

Peramalan Tingkat Inflasi di Indonesia Menggunakan Pendekatan *Bayesian Vector Autoregressive* (BVAR)

Widyanti Rahayu^{1*}, Farah Dhiya Fadilah², Vera Maya Santi³

^{1,2,3} Universitas Negeri Jakarta, Jl. Rawamangun Muka, Kec. Pulogadung, Jakarta Timur, DKI Jakarta

^{1,2,3} Program Studi Statistika Universitas Negeri Jakarta Indonesia

e-mail: wrahayu@unj.ac.id

Diajukan: 16 September 2025, Diperbaiki: 17 April 2026, Diterima: 5 Mei 2026

Abstrak

Inflasi merupakan indikator penting dalam menilai stabilitas ekonomi suatu negara. Pergerakan inflasi yang dipengaruhi oleh faktor domestik maupun global memerlukan metode peramalan yang akurat. Penelitian ini bertujuan untuk meramalkan tingkat inflasi di Indonesia dengan menggunakan pendekatan *Bayesian Vector Autoregressive* (BVAR) dan membandingkan hasilnya dengan model klasik *Vector Autoregressive* (VAR). Variabel yang digunakan meliputi tingkat inflasi, *BI Rate*, Indeks Harga Konsumen (IHK), dan nilai tukar mata uang USD (KURS), dengan cakupan data bulanan dari Januari 2010 hingga Desember 2024 yang bersumber dari *website* resmi Bank Indonesia (BI), Badan Pusat Statistik (BPS). Parameter model VAR diestimasi menggunakan metode *Maximum Likelihood Estimation* (MLE), sedangkan parameter model BVAR menggunakan *prior* Minnesota yang menghasilkan distribusi *posterior* secara analitik. Hasil penelitian diharapkan dapat memberikan kontribusi pada pencapaian *Sustainable Development Goals* (SDGs), khususnya SDG 8. Hasil peramalan selama 18 bulan menunjukkan bahwa model BVAR memberikan kinerja prediksi yang lebih baik dibandingkan VAR, dengan nilai MAPE sebesar 12,43% untuk BVAR dan 52,18% untuk VAR. Selain itu, analisis *Impulse Response Function* (IRF) menunjukkan bahwa inflasi merespons secara signifikan terhadap kejutan pada nilai tukar dan IHK dalam jangka pendek. Sementara itu, hasil *Forecast Error Variance Decomposition* (FEVD) menunjukkan bahwa variabilitas inflasi sebagian besar dijelaskan oleh dirinya sendiri, diikuti oleh kontribusi dari nilai tukar dan suku bunga. Hasil ini menunjukkan bahwa model BVAR dengan *prior* Minnesota lebih akurat dan stabil dalam meramalkan inflasi dibandingkan model VAR.

Kata Kunci: Inflasi, Peramalan, VAR, BVAR, *Prior* Minnesota

Abstract

Inflation is a key indicator of a country's economic stability, influenced by both domestic and global factors, making accurate forecasting essential for effective policy decisions. This study forecasts Indonesia's inflation rate using the *Bayesian Vector Autoregressive* (BVAR) approach and compares its performance with the classical *Vector Autoregressive* (VAR) model. The variables analyzed include the inflation rate, *BI Rate*, Consumer Price Index (CPI), and USD exchange rate (KURS), with monthly data from January 2010 to December 2024 obtained from Bank Indonesia (BI) and Central Bureau Statistics (BPS). VAR parameters were estimated using *Maximum Likelihood Estimation* (MLE), while BVAR parameters employed the Minnesota prior, enabling analytical posterior derivation. The research findings are expected to contribute to the achievement of the *Sustainable Development Goals* (SDGs), particularly SDG 8. Forecasting performance was assessed using predictive accuracy metrics. The 18-month forecasts indicate that BVAR outperforms VAR, with Mean Absolute Percentage Error (MAPE) values of 12.43% and 52.18%, respectively. *Impulse Response Function* (IRF) analysis reveals that inflation responds significantly to short-term shocks in the exchange rate and CPI. *Forecast Error Variance Decomposition* (FEVD) shows that inflation variability is primarily driven by its own shocks, followed by exchange rate and interest rate fluctuations. These findings demonstrate that the BVAR model with Minnesota prior

provides more accurate and stable inflation forecasts than the classical VAR approach, offering valuable insights for monetary policy formulation in Indonesia.

Keywords: *Inflation, Forecasting, VAR, BVAR, Minnesota Prior*

1 Pendahuluan

Inflasi merupakan salah satu indikator ekonomi yang penting dalam mengukur stabilitas suatu negara. Tingginya inflasi dapat mengurangi daya beli masyarakat, menekan konsumsi, dan menciptakan ketidakpastian bagi pelaku usaha dan investor. Sebaliknya, inflasi yang terlalu rendah bisa menunjukkan lemahnya permintaan domestik, yang dapat menghambat pertumbuhan ekonomi [1]. Oleh karena itu, pengendalian inflasi menjadi fokus utama kebijakan moneter di Indonesia. Bank Indonesia menetapkan target inflasi sebesar $2,5\% \pm 1\%$ pada tahun 2024 sebagai upaya menjaga stabilitas harga dan mendukung pertumbuhan ekonomi yang berkelanjutan [2]. Upaya menjaga stabilitas inflasi ini juga sejalan dengan pencapaian Tujuan Pembangunan Berkelanjutan (*Sustainable Development Goals/SDGs*), khususnya SDG 8 yang menekankan pentingnya pertumbuhan ekonomi yang inklusif dan berkelanjutan.

