

Prediksi Permintaan Obat Menggunakan Time Series dan Machine Learning untuk Sistem Peringatan Dini Ketersediaan Obat

Muhamad Satriadi¹, Rusdah^{2*}

^{1,2} Magister Ilmu Komputer, Fakultas Teknologi Informasi, Universitas Budi Luhur, Jakarta, Indonesia

E-mail: ¹2511600401@student.budiluhur.ac.id, ²rusdah@budiluhur.ac.id

(*: corresponding author)

Abstrak

Manajemen persediaan obat yang efektif merupakan bagian penting dalam mendukung keberlanjutan pelayanan kesehatan di rumah sakit. Perencanaan permintaan yang tidak tepat dapat menyebabkan kekurangan stok (stockout) maupun kelebihan persediaan (overstock) yang memicu inefisiensi anggaran sebesar 25–40%. Penelitian ini bertujuan untuk mengembangkan dan membandingkan model forecasting permintaan obat serta mengimplementasikan hasil forecasting ke dalam aplikasi SmartMed yang mengintegrasikan Safety Stock, Reorder Point (ROP), dan sistem peringatan dini di RSUD Kota Bogor. Penelitian ini menggunakan metodologi Knowledge Discovery in Databases dengan data periode Januari 2020 sampai Desember 2025. Lima metode forecasting dibandingkan, yaitu ARIMA, Exponential Smoothing, Prophet, Random Forest, dan XGBoost, dengan menggunakan parameter uji MAE, RMSE, dan MAPE. Hasil evaluasi menunjukkan bahwa Random Forest menjadi model terbaik pada empat jenis obat, XGBoost pada tiga jenis obat, ARIMA pada dua jenis obat, dan Exponential Smoothing pada satu jenis obat, sedangkan Prophet tidak menjadi model terbaik. Pada studi kasus Amlodipin 10 mg, Random Forest menghasilkan MAE 715,94, RMSE 845,07, dan MAPE 6,72% (Sangat Baik). Model terbaik selanjutnya digunakan dalam SmartMed untuk mendukung pemantauan persediaan melalui Safety Stock, ROP, dan sistem peringatan dini. Sistem ini diharapkan dapat membantu manajemen dalam mengambil keputusan preventif terkait persediaan obat.

Kata kunci: Forecasting, Machine Learning, KDD, Sistem Peringatan Dini, Antihipertensi.

Abstract

Effective pharmaceutical inventory management is crucial for sustaining healthcare services in hospitals. Inaccurate demand planning can lead to stockouts or overstock situations, resulting in budget inefficiencies of 25–40%. This study aims to develop and compare pharmaceutical demand forecasting models and implement the results into the SmartMed application, which integrates Safety Stock, Reorder Point (ROP), and an early warning system at RSUD Kota Bogor. The study employs the Knowledge Discovery in Databases methodology using data from January 2020 to December 2025. The study compared five forecasting methods—ARIMA, Exponential Smoothing, Prophet, Random Forest, and XGBoost—using MAE, RMSE, and MAPE metrics. Evaluation results indicate that Random Forest was the best model for four medication types, XGBoost for three, ARIMA for two, and Exponential Smoothing for one, while Prophet did not emerge as the best model for any. For Amlodipine 10 mg, Random Forest yielded an MAE of 715.94, an RMSE of 845.07, and a MAPE of 6.72% (rated "Very Good"). The best-performing models were subsequently incorporated into SmartMed to support inventory monitoring via Safety Stock, ROP, and the early warning system. This system is expected to help management make proactive decisions about pharmaceutical inventory.

Keywords: Forecasting, Machine Learning, KDD, Early Warning System, Antihypertensive Drugs.

1. PENDAHULUAN

Manajemen persediaan sediaan farmasi di rumah sakit memegang peranan yang sangat vital dalam rantai nilai pelayanan kesehatan dan keselamatan pasien (patient safety). Sesuai dengan Peraturan Menteri Kesehatan Republik Indonesia Nomor 72 Tahun 2016 tentang Standar Pelayanan Kefarmasian di Rumah Sakit, instalasi farmasi berkewajiban untuk menjamin ketersediaan obat-obatan secara tepat jumlah, tepat waktu, tepat jenis, serta efisien demi menjaga kontinuitas pengobatan pasien [1]. Dalam perspektif manajemen operasi, pengelolaan inventori yang tidak terkontrol akan memicu ketidakseimbangan pasokan, yang pada gilirannya berakibat pada dua skenario merugikan: stock-out (kekosongan stok) yang mengancam keselamatan jiwa pasien, atau overstock (penumpukan stok berlebih) yang melahirkan pemborosan modal kerja

akibat biaya penyimpanan yang tinggi serta tingginya risiko obat kedaluwarsa [2], [3].

Berdasarkan analisis operasional di Rumah Sakit Umum Daerah (RSUD) Kota Bogor, proses perencanaan kebutuhan obat selama ini masih mengandalkan pendekatan konvensional dan pengolahan data manual berbasis spreadsheet. Metode konvensional ini memiliki kerentanan yang tinggi terhadap human error, memerlukan waktu pemrosesan yang sangat lama, serta tidak adaptif terhadap fluktuasi pola penyakit dan jumlah kunjungan pasien di rumah sakit. Akibatnya, rumah sakit sering menghadapi ancaman inefisiensi anggaran yang diperkirakan berkisar antara 25% hingga 40% akibat penumpukan obat mati (dead stock) yang kedaluwarsa, atau sebaliknya terhambatnya pelayanan akibat kekosongan obat-obatan esensial. Salah satu kelompok obat yang memerlukan perhatian khusus adalah kelompok obat antihipertensi. Penyakit hipertensi merupakan penyakit kronis yang membutuhkan terapi jangka panjang secara rutin, sehingga jaminan ketersediaan obat menjadi faktor determinan utama keberhasilan klinis pasien [4], [5].

