

---

## **Prediksi Jumlah Permintaan Darah UTD PMI Kota Pontianak Menggunakan ARIMA-Kalman Filter**

---

**Lyra Mauditia\*, Nurfitri Imro'ah, Wirda Andani**

Program Studi Statistika, Universitas Tanjungpura, Pontianak, Indonesia

*\*Corresponding author:* [lyramauditia@gmail.com](mailto:lyramauditia@gmail.com)

**Submitted:** 11-Apr-2024

**Revised:** 17-Okt-2024

**Accepted:** 23-Okt-2024

---

**Abstract.** Ensuring a sufficient supply of blood is a crucial aspect of providing health services. However, the large demand for blood is sometimes difficult to fulfill for one of the work units in the Indonesian Red Cross (PMI), namely the Blood Transfusion Unit. Therefore, blood demand prediction is needed to assist the blood transfuse unit in preparing sufficient blood stock. This study uses the ARIMA-Kalman Filter model to anticipate the quantity of blood demand for Blood Transfusion Unit PMI. The observations modeled in this study are daily observations of the amount of blood demand with the period January 1 to December 26, 2023 as an in-sample of 360 observations and blood demand for the period 27 to 31 December 2023 which amounted to 5 observations as an out-sample used to evaluate the model. The analysis's findings indicate that the model obtained for predicting the amount of blood demand is the ARIMA (0,0,2) model, then the model parameters are estimated using Kalman Filter. The model used fulfills the diagnostic test and obtained a MAPE value of 15.021% in predicting out-sample data. Thus it can be concluded that the model used is in the very good category and is suitable for prediction. Furthermore, predictions are made for the next three days on the number of blood requests at Blood Transfusion Unit PMI Pontianak City to help health services prepare blood stocks for patients in need.

**Keywords:** state space; covariance error; MAPE

---

### **1. PENDAHULUAN**

Pertumbuhan penduduk yang semakin meningkat, kenaikan angka kecelakaan, serta perubahan gaya hidup masyarakat yang tidak sehat menyebabkan permintaan darah semakin banyak diperlukan. Selain itu, peningkatan permintaan darah juga disebabkan oleh pasien dengan penyakit tertentu dan wanita hamil [1]. Oleh karena itu, sangat penting bagi layanan kesehatan untuk memberikan pasokan darah yang cukup. Kebutuhan darah yang cukup besar terkadang juga sulit terpenuhi bagi suatu layanan kesehatan salah satunya Unit Transfusi Darah (UTD) yang merupakan bagian dari Palang Merah Indonesia (PMI). UTD adalah suatu fasilitas pelayanan kesehatan yang melakukan kegiatan seperti pendonoran darah, penyediaan darah dan penyaluran darah, sementara PMI yaitu suatu organisasi perhimpunan nasional Indonesia yang bergerak di bagian kesehatan dan sosial kemanusiaan [2]. Masalah yang umumnya terjadi pada UTD PMI adalah permintaan darah yang tidak bisa terpenuhi dikarenakan ketersediaan darah yang kurang dan sulit dikontrol. Hal ini menjadikan pasien mengalami kesulitan untuk mencari pendonor yang tepat. Oleh sebab itu, dibutuhkan analisis statistik yang diharapkan dapat memberikan bantuan

kepada UTD PMI dalam mempersiapkan stok darah yang cukup kedepannya. Analisis statistik yang dilakukan yaitu dengan melakukan prediksi permintaan darah untuk waktu kedepan. Sehingga dengan informasi yang telah didapatkan, UTD PMI diharapkan dapat meningkatkan pelayanan kebutuhan stok darah bagi pasien.

Sebuah upaya dalam melakukan pendugaan atau melakukan prediksi apa yang akan terjadi pada waktu kedepan dengan memanfaatkan nilai-nilai pada waktu sebelumnya menggunakan suatu metode ilmiah biasa disebut dengan prediksi [3]. Prediksi memiliki tujuan untuk memperoleh informasi yang akan terjadi kedepannya dengan kemungkinan-kemungkinan terbesar. Untuk melakukan prediksi kedepannya digunakan ilmu statistik dengan cara pengumpulan data, pengolahan, analisis dan menarik kesimpulan. Ilmu statistik yang dapat dilakukan yaitu salah satunya menggunakan analisis deret waktu.

Analisis deret waktu yaitu analisis yang memiliki tujuan untuk mengidentifikasi data deret waktu dengan memanfaatkan pengamatan masa lalu untuk melakukan prediksi kedepannya. Data dikumpulkan secara sistematis secara berkala, baik dalam harian, mingguan, bulanan maupun dalam tahunan [4]. *Autoregressive integrated moving average* (ARIMA) adalah salah satu model yang seringkali digunakan untuk pemodelan deret waktu karena sangat baik untuk memprediksi. Model ARIMA yang digunakan untuk prediksi adalah model ARIMA terbaik dengan mempertimbangkan AIC (*Akaike's information criterion*) terkecil. Setelah didapat model ARIMA terbaik, langkah berikutnya melakukan estimasi atau perkiraan parameter menggunakan *Kalman filter*. *Kalman filter* adalah perkiraan parameter yang bisa meminimumkan nilai kesalahan dari estimasi parameter ARIMA biasa menggunakan *maximum likelihood*. Metode ini merupakan komponen dari *state space* yang bisa diimplementasikan pada model prediksi. *Kalman filter* menggunakan teknik rekrusif dalam menggabungkan observasi terkini ke dalam model dengan tujuan melakukan koreksi dari prediksi terdahulu dan melakukan prediksi kedepannya sebaik mungkin dari informasi yang diperoleh sebelumnya dan informasi kedepannya. Penggunaan *Kalman filter* memiliki dampak yang baik terhadap keakuratan hasil peramalan yang ditunjukkan dari *mean absolute percentage error* (MAPE) yang lebih rendah. Semakin rendah nilai MAPE maka ketepatan untuk hasil prediksi semakin dekat [5]. Sukarna, Ananda, dan Wahyuni pada tahun 2021 melakukan suatu penelitian yaitu meramalkan curah hujan Makassar menggunakan ARIMA dan *Kalman filter*. Hasil penelitian menunjukkan bahwa nilai MAPE menggunakan *Kalman Filter* lebih kecil yaitu 47,000 dibandingkan dengan ARIMA sebesar 111,480 [6].