Pergerakan inflasi di Indonesia dipengaruhi oleh berbagai faktor makroekonomi seperti Indeks Harga Konsumen (IHK), kebijakan suku bunga (*BI Rate*), dan nilai tukar rupiah terhadap dolar Amerika Serikat [3]. Tren inflasi Indonesia dalam beberapa tahun terakhir mengalami fluktuasi tajam, khususnya pada masa krisis global dan pandemi COVID-19. Inflasi turun hingga di bawah 2% pada 2020–2021, meningkat mendekati 6% pada 2022, dan kembali turun ke 2,61% pada 2023. Hal ini menunjukkan perlunya metode peramalan yang adaptif dan mampu menangkap keterkaitan antar variabel makroekonomi secara dinamis, karena data ekonomi cenderung berfluktuasi dan memiliki pola musiman.

Peramalan adalah proses analisis data historis untuk memprediksi nilai variabel di masa mendatang [4]. Peramalan biasanya menggunakan data *time series* (deret waktu), dengan metode yang umum digunakan yaitu *Autoregressive Integrated Moving Average* (ARIMA) dan *Vector Autoregression* (VAR). ARIMA cocok untuk data univariat namun tidak dapat menangkap hubungan antar variabel. VAR dapat memodelkan hubungan multivariat, tetapi memiliki keterbatasan berupa *overparameterization* ketika jumlah variabel dan *lag* besar, sehingga estimasi menjadi tidak stabil [5]. Untuk mengatasi masalah ini, pendekatan *Bayesian Vector Autoregressive* (BVAR) dikembangkan dengan memasukkan informasi awal (*prior*) ke dalam proses estimasi [6]. Pemilihan *prior* menjadi aspek penting dalam pendekatan Bayesian karena dapat memengaruhi hasil estimasi. *Priors* yang lemah mencerminkan distribusi yang lebih lebar, sedangkan *priors* yang kuat menghasilkan interval sempit [7]. Salah satu *prior* yang populer adalah *Prior Minnesota*,

bekerja dengan cara menyusutkan (*shrinkage*) koefisien *lag* menuju nol seiring bertambahnya *lag*, sehingga mengurangi variabilitas estimasi dan meningkatkan akurasi peramalan [8].

Beberapa penelitian sebelumnya telah membuktikan keunggulan BVAR dalam peramalan inflasi dan variabel makroekonomi. Domit, dkk (2019) membandingkan BVAR dengan model struktural COMPASS dan menemukan bahwa BVAR memberikan hasil prediksi yang kompetitif [9]. Angelini, dkk (2019) menggunakan BVAR untuk peramalan lintas negara di Uni Eropa dan menemukan akurasi yang lebih baik dibanding VAR klasik [10]. Shapovalenko (2021) juga membuktikan keunggulan BVAR dalam memprediksi inflasi Ukraina dibanding model QPM [11]. Namun, kajian mengenai penerapan BVAR untuk memodelkan dan meramalkan inflasi di Indonesia, dengan keterkaitan antara inflasi, IHK, BI *Rate*, dan nilai tukar, masih relatif terbatas.

Penelitian ini bertujuan mengimplementasikan model BVAR dengan pendekatan *prior* Minnesota dalam pemodelan dan peramalan inflasi di Indonesia. Pendekatan Bayesian digunakan untuk mengatasi permasalahan *overparameterization* dan ketidakstabilan estimasi yang umum terjadi pada model VAR klasik, khususnya pada sistem multivariat dengan jumlah parameter yang besar. Kebaruan penelitian terletak pada penerapan kerangka BVAR berbasis *shrinkage prior* untuk menangkap dinamika interdependensi variabel makroekonomi secara lebih stabil, efisien, dan *robust* dalam konteks ekonomi Indonesia, yang masih terbatas dalam literatur empiris nasional. Hasil penelitian diharapkan memberikan kontribusi metodologis dalam pengembangan teknik peramalan deret waktu multivariat berbasis Bayesian sekaligus menghasilkan model prediksi inflasi dengan akurasi yang lebih baik dibandingkan pendekatan konvensional.

2 Metode Penelitian

2.1 Data Penelitian

Penelitian ini menggunakan data sekunder dari *website* resmi Bank Indonesia (BI), Badan Pusat Statistik (BPS), dan Satu Data Perdagangan. Jumlah data sebanyak 180 amatan dengan periode pengamatan dari Januari 2010 sampai Agustus 2024. Kemudian, data dibagi menjadi dua bagian, yaitu 90% untuk data latih, dan 10% untuk data uji [12]. Variabel penelitian secara lengkap disajikan pada Tabel 1.