Meskipun SIMRS RSUD Kota Bogor telah mencatat transaksi pelayanan dan logistik dalam volume yang sangat besar—mencapai 903.416 record kunjungan pasien global periode Januari 2020 hingga Desember 2025—data administratif tersebut masih terisolasi sebagai catatan transaksional belaka dan belum dimanfaatkan untuk mendukung keputusan taktis manajemen. Untuk mengatasi hambatan tersebut, penelitian ini menerapkan kerangka kerja Knowledge Discovery in Databases (KDD) guna mengekstraksi pengetahuan prediktif dari data besar rumah sakit [6], [7]. KDD diimplementasikan secara sistematis untuk menyaring 6.215 record pasien hipertensi spesifik (berdasarkan kode ICD-10) dan 720 record transaksi bulanan dari 10 jenis obat antihipertensi utama guna membangun model peramalan permintaan logistik farmasi.


Penelitian terkait peramalan persediaan telah dipublikasikan di berbagai literatur akademik. Di dalam jurnal SKANIKA, Putri dkk. mengembangkan sistem peramalan menggunakan metode Double Exponential Smoothing (DES) berbasis web untuk melacak pola tren jangka menengah, menghasilkan nilai MAPE sebesar 7,9% [8]. Meskipun DES tangguh terhadap pola tren linier yang stabil, metode ini kurang optimal jika dihadapkan pada pola musiman yang kompleks dan keterlibatan banyak variabel eksternal. Sementara itu, Imron dkk. membuktikan bahwa penyeteran hyperparameter pada algoritma machine learning ensemble seperti XGBoost dan Random Forest dapat meningkatkan akurasi prediksi secara signifikan dari 88,15% menjadi 91,66% [9]. Peningkatan akurasi model ML ensemble ini juga sejalan dengan penelitian Vannesa dkk. di SKANIKA yang memanfaatkan algoritma Random Forest dikombinasikan dengan GridSearchCV untuk mengoptimalkan kinerja model pada data multi-atribut campuran [10]. Sementara itu, peramalan obat berbasis Facebook Prophet dengan memanfaatkan Python di instalasi farmasi menghasilkan akurasi MAPE sebesar 4,93% dalam studi Maulana [11].

Berangkat dari kesenjangan penelitian sebelumnya yang sebagian besar hanya menguji satu algoritma tunggal atau tidak mengintegrasikan variabel klinis eksternal, penelitian ini mengusulkan sebuah pendekatan komparatif komprehensif. Kami membandingkan lima algoritma lintas paradigma: model statistik klasik ARIMA [12] dan Exponential Smoothing [13], model aditif Facebook Prophet [14], serta model machine learning ensemble Random Forest [15] dan XGBoost [16]. Kelima model dilatih menggunakan fitur hasil rekayasa data yang mencakup dimensi temporal, fitur historis (Lag-1, Lag-2, Rolling3), serta variabel pelayanan pasien riil. Model dengan akurasi terbaik diintegrasikan ke dalam sistem peringatan dini (Early Warning System/EWS) berbasis web bernama SmartMed. Melalui perhitungan Safety Stock dan Reorder Point (ROP) secara otomatis, SmartMed meramalkan kuantitas kebutuhan sekaligus memberikan klasifikasi status persediaan secara proaktif (AMAN, WASPADA, atau KRITIS) untuk memandu pengadaan obat secara akurat [17].

2. METODE PENELITIAN

Metodologi yang digunakan dalam penelitian ini adalah kuantitatif berbasis eksperimen komputasional. Arsitektur penelitian secara sistematis mengikuti siklus KDD (Knowledge Discovery in Databases) yang terdiri atas lima tahap utama: Selection, Preprocessing, Transformation, Data Mining, dan Evaluation [6], [7]. Setelah model terbaik didapatkan pada

tahap evaluasi, model tersebut diintegrasikan dengan logika kontrol persediaan Safety Stock dan ROP ke dalam aplikasi pendukung keputusan SmartMed yang dibangun berbasis web menggunakan framework CodeIgniter [18]. Alur tahapan penelitian secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 1. Alur penelitian berbasis KDD

2.1. Pengolahan Data Berbasis KDD

Siklus pengolahan data dalam penelitian ini dijabarkan sebagai berikut:

- Selection:** Tahap seleksi diawali dengan mengekstrak data dari database Sistem Informasi Manajemen Rumah Sakit (SIMRS) dan Instalasi Farmasi RSUD Kota Bogor periode Januari 2020 hingga Desember 2025. Dari data mentah kunjungan pasien sebanyak 903.416 record, dilakukan penyaringan ketat menggunakan kode diagnosis ICD-10 untuk hipertensi (kode I10 hingga I15) sehingga diperoleh sub-populasi sebanyak 6.215 record pasien hipertensi. Pada data logistik farmasi, dari total 35.135 record transaksi, dilakukan pemisahan kelompok obat antihipertensi hingga disaring menjadi 10 jenis obat antihipertensi utama (terdiri atas 1.582 record bulanan sebelum dibersihkan).
- Preprocessing:** Tahap pra-pemrosesan ditujukan untuk meningkatkan kualitas data (data cleaning). Kegiatan utama meliputi penanganan missing value, penghapusan duplikasi pencatatan, pemeriksaan validitas numerik (menghilangkan nilai negatif), serta standarisasi nama obat. Ditemukan 24 variasi penulisan nama obat untuk zat aktif yang sama (akibat perbedaan penulisan dosis, singkatan, atau kode jaminan seperti REG dan JKN). Melalui standarisasi, variasi tersebut disatukan menjadi 10 identitas nama obat yang konsisten sehingga menyederhanakan volume record dari 1.582 menjadi 720 record transaksi bulanan yang bersih (10 obat x 72 bulan).
- Transformation:** Tahap transformasi melakukan rekayasa fitur (feature engineering) untuk merancang atribut prediktor baru yang mampu menangkap pola temporal dan dependensi historis deret waktu [19], [20]. Data pasien hipertensi agregat bulanan dikelompokkan menjadi tiga fitur eksternal klinis: Ranap_Hipertensi (pasien rawat inap), Rajal_Hipertensi (pasien rawat jalan), dan Total_Hipertensi (total kunjungan pasien hipertensi). Fitur internal historis dirancang secara terprogram menggunakan Python, menghasilkan fitur Lag-1, Lag-2, dan Rolling3. Selain itu, fitur temporal berupa Bulan_Num (Januari = 1 s.d. Desember = 12) serta fitur operasional berupa Stok_Akhir dan Lead_Time ditambahkan. Dataset akhir hasil transformasi terdiri atas 720 baris dengan 9 variabel prediktor dan 1 variabel target berupa Permintaan Obat.
- Data Mining:** Tahap penambangan data melakukan pelatihan dan pengujian komparatif terhadap lima model forecasting lintas paradigma. Model statistik klasik ARIMA memodelkan ketergantungan linear pada data stasioner [12]. Exponential Smoothing (dengan metode Holt's Linear Trend) melakukan pemulusan data tren linier [12]. Facebook Prophet memproses regresi aditif dengan deteksi otomatis titik perubahan tren dan musiman nonlinier menggunakan deret Fourier [14]. Sementara itu, model machine learning ensemble Random Forest (berbasis bootstrap aggregating/bagging) [16] dan XGBoost (berbasis gradient boosting dengan regularisasi L1/L2) [16] melatih hubungan nonlinier multivariat

antara fitur logistik dan kunjungan klinis pasien.

- e. *Evaluation*: Kinerja peramalan dari kelima model diukur secara kuantitatif pada data pengujian tahun 2025 menggunakan tiga metrik kesalahan: Mean Absolute Error (MAE), Root Mean Square Error (RMSE), dan Mean Absolute Percentage Error (MAPE). Model dengan nilai MAPE terkecil untuk masing-masing obat ditetapkan sebagai model terbaik untuk memprediksi kebutuhan pada periode Januari 2026.

2.2. Formulasi Rekayasa Fitur

Fitur historis yang dibentuk melalui proses *feature engineering* diekstrak dari nilai target sebelumnya untuk membantu algoritma machine learning mengenali tren temporal. Persamaan matematis pembentukan fitur tersebut adalah sebagai berikut:

- a. Lag-1 merupakan nilai permintaan obat pada satu bulan sebelumnya:

$$Lag - 1 = Y(t - 1) \quad (1)$$

- b. Lag-2 merupakan nilai permintaan obat pada dua bulan sebelumnya:

$$Lag - 2 = Y(t - 2) \quad (2)$$

- c. Rolling3 merupakan rata-rata bergerak dari permintaan obat selama tiga bulan terakhir:

$$Rolling3 = (Y(t - 1) + Y(t - 2) + Y(t - 3)) / 3 \quad (3)$$

Keterangan: $Y(t - 1)$ adalah kuantitas permintaan obat pada satu bulan sebelumnya, $Y(t - 2)$ adalah kuantitas pada dua bulan sebelumnya, dan $Y(t - 3)$ adalah kuantitas pada tiga bulan sebelumnya. Fitur Rolling3 merepresentasikan nilai rata-rata bergerak tiga bulanan untuk menghaluskan fluktuasi ekstrem pada data historis.

2.3. Logika Sistem Peringatan Dini

Keluaran peramalan dari model terbaik diintegrasikan secara matematis dengan logika pengendalian persediaan untuk menghasilkan peringatan dini ketersediaan obat. Parameter Safety Stock (SS) dihitung untuk mengantisipasi ketidakpastian permintaan dan keterlambatan pengiriman menggunakan standar deviasi permintaan historis dan lead time [2], [17]:

$$SS = Z \times s \times \sqrt{LT} \quad (4)$$

Keterangan: Z adalah nilai Z-score yang mewakili tingkat pelayanan (service level 95% = 1,65), s adalah nilai standar deviasi permintaan historis, dan LT adalah nilai Lead Time (waktu tunggu pengadaan dari pemesanan hingga obat masuk gudang farmasi, di mana RSUD Kota Bogor menetapkan rata-rata LT sebesar 1 atau 2 bulan).