## 2. KAJIAN PUSTAKA

### 2.1 Transfusi Darah

Darah merupakan cairan pada jaringan ikat pada tubuh yang memiliki fungsi guna membawa berbagai jenis zat seperti oksigen, karbon dioksida, nutrisi, gula dan hormone ke organ-organ tubuh. Terdapat beberapa komponen dalam pembentukan darah, yaitu sel darah merah (*eritrosit*), sel darah putih (*leukosit*), keping darah (*trombosit*), dan plasma darah [7]. Pasien dengan kekurangan darah melakukan permintaan darah pada suatu unit layanan kesehatan yaitu Unit Transfusi Darah (UTD). UTD adalah unit yang didirikan oleh Palang Merah Indonesia (PMI) dengan tujuan untuk memberikan pelayanan terkait penyediaan darah serta layanan terkait donor darah [8]. PMI adalah sebuah badan nasional yang berusaha di bagian sosial kemanusiaan. Penataan dan pelaksanaan kegiatan transfusi darah yang diperintahkan untuk PMI atau organisasi

lain yang ditetapkan oleh Menteri Kesehatan adalah pekerjaan utama PMI yang dijelaskan dalam Peraturan Pemerintah No. 18/1980 Bab IV, pasal 6, ayat (1) [1].

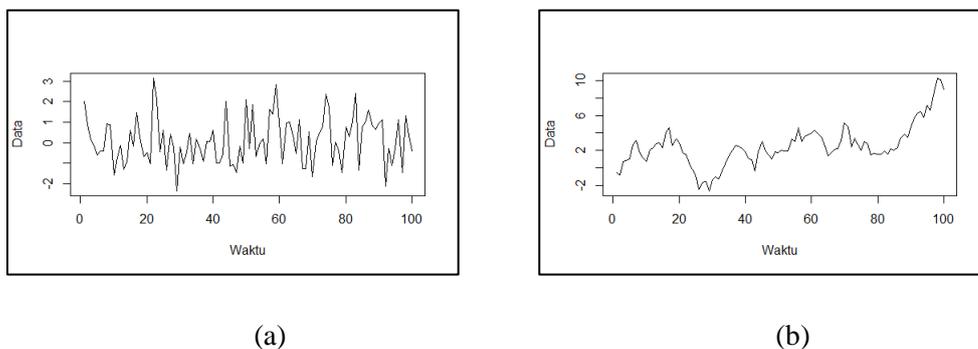
## 2.2 Analisis Deret Waktu

Suatu proses yang dibangun pada urutan waktu tertentu yang digunakan guna melakukan peramalan adalah analisis deret waktu [9]. Data deret waktu dapat dilihat secara visualisasi melalui pola deret waktu pada grafik yang ditandai dengan gerakan ke atas dan ke bawah. Gambaran grafik tersebut dapat berfungsi sebagai dasar untuk melihat plot garis arah perkembangan data. Analisis deret waktu dapat digunakan untuk mendapatkan perkiraan dari data beberapa waktu guna membentuk suatu perancangan.

Data deret waktu memiliki beberapa pola atau bentuk data yaitu, pola data horizontal, pola data trend, pola data musiman, dan pola data siklis dengan variasi acak [10]. Pola data horizontal terbentuk dari fluktuasi data yang berada di kisaran nilai rata-rata yang cenderung tetap. Pola data trend digambarkan sebagai pola data yang mengalami kenaikan atau penurunan dalam periode tertentu. Pola data musiman terbentuk apabila data disebabkan oleh faktor musiman yang cukup besar sehingga pola data naik dan turun mengalami perulangan dari satu periode ke periode selanjutnya. Kemudian yang terakhir pola data siklis adalah pola data yang tidak beraturan sepanjang sumbu waktu atau memiliki pola data yang acak. [11].

## 2.3 Stasioneritas Data

Stasioneritas terbagi dua yaitu stasioner dalam variansi (*varians*) dan stasioner dalam rataan (*mean*). Data yang stasioner dan tidak stasioner dapat dilihat secara visual pada Gambar 1.



Gambar 1. (a) Plot data stasioner dan (b) tidak stasioner

Data stasioner dalam variansi ketika bentuk data bersifat melintang sepanjang sumbu waktu (konstan). Sedangkan stasioner dalam rataan apabila fluktuasi data berada di dekat nilai rata-rata yang stabil atau tidak ditemukannya pola *trend* [12].

## 2.4 Model Autoregressive Integrated Moving Average

Model dari observasi yang telah dilakukan *differencing* adalah model *autoregressive integrated moving average* (ARIMA). Model ARIMA berorde  $(p, d, q)$  yaitu model yang menjelaskan data deret waktu yang memenuhi kondisi stasioner. Model ARIMA adalah kombinasi dari model AR ( $p$ ) dan MA ( $q$ ) yang mendapati proses *differencing* dengan orde  $d$ . Persamaan umum ARIMA dapat dilihat pada Persamaan (1) [13]:

$$\phi_p(B)(1 - B)^d Z_t = \theta_q(B)a_t \tag{1}$$

dengan  $(1 - B)^d$  merupakan *differencing* orde ke  $d$ ;  $B$  operator *Backward Shift*;  $\phi_p$  parameter AR ( $p$ );  $\theta_q$  parameter MA ( $q$ );  $Z_t$  data pada waktu ke  $t$ ; dan  $a_t$  merupakan nilai kesalahan pada observasi.