Tabel 1. Variabel Penelitian

Notasi	Variabel	Skala
INF	Inflasi	Rasio
SBI	BI <i>Rate</i>	Rasio
IHK	Indeks Harga Konsumen	Rasio
KURS	Nilai Tukar Mata Uang (USD)	Rasio

2.2 Uji Stasioneritas

Model VAR dan BVAR memerlukan data stasioner, yaitu rata-rata dan varians konstan sepanjang waktu. Untuk menguji stasioneritas digunakan uji *Augmented Dickey-Fuller* (ADF). Jika $\phi = 1$ maka deret waktu tidak stasioner dalam rata-rata karena data tersebut memiliki akar unit [13], [14]. Dengan menggunakan *backshift operator* (B), persamaan AR(1) dapat ditulis sebagai:

$$(1 - B)Y_t = \delta Y_{t-1} + \varepsilon_t \quad (1)$$

Hipotesis nol menyatakan data tidak stasioner ($\delta = 0$). Jika $p\text{-value} < 0,05$ maka data stasioner; jika tidak, dilakukan transformasi seperti *differencing* atau Box-Cox [15].

2.3 Penentuan Lag Optimal

Panjang lag optimal ditentukan berdasarkan kriteria informasi seperti *Akaike Information Criteria* (AIC) [6], *Schwarz Information Criterion* (SIC), dan *Hannan-Quinn Criterion* (HQ).

$$AIC(p) = \ln|\Sigma(p)| + \frac{2}{T}pk^2 \quad (2)$$

$$SIC(p) = \ln|\Sigma(p)| + \frac{\ln T}{T}pk^2 \quad (3)$$

$$HQ(p) = \ln|\Sigma(p)| + \frac{2 \ln \ln T}{T}pk^2 \quad (4)$$

dimana T adalah jumlah pengamatan, p adalah panjang lag, k banyaknya variabel, dan $|\Sigma(p)|$ adalah determinan dari matriks varians kovarians residual. Model dengan nilai kriteria informasi terendah dianggap paling baik [16].

2.4 Uji Kausalitas Granger dan Uji Kointegrasi Johansen

Uji kausalitas Granger digunakan untuk mengidentifikasi hubungan sebab-akibat jangka pendek antar variabel dalam model VAR [5]. Pengujian dilakukan dengan membandingkan dua model, yaitu *unrestricted* (memuat lag kedua variabel) dan *restricted* (hanya memuat lag variabel dependen). Statistik uji yang digunakan adalah uji F:

$$F_{hitung} = (n - k) \frac{RSS_R - RSS_{UR}}{p (RSS_{UR})} \quad (5)$$

dengan RSS_R dan RSS_{UR} berturut-turut adalah *Residual Sum of Squares* untuk model *restricted* dan *unrestricted*, p panjang lag, n banyaknya observasi, dan k banyaknya parameter yang diestimasi. Jika $p\text{-value} < 0,05$, maka hipotesis nol ditolak, yang berarti bahwa terdapat hubungan kausalitas Granger.

Uji kointegrasi digunakan untuk mengetahui apakah beberapa variabel non-stasioner memiliki hubungan keseimbangan jangka panjang (*long-run equilibrium relationship*) dengan hipotesisnya adalah H_0 : Tidak terdapat kointegrasi, lawan H_0 : Terdapat kointegrasi. Uji ini dilakukan menggunakan metode Johansen dengan pendekatan *Trace Statistic* dan *Maximum*

Eigenvalue Statistic. Keputusan tolak H_0 apabila nilai statistik uji melebihi nilai kritis pada taraf signifikansi tertentu (α) [16].

2.5 Model VAR (*Vector Autoregressive*)

Secara umum model VAR dapat diformulasikan sebagai berikut [6]:

$$\mathbf{Y}_t = \mathbf{c} + \Phi_1 \mathbf{Y}_{t-1} + \dots + \Phi_p \mathbf{Y}_{t-p} + \boldsymbol{\varepsilon}_t \quad (6)$$

dengan $\mathbf{Y}_t$ untuk $t = 1, 2, \dots, p$ adalah vektor variabel endogen berukuran $N \times 1$, $\Phi_1, \dots, \Phi_p$ adalah matriks $N \times N$, $\boldsymbol{\varepsilon}_t$ adalah vektor residual $N \times 1$, yang diasumsikan berdistribusi normal multivariat dengan rata-rata nol dan kovarians Σ . Estimasi parameter dilakukan menggunakan *Maximum Likelihood Estimation* (MLE), yang memberikan estimasi efisien dengan memaksimalkan fungsi *likelihood* dari model VAR.

