

Peramalan Penjualan Obat Menggunakan Metode ARIMA

Forecasting Pharmaceutical Sales Using the ARIMA Method

Muhammad Nur Arafah¹; Firman Aziz²; Hanny^{3*}; Fadly Irwinsyah⁴; Irmawati⁵

^{1,5} Irmex Digital Akademika 90551, Indonesia

^{2,3,4} Universitas Pancasakti Makassar, 90121, Indonesia

¹ mnurarafah26@gmail.com; ² firman.aziz@unpacti.ac.id; ³ hannypalu.88@gmail.com; ⁴ fadlyirwansyah26@gmail.com; ⁵ irmawati@irmexdigika.com

* Corresponding author

Abstrak

Peningkatan kompleksitas industri farmasi menuntut sistem manajemen inventori yang adaptif dan prediktif untuk memitigasi risiko stockout dan inefisiensi biaya. Penelitian ini bertujuan untuk meningkatkan akurasi peramalan permintaan obat di PT. XYZ, distributor farmasi vital, melalui implementasi model Time Series ARIMA (Autoregressive Integrated Moving Average). Dataset historis 17.521 transaksi penjualan obat diolah dan dimodelkan untuk memproyeksikan permintaan di masa mendatang. Hasil empiris menunjukkan bahwa model ARIMA (1,1,1) terbukti valid dan robust sebagai instrumen farmakoeonomi, mencapai tingkat akurasi yang superior MSE 91.20% dan Akurasi RMSE 92.50%. Temuan ini menggarisbawahi kapabilitas model dalam memprediksi pola deret waktu penjualan obat dengan error minimal. Implikasi utama dari forecasting ini terletak pada manajemen rantai pasok kefarmasian. Analisis mengidentifikasi kebutuhan strategis yang berbeda: Produk Fast-Moving esensial (misalnya Neozep Forte), yang menunjukkan tren pertumbuhan (GF=1.13) dan Risk Score tinggi (1.49), memerlukan penetapan Safety Stock yang cermat untuk menjamin ketersediaan terapi (drug availability) dan menjaga kesinambungan pelayanan kesehatan. Sebaliknya, produk Slow-Moving yang sangat fluktuatif (misalnya Biogesic Anak, Risk Score 1.76) menuntut strategi pengadaan minimal guna mengurangi kerugian akibat obat kedaluwarsa (expired stock) dan overstocking. Secara keseluruhan, implementasi ARIMA mendukung pengambilan keputusan logistik yang berbasis data (data-driven decision-making), memungkinkan PT. XYZ menyeimbangkan optimalisasi biaya operasional dengan tanggung jawab profesional kefarmasian dalam menjamin pasokan obat yang aman dan efisien.

Kata Kunci: Forecasting; ARIMA; Manajemen Farmasi; Obat; Rantai Pasok Kefarmasian

Abstract

The increasing complexity of the pharmaceutical industry necessitates adaptive and predictive inventory management systems to mitigate the risks of stockout and cost inefficiency. This study aims to enhance the accuracy of drug demand forecasting at PT. XYZ, a vital pharmaceutical distributor, through the implementation of the Time Series Model ARIMA (Autoregressive Integrated Moving Average). A historical dataset of 17,521 drug sales transactions was processed and modeled to project future demand. Empirical results demonstrate that the ARIMA (1,1,1) model proves to be a valid and robust pharmacoeconomic instrument, achieving a superior level of accuracy (MSE Accuracy, 91.20% and RMSE Accuracy, 92.50%). These findings underscore the model's capability in predicting the time series pattern of drug sales with minimal error. The primary implication of this forecasting lies in pharmaceutical supply chain management. The analysis identifies distinct strategic needs: Essential Fast-Moving products (e.g., Neozep Forte), which exhibit an upward growth trend (SGF=1.13\$) and high Risk Score (1.49), require meticulous Safety Stock determination to ensure therapeutic availability (drug availability) and maintain the continuity of primary healthcare services. Conversely, highly volatile Slow-Moving products (e.g., Biogesic Anak, Risk Score 1.76) demand a minimal procurement strategy to reduce losses from overstocking and the potential for expired stock. Overall, the implementation of ARIMA supports data-driven logistical decision-making, enabling PT. XYZ to balance operational cost optimization with its professional pharmaceutical responsibility in guaranteeing a safe, precisely quantified, and efficient drug supply.

Keywords: Forecasting; ARIMA; Pharmaceutical Management; Drugs; Supply Chain.