### 2.5 Identifikasi Orde

Identifikasi orde dalam analisis deret waktu dilakukan dengan cara melihat plot ACF dan PACF yang sesuai. Dalam analisis deret waktu, terdapat hubungan yang kuat antara model AR dan MA dengan ACF dan PACF. Terdapat beberapa identifikasi orde bentuk ACF dan PACF yang ditunjukkan pada Tabel 1. [13]

Tabel 1. Identifikasi orde AR, MA dan ARMA

Model	ACF	PACF
AR ( $p$ )	<i>Tail off</i> atau menurun secara eksponensial	<i>Cut off</i> atau berbeda nyata pada <i>lag- p</i>
MA ( $q$ )	<i>Cut off</i> atau berbeda nyata pada <i>lag- q</i>	<i>Tail off</i> atau menurun secara eksponensial
ARMA ( $p, q$ )	<i>Tail off</i> atau menurun secara eksponensial	<i>Tail off</i> atau menurun secara eksponensial

### 2.6 Uji Diagnostik Residual

Uji diagnostik residual terdiri dari autokorelasi residual dan uji normalitas. Untuk autokorelasi residual, residual dapat dikatakan saling bebas apabila nilai pada *lag-k* di dalam batas kepercayaan. Jika nilai pada *lag-k* melewati batas kepercayaan maka residual tidak saling bebas [14]. Sementara pada uji normalitas dapat menggunakan *Kolmogorov-Smirnov test* dengan kriteria pengambilan keputusan yaitu  $p\text{-value} < \alpha$  [15].

### 2.7 Kalman Filter

Suatu proses yang terdiri dari persamaan pengukuran dan persamaan transisi, serta memakai data pengukuran untuk menyempurnakan hasil estimasi adalah pengertian dari *Kalman filter* [5]. Berikut Persamaan (2) dan (3) model *system* dan pengukuran *Kalman filter* dalam estimasi parameter model ARIMA [16].

$$\mathbf{x}_{t+1} = \mathbf{A}_t \mathbf{x}_t + \mathbf{w}_t \tag{2}$$

$$z_t = \mathbf{H} \mathbf{x}_t + \mathbf{v}_t \tag{3}$$

dengan:

- $\mathbf{x}_{t+1}$  : variabel *system* untuk waktu  $t + 1$
- $\mathbf{x}_t$  : variabel *system* untuk waktu  $t$  dengan nilai estimasi awal yaitu  $\bar{x}_0$  dan kovarian awal  $P_{x_0}$
- $\mathbf{w}_t$  : *noise* pada model *system* yang diperoleh dengan membangkitkan bilangan acak melalui program komputasi
- $z_t$  : variabel pengukuran
- $\mathbf{v}_t$  : *noise* pada model pengukuran
- $\mathbf{A}, \mathbf{H}$  : matriks konstan pengukuran dengan  $\mathbf{A} = m \times m$ ,  $\mathbf{H} = m \times 1$

Untuk nilai  $m$  merupakan banyaknya parameter pada model ARIMA ditambah dengan nilai pada data pertama ( $Z_1$ ). Sebagai ilustrasi pada model  $AR(1)$  dengan koefisien  $\phi_1$  yang dapat dilihat pada Persamaan (4).

$$Z_t = \phi_1 Z_{t-1} + a_t \quad (4)$$

matriksnya ditunjukkan pada persamaan (5):

$$\mathbf{x}_t = \begin{bmatrix} \phi_1 \\ Z_1 \end{bmatrix} \quad (5)$$

Kemudian untuk matriks konstan pengukuran misalnya pada matriks  $\mathbf{A}$  ditunjukkan pada persamaan (6) [9]

$$\mathbf{A} = \begin{bmatrix} 1 & 0 \\ Z_{t-1} & 0 \end{bmatrix} \quad (6)$$

*Kalman Filter* terbagi menjadi beberapa tahapan yaitu [16]

1. Inisialisasi nilai awal pada persamaan (7):

$$\mathbf{P}_0 = \mathbf{P}_{x_0}, \hat{\mathbf{x}}_0 = \bar{\mathbf{x}}_0 \quad (7)$$

dengan:

$\bar{\mathbf{x}}_0$  : inisialisasi nilai awal yang diperoleh dari nilai parameter sebelumnya

$\mathbf{P}_0$  : kovarian *error* nilai awal dengan  $\mathbf{P}_0 = \mathbf{I}$  atau matriks identitas

2. Prediksi pada persamaan (8) dan (9):

$$\hat{\mathbf{x}}_{t+1}^- = \mathbf{A}_t \hat{\mathbf{x}}_t + \mathbf{w}_t \quad (8)$$

$$\mathbf{P}_{t+1}^- = \mathbf{A}_t \mathbf{P}_t \mathbf{A}_t^T + \mathbf{Q}_t \quad (9)$$

3. Koreksi dengan melibatkan  $\mathbf{K}_{t+1}$  yaitu *Kalman gain* yang merupakan suatu nilai untuk memperbaiki nilai estimasi pada tahap prediksi. Nilai ini umumnya berkisar antara 0 hingga 1. Jika nilai *Kalman gain* mendekati 1 maka hasil pengukuran lebih akurat [17]. Persamaan *Kalman Gain* dapat dilihat pada persamaan (10).

$$\mathbf{K}_{t+1} = \mathbf{P}_{t+1}^- \mathbf{H}_{t+1}^T (\mathbf{H}_{t+1} \mathbf{P}_{t+1}^- \mathbf{H}_{t+1}^T + \mathbf{R}_{t+1})^{-1} \quad (10)$$

$$\hat{\mathbf{x}}_{t+1} = \hat{\mathbf{x}}_{t+1}^- + \mathbf{K}_{t+1} [z_{t+1} - \mathbf{H}_{t+1} \hat{\mathbf{x}}_{t+1}^-] \quad (11)$$

$$\mathbf{P}_{t+1} = (\mathbf{I} - \mathbf{K}_{t+1} \mathbf{H}_{t+1}) \mathbf{P}_{t+1}^- \quad (12)$$

dengan:

$\hat{\mathbf{x}}_{t+1}^-$  : matriks nilai estimasi tahapan prediksi

$\mathbf{P}_{t+1}^-$  : matriks nilai kovarian *error* tahapan prediksi

$\hat{\mathbf{x}}_{t+1}$  : matriks nilai estimasi tahapan koreksi

$\mathbf{P}_{t+1}$  : matriks nilai kovarian *error* tahapan koreksi

## 2.8 Ukuran Ketepatan Model

*Mean absolute percentage error* (MAPE) dihitung dengan menemukan nilai tengah dalam satuan persentase, yang memiliki fungsi untuk memverifikasi keakuratan dalam peramalan [18]. Bentuk umumnya dapat ditulis pada persamaan (13).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Z_t - \hat{Z}_t|}{Z_t} \times 100\% \quad (13)$$

dengan:

$n$  : banyak observasi

$Z_t$  : nilai aktual ke-  $t$

$\hat{Z}_i$  : nilai prediksi ke-  $t$

Jika nilai MAPE kurang dari 10% prediksi dikategorikan sangat baik, jika kisaran antara 10%-20% maka prediksi dikategorikan baik, kemudian untuk 20%-50% prediksi dikategorikan cukup baik, dan jika melebihi dari 50% prediksi dikategorikan buruk.