2.6 Model BVAR (*Bayesian Vector Autoregressive*)

Bayesian Vector Autoregressive (BVAR) adalah pengembangan dari model VAR dengan menggunakan pendekatan Bayesian dalam proses estimasi parameter [6]. Estimasi BVAR dilakukan dengan cara menggabungkan fungsi *likelihood* dengan *prior* pada parameter untuk menghasilkan distribusi *posterior* [17]. Hal ini dapat dilakukan dengan menggunakan Teorema Bayes, yaitu [18]:

$$p(\theta|y) \propto p(y|\theta)p(\theta) \quad (7)$$

Penelitian ini menggunakan *Prior Minnesota* untuk mengatasi masalah *overparameterization* pada VAR. Minnesota mengasumsikan bahwa parameter Φ mengikuti distribusi normal multivariat dengan rata-rata $\bar{\Phi}$ dan matriks kovarians $\bar{\Sigma}$ [17].

$$p(\Phi) \sim N(\bar{\Phi}, \bar{\Sigma}) \quad (8)$$

Prior ini bekerja dengan mekanisme *shrinkage*, yaitu menyusutkan koefisien *lag* variabel sendiri mendekati satu dan koefisien *lag* variabel lain mendekati nol, dengan varians kesalahan diasumsikan diagonal [8]. Mekanisme *shrinkage* diatur oleh beberapa *hyperparameter* $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ yang berguna untuk mengendalikan seberapa besar *prior* mempengaruhi koefisien regresi. Standar deviasi *prior* dirumuskan sebagai:

$$\sigma_{a_{ij}}^2 = \begin{cases} \left(\frac{\lambda_1}{l^{\lambda_3}}\right)^2, & \text{lag variabel sendiri} \\ \left(\frac{\sigma_i^2}{\sigma_j^2}\right)\left(\frac{\lambda_1\lambda_2}{l^{\lambda_3}}\right)^2, & \text{lag variabel lain} \\ \sigma_i^2(\lambda_1\lambda_4)^2, & \text{variabel eksogen(konstanta)} \end{cases} \quad (9)$$

dengan λ_1 sebagai *overall tightness*, λ_2 sebagai *cross-variable weighting*, λ_3 sebagai *lag decay*, λ_4 sebagai parameter untuk konstanta, dan σ_i^2, σ_j^2 adalah varians residual dari estimasi

VAR. Formulasi ini memungkinkan estimasi analitik (*closed-form*) tanpa *Gibbs Sampling* dan digunakan untuk proses peramalan.

2.7 Peramalan

Dalam pendekatan Bayesian, peramalan didasarkan pada distribusi prediktif *posterior*, yang mempertimbangkan ketidakpastian parameter [17]:

$$f(y_{T+1:T+h}|y_T) = \int f(y_{T+1:T+h}|\theta, y_T) f(\theta|y_T) d\theta \quad (10)$$

Persamaan tersebut menggambarkan bahwa prediksi masa depan $f(y_{T+1:T+h}|y_T)$ diperoleh dengan mengintegrasikan distribusi prediktif bersyarat terhadap distribusi *posterior* parameter. *Prior Minnesota* membuat distribusi *posterior* berbentuk analitik (*closed-form*), sehingga proses peramalan dapat dilakukan langsung tanpa memerlukan simulasi Monte Carlo yang biasanya lebih kompleks. Proses peramalan dilakukan secara iteratif untuk beberapa periode ke depan, di mana pada setiap langkah digunakan parameter hasil estimasi sebelumnya.

2.8 Impulse Response Function (IRF)

Impulse Response Function (IRF) menggambarkan respons suatu variabel terhadap guncangan pada variabel lain, sehingga hubungan dinamis antarvariabel dapat diamati dari waktu ke waktu [16]. Persamaan *Orthogonal IRF* dapat dituliskan [6]:

$$IRF_{i,j}(k) = \frac{\partial y_{i,t+p}}{\partial a_{j,p}} = [\Psi_p P]_{i,j} \quad (11)$$

2.9 Forecast Error Variance Decomposition (FEVD)

Forecast Error Variance Decomposition (FEVD) digunakan untuk mengukur kontribusi masing-masing shock struktural dalam menjelaskan varians kesalahan prediksi suatu variabel endogen dari waktu ke waktu [19]. Berdasarkan [6] persamaan FEVD dapat ditulis sebagai berikut:

$$FEVD_{i,j(h)} = \frac{\sigma_{a_j}^2 \sum_{s=0}^{h-1} (\theta_{ij}^s)^2}{\sigma_{a_1}^2 \sum_{s=0}^{h-1} (\theta_{i1}^s)^2 + \dots + \sigma_{a_n}^2 \sum_{s=0}^{h-1} (\theta_{in}^s)^2}, \quad i, j = 1, \dots, n \quad (12)$$

2.10 Mean Absolute Percentage Error (MAPE)

Mean Absolute Percentage Error (MAPE) merupakan salah satu statistik yang dapat digunakan untuk mengukur ketepatan ramalan. Nilai MAPE dirumuskan sebagai [20]:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|y_t - \bar{y}_t|}{y_t} \times 100\% \quad (13)$$


2.11 Prosedur penelitian

Berikut ini adalah langkah-langkah analisis data:

1. Mengumpulkan data bulanan dari variabel Inflasi, *BI Rate*, *IHK*, dan kurs.
2. Eksplorasi data dan pembagian data latih dan data uji.