Selanjutnya, batas titik pemesanan kembali atau Reorder Point (ROP) dihitung berdasarkan jumlah kebutuhan rata-rata selama periode lead time ditambah dengan kuantitas Safety Stock yang telah diperoleh [2], [17]:

$$ROP = (Average Demand \times LT) + SS \quad (5)$$

Keterangan: Average Demand diperoleh secara dinamis dari nilai hasil peramalan model terbaik untuk periode berikutnya. Nilai ROP ini berfungsi sebagai batas kritis.

Status peringatan dini persediaan kemudian diklasifikasikan ke dalam tiga kategori bisnis berdasarkan rasio perbandingan antara stok aktual (stok fisik saat ini) dengan nilai ROP yang dihitung sistem:

- a. AMAN: Kondisi stok aktual berada di atas 110% dari nilai ROP. Gudang farmasi memiliki stok yang cukup untuk memenuhi kebutuhan pelayanan, sehingga pengadaan kembali belum diperlukan.


- b. WASPADA: Kondisi stok aktual berkisar antara 80% dan 110% dari nilai ROP. Petugas farmasi harus mulai meningkatkan pengawasan dan mempersiapkan berkas rencana usulan pembelian.
- c. KRITIS: Kondisi stok aktual berada di bawah 80% dari nilai ROP. Sistem secara otomatis memberikan rekomendasi jumlah pemesanan obat (gap) untuk menghindari kekosongan obat-obat vital.

2.4. Arsitektur Prototipe Aplikasi SmartMed.

Arsitektur sistem SmartMed dirancang untuk mengintegrasikan proses pengolahan data, forecasting, hingga penyajian informasi persediaan melalui dashboard. Sistem terdiri atas empat lapisan utama, yaitu:

- a. *Backend Layer* – Menggunakan Python, scikit-learn, dan XGBoost untuk data *preprocessing*, feature engineering, serta pembangunan model forecasting.
- b. *Data Layer* – Menggunakan MySQL untuk menyimpan 903.416 data kunjungan pasien, transaksi obat, hasil prediksi, serta parameter Safety Stock dan Reorder Point (ROP).
- c. *Application Layer* – Menggunakan PHP dan CodeIgniter 4 untuk menjalankan logika bisnis serta menentukan status persediaan berdasarkan stok aktual dan ROP.
- d. *Presentation Layer* – Menggunakan dashboard berbasis Chart.js untuk menampilkan tren historis, hasil prediksi, serta status persediaan AMAN, WASPADA, dan KRITIS.

Integrasi keempat lapisan tersebut memungkinkan SmartMed menerapkan proses KDD secara terintegrasi dan menghasilkan rekomendasi pengadaan obat berbasis forecasting serta sistem peringatan dini. Arsitektur sistem SmartMed ditunjukkan pada Gambar 2.



Gambar 2. Arsitektur SmartMed

3. HASIL DAN PEMBAHASAN

Hasil eksperimen dan pembahasan memaparkan transformasi data transaksional rumah sakit menjadi keluaran prediktif yang siap digunakan untuk pengambilan keputusan logistik di Instalasi Farmasi RSUD Kota Bogor. Seluruh analisis kuantitatif dan performa komparatif dirangkum secara transparan.

3.1. Analisis Karakteristik Data (Data Understanding)

Dataset terintegrasi final mencakup data runtun waktu (time series) bulanan selama 6 tahun (Januari 2020 s.d. Desember 2025). Karakteristik variabel yang terlibat dalam model peramalan dirangkum dalam Tabel 1.

Tabel 1. Karakteristik Dataset Penelitian

Atribut	Tipe Data	Fungsi dalam Model	Deskripsi Fitur
Permintaan Obat	Numerik (Integer)	Variabel Target (Output)	Kuantitas penggunaan obat riil per bulan.
Lag-1, Lag-2	Numerik (Float)	Prediktor Historis (Internal)	Kuantitas permintaan pada bulan t-1 dan t-2.

Atribut	Tipe Data	Fungsi dalam Model	Deskripsi Fitur
Rolling3	Numerik (Float)	Prediktor Historis (Internal)	Rata-rata bergerak permintaan 3 bulan terakhir.
Ranap_Hipertensi	Numerik (Integer)	Prediktor Pelayanan (External)	Jumlah pasien rawat inap diagnosis hipertensi.
Rajal_Hipertensi	Numerik (Integer)	Prediktor Pelayanan (External)	Jumlah pasien rawat jalan diagnosis hipertensi.
Total_Hipertensi	Numerik (Integer)	Prediktor Pelayanan (External)	Total kunjungan pasien hipertensi (Ranap + Rajal).
Bulan_Num	Numerik (Integer)	Prediktor Temporal	Siklus bulanan dalam representasi angka 1 s.d 12.
Stok_Akhir	Numerik (Integer)	Prediktor Operasional	Sisa persediaan akhir periode berjalan.
Lead_Time	Numerik (Integer)	Prediktor Operasional	Waktu tunggu pengadaan obat (dalam satuan bulan).

3.2. Hasil Pembersihan Data (*Preprocessing*)

Proses pembersihan data berhasil menyeragamkan variasi penulisan nama obat yang terduplikasi di SIMRS. Dari 24 nama obat yang tidak konsisten, disatukan menjadi 10 identitas obat yang lebih konsisten. Beberapa contoh standarisasi nama obat dirangkum pada Tabel 2.