Selain MAPE, untuk melihat keakuratan dalam prediksi yaitu dilihat dari nilai *root mean squared error* (RMSE) yang merupakan akar dari nilai *mean error* yang dihasilkan oleh suatu metode atau perbedaan dari nilai observasi dan hasil prediksi yang dikuadratkan. Nilai RMSE cenderung menonjolkan penyimpangan besar karena istilah kuadrat [19]. Perhitungan untuk mencari RMSE dapat dilihat pada Persamaan (14) sebagai berikut:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2} \quad (14)$$

dengan:

$n$  : banyak observasi

$Z_t$  : nilai aktual ke- $t$

$\hat{Z}_i$  : nilai prediksi ke-  $t$

Alat ukur lainnya untuk menghitung keakuratan dalam peramalan adalah *Akaike's information criterion* (AIC). Kriteria yang dikenal sebagai AIC dapat menyeimbangkan kesesuaian model pada nilai *likelihood* dengan berbagai parameternya. Model dengan AIC paling kecil adalah model yang paling baik. Nilai AIC didapat dari persamaan (15) [13].

$$AIC = k \ln \hat{\sigma}_a^2 + 2n \quad (15)$$

dengan:

$k$  : jumlah parameter pada model ARIMA

$\hat{\sigma}_a^2$  : estimasi *maximum likelihood* bagi  $\sigma_a^2$

$n$  : banyaknya observasi

## 3. METODE PENELITIAN

Pada penelitian ini observasi yang digunakan diambil dari Unit Transfusi Darah (UTD) PMI Kota Pontianak periode Januari hingga Desember tahun 2023 yang berjumlah 365 observasi. Observasi yang dimodelkan dalam penelitian ini adalah observasi harian jumlah permintaan darah periode 1 Januari hingga 26 November 2023 sebagai *in-sampel* sebanyak 360 observasi dan

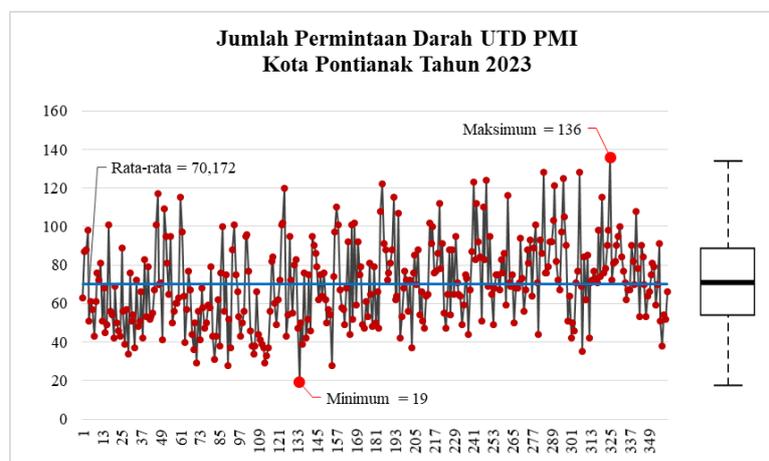
jumlah permintaan darah periode 27 sampai 31 Desember 2023 yang berjumlah 5 observasi sebagai *out-sampel* digunakan untuk membandingkan hasil prediksi dari model dengan data aktual. Satuan yang digunakan untuk observasi permintaan darah adalah kantong.

Langkah pertama dalam menganalisis data yaitu menginput data jumlah permintaan darah yang terbagi dari data *in-sample* dan *out-sample*. Data periode 1 Januari sampai 26 Desember sebagai *in-sample* dan data 27 Desember sampai 31 Desember sebagai *out-sample*. Langkah selanjutnya yaitu membentuk plot data guna melihat pola pada data jumlah permintaan darah tahun 2023. Setelah itu, dilakukan uji stasioner data *in-sample* jumlah permintaan darah yang dilihat dari plot data. Transformasi dilakukan jika tidak memenuhi stasioneritas data dalam varians dan *differencing* dilakukan apabila stasioneritas dalam rata-rata tidak terpenuhi.

Setelah stasioneritas data terpenuhi, tahap berikutnya yaitu identifikasi orde model ARIMA yang diamati dari plot ACF dan PACF. Kemudian, dengan model ARIMA yang didapat dilakukan estimasi parameter dan uji diagnostik. Setelah melakukan uji diagnostik maka didapat model ARIMA paling baik yang mempunyai nilai AIC, MAPE dan RMSE paling kecil. Selanjutnya untuk meminimumkan nilai kesalahan dari estimasi sebelumnya, dilakukan suatu estimasi parameter dari model ARIMA terbaik yang didapat yaitu menggunakan *Kalman filter*. Tahapan dalam *Kalman filter* meliputi tahapan inisialisasi nilai awal, tahap prediksi dan tahap koreksi. Tahapan inisialisasi awal yaitu menggunakan nilai parameter dari model ARIMA yang telah diperoleh sebelumnya. Kemudian dilakukan tahap prediksi dengan membuat perkiraan tentang keadaan *system* pada waktu berikutnya. Setelah tahap prediksi yaitu tahap koreksi dengan melibatkan *Kalman gain* yang menentukan sejauh mana informasi dan pengukuran diintegrasikan ke dalam estimasi status. Setelah dilakukan tahapan-tahapan tersebut, maka selanjutnya memprediksi jumlah permintaan darah dengan model ARIMA-*Kalman Filter* untuk tiga hari kedepan.