3. Melakukan uji stasioneritas terhadap rata-rata menggunakan Uji (ADF).
4. Menentukan Panjang *lag* optimal dengan membandingkan nilai AIC, SIC, dan HQ.
5. Spesifikasi model VAR. Membentuk model VAR berdasarkan data yang telah stasioner dan jumlah *lag* optimal.
6. Melakukan uji kausalitas Granger dan uji kointegrasi Johansen pada model VAR.
7. Estimasi Model menggunakan pendekatan klasik dan Bayesian.
8. Melakukan peramalan nilai inflasi dengan model VAR dan BVAR.
9. Melakukan analisis keakuratan hasil peramalan dengan menghitung MAPE.
10. Menganalisis IRF untuk mengetahui respon dari suatu variabel terhadap variabel lain dalam sistem BVAR.
11. Menganalisis FEVD untuk memprediksi persentase kontribusi varian dari setiap variabel.
12. Menginterpretasi hasil yang diperoleh.

Alur penelitian ini seperti disajikan pada Gambar 1:



Gambar 1. Diagram Alir Penelitian

3 Hasil dan Pembahasan

3.1 Statistika Deskriptif

Statistika deskriptif data meliputi nilai minimum, nilai maksimum, nilai rata-rata (*mean*), dan standar deviasi. Tabel 2 berikut menyajikan ringkasan statistik dari keempat variabel:

Tabel 2. Statistika Deskriptif Data

Variabel	Rata-rata	Minimum	Maksimum	Std. Deviasi
INF	4,127	1,32	8,79	1,84
SBI	5,692	3,5	7,75	1,25
IHK	121,7	104,3	146,84	11,77
KURS	12.887	8.508	16.421	2324,42

Berdasarkan Tabel 2, rata-rata tingkat inflasi (INF) selama periode pengamatan adalah sebesar 4,13% dengan standar deviasi sebesar 1,84%, menunjukkan fluktuasi moderat. Tingkat suku bunga (SBI) memiliki rata-rata 5,69% dengan standar deviasi lebih rendah, yaitu 1,25%, yang mengindikasikan variasi yang relatif kecil. Indeks Harga Konsumen (IHK) memiliki nilai rata-rata sebesar 121,7, minimum 104,3, dan maksimum 146,84, serta standar deviasi 11,77, mencerminkan adanya peningkatan harga barang dan jasa secara umum. Sementara itu, nilai tukar (KURS) menunjukkan rata-rata sebesar 12.887 dengan standar deviasi yang cukup tinggi yaitu 2.324,42, menunjukkan bahwa nilai tukar cenderung lebih volatil dibanding variabel lainnya selama periode analisis. Secara keseluruhan, KURS merupakan variabel yang paling berfluktuasi, sedangkan SBI adalah yang paling stabil.

3.2 Uji Stasioneritas Data

Uji stasioneritas dilakukan untuk memastikan bahwa data tidak memiliki akar unit. Sebelum dilakukan uji stasioneritas, data terlebih dahulu dibagi menjadi data latih dan data uji. Data latih yang digunakan berukuran $n = 162$ amatan, data ini yang akan digunakan untuk membangun model VAR. Berikut hasil uji stasioneritas ADF dari data latih:

Tabel 3. Hasil Uji Stasioneritas

Variabel	Level <i>p-value</i>	<i>Differencing ke-1</i> <i>p-value</i>
INF	0,164	0,01
SBI	0,3142	0,026
IHK	0,2093	0,01
KURS	0,7931	0,01

Berdasarkan Tabel 3, uji ADF pada level menunjukkan $p\text{-value} > 0,05$ sehingga keempat variabel tidak stasioner. Setelah dilakukan *differencing* pertama, $p\text{-value} < 0,05$ sehingga keempat variabel menjadi stasioner.

3.3 Pemilihan Lag Optimal

Pemilihan *lag* optimal bertujuan supaya nilai *lag* yang akan digunakan tidak terlalu besar ataupun terlalu kecil. Tabel 4 menunjukkan hasil dari kriteria informasi pada setiap *lag*.

Tabel 4. Kriteria Informasi Lag Optimal

Kriteria	Lag 1	Lag 2	Lag 3	Lag 4	Lag 5
AIC	9,697	9,646	9,760	9,903	10,012
SIC	10,096	10,365	10,799	11,261	11,690
HQ	9,859	9,738	10,182	10,455	10,694

Lag optimal dipilih berdasarkan kriteria informasi dengan nilai terkecil. Berdasarkan Tabel 4, *lag* ke-2 dipilih karena memiliki nilai AIC dan HQ terendah dan dianggap paling mewakili dinamika model.