Tabel 2. Sampel Hasil Standarisasi dan Pembersihan Nama Obat

Nama Obat Sebelum Pembersihan (SIMRS)	Nama Obat Setelah Standarisasi	Jumlah Record Sebelum	Jumlah Record Sesudah
AMLODIPINE 10 MG TAB REG AMLODIPIN 10MG AMLODIPIN 10 MG JKN	AMLODIPIN 10 MG TAB	230	72
AMLODIPINE 5 MG TAB REG AMLODIPIN 5MG TAB	AMLODIPIN 5 MG TAB	180	72
BISOPROLOL 2.5 MG TAB REG BISOPROLOL 2,5 MG TAB	BISOPROLOL 2,5 MG TAB	145	72
CANDESARTAN 16 MG TAB JKN CANDESARTAN 16MG TAB	CANDESARTAN 16 MG TAB	162	72
SPIRONOLACTONE TAB 25 MG SPIRONOLACTONE 25 MG REG	SPIRONOLACTONE 25 MG TAB	110	72

3.3. Hasil Eksperimen Komparatif Studi Kasus Utama (Amlodipin 10 mg TAB)

Amlodipin 10 mg TAB dipilih sebagai objek studi kasus utama karena memiliki volume permintaan tertinggi dan fluktuasi bulanan yang signifikan. Model dilatih menggunakan data pelatihan (Januari 2020 - Desember 2024) dan kinerjanya diuji menggunakan data pengujian tahun 2025. Performa akurasi peramalan dari kelima model dirangkum dalam Tabel 3. Sebagai contoh, pada Gambar 3 disajikan hasil prediksi seluruh model forecasting untuk obat Amlodipin 10 mg Tab.


Tabel 3. Komparasi Akurasi Peramalan Amlodipin 10 MG TAB

Model	MAE	RMSE	MAPE (%)
Random Forest	715,94	845,07	6,72% (Sangat Baik)
XGBoost	973,33	1.254,21	9,26% (Sangat Baik)
ARIMA (3,1,2)	1.056,13	1.496,65	11,82% (Baik)
Facebook Prophet	1.827,85	2.327,84	19,89% (Baik)
Exponential Smoothing	2.077,94	2.641,71	22,63% (Cukup)

Evaluasi Model

Model	Prediksi Bulan Ke-1	MAE	RMSE	MAPE (%)	Keterangan
ARIMA	11.280	1.056,13	1.496,65	11,82	Pembanding
Exponential Smoothing	11.662	2.077,94	2.641,71	22,63	Pembanding
Prophet	12.720	1.827,85	2.327,84	19,89	Pembanding
Random Forest	7.617	715,94	845,07	6,72	Model terbaik
XGBoost	7.196	973,33	1.254,21	9,26	Pembanding

Gambar 3. Hasil Prediksi Seluruh Model Forecasting Amlodipin 10 MG Tab



Gambar 4. Perbandingan MAPE Lima Model pada Amlodipin 10 mg

Berdasarkan hasil pada Tabel 3 dan Gambar 4, model Random Forest menghasilkan nilai kesalahan terkecil dengan MAPE sebesar 6,72%. XGBoost berada di peringkat kedua dengan MAPE sebesar 9,26%. Kedua model machine learning ini mengungguli model statistik tradisional. Hal ini membuktikan bahwa pendekatan non-linier multivariat mampu menangkap dinamika permintaan obat secara lebih baik dengan memanfaatkan variabel klinis eksternal (jumlah pasien), sedangkan model klasik seperti Exponential Smoothing (Double Holt) mengalami lagging dengan nilai MAPE tertinggi sebesar 22,63%.

3.4. Evaluasi Konsistensi pada Seluruh Obat Antihipertensi

Pengujian lebih lanjut diperluas untuk mencakup seluruh sepuluh jenis obat antihipertensi guna mengevaluasi konsistensi performa model di bawah karakteristik data yang bervariasi. Ringkasan model terbaik dan nilai kesalahan peramalan terkecil disajikan pada Tabel 4.

Tabel 4. Ringkasan Hasil Evaluasi Seluruh Obat Antihipertensi

Nama Obat Antihipertensi	Model Peramalan Terbaik	MAE (Unit)	RMSE (Unit)	MAPE (%)	Kategori Akurasi
Spironolactone 25 MG Tab	Exponential Smoothing	98,35	108,13	3,32%	Sangat Baik
Candesartan 8 MG Tab	ARIMA (1, 1, 1)	172,94	209,53	4,78%	Sangat Baik
Bisoprolol 5 MG Tab	ARIMA (2, 1, 1)	191,36	287,96	5,56%	Sangat Baik
Amlodipin 10 MG Tab	Random Forest	715,94	845,07	6,72%	Sangat Baik
Amlodipin 5 MG Tab	Random Forest	172,93	204,96	7,08%	Sangat Baik
Furosemide 40 MG Tab	XGBoost	498,06	620,85	7,57%	Sangat Baik
Bisoprolol 2.5 MG Tab	Random Forest	1.081,71	1.478,18	9,52%	Sangat Baik
Captopril 25 MG Tab	XGBoost	52,24	69,58	11,82%	Baik
Ramipril 5 MG Tab	Random Forest	1.190,04	1.526,73	14,92%	Baik
Candesartan 16 MG Tab	XGBoost	759,57	915,99	24,28%	Cukup