#### 4. HASIL DAN PEMBAHASAN

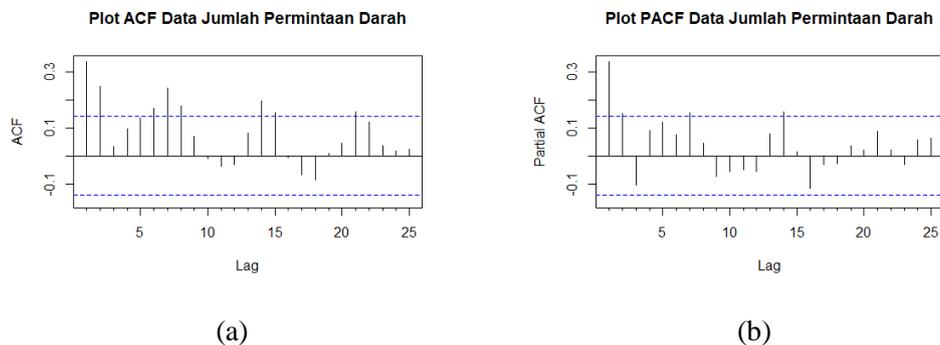
Data jumlah permintaan darah UTD PMI Kota Pontianak tahun 2023 yang digunakan dalam pemodelan yaitu sebanyak 360 data. Deskripsi data jumlah permintaan darah bisa diamati pada Gambar 2 sebagai berikut.



Gambar 2. Plot data jumlah permintaan darah

Berdasarkan Gambar 2 diketahui bahwa rata-rata jumlah permintaan darah UTD PMI Kota Pontianak sebanyak 70 kantong darah per harinya. Jumlah permintaan darah paling rendah terjadi pada bulan Mei yaitu sejumlah 19 kantong. Jumlah permintaan darah tertinggi terjadi pada bulan November yaitu sejumlah 136 kantong. Selanjutnya pada *boxplot* yang terdapat di Gambar 2 memperlihatkan bahwa data bersifat distribusi normal yang disebabkan garis median terletak di tengah *box* dan *upper whisker* mempunyai panjang yang setara dengan *lower whisker* serta tidak terdapat nilai *outlier*. Selanjutnya yaitu dilakukan uji stasioneritas pada data untuk melihat stasioneritas data sudah terpenuhi atau belum. Uji stasioneritas yang dikerjakan yaitu uji stasioner terhadap variansi dan uji stasioner terhadap rata-rata. Berdasarkan Gambar 1 dapat dilihat secara visual bahwa data tersebut memiliki pola horizontal, dimana ini merupakan pola dari stasioneritas data yang terpenuhi. Selain itu, dilihat dari *augmented Dickey fuller test* (ADF) dengan bantuan *software* R Studio diperoleh nilai *p-value* sebesar 0,01 yang artinya nilai  $p\text{-value} < \alpha$  ( $\alpha = 0,05$ ). Hal ini dapat disimpulkan bahwa data jumlah permintaan darah sudah stasioner.

Setelah dilakukan uji stasioner, langkah selanjutnya yaitu identifikasi orde. Identifikasi orde bisa diamati dari plot ACF dan plot PACF pada Gambar 3.



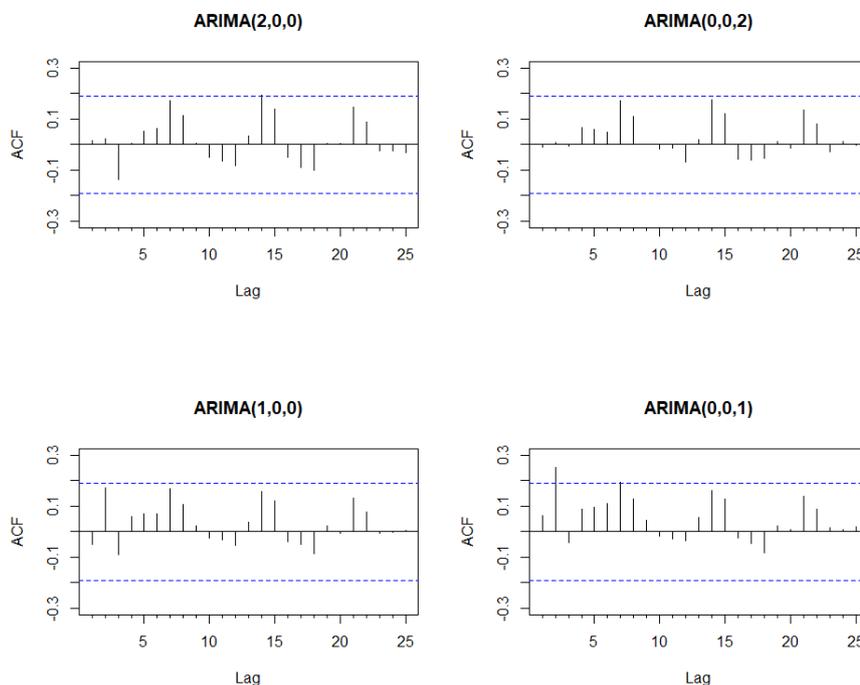
Gambar 3. (a) Plot ACF dan (b) plot PACF

Pada Gambar 3 bisa diamati bahwa pada plot ACF terjadi *tail off* setelah lag 1 sedangkan plot PACF terjadi *cut off* setelah lag 2 sehingga didapat beberapa kemungkinan model yang terbentuk yaitu ARIMA (0,0,2), ARIMA (2,0,0), ARIMA (1,0,0), ARIMA (0,0,1). Setelah diperoleh beberapa kemungkinan model, langkah selanjutnya yaitu estimasi parameter. Dengan memakai *maximum likelihood estimation* yang dibantu oleh *software* R Studio didapat nilai parameter untuk masing-masing model yang bisa diamati pada Tabel 2.