3.4 Spesifikasi Model VAR

Setelah variabel memenuhi stasioneritas dan *lag* optimal ditentukan, dibentuk model VAR(2). Model VAR(2) dapat dituliskan dalam bentuk sistem persamaan sebagai berikut:

$$\begin{aligned} INF_t = & c_1 + a_{11}^{(1)} INF_{t-1} + a_{12}^{(1)} SBI_{t-1} + a_{13}^{(1)} IHK_{t-1} + a_{14}^{(1)} KURS_{t-1} \\ & + a_{11}^{(2)} INF_{t-2} + a_{12}^{(2)} SBI_{t-1} + a_{13}^{(2)} IHK_{t-2} + a_{14}^{(2)} KURS_{t-2} + \varepsilon_{1t} \end{aligned} \quad (14)$$

$$SBI_t = c_3 + a_{31}^{(1)} INF_{t-1} + \dots + a_{34}^{(2)} KURS_{t-2} + \varepsilon_{3t} \quad (15)$$

$$IHK_t = c_2 + a_{21}^{(1)} INF_{t-1} + \dots + a_{24}^{(2)} KURS_{t-2} + \varepsilon_{2t} \quad (16)$$

$$KURS_t = c_4 + a_{41}^{(1)} INF_{t-1} + \dots + a_{44}^{(2)} KURS_{t-2} + \varepsilon_{4t} \quad (17)$$

Model ini digunakan untuk menganalisis hubungan dinamis antar variabel makroekonomi serta menjadi dasar peramalan inflasi, uji Granger, IRF, dan FEVD.

3.5 Uji Kausalitas Granger dan Uji Kointegrasi Johansen

Pengujian kausalitas Granger dilakukan untuk mengetahui hubungan sebab-akibat (kausalitas) jangka pendek dan jangka panjang antar variabel, khususnya terhadap variabel inflasi.

Tabel 5. Hasil Uji Kausalitas Granger

Hipotesis Nol (H_0)	F-stat	$p\text{-value}$	Keputusan
SBI tidak memiliki hubungan kausalitas dengan INF	0,965	0,448	Gagal Tolak H_0
IHK tidak memiliki hubungan kausalitas dengan INF	2,924	0,008	Tolak H_0
KURS tidak memiliki hubungan kausalitas dengan INF	1,585	0,149	Gagal Tolak H_0

Tabel 5 menunjukkan hanya IHK yang memiliki hubungan kausal terhadap inflasi dengan nilai $p\text{-value}$ $0,008 < 0,05$. SBI dan KURS tidak signifikan karena $p\text{-value}$ masing-masing 0,448 dan $0,149 > 0,05$. Sebaliknya, hubungan kausal antara INF terhadap IHK, menunjukkan nilai F-stat sebesar 1,135 dengan $p\text{-value}$ 0,339 ($> 0,05$), sehingga hipotesis nol gagal ditolak. Dengan demikian, inflasi (INF) tidak memiliki hubungan kausalitas Granger terhadap IHK pada taraf signifikansi 5%.

Dalam analisis *time series*, uji kointegrasi digunakan untuk mengetahui apakah beberapa variabel non-stasioner memiliki hubungan keseimbangan jangka panjang (*long-run equilibrium relationship*). Hasil analisis uji kointegrasi diperoleh dimana nilai statistik uji Johansen sebesar 50,48, sedangkan nilai kritisnya sebesar 53,12 untuk $\alpha=5\%$ yang menyebabkan gagal tolak H_0 . Hal ini mengindikasikan bahwa tidak terdapat kointegrasi.

3.6 Estimasi Model VAR

Model VAR(2) dengan estimasi MLE, diperoleh hasil estimasi model sebagai berikut.

Tabel 6. Hasil Estimasi Model VAR dengan MLE

	INF	SBI	IHK	KURS
INF.Lag1	0,304*	0,047	0,395	53,130
SBI.Lag1	0,263*	0,357	1,789	260,408
IHK.Lag1	0,001	0,003	-0,012	2,467
KURS.Lag1	-0,00004	0,00005	-0,000026	-0,145
INF.Lag2	-0,188*	-0,009	0,0793	54,143
SBI.Lag2	-0,183*	0,152	-2,402	0,027
IHK.Lag2	0,0049	0,0007	-0,0008	-24,063
KURS.Lag2	0,0001	0,00009	-0,0017	-0,140
Konstanta	-0,0009	-0,007	0,033	47,612

Berdasarkan Tabel 6 hasil estimasi VAR(2) dengan MLE diperoleh model untuk variabel inflasi (INF) sebagai berikut:

$$INF_t = -0,0009 + 0,304INF_{t-1} + 0,263SBI_{t-1} + 0,001IHK_{t-1} - 0,00004KURS_{t-1} - 0,188INF_{t-2} - 0,183SBI_{t-2} + 0,0049IHK_{t-2} + 0,0001KURS_{t-2} \quad (18)$$

Hasil estimasi model VAR menunjukkan bahwa inflasi dipengaruhi signifikan oleh nilai inflasi dan BI Rate pada periode sebelumnya. Inflasi lag-1 berpengaruh positif (0,304) sedangkan lag-2 negatif (-0,188), sementara BI Rate lag-1 positif (0,263) dan lag-2 negatif (-0,183). IHK berpengaruh positif namun kecil, sedangkan kurs memiliki pengaruh sangat kecil dan tidak signifikan. Hal ini menunjukkan bahwa inflasi masa lalu dan BI Rate merupakan faktor dominan terhadap inflasi saat ini.