Analisis Seluruh Obat Antihipertensi

Jumlah Obat
10

RF Terbaik
4

XGB Terbaik
3

ARIMA
2

ES
1

Prophet
0

Perbandingan Model Terbaik Seluruh Obat

No	Nama Obat	Model Terbaik	MAE	RMSE	MAPE (%)
1	SPIRONOLACTONE 25 MG TAB	Exponential Smoothing	98,35	108,13	3,32
2	CANDESARTAN 8 MG TAB	ARIMA	172,94	209,53	4,78
3	BISOPROLOL 5 MG TAB	ARIMA	191,36	287,96	5,56
4	AMLODIPIN 10 MG TAB	Random forest	715,94	845,07	6,72
5	AMLODIPIN 5 MG TAB	XGBoost	172,93	204,96	7,08
6	FUROSEMIDE 40 MG TAB	Random Forest	498,06	620,85	7,57
7	BISOPROLOL 2.5 MG TAB	Random Forest	1.081,71	1.478,18	9,52
8	CAPTOPRIL 25 MG TAB	XGBoost	52,24	69,58	11,82
9	RAMIPRIL 5 MG TAB	Random forest	1.190,04	1.526,73	14,92
10	CANDESARTAN 16 MG TAB	XGBoost	759,57	915,99	24,28

Gambar 5. Hasil Evaluasi Seluruh Obat Antihipertensi

Berdasarkan data pada Tabel 4 dan Gambar 5, diperoleh kesimpulan penting terkait hipotesis penelitian. Model berbasis machine learning (Random Forest dan XGBoost) secara agregat mendominasi dan menjadi model terbaik pada 7 dari 10 jenis obat (70% dari objek penelitian). Random Forest unggul pada 4 jenis obat, sedangkan XGBoost unggul pada 3 jenis obat. Di sisi lain, model statistik klasik (ARIMA dan Exponential Smoothing) tetap menunjukkan keunggulan pada 3 jenis obat (30% dari objek penelitian) yang memiliki karakteristik tren linier yang sangat stabil atau stasioneritas yang konstan (seperti pada Spironolactone 25 mg dengan MAPE 3,32%). Model Facebook Prophet tidak menjadi model terbaik pada satu obat pun karena menghasilkan deviasi yang relatif lebih besar pada dataset berskala menengah ini. Dengan demikian, hipotesis penelitian yang diajukan terbukti dapat diterima.

3.5. Analisis Feature Importance

Analisis *feature importance* dijalankan pada algoritma Random Forest dan XGBoost untuk mengidentifikasi variabel yang paling berkontribusi terhadap hasil prediksi. Pada model Random Forest, variabel Lag-1 (permintaan satu bulan sebelumnya) menjadi fitur paling dominan dengan nilai koefisien kontribusi sebesar 0,2650, diikuti oleh Rolling3 sebesar 0,2491, Lag-2 sebesar 0,1996, dan Stok_Akhir sebesar 0,1928. Pada XGBoost, Lag-1 sangat mendominasi dengan kontribusi sebesar 0,5633, diikuti oleh Rolling3 sebesar 0,2188, dan Stok_Akhir sebesar 0,2065. Variabel klinis eksternal (Total_Pasien, Ranap, dan Rajal) memberikan kontribusi tambahan dengan nilai yang relatif kecil (berkisar antara 0,0100 s.d. 0,0481). Hal ini menunjukkan bahwa pola historis permintaan internal tetap menjadi basis informasi utama, sedangkan data klinis bertindak sebagai prediktor pendukung untuk menyesuaikan fluktuasi di lapangan. Gambar 6, menunjukkan variabel yang paling dominan digunakan oleh kedua model machine learning.

```

=== RF FEATURE IMPORTANCE ===    === XGB FEATURE IMPORTANCE ===
lag1 = 0.265013                    lag1 = 0.563334
rolling3 = 0.249114                rolling3 = 0.218873
lag2 = 0.199613                    stok_akhir = 0.206580
stok_akhir = 0.192858              ranap_hipertensi = 0.010068
total_hipertensi = 0.048152         total_hipertensi = 0.000517
ranap_hipertensi = 0.027710         lag2 = 0.000267
rajal_hipertensi = 0.013770         rajal_hipertensi = 0.000226
bulan_num = 0.003772               bulan_num = 0.000134
lead_time = 0.000000               lead_time = 0.000000

```

Gambar 6. Feature importance Random Forest dan XGBoost

3.6. Validasi Sistem Peringatan Dini

Model terbaik hasil evaluasi diimplementasikan ke dalam modul peringatan dini pada aplikasi SmartMed. Sistem menghitung Safety Stock dan ROP secara dinamis menggunakan nilai peramalan untuk periode berikutnya. Hasil validasi sistem untuk sepuluh jenis obat antihipertensi per Januari 2026 disajikan pada Tabel 5.