Pendahuluan

Perkembangan industri farmasi dalam beberapa tahun terakhir menunjukkan meningkatnya kebutuhan akan sistem manajemen inventori yang akurat, adaptif, dan efisien. Ketidakpastian permintaan obat, perubahan pola konsumsi masyarakat, variasi musiman, serta dinamika distribusi nasional menuntut perusahaan farmasi memiliki kemampuan prediksi permintaan yang lebih andal untuk mencegah terjadinya stockout maupun kelebihan stok [1], [2]. PT APL Semarang sebagai salah satu distributor farmasi besar di Indonesia menghadapi tantangan serupa dalam menjaga ketersediaan obat di berbagai fasilitas kesehatan [3]. Metode statistik tradisional sering kali tidak mampu menangkap pola permintaan yang bersifat non-linear dan dipengaruhi oleh banyak faktor eksternal. Teknologi machine learning (ML) menawarkan solusi yang lebih adaptif melalui kemampuan mengenali pola laten dalam data historis penjualan

obat [4], [5]. Berbagai algoritma seperti Random Forest, Gradient Boosting, XGBoost, ARIMA, dan LSTM telah menunjukkan performa tinggi dalam memprediksi permintaan pada rantai pasok farmasi [6][7][8][9]. Penerapan model prediktif tersebut terbukti meningkatkan akurasi peramalan, memperbaiki proses pengadaan, serta menekan biaya penyimpanan dan distribusi [10][11]. Namun, implementasi ML dalam manajemen inventori farmasi masih menghadapi sejumlah kendala, termasuk pemanfaatan data yang belum optimal, kurangnya model yang sesuai karakteristik distribusi obat, dan minimnya integrasi sistem operasional dengan peramalan prediktif [12], [13]. Di PT APL Semarang, tantangan tersebut terlihat dari fluktuasi stok, keterlambatan pemenuhan permintaan, dan potensi inefisiensi biaya akibat belum digunakannya pendekatan analitik modern. Berdasarkan permasalahan tersebut, penelitian ini difokuskan pada penerapan model machine learning untuk meningkatkan akurasi prediksi permintaan obat di PT APL Semarang. Cakupan penelitian meliputi analisis data historis penjualan, perbandingan performa beberapa algoritma ML, evaluasi hasil prediksi, dan penyusunan rekomendasi pengendalian inventori berbasis model prediktif [14]. Penelitian ini bertujuan mengembangkan model prediksi permintaan yang mampu mendukung efektivitas manajemen persediaan, sekaligus memperkuat pengambilan keputusan berbasis data di sektor distribusi farmasi.

Metode

Metode penelitian ini dirancang untuk membangun model prediksi permintaan obat berbasis machine learning guna mendukung optimalisasi manajemen inventori di PT APL Semarang. Tahapan penelitian meliputi:

A. Pengumpulan Data

Dataset penelitian ini mencakup 17.521 transaksi penjualan obat di PT. XYZ, dengan enam variabel utama: Plant, Material, Sold-To Party, Date, Gr. Invs. Sls, dan Invc. Qty. Data ini menggambarkan aktivitas penjualan mitra farmasi di seluruh Indonesia selama 2024–2025, dan digunakan untuk menganalisis pola penjualan serta memproyeksikan penjualan di masa depan, dan Adapun data obat yang akan diolah yaitu ;