3.7 Estimasi Model BVAR dengan *Prior* Minnesota

Model BVAR dengan *prior* Minnesota, diperoleh hasil estimasi model sebagai berikut.

Tabel 7. Hasil Estimasi Model BVAR dengan *Prior* Minnesota

	INF	SBI	IHK	KURS
Konstanta	0,001	-0,006	0,034	47,297
INF.Lag1	0,363*	0,039	0,339	52,578
SBI.Lag1	0,157*	0,469	1,183	229,837
IHK.Lag1	0,000	0,003	0,017	2,876
KURS.Lag1	0,000	0,000	0,000	-0,141
INF.Lag2	-0,132*	-0,006	0,047	36,768
SBI.Lag2	-0,132*	0,064	-1,373	10,898
IHK.Lag2	-0,004*	0,000	0,000	-21,129
KURS.Lag2	0,000	0,000	-0,002	-0,134

Berdasarkan Tabel 7 hasil estimasi BVAR dengan *prior* Minnesota diperoleh model untuk variabel inflasi (INF) sebagai berikut:

$$INF_t = 0,001 + 0,363INF_{t-1} + 0,157SBI_{t-1} - 0,132INF_{t-2} - 0,132SBI_{t-2} - 0,004IHK_{t-1} \quad (19)$$

Estimasi model BVAR menunjukkan bahwa inflasi saat ini dipengaruhi positif oleh inflasi *lag*-1 (0,363) dan BI Rate *lag*-1 (0,157), serta dipengaruhi negatif oleh inflasi *lag*-2 (-0,132), BI Rate *lag*-2 (-0,132), dan IHK *lag*-1 (-0,004). Konstanta bernilai 0,001. Hal ini mengindikasikan bahwa dinamika inflasi terutama dipengaruhi oleh pola inflasi dan BI Rate sebelumnya.


3.8 Peramalan Inflasi

Peramalan tingkat inflasi dilakukan menggunakan dua pendekatan, yaitu model VAR dan BVAR dengan *prior* Minnesota. Peramalan dilakukan untuk periode Juli 2023 hingga Desember 2024. Hasil peramalan dibandingkan dengan data aktual guna mengevaluasi kinerja masing-masing model.

Tabel 8. Hasil Peramalan Inflasi Menggunakan Model VAR dan BVAR

Bulan	INF Aktual	Prediksi VAR	Prediksi BVAR
Juli 2023	3,08	3,46	3,36
Agustus 2023	3,27	3,53	3,06
September 2023	2,28	3,56	3,01
Oktober 2023	2,56	3,55	3,23
November 2023	2,86	3,55	3,08
Desember 2023	2,61	3,55	2,99
Januari 2024	2,57	3,55	3,05

Bulan	INF Aktual	Prediksi VAR	Prediksi BVAR
Februari 2024	2,75	3,55	3,14
Maret 2024	3,05	3,55	3,40
April 2024	3,00	3,56	2,94
Mei 2024	2,84	3,56	2,93
Juni 2024	2,51	3,56	2,69
Juli 2024	2,13	3,56	2,24
Agustus 2024	2,12	3,56	2,02
September 2024	1,84	3,56	2,22
Oktober 2024	1,71	3,56	1,99
November 2024	1,55	3,57	1,88
Desember 2024	1,57	3,57	1,62





Gambar 2. Plot Peramalan Perbandingan Data Aktual, Model VAR, dan Model BVAR

Tabel 8 dan Grafik 2 menunjukkan hasil perbandingan antara data aktual dan model, selama 18 periode pengujian, model VAR cenderung memprediksi inflasi lebih tinggi dari nilai aktual, sedangkan BVAR mampu mengikuti arah tren inflasi dengan lebih baik.

3.9 IRF model VAR dengan respons INF


Gambar 3 berikut menampilkan plot IRF model VAR dengan respons INF.





Gambar 3. Grafik IRF Model VAR Respons INF

IRF model VAR menunjukkan bahwa inflasi merespons paling kuat terhadap *shock* dari dirinya sendiri dan IHK, dengan dampak awal besar yang kemudian mereda sekitar periode ke-5. Respons terhadap *shock* BI Rate relatif kecil dan cepat stabil, sedangkan respons terhadap nilai tukar berfluktuasi (negatif ke positif) sebelum kembali nol. Hal ini mengindikasikan bahwa pengaruh utama terhadap inflasi berasal dari faktor internal dan IHK, sementara pengaruh BI Rate dan kurs lebih lemah dan bersifat sementara.



Gambar 4. Grafik IRF Model BVAR Respons INF

IRF model BVAR pada Gambar 4 menunjukkan bahwa inflasi merespons paling kuat terhadap *shock* dari dirinya sendiri dengan dampak awal positif yang kemudian mereda. *Shock* dari BI Rate memberi pengaruh jangka pendek yang cepat hilang, sedangkan respons terhadap IHK bersifat fluktuatif dan tidak konsisten. Nilai tukar memberi respons awal negatif lalu meningkat sebelum kembali stabil. Secara umum, pengaruh dominan berasal dari inflasi itu sendiri, sementara SBI dan KURS berpengaruh jangka pendek dan IHK relatif lemah.