Tabel 5. Ringkasan Hasil Evaluasi Seluruh Obat Antihipertensi

Nama Obat Antihipertensi	Stok Aktual	Hasil Prediksi	Safety Stock	Reorder Point	Status Peringatan Dini	Rekomendasi Pemesanan
Amlodipin 10 MG Tab	9	7.617	1.045	16.280	KRITIS	Pesan 16.272 unit
Bisoprolol 2.5 MG Tab	8.774	10.546	1.432	22.523	KRITIS	Pesan 13.749 unit
Furosemide 40 MG Tab	14	5.413	658	11.484	KRITIS	Pesan 11.470 unit
Candesartan 8 MG Tab	1.232	3.904	361	8.169	KRITIS	Pesan 6.938 unit
Bisoprolol 5 MG Tab	2.095	3.933	365	8.231	KRITIS	Pesan 6.136 unit
Ramipril 5 MG Tab	9.870	7.034	1.290	15.358	KRITIS	Pesan 5.489 unit
Candesartan 16 MG Tab	0	1.716	479	3.911	KRITIS	Pesan 3.912 unit
Amlodipin 5 MG Tab	92	1.730	245	3.705	KRITIS	Pesan 3.613 unit
Captopril 25 MG Tab	0	278	69	625	KRITIS	Pesan 626 unit
Spironolactone 25 MG Tab	7.660	2.811	253	5.875	AMAN	Stok aman, tunda pemesanan

Early Warning System

Nama Obat	Stok	Prediksi	ROP	Gap	Status	Rekomendasi
AMLODIPIN 10 MG TAB	9	7.617	16.280	16.271	KRITIS	Pesan 16272 unit
BISOPROLOL 2.5 MG TAB	8.774	10.546	22.523	13.749	KRITIS	Pesan 13749 unit
FUROSEMIDE 40 MG TAB	14	5.413	11.484	11.470	KRITIS	Pesan 11470 unit
CANDESARTAN 8 MG TAB	1.232	3.904	8.169	6.937	KRITIS	Pesan 6938 unit
BISOPROLOL 5 MG TAB	2.095	3.933	8.231	6.136	KRITIS	Pesan 6137 unit
RAMIPRIL 5 MG TAB	9.870	7.034	15.358	5.488	KRITIS	Pesan 5489 unit
CANDESARTAN 16 MG TAB	0	1.716	3.911	3.911	KRITIS	Pesan 3912 unit
AMLODIPIN 5 MG TAB	92	1.730	3.705	3.613	KRITIS	Pesan 3613 unit
CAPTOPRIL 25 MG TAB	0	278	625	625	KRITIS	Pesan 626 unit
SPIRONOLACTONE 25 MG TAB	7.660	2.811	5.875	0	AMAN	Stok aman

Gambar 7. Hasil validasi Sistem Peringatan Dini.

Hasil validasi pada Tabel 5 dan Gambar 7, menunjukkan bahwa 9 dari 10 jenis obat (90%) berada dalam kondisi KRITIS. Hal ini dikarenakan sisa stok aktual di gudang farmasi berada jauh di bawah nilai Reorder Point (ROP) yang disyaratkan oleh sistem, sehingga memicu Sistem Peringatan Dini untuk memberikan peringatan status KRITIS berwarna merah serta mengeluarkan rekomendasi jumlah pemesanan secara otomatis. Sebaliknya, 1 jenis obat (seperti Spironolactone 25 mg dengan stok aktual 7.660 unit) berada dalam kondisi AMAN karena stoknya masih berada di atas nilai ROP gudang (5.875 unit). Integrasi peramalan dengan logika persediaan pada aplikasi SmartMed ini terbukti berhasil mentransformasi data pelayanan menjadi pendukung keputusan taktis bagi petugas Instalasi Farmasi RSUD Kota Bogor.

4. KESIMPULAN DAN SARAN

Penelitian ini berhasil merancang dan mengembangkan model prediksi kebutuhan obat yang diintegrasikan dengan sistem peringatan dini ketersediaan obat pada aplikasi SmartMed berbasis web. Melalui siklus metodologi Knowledge Discovery in Databases (KDD), penelitian ini memanfaatkan aset data administratif rumah sakit yang besar, menyaring 903.416 record kunjungan menjadi 6.215 record pasien hipertensi klinis dan 720 record transaksi logistik bulanan yang telah dibersihkan. Komparasi terhadap lima metode forecasting menunjukkan keunggulan model nonlinier machine learning (Random Forest dan XGBoost) dalam menangani variabilitas data yang kompleks, di mana model machine learning menjadi yang terbaik pada 70% objek penelitian. Pada studi kasus utama Amlodipin 10 mg TAB, algoritma Random Forest memberikan akurasi peramalan yang paling superior dengan nilai kesalahan terkecil (MAPE sebesar 6,72%, MAE sebesar 715,94 unit, dan RMSE sebesar 845,07 unit). Integrasi prediksi model terbaik dengan logika Safety Stock dan ROP pada aplikasi SmartMed telah divalidasi berhasil melahirkan mekanisme monitoring otomatis, yang mengklasifikasikan 90% persediaan dalam status KRITIS dan 10% dalam status AMAN untuk mendukung perencanaan persediaan yang proaktif.

Saran untuk pengembangan sistem ke depan dapat direalisasikan melalui beberapa langkah strategis, yaitu dengan merealisasikan integrasi data secara langsung (real-time API) antara aplikasi SmartMed dan database SIMRS RSUD Kota Bogor agar parameter stok aktual dan data kunjungan pasien dapat diperbarui secara otomatis tanpa melalui proses impor data secara manual. Selain itu, disarankan pula untuk mengadopsi secara resmi klasifikasi status AMAN, WASPADA, dan KRITIS pada SmartMed sebagai dasar penyusunan Rencana Usulan Pembelian (RUP) guna menekan inefisiensi anggaran operasional secara lebih proaktif. Terakhir, pengembangan sistem berikutnya dapat difokuskan pada perluasan cakupan peramalan SmartMed

ke kelompok obat esensial lainnya serta mengeksplorasi penggunaan algoritma deep learning seperti Long Short-Term Memory (LSTM) dalam penelitian mendatang guna menangkap pola deret waktu yang lebih panjang dan kompleks.