Tabel 2. Estimasi parameter

Model ARIMA	Koefisien	<i>P-Value</i>
ARIMA (2,0,0)	$\phi_1$	0,286
	$\phi_2$	0,139
ARIMA (0,0,2)	$\theta_1$	0,311
	$\theta_2$	0,246
ARIMA (1,0,0)	$\phi_1$	0,333
ARIMA (0,0,1)	$\theta_1$	0,240

Setelah diperoleh nilai estimasi parameter dari masing-masing model pada data *in-sample* jumlah permintaan darah UTD PMI Kota Pontianak. Beberapa model tersebut berikutnya dilakukan pengecekan uji diagnostik residual untuk memperoleh model yang asumsi *white noise* terpenuhi. Hasil uji diagnostik dibagi menjadi dua yaitu diamati dari plot ACF dan uji normalitas. Plot ACF bisa diperhatikan pada Gambar 4.



Gambar 4. Plot ACF autokorelasi residual

Berdasarkan Gambar 4 dapat dilihat bahwa model ARIMA (2,0,0) dan ARIMA (0,0,1) residual tidak saling bebas. Sedangkan pada uji normalitas menggunakan *Kolmogorov-Smirnov test* yang bisa diperhatikan dari Tabel 3.

Tabel 3. Hasil *Kolmogorov-Smirnov test*

Model	<i>P-value</i>
ARIMA (2,0,0)	0,233
ARIMA (0,0,2)	0,438
ARIMA (1,0,0)	0,463
ARIMA (0,0,1)	0,681

Berdasarkan Tabel 2 dapat dilihat bahwa nilai *p – value* > 0,05, sehingga bisa diambil kesimpulan bahwa semua model memiliki residual berdistribusi normal. Sehingga model yang uji asumsi *white noise* dan normalitas terpenuhi yaitu ARIMA (0,0,2) dan ARIMA (1,0,0). Selanjutnya untuk penentuan model ARIMA paing baik bisa dilakukan dengan membandingkan AIC, MAPE dan RMSE terkecil. Perbandingan nilai AIC, MAPE, dan RMSE bisa diperhatikan dari Tabel 4.

Tabel 4. Nilai AIC, MAPE dan RMSE

Model ARIMA	AIC	MAPE	RMSE
ARIMA (0,0,2)	<b>3189,440</b>	<b>26,394</b>	<b>20,074</b>
ARIMA (1,0,0)	3197,960	26,767	20,372

Dari Tabel 4 bisa diperhatikan bahwa model ARIMA (0,0,2) menunjukkan nilai AIC, MAPE dan RMSE yang paling kecil, maka dari itu model ARIMA (0,0,2) adalah model yang paling baik. Berdasarkan penentuan model terbaik maka didapat persamaan model ARIMA (0,0,2) adalah:

$$Z_t = a_t - 0,311a_{t-1} - 0,246a_{t-2}$$

Selanjutnya dilakukan kembali estimasi parameter menggunakan *Kalman filter* untuk memperkecil kesalahan dalam prediksi pada model sebelumnya yang menggunakan *maximum likelihood estimation*. Tahapan pertama yang dilakukan dalam estimasi parameter dengan *Kalman filter* yaitu menentukan model ruang keadaan. Pada bagian ini menggunakan data *in-sampel* untuk mengestimasi model ARIMA dengan orde yang sama.

Estimasi parameter pada *Kalman filter* menggunakan model ARIMA terbaik yang sebelumnya diperoleh yaitu model ARIMA (0,0,2). Matriksnya ditentukan dengan menggunakan parameter dari model ARIMA (0,0,2) yang terdapat dua komponen *moving average* (MA) yaitu MA  $\theta_1$  dan  $\theta_2$ . Adapun matriksnya dapat dilihat sebagai berikut:

$$\begin{aligned} \mathbf{x}_t &= \mathbf{A}\mathbf{x}_t + \mathbf{w}_t \\ \begin{bmatrix} \theta_1 \\ \theta_2 \\ Z_t \end{bmatrix}_{t+1} &= \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ a_{t-1} & a_{t-2} & 0 \end{bmatrix} \begin{bmatrix} \theta_1 \\ \theta_2 \\ Z_t \end{bmatrix}_t + \mathbf{w}_t \end{aligned}$$

dengan model pengukuran:

$$z = [0 \quad 0 \quad 1] \begin{bmatrix} \theta_1 \\ \theta_2 \\ Z_t \end{bmatrix} + \mathbf{v}_t$$

Sesudah didapat model *system* dan pengukuran, maka berikutnya dilakukan inisialisasi nilai awal. Pada inisialisai, nilai awal  $Z_t$  diambil dari data pertama jumlah permintaan darah yang ditunjukkan sebagai berikut:

Kovarian *error* model *system*:

$$\mathbf{R} = 10^{-6}$$

Kovarian *error* model pengukuran:

$$\mathbf{Q}_0 = \begin{bmatrix} 10^{-6} & 0 & 0 \\ 0 & 10^{-6} & 0 \\ 0 & 0 & 10^{-6} \end{bmatrix}$$

Adapun nilai  $10^{-6}$  diperoleh dari ketetapan beberapa peneliti [9].

Nilai estimasi awal diambil dari nilai estimasi parameter sebelumnya dan data pertama:

$$\hat{\mathbf{x}}_0 = \begin{bmatrix} 0,311 \\ 0,246 \\ 63,000 \end{bmatrix}$$

Nilai awal kovarian *error*:

$$\mathbf{P}_0 = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

Berikutnya langkah prediksi pada iterasi pertama:

$$\begin{aligned}\hat{\mathbf{x}}_1^- &= \mathbf{A}_0 \hat{\mathbf{x}}_0 + \mathbf{w}_0 \\ &= \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 0,311 \\ 0,246 \\ 63 \end{bmatrix} + \begin{bmatrix} -0,108 \\ 0,002 \\ -0,179 \end{bmatrix} \\ &= \begin{bmatrix} 0,203 \\ 0,246 \\ -0,179 \end{bmatrix}\end{aligned}$$

$$\begin{aligned}\mathbf{P}_1^- &= \mathbf{A}_0 \mathbf{P}_0 \mathbf{A}_0^T + \mathbf{Q}_0 \\ &= \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 10^{-6} & 0 & 0 \\ 0 & 10^{-6} & 0 \\ 0 & 0 & 10^{-6} \end{bmatrix} \\ &= \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}\end{aligned}$$

