitungkan dalam pemodelan agar prediksi yang dihasilkan lebih akurat dan dapat digunakan dalam perencanaan bisnis. Menunjukkan bahwa LilyBlossom memiliki rata-rata penjualan (mean) tertinggi sebesar 24.31 unit, sementara Citrus memiliki rata-rata penjualan terendah (15.76 unit). Hal ini menunjukkan bahwa permintaan terhadap LilyBlossom cenderung lebih tinggi dibandingkan produk lainnya. BloomingTea berada di posisi kedua dengan 21.89 unit, sedangkan SweetFlower memiliki rata-rata 16.68 unit. Dari segi standar deviasi (Std Dev), SweetFlower menunjukkan variasi penjualan tertinggi (5.45), diikuti oleh Citrus (4.91). Ini menunjukkan bahwa penjualan kedua produk ini lebih fluktuatif dibandingkan BloomingTea (2.49) dan LilyBlossom (2.80), yang memiliki variasi penjualan lebih stabil. Dalam hal minimum dan maksimum penjualan, SweetFlower memiliki rentang terlebar, dengan penjualan minimum 3 unit dan maksimum 37 unit, sedangkan BloomingTea memiliki rentang yang lebih kecil dengan minimum 16 unit dan maksimum 35 unit. Hal ini menunjukkan bahwa SweetFlower memiliki pola penjualan yang lebih tidak menentu dibandingkan produk lainnya. Distribusi kuartil menunjukkan bahwa BloomingTea dan LilyBlossom memiliki median penjualan lebih tinggi dibandingkan produk lainnya, mengindikasikan bahwa permintaan mereka lebih stabil. Sedangkan Citrus dan SweetFlower memiliki distribusi penjualan yang lebih luas, mengindikasikan adanya faktor eksternal yang lebih mempengaruhi permintaan mereka.

3.4 Pemodelan dan Evaluasi

Untuk memprediksi penjualan, dilakukan pemodelan menggunakan tiga pendekatan utama: ARIMA, LSTM, dan GRU. Model diuji dengan data latih (80%) dan data uji (20%). Pemodelan dilakukan untuk mengevaluasi seberapa baik setiap pendekatan dapat menangkap tren historis dan fluktuasi musiman dalam data penjualan produk Aerosol. ARIMA digunakan sebagai baseline karena kemampuannya dalam menangkap pola tren dan musiman dari data deret waktu. Namun, ARIMA memiliki keterbatasan dalam menangani data yang memiliki variasi non-linear yang kompleks. LSTM dan GRU yang merupakan bagian dari jaringan saraf tiruan berbasis RNN digunakan untuk menangani kompleksitas dalam pola musiman dan tren jangka panjang.

Hasil pemodelan menunjukkan bahwa setiap pendekatan memiliki kelebihan dan kelemahan masing-masing. ARIMA cocok untuk data dengan pola musiman yang jelas, sementara LSTM dan GRU lebih unggul dalam menangkap pola kompleks dan variasi non-linear dalam data penjualan.

3.5 Model ARIMA

ARIMA digunakan sebagai baseline untuk melihat keakuratan prediksi berdasarkan pola historis.

Tabel 2. Parameter Optimal Model ARIMA

Produk	Model Optimal
BloomingTea	ARIMA(1,0,0)(3,0,2)[12]
Citrus	ARIMA(0,1,2)(0,0,0)[12]
SweetFlower	ARIMA(3,1,3)(0,0,0)[12]
LilyBlossom	ARIMA(3,0,3)(0,0,2)[12]

Tabel parameter optimal model ARIMA menunjukkan bahwa setiap produk memiliki konfigurasi model yang berbeda untuk menangkap pola tren dan musiman dalam data penjualan. BloomingTea menggunakan model ARIMA(1,0,0)(3,0,2)[12], yang menunjukkan adanya komponen autoregresif sederhana tanpa differencing. Citrus menggunakan model ARIMA(0,1,2)(0,0,0)[12], yang berarti model ini memerlukan satu kali differencing untuk menghilangkan tren tetapi tidak memiliki komponen musiman. Hal ini menunjukkan bahwa penjualan Citrus mengalami tren yang lebih fluktuatif dan tidak memiliki pola musiman yang kuat dibandingkan dengan produk lain. Untuk SweetFlower, model terbaik adalah ARIMA(3,1,3)(0,0,0)[12], yang memiliki tiga komponen autoregresif dan tiga moving average dengan satu kali differencing. Ini menunjukkan bahwa SweetFlower memiliki fluktuasi yang lebih kompleks dan memerlukan kombinasi lebih banyak lag dalam model untuk mendapatkan prediksi yang akurat. LilyBlossom menggunakan ARIMA(3,0,3)(0,0,2)[12], yang menunjukkan adanya tiga komponen autoregresif dan tiga moving average tanpa differencing, tetapi dengan dua komponen musiman. Ini menandakan bahwa LilyBlossom memiliki pola musiman yang lebih kuat dibandingkan Citrus dan SweetFlower.