Tabel 1. Produk Obat Pada PT. XYZ

<i>Nama Obat</i>	<i>Bentuk</i>	<i>Komposisi / Dosis Obat</i>	<i>Jenis Obat</i>
<i>Biogesic Anak 60 mL</i>	Sirup	- Paracetamol 160 mg / 5 mL	Analgesik – Antipiretik
<i>Biogesic Blister 100</i>	Tablet	- Paracetamol 500 mg / tablet	Analgesik – Antipiretik
<i>Decolgen FX Tabs 100s</i>	Kaplet	- Paracetamol 650 mg - Pseudoephedrine HCl 30 mg - CTM 2 mg	Analgesik Aantihistamin, dekonjestan
<i>Decolgen Kids</i>	Sirup	Per 5 mL: - Paracetamol 125 mg - Phenylephrine HCl 2.5 mg - CTM 0.5 mg	Obat Flu Anak (analgesik, antihistamin, dekonjestan)
<i>Decolgen Tabs 100s</i>	Tablet	- Paracetamol 400 mg - Phenylpropanolamine HCl 12.5 mg - CTM 1 mg	Obat Flu Kombinasi
<i>Decolsin Caps 100s</i>	Kapsul	- Paracetamol 250 mg - Pseudoephedrine HCl 30 mg - CTM 2 mg - Dextromethorphan HBr 10–15 mg - Guaifenesin 100 mg	Obat Batuk & Flu Kombinasi (ekspektoran, dekonjestan, antihistamin, antitusif)
<i>Decolsin Syrup 60 mL</i>	Sirup	Per 5 mL: - Paracetamol 125 mg - Pseudoephedrine HCl 15 mg - CTM 1 mg - Dextromethorphan HBr 5 mg - Guaifenesin 50 mg	Obat Batuk & Flu Anak
<i>Neozep Forte Tabs 100s (N)</i>	Tablet	- Paracetamol 500 mg - PPA 12.5 mg - CTM 2 mg	Obat Flu Kombinasi
<i>New Diatabs (N)</i>	Tablet	Activated Attapulgate 600 mg / tablet	Antidiare Adsorben

```
# Tampilkan hasil
print(tabulate(obat.head(), headers='keys', tablefmt='psql'))
```

	Plant	Material	Sold-To Party	Date	Gr.inv.sls	Invcd. qty
0	PT. APL SEMARANG	BIOGESIC ANAK 60ML	SEMESTA MEGAH SENTOSA, PT.	2024-06-19	-570240	-24
1	PT. APL SEMARANG	BIOGESIC ANAK 60ML	SEMESTA MEGAH SENTOSA, PT.	2024-10-19	587352	24
2	PT. APL SEMARANG	BIOGESIC ANAK 60ML	SEMESTA MEGAH SENTOSA, PT.	2025-04-30	636298	26
3	PT. APL SEMARANG	BIOGESIC ANAK 60ML	BRAMADA PARMA SARI. PT.	2024-01-13	475200	20
4	PT. APL SEMARANG	BIOGESIC ANAK 60ML	BRAMADA PARMA SARI. PT.	2024-01-20	-475200	-20

Gambar 1. Data Historis Penjualan Obat

B. Preprocessing Data

Tahap ini dilakukan untuk memastikan kualitas dan kelayakan data untuk pemodelan:

Tabel 2. Preprocessing Data

Preprocessing Data	Keterangan
Data Cleaning	Mengatasi Missing Values, Duplikasi Data, dan Outlier.
Time Series Implementation	Agar model lebih mengenali pola penjualan.
Numeric Column Transformation	Mengubah kolom penjualan dan kuantitas menjadi tipe numerik (float)

C. Persamaan yang digunakan

Beberapa algoritma digunakan untuk membandingkan performa prediksi permintaan:

Dengan aproksimasi Taylor orde-2, pada iterasi t ditambahkan pohon f_t

- ARIMA

ARIMA adalah model deret waktu yang menggabungkan autoregressive (AR), differencing (I), dan moving average (MA). Cocok untuk data yang stasioner atau dapat dibuat stasioner.

$$\Phi(B)(1-B)^d y_t = c + \theta(B)\varepsilon_t \quad (3)$$

- y_t = nilai deret waktu pada periode ke- t .
- B = operator backshift, $By_t = y_{t-1}$.
- $(1-B)^d$ = operator differencing orde- d untuk membuat data stasioner.
- $\phi(B)$ = polinomial autoregressive (AR) orde- p .
- $\theta(B)$ = polinomial moving average (MA) orde- q .
- ε_t = error acak (white noise) dengan mean = 0.
- c = konstanta level rata-rata deret waktu setelah differencing.

D. Penerapan Model Forecasting

Tabel 3. Penggunaan Model

Algoritma	Kelebihan	Kelemahan	Metrik Evaluasi
ARIMA	Cocok digunakan untuk deret waktu stasioner, mampu menangkap tren dan pola musiman, serta modelnya mudah diinterpretasikan.	Membutuhkan data stasioner, kurang fleksibel untuk hubungan non-linear, dan performa menurun pada dataset besar dengan banyak fitur.	RMSE, MAE

E. Evaluasi Model

1) Mean Squared Error (MSE)

MSE mengukur rata-rata kuadrat selisih antara nilai aktual dan nilai prediksi. Semakin kecil nilai MSE, semakin baik model dalam menyesuaikan pola data historis.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

2) Root Mean Squared Error (RMSE)

RMSE adalah akar dari MSE dan memberikan interpretasi yang lebih mudah karena berada pada satuan yang sama dengan data aktual. RMSE digunakan untuk melihat seberapa jauh prediksi model berbeda dari nilai observasi.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$$

F. Interpretasi dan Rekomendasi

Hasil prediksi dianalisis untuk memberikan rekomendasi pengendalian inventori, seperti:

- Total Produk obat yang terlaris dan jumlah return.
- Estimasi risiko stockout untuk setiap produk,
- Penyesuaian safety stock dan reorder point,
- Identifikasi produk fast-moving dan slow-moving berdasarkan prediksi permintaan.