DAFTAR PUSTAKA

- [1] Kementerian Kesehatan Republik Indonesia, *Peraturan Menteri Kesehatan Republik Indonesia Nomor 72 Tahun 2016 tentang Standar Pelayanan Kefarmasian di Rumah Sakit*, Jakarta: Kementerian Kesehatan RI, 2016.
- [2] J. Heizer, B. Render, and C. Munson, *Operations Management: Sustainability and Supply Chain Management*, 13th ed. Pearson, 2020.
- [3] S. Chopra, and P. Meindl, *Supply Chain Management: Strategy, Planning, and Operation*, 7th ed. Pearson, 2019.
- [4] World Health Organization, *Global Report on Hypertension: The Race Against a Silent Killer*, Geneva: WHO, 2023.
- [5] Kementerian Kesehatan Republik Indonesia, *Laporan Riset Kesehatan Dasar (Riskesdas) 2023*, Jakarta: Badan Penelitian dan Pengembangan Kesehatan, 2023.
- [6] X. Shu, and Y. Ye, "Knowledge Discovery: Methods from data mining and machine learning," *Social Science Research*, vol. 110, p. 102817, 2023, doi: 10.1016/j.ssresearch.2022.102817.
- [7] W. Widayat, et al., "Data Mining Implementation: A Survey," *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 36, no. 3, pp. 1960-1968, 2024, doi: 10.11591/ijeecs.v36.i3.pp1960-1968.
- [8] V. A. Putri, S. Achmadi, and A. Mahmudi, "Rancang Bangun Sistem Peramalan Penjualan Es Krim Dengan Metode Double Exponential Smoothing," *SKANIKA: Sistem Komputer dan Teknik Informatika*, vol. 9, no. 1, pp. 24-34, 2026, doi: 10.36080/skanika.v9i1.3618.
- [9] S. Imron, A. Faizah, and Sugianto, "Prediksi Kelulusan Mahasiswa Menggunakan Algoritma XGBoost," *SKANIKA: Sistem Komputer dan Teknik Informatika*, vol. 9, no. 1, pp. 76-86, 2026, doi: 10.36080/skanika.v9i1.3647.
- [10] N. D. Vannesa, and F. Budiman, "Klasifikasi Kelayakan Kredit Menggunakan Random Forest Dengan Optimisasi SMOTENC dan GridSearchCV," *SKANIKA: Sistem Komputer dan Teknik Informatika*, vol. 9, no. 2, pp. 270-283, 2026, doi: 10.36080/skanika.v9i2.3829.
- [11] K. R. Maulana, W. Widiyono, and A. S. Darmawan, "Predicting Tablet Drug Expenditures Using Python-Based Facebook Prophet in Pharmaceutical Installations," *Jurnal Teknologi dan Open Source*, vol. 8, no. 2, pp. 709-721, 2025, doi: 10.36378/jtos.v8i2.4907.
- [12] K. Arunika, and L. J. E. Dewi, "Perbandingan Model SARIMA, Exponential Smoothing, dan XGBoost untuk Prediksi Penjualan Super Store," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 13, no. 1, pp. 60-69, 2025, doi: 10.23960/jitet.v13i3S1.8173.
- [13] F. R. Hariri, and C. Mashuri, "Sistem Informasi Peramalan Penjualan dengan Menerapkan Metode Double Exponential Smoothing Berbasis Web," *Generation Journal*, vol. 6, no. 1, pp. 68-77, 2022, doi: 10.29407/gj.v6i1.16204.
- [14] S. J. Taylor and B. Letham, "Forecasting at Scale," *The American Statistician*, vol. 72, no. 1, pp. 37-45, 2018, doi: 10.1080/00031305.2017.1380080.
- [15] L. Breiman, "Random Forests," *Machine Learning*, vol. 45, no. 1, pp. 5-32, 2001, doi: 10.1023/A:1010933404324.
- [16] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 785-794, 2016, doi: 10.1145/2939672.2939785.
- [17] E. A. Silver, D. F. Pyke, and D. J. Thomas, *Inventory and Production Management in Supply Chains*, 4th ed. Boca Raton, FL: CRC Press, 2017, doi: 10.1201/9781315374406.
- [18] D. Rakasiwi, R. Arafiah, and F. H. Indiyah, "Rancang Bangun Sistem Electronic Prescribing Dokter dengan Menggunakan Codeigniter," *J-KOMA : Jurnal Ilmu Komputer dan Aplikasi*, vol. 2, no. 1, 2018, doi: 10.21009/j-koma.v2i1.6484.

- [19] M. D. A. Alhamdi, Herman, and W. Astuti, "Peramalan Kebutuhan Obat Menggunakan XGBoost Studi Kasus pada Rumah Sakit XYZ," *Indonesian Journal of Computer Science*, vol. 12, no. 5, pp. 2758–2764, 2023, doi: 10.33022/ijcs.v12i5.3344.
- [20] E. M. Padilla, Utari, and R. Y. Simanullang, "Optimization of Tomato Production Prediction Using XGBoost and CatBoost Based on Lag Features in Aceh Province," *Jurnal Armada Informatika*, vol. 10, no. 1, pp. 34-42, 2026, doi: 10.36520/jai.v10i1.305.