3.6 Model LSTM

LSTM digunakan untuk menangani pola musiman dan tren jangka panjang dengan menggunakan teknik pembelajaran mendalam.

Tabel 3. Evaluasi Model LSTM

Produk	MSE	RMSE	MAE	MAPE
BloomingTea	1.12	1.06	0.81	3.81%
Citrus	7.03	2.65	1.87	13.28%
SweetFlower	15.41	3.92	2.93	22.00%
LilyBlossom	1.44	1.20	0.93	3.93%

Tabel evaluasi model LSTM menunjukkan bahwa kinerja model bervariasi antar produk. BloomingTea dan LilyBlossom memiliki nilai MSE dan RMSE yang lebih rendah dibandingkan produk lainnya, menunjukkan bahwa prediksi untuk kedua produk ini lebih akurat dan stabil. BloomingTea memiliki MSE sebesar 1.12, RMSE 1.06, MAE 0.81, dan MAPE 3.81%, yang merupakan metrik error terendah di antara semua produk, menunjukkan model LSTM dapat menangkap pola penjualan produk ini dengan baik. Sebaliknya, SweetFlower memiliki nilai error tertinggi dengan MSE 15.41, RMSE 3.92, MAE 2.93, dan MAPE 22.00%, menandakan bahwa model kesulitan menangkap pola yang tepat pada produk ini. Hal ini dapat disebabkan oleh pola penjualan yang lebih tidak

teratur atau dipengaruhi oleh faktor eksternal yang tidak tercakup dalam model. Citrus memiliki MSE 7.03, yang lebih tinggi dibandingkan BloomingTea dan LilyBlossom tetapi masih lebih rendah dibandingkan SweetFlower. MAPE Citrus sebesar 13.28%, menandakan model cukup kesulitan menangkap pola penjualan produk ini.

Secara keseluruhan, model LSTM bekerja lebih baik untuk produk dengan pola penjualan yang lebih stabil, seperti BloomingTea dan LilyBlossom, sementara performanya lebih rendah untuk produk dengan fluktuasi lebih besar seperti SweetFlower dan Citrus.

3.7 Model GRU

GRU digunakan sebagai alternatif LSTM untuk meningkatkan efisiensi dan kecepatan pelatihan.

Tabel 4. Evaluasi Model GRU

Produk	MSE	RMSE	MAE	MAPE
BloomingTea	1.17	1.08	0.83	3.92%
Citrus	6.96	2.63	1.90	13.48%
SweetFlower	16.40	4.04	2.92	24.58%
LilyBlossom	1.41	1.18	2.24	3.90%

Tabel evaluasi model GRU menunjukkan bahwa hasil prediksi bervariasi berdasarkan produk yang diuji. BloomingTea memiliki nilai MSE 1.17, RMSE 1.08, MAE 0.83, dan MAPE 3.92%, yang menunjukkan bahwa model GRU dapat menangkap pola penjualan dengan cukup baik, meskipun sedikit kurang akurat dibandingkan model LSTM untuk produk ini. Sementara itu, Citrus memiliki MSE 6.96 dan MAPE 13.48%, yang lebih tinggi dibandingkan BloomingTea dan LilyBlossom, menunjukkan bahwa model mengalami kesulitan dalam menangkap pola penjualan produk ini yang mungkin lebih fluktuatif dibandingkan dengan yang lain. SweetFlower memiliki nilai error tertinggi dengan MSE 16.40, RMSE 4.04, MAE 2.92, dan MAPE 24.58%. Di sisi lain, LilyBlossom menunjukkan hasil yang relatif baik dengan MSE 1.41 dan MAPE 3.90%, yang menunjukkan bahwa pola penjualannya lebih dapat diprediksi dibandingkan dengan Citrus dan SweetFlower. Secara keseluruhan, model GRU menunjukkan performa yang lebih baik dibandingkan ARIMA untuk menangkap pola musiman dan tren jangka panjang, tetapi masih memiliki tantangan dalam menangani produk dengan fluktuasi penjualan yang tinggi.

Berdasarkan hasil analisis terhadap ketiga model, LSTM dan GRU menunjukkan performa yang lebih baik dalam menangani pola penjualan fluktuatif dan menangkap hubungan jangka panjang dalam data. Model LSTM memberikan hasil terbaik dengan nilai error yang lebih rendah dibandingkan dengan ARIMA dan GRU, terutama pada produk dengan tren penjualan yang lebih stabil seperti BloomingTea dan LilyBlossom. Model GRU menunjukkan kinerja yang cukup baik dan memiliki keunggulan dalam kecepatan pelatihan dibandingkan LSTM.