Hasil dan Diskusi

A. Hasil Pengujian

Tabel 4. Metrik Evaluasi Model		
Model ARIMA	Hasil MSE	Hasil RMSE
(1,1,1)	114.82 (8.80%)	95.79 (7.50%)
Acuracy Model	91.20%	92.50%

Berdasarkan Tabel 4, hasil metrik evaluasi untuk Model ARIMA (1,1,1) menunjukkan kinerja peramalan yang sangat tinggi. Model ini mencatatkan nilai Mean Squared Error (MSE) sebesar 114.82 unit, yang setara dengan persentase kesalahan sebesar 8.80%, dan nilai Root Mean Squared Error (RMSE) sebesar 95.79 unit, yang merepresentasikan persentase kesalahan 7.50%. Akurasi model yang diukur dari kedua metrik ini adalah 91.20% untuk MSE dan 92.50% untuk RMSE. Tingkat akurasi yang baik ini mengindikasikan bahwa Model ARIMA (1,1,1) berhasil memprediksi permintaan unit produk obat dengan tingkat kesalahan yang sangat rendah, memvalidasi efektivitasnya sebagai alat forecasting.

B. Trend Umum Penjualan Produk

Berdasarkan hasil agregasi bulanan dan forecast:

a. Produk Fast-Moving (Penjualan Tinggi & Stabil)

Tabel 5. Produk Fast-Moving Menggunakan Model Arima

Produk	Mean Bulanan	Cv	Trend
NEOZEP FORTE 100'S (N)	±6.744	0.31	Trend naik, penjualan stabil, risiko stockout tinggi tanpa safety stock memadai.
DECOLGEN TABS 100'S	±4.968	0.50	Penjualan konsisten, sedikit fluktuatif, masih fast moving.
DECOLGEN KIDS	±3.282	0.45	Ada penurunan demand ke bulan terakhir, perlu monitoring.
DECOLSIN SYRUP 60 ML	±2.422	0.55	Stabil dengan sedikit turun, fluktuasi sedang.

Produk fast-moving menunjukkan konsistensi permintaan sehingga perlu ROP (Reorder Point) dan Safety Stock lebih tinggi untuk menghindari stockout.

b. Produk Slow-Moving (Penjualan Rendah & Tidak Stabil)

Produk slow-moving mengalami fluktuasi tinggi lebih tepat menggunakan strategi minim stok, menghindari penumpukan barang.

Produk	Mean Bulanan	Cv	Trend
BIOGESIC BLISTER 100'S	±580	0.50	Stabil Tapi Volume Kecil, Termasuk Slow Moving.
DECOLGEN FX TABS 100'S	±105	0.77	Sangat Fluktuatif, Cenderung Menurun.
BIOGESIC ANAK 60 ML	±41	1.87	Permintaan Sangat Tidak Stabil, Risiko Overstock Tinggi.

c. Pola Pertumbuhan (Growth Factor)

Produk dengan growth factor < 1 perlu evaluasi marketing, distribusi, atau ada faktor musiman.


Tabel 6. Growth Factor

Produk	Growth Factor	Interpretasi
Neozept Forte	1.13	Ada kenaikan demand ke depan.
Decolgen Tabs	0.97	Stabil–sedikit menurun.
Decolgen Kids	0.81	Penurunan signifikan mungkin ada substitusi produk.
Biogesic Anak	0.61	Demand menurun tajam.


d. Risiko Stockout Menggunakan Risk Score

Produk dengan risk score tinggi memerlukan Safety Stock tambahan, karena potensi mismatch demand sangat besar.


Produk	Risk Score	Tingkat Risiko
Biogesic Anak 60 ml	1.76	Risiko stockout sangat tinggi, permintaan tidak stabil.
Decolgen FX	1.19	Risiko tinggi karena fluktuatif & volume rendah.
Neozept Forte	1.49	Risiko tinggi karena demand besar & terus naik.