Tahapan koreksi:

Pada tahapan koreksi, nilai *Kalman Gain* dilibatkan yang dapat dilihat sebagai berikut.

$$\begin{aligned}\mathbf{K}_1 &= \mathbf{P}_1^- \mathbf{H}_1^T (\mathbf{H}_1 \mathbf{P}_1^- \mathbf{H}_1^T + \mathbf{R}_1)^{-1} \\ &= \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \times \left( \begin{bmatrix} 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} + 10^{-6} \right)^{-1} \\ &= \begin{bmatrix} 0 \\ 0 \\ 0,999 \end{bmatrix}\end{aligned}$$

Selanjutnya untuk nilai  $\mathbf{P}_{t+1}$  dihitung dengan nilai  $\mathbf{P}_{t+1}^-$  yang didapat dari langkah prediksi.

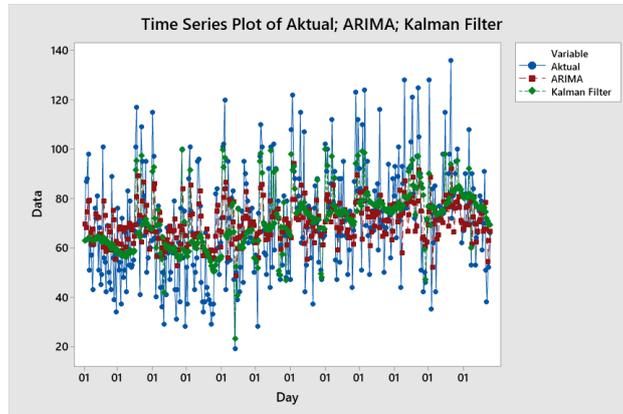
$$\begin{aligned}\mathbf{P}_1 &= (\mathbf{I} - \mathbf{K}_1 \mathbf{H}_1) \mathbf{P}_1^- \\ &= \left( \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} - \begin{bmatrix} 0 \\ 0 \\ 0,999 \end{bmatrix} \begin{bmatrix} 0 & 0 & 1 \end{bmatrix} \right) \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \\ &= \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}\end{aligned}$$

Kemudian nilai  $\hat{\mathbf{x}}_{t+1}$  diperkirakan dengan menggunakan nilai  $\hat{\mathbf{x}}_{t+1}^-$  yang didapat dari langkah prediksi.

$$\begin{aligned}\hat{\mathbf{x}}_1 &= \hat{\mathbf{x}}_1^- + \mathbf{K}_1 (z_1 - \mathbf{H}_1 \hat{\mathbf{x}}_1^-) \\ &= \begin{bmatrix} 0,203 \\ 0,246 \\ -0,179 \end{bmatrix} + \begin{bmatrix} 0 \\ 0 \\ 0,999 \end{bmatrix} \left( \left( \begin{bmatrix} 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 0,311 \\ 0,246 \\ 63,000 \end{bmatrix} + \begin{bmatrix} -0,108 \\ 0,002 \\ -0,181 \end{bmatrix} \right) - \begin{bmatrix} 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} 0,203 \\ 0,246 \\ 62,821 \end{bmatrix} \right)\end{aligned}$$

$$= \begin{bmatrix} 0,311 \\ 0,245 \\ 62,819 \end{bmatrix}$$

dilakukan iterasi sebanyak 360 kali atau sebanyak jumlah observasi *in-sample*. Kemudian dapat dilihat plot dari perbedaan data aktual, hasil prediksi model ARIMA dan ARIMA-Kalman filter pada Gambar 5.



Gambar 5. Plot perbandingan data aktual, ARIMA dan ARIMA-Kalman filter

Pada Gambar 5 dapat dilihat bahwa plot hasil peramalan ARIMA-Kalman filter cenderung mendekati observasi aktual. Selanjutnya juga dibuktikan pada perbandingan prediksi *out-sample* model ARIMA dan ARIMA-Kalman filter selama lima hari kedepan untuk mengevaluasi model yang ditunjukkan pada Tabel 5.

Tabel 5. Perbandingan hasil prediksi

Tanggal	Data Aktual	ARIMA	ARIMA-Kalman filter
27/12/2023	54	67,259	70,203
28/12/2023	98	69,969	71,928
29/12/2023	78	70,145	72,821
30/12/2023	74	70,145	72,392
31/12/2023	80	70,145	72,256
<b>MAPE</b>		<b>16,151%</b>	<b>15,021%</b>
<b>RMSE</b>		<b>15,068</b>	<b>14,364</b>

Berdasarkan Tabel 5 bisa diperhatikan bahwa hasil prediksi pada model ARIMA dan ARIMA-Kalman filter. Perbandingan nilai MAPE dan RMSE dari hasil prediksi ARIMA-Kalman filter lebih rendah dari model ARIMA biasa, sehingga dapat dikatakan bahwa ARIMA-Kalman filter mempunyai kemampuan prediksi yang lebih baik. Oleh karena itu, dilakukan prediksi tiga hari kedepan menggunakan ARIMA-Kalman filter pada Tabel 6.