Penelitian lain oleh (Meri Aryati, Wiguna, Putri, Widiartha, & Ginantra, 2024) menunjukkan bahwa LSTM lebih unggul dibandingkan GRU dalam memprediksi harga emas, dengan metrik evaluasi yang lebih baik. Hasil penelitian ini sejalan dengan studi terdahulu yang menyatakan bahwa model berbasis deep learning sering kali lebih akurat dalam menangkap pola kompleks dibandingkan model statistik tradisional seperti ARIMA. Namun, pendekatan yang digunakan dalam penelitian ini, yaitu optimasi hyperparameter menggunakan Grid Search, memberikan keunggulan tambahan dalam meningkatkan performa model dibandingkan dengan tuning manual yang dilakukan dalam studi sebelumnya.

4. KESIMPULAN

Berdasarkan hasil analisis terhadap ketiga model prediksi yang digunakan, yaitu ARIMA, LSTM, dan GRU, dapat disimpulkan bahwa pendekatan berbasis deep learning, khususnya LSTM, memiliki keunggulan dalam menangkap pola penjualan produk dengan lebih akurat dibandingkan model tradisional seperti ARIMA. ARIMA masih dapat digunakan sebagai baseline, terutama untuk produk dengan tren musiman yang jelas, namun kurang efektif dalam menangani variasi data yang kompleks.

LSTM dan GRU menunjukkan performa yang lebih baik dalam menangani pola penjualan yang lebih fluktuatif dan menangkap hubungan jangka panjang dalam data. Model LSTM memberikan hasil terbaik dengan nilai error yang lebih rendah dibandingkan dengan ARIMA dan GRU, terutama pada produk dengan tren penjualan yang lebih stabil seperti BloomingTea dan LilyBlossom. Model GRU juga menunjukkan kinerja yang cukup baik dan memiliki keunggulan dalam kecepatan pelatihan dibandingkan dengan LSTM, meskipun pada beberapa kasus tidak seakurat LSTM.

REFERENCES

- Ali, I., & Rizki Rinaldi, A. (2023). *PENERAPAN METODE K-NEAREST NEIGHBOR UNTUK PREDIKSI PENJUALAN SEPEDA MOTOR TERLARIS*. *Jurnal Mahasiswa Teknik Informatika* (Vol. 7).
- Hasanah, M. A., Soim, S., & Handayani, A. S. (2021). *Implementasi CRISP-DM Model Menggunakan Metode Decision Tree dengan Algoritma CART untuk Prediksi Curah Hujan Berpotensi Banjir*. *Journal of Applied Informatics and Computing (JAIC)* (Vol. 5). Retrieved from <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Meri Aryati, N. W., Wiguna, I. K. A. G., Putri, N. W. S., Widiartha, I. K. K., & Ginantra, N. L. W. S. R. (2024). Komparasi Metode LSTM dan GRU dalam Memprediksi Harga Saham. *JURNAL MEDIA INFORMATIKA BUDIDARMA*, 8(2), 1131. Retrieved from <https://doi.org/10.30865/mib.v8i2.7342>
- Nosouhian, S., Nosouhian, F., & Kazemi Khoshouei, A. (2021, July 12). A Review of Recurrent Neural Network Architecture for Sequence Learning: Comparison between LSTM and GRU. Retrieved from <https://doi.org/10.20944/preprints202107.0252.v1>
- Saputra, D. B., Atina, V., & Nastiti, F. E. (2024). PENERAPAN MODEL CRISP-DM PADA PREDIKSI NASABAH KREDIT MENGGUNAKAN ALGORITMA RANDOM FOREST. *IDEALIS: InDonEsiA Journal Information System*, 7(2), 240–247. Retrieved from <https://doi.org/10.36080/idealisi.v7i2.3244>
- Sastya, N. C., & Nugraha, I. (2023). Penerapan Metode CRISP-DM dalam Menganalisis Data untuk Menentukan Customer Behavior di MeatSolution. *UNISTEK*, 10(2), 103–115. Retrieved from <https://doi.org/10.33592/unistik.v10i2.3079>
- Si, Y., Nadarajah, S., Zhang, Z., & Xu, C. (2024). Modeling opening price spread of Shanghai Composite Index based on ARIMA-GRU/LSTM hybrid model. *PLOS ONE*, 19(3), e0299164. Retrieved from <https://doi.org/10.1371/journal.pone.0299164>
- Yavasani, R., & Wang, H. (2023a). Comparative Analysis of LSTM, GRU, and ARIMA Models for Stock Market Price Prediction. *Journal of Student Research*, 12(4). Retrieved from <https://doi.org/10.47611/jsrhs.v12i4.5888>
- Yavasani, R., & Wang, H. (2023b). Comparative Analysis of LSTM, GRU, and ARIMA Models for Stock Market Price Prediction. *Journal of Student Research*, 12(4). Retrieved from <https://doi.org/10.47611/jsrhs.v12i4.5888>