(a) Trend Penjualan by Customer



(b) Trend Penjualan by Material (Produk)



Gambar 2. Plot dan Grafik Penjualan Obat Pada PT. XYZ



Gambar 3. Grafik Hasil Forecast Pada PT. XYZ

Pada gambar 3, merupakan hasil grafik forecast menggunakan model arima yang dimana menunjukkan trend grafik yang stabil dan menunjukkan forecast yang bagus dan naik bagi PT. XYZ.

Kesimpulan

Dari hasil penelitian ini menunjukkan bahwa implementasi metode ARIMA (1,1,1) dalam forecasting penjualan obat pada PT. XYZ menegaskan bahwa model ini merupakan instrumen farmakoekonomi yang sangat valid, terbukti dengan tingkat akurasi yang baik (di atas 90% pada MSE dan RMSE). Keberhasilan ini memiliki implikasi kritis dalam manajemen rantai pasok obat, yang bertujuan menjamin ketersediaan terapi (drug availability) bagi masyarakat. Analisis menunjukkan bahwa produk-produk Fast-Moving yang esensial, seperti Neozep Forte (dengan tren permintaan naik, $GF=1.13$), memiliki Risk Score tinggi, sehingga memerlukan penetapan Safety Stock yang cermat untuk mencegah stockout dan menjaga kesinambungan pelayanan kesehatan primer. Sebaliknya, produk Slow-Moving yang

sangat fluktuatif (misalnya Biogesic Anak, Risk Score 1.76) menuntut strategi pengadaan minimal dan pemantauan stok ketat untuk mengurangi risiko overstocking dan potensi kerugian akibat obat kedaluwarsa (expired stock), yang merupakan isu vital dalam praktik kefarmasian. Secara keseluruhan, PT. XYZ dapat memanfaatkan hasil forecasting ini untuk mengambil keputusan pengadaan yang berbasis data, menyeimbangkan optimalisasi biaya logistik dengan tanggung jawab kefarmasian dalam menjamin pasokan obat yang aman, tepat jumlah, dan efisien.

Daftar Pustaka

- [1] X. Zhu, A. Ninh, and H. Zhao, "Demand Forecasting with Supply-Chain Information and Machine Learning: Evidence in the Pharmaceutical Industry," *Prod. Oper. Manag.*, 2021.
- [2] M. A. Raza, "Artificial Intelligence (AI) in Pharmacy: An Overview of Applications," *Open Access Rev.*, 2022.
- [3] K. Huanbutta, "Artificial Intelligence-driven Pharmaceutical Industry: Demand Forecasting with Supply-chain Information and Machine Learning," *Eur. J. Pharm. Sci.*, 2024.
- [4] K. Douaioui, N. Idrissi, and A. Abouabdellah, "Machine Learning Models for Demand Forecasting in Healthcare Supply Chains," *Procedia Comput. Sci.*, 2024.
- [5] M. Yasir, "Machine Learning-assisted Efficient Demand Forecasting," *J. Artic.*, 2024.
- [6] B. A. Mousa, "Predicting Medicine Demand Using Deep Learning Techniques," *J. Intell. Syst.*, 2023.
- [7] R. Rathipriya, "Demand Forecasting Model for Time-Series Pharmaceutical Products," *Neural Comput. Appl.*, 2023.
- [8] G. Fourkiotis and A. Theodoridis, "Comparative Study of Traditional and Machine Learning Forecasting Models," *J. Intell. Manuf. Syst.*, 2024.
- [9] M. Jahani and others, "Drug Demand Forecasting: AI Competition Report / Methods," *PMC Artic.*, 2024.
- [10] K. R. Alla, "Supply Chain Management of Drug Products Using Numerical Forecasting and Machine Learning," *Int. J. Technol.*, 2023.
- [11] F. M. Rizaldy, "Comparative Analysis of Demand Forecasting Methods to Medication Supply," *IJCSRR*, 2024.
- [12] J. Feizabadi and others, "Hybrid Demand Forecasting Methods (ARIMAX + Neural Network) for Retail/Pharma Forecasting," *J. Artic.*, 2022.
- [13] A. Puspitasari, "Forecasting Drug Demand at Hospital/Pharmacy Using Time-series Methods: A Case Study," *J. Nas.*, 2022.
- [14] Anonymous, "Pharmaceutical Sales Forecasting with Machine Learning," *IJISAE*, 2024.