Tabel 6. Prediksi jumlah permintaan darah tiga hari kedepan

Tanggal	ARIMA-Kalman Filter
01/01/2024	72,100
02/01/2024	71,919
03/01/2024	72,209

Persamaan model dapat dilihat sebagai berikut:

$$Z_t = a_t - 0,313a_{t-1} - 0,248a_{t-2}$$

## 5. KESIMPULAN

Berdasarkan analisis yang telah dilakukan hasil analisis memperlihatkan model yang diperoleh untuk prediksi jumlah permintaan darah bulan Desember 2023 adalah model ARIMA (0,0,2). Estimasi parameter pada model ARIMA (0,0,2) menggunakan *Kalman filter* yang diperoleh nilai MAPE sebesar 15,021% dan nilai RMSE sebesar 14,364 yang dapat disimpulkan bahwa model yang dipakai termasuk ke kategori baik dan pantas untuk digunakan dalam prediksi. Hasil prediksi menunjukkan bahwa dengan menggunakan metode ARIMA dan *Kalman filter*, diharapkan UTD PMI Kota Pontianak dapat mempersiapkan stok darah yang cukup untuk pasien yaitu sebanyak 72 kantong atau lebih sehingga dapat meminimalisir pasien yang kekurangan stok darah. Sementara itu, untuk penelitian berikutnya diharapkan bisa meneliti terkait pengembangan dari metode ini seperti menggunakan parameter yang semakin kompleks untuk mendapatkan hasil prediksi yang lebih akurat atau melakukan perbandingan dari pengembangan metode *Kalman filter* seperti *extended Kalman filter* (EKF) atau *unscented Kalman filter* (UKF) untuk menanggapi outlier jika dalam observasi terdeteksi *outlier*.

## DAFTAR PUSTAKA

- [1] F. A. Yul, S. N. Meirizha, dan W. Laila, "Pengendalian persediaan darah dengan metode continuous review system pada Palang Merah Indonesia (PMI) Kota Pekanbaru," *Photon: Jurnal Sain dan Kesehatan*, vol. 9, no. 2, pp. 49–57, 2019, doi: 10.37859/jp.v9i2.1119.
- [2] A. Rakhman dan A. Y. F. Sabanise, "Sistem informasi stok kebutuhan darah pada palang merah indonesia metode moving average," *Jurnal Ilmiah Indonesia*, vol. 4, no. 7, 2019.
- [3] A. Wanto dan A. P. Windarto, "Analisis prediksi indeks harga konsumen berdasarkan kelompok kesehatan dengan menggunakan metode backpropagation," *Jurnal & Penelitian Teknik Informatika Sinkron*, vol. 2, no. 2, pp. 37–43, 2017, [Daring]. Tersedia pada: <https://zenodo.org/record/1009223#.Wd7norITbhQ>
- [4] H. A. Maulana, "Pemodelan deret waktu dan peramalan curah hujan pada dua belas stasiun di Bogor," *Jurnal Matematika Statistika dan Komputasi*, vol. 15, no. 1, pp. 50, 2018, doi: 10.20956/jmsk.v15i1.4424.
- [5] T. Kurniawan, L. Hanafi, dan E. Apriliani, "Penerapan metode filter Kalman dalam perbaikan hasil prediksi cuaca dengan metode ARIMA," *Jurnal Sains Dan Seni ITS*, vol. 3, no. 2, hal. 28–33, 2014, [Daring]. Tersedia pada: [http://ejournal.its.ac.id/index.php/sains\\_seni/article/view/7984](http://ejournal.its.ac.id/index.php/sains_seni/article/view/7984)
- [6] S. Sukarna, E. Y. P. Ananda, dan M. S. Wahyuni, "Rainfall forecasting model using arima and Kalman filter in Makassar, Indonesia," *Journal of Physics: Conference Series*, vol. 2123, no. 1, 2021, doi: 10.1088/1742-6596/2123/1/012044.
- [7] R. Arviananta, S. Syuhada, dan A. Aditya, "Perbedaan jumlah eritrosit antara darah segar dan darah simpan," *Jurnal Ilmiah Kesehatan Sandi Husada*, vol. 12, no. 2, pp. 686–694, 2020, doi: 10.35816/jiskh.v12i2.388.
- [8] I. H. Marysa dan A. W. Anggraita, "Studi pengaruh warna pada interior terhadap psikologis penggunaanya, studi kasus pada unit transfusi darah Kota X," *JURNAL DESAIN INTERIOR*, vol. 1, no. 1, pp. 41–50, 2016.

- [9] W. A. Mehta, Y. Sukmawaty, dan Khairullah, "Rainfall prediction climatological station of Banjarbaru using arima kalman filter," *Journal of Physics: Conference Series*, vol. 2106, no. 1, 2021, doi: 10.1088/1742-6596/2106/1/012003.
- [10] H. Kusdarwati, U. Effendi, dan S. Handoyo, *Analisis Deret Waktu Univariat Linier*. Malang: UB Press Malang, 2022.
- [11] J. . Hanke dan D. . Wichern, "Business Forecasting Eight Edition," *New Jersey: Pearson Prenticehall.*, 2005.
- [12] N. W. Y. Cahyani, I. G. A. M. Srinadi, dan M. Susilawati, "Perbandingan transformasi box-cox," *E-Jurnal Matematika*, vol. 4, no. 1, pp. 8–13, 2015.
- [13] W. W. Wei, "Time Series Analysis, Univariate and Multivariate Method Second Edition," *New York: Pearson Education.*, 2006.
- [14] N. M. Huda dan N. Imroah, *Pengantar Analisis Deret Waktu Studi Kasus: Data Kalimantan Barat Dengan Aplikasi R*. Pontianak: UNTAN PRESS, Pontianak, 2023.
- [15] G. Mokolang, Y. A. R. Langi, dan M. L. Mananohas, "Prediksi harga saham Kimia Farma dan saham Netflix di era new normal menggunakan model autoregressive integrated moving average," *Jurnal Matematika dan Aplikasi*, vol. 11, no. 1, pp. 23–31, 2022, [Daring]. Tersedia pada: <https://ejournal.unsrat.ac.id/index.php/decartesian>
- [16] F. L. Lewis, L. Xie, dan D. Popa, *Optimal and Robust Estimation: With an Introduction to Stochastic Control Theory*. CRC Press, 2008. doi: 10.1201/9781315221656.
- [17] D. J. Simon, "Kalman Filtering," vol. 14, no. 6, pp. 72–79, 2001.
- [18] U. Khair, H. Fahmi, S. Al Hakim, dan R. Rahim, "Forecasting error calculation with mean absolute deviation and mean absolute percentage error," *Journal of Physics: Conference Series*, 2017.
- [19] R. T. Prasetyo, "Inventory control using statistics forecasting on manufacture company," *Jurnal Informatika*, vol. 1, no. 2, pp. 136–142, 2014, doi: 10.31311/ji.v1i2.45.