3.10 FEVD Model VAR

Tabel 9. Hasil FEVD Model VAR

Periode	FEVD			
	INF	SBI	IHK	KURS
INF				
1	1,0000	0,0000	0,0000	0,0000
2	0,9934	0,0060	0,0001	0,0005
3	0,9873	0,0060	0,0021	0,0045
4	0,9864	0,0059	0,0025	0,0051
5	0,9853	0,0060	0,0031	0,0056
6	0,9851	0,0060	0,0032	0,0057
7	0,9850	0,0060	0,0033	0,0057
8	0,9850	0,0060	0,0033	0,0057
9	0,9850	0,0060	0,0033	0,0057
10	0,9850	0,0060	0,0033	0,0057

Hasil FEVD model VAR pada Tabel 9 menunjukkan bahwa variasi inflasi pada awal periode sepenuhnya dijelaskan oleh dirinya sendiri (100%) dan tetap dominan hingga periode ke-10 (98,50%). Kontribusi SBI, IHK, dan KURS relatif kecil, masing-masing sekitar 0,60%, 0,33%, dan 0,57%, sehingga pengaruh variabel makroekonomi lain terhadap fluktuasi inflasi dalam jangka pendek hingga menengah tergolong terbatas.

Tabel 10. Hasil FEVD Model BVAR

Periode	FEVD			
	INF	SBI	IHK	KURS
INF				
1	1,0000	0,0068	0,0091	0,0212
2	0,9915	0,0349	0,0171	0,0328
3	0,9759	0,0484	0,0213	0,0378
4	0,9720	0,0536	0,0221	0,0388
5	0,9701	0,0557	0,0225	0,0391
6	0,9695	0,0564	0,0226	0,0392
7	0,9693	0,0566	0,0227	0,0393
8	0,9692	0,0567	0,0227	0,0393
9	0,9692	0,0567	0,0227	0,0393
10	0,9692	0,0567	0,0227	0,0393

Hasil FEVD model BVAR pada Tabel 10 menunjukkan bahwa variasi inflasi awalnya sepenuhnya dijelaskan oleh dirinya sendiri (100%) dan tetap dominan hingga periode ke-10

(96,92%). Kontribusi variabel lain meningkat, dengan SBI sebesar 5,67%, IHK 2,27%, dan KURS 3,93%. Hal ini mengindikasikan bahwa inflasi tetap dipengaruhi terutama oleh nilainya sendiri, namun peran SBI dan KURS lebih terlihat dibandingkan pada model VAR.

3.11 Evaluasi Model

Tingkat akurasi peramalan pada model dapat dilihat pada Tabel 11.


Tabel 11. Tingkat Akurasi Peramalan Model VAR dan BVAR

Model	MAPE
VAR	52,18%
BVAR	12,43%

Semakin kecil nilai MAPE menunjukkan semakin baik model untuk dilakukan peramalan. Pada Tabel 11, model VAR memiliki nilai MAPE 52,18% > 50%, artinya model memiliki kinerja yang kurang baik dalam peramalan. Pada model BVAR memiliki nilai MAPE 12,43% dimana nilai MAPE berada diantara 10%-20%, artinya kinerja model baik dalam melakukan peramalan.

3.12 Hasil peramalan

Hasil peramalan dengan menggunakan data di luar data latih dan data uji selama periode 6 bulan seperti disajikan pada Gambar 5.



Gambar 5. Grafik Kipas Peramalan INF

Pada Gambar 5 menunjukkan bahwa inflasi periode Januari–Juni 2025 diproyeksikan relatif stabil berdasarkan median *forecast* model BVAR. Namun, *credible interval* 68% yang semakin melebar pada horizon lebih panjang mengindikasikan meningkatnya ketidakpastian prediksi, sehingga hasil forecast jangka menengah perlu diinterpretasikan secara hati-hati.

4 Simpulan dan Saran

Hasil penelitian menunjukkan bahwa IHK memiliki hubungan kausal signifikan terhadap inflasi, sedangkan BI Rate dan kurs tidak berpengaruh kausal. Model BVAR dengan *prior*

Minnesota menghasilkan persamaan yang menunjukkan inflasi dipengaruhi oleh *lag* inflasi dan *lag* BI Rate, sementara pengaruh IHK dan kurs relatif kecil. Peramalan inflasi periode Juli 2023–Desember 2024 menunjukkan bahwa model VAR cenderung melebihkan tren, sedangkan BVAR menghasilkan prediksi yang lebih stabil dan sesuai kondisi historis. Evaluasi MAPE memperkuat temuan ini, di mana VAR memiliki MAPE 52,18% (kategori buruk) sedangkan BVAR 12,43% (kategori baik), sehingga pendekatan Bayesian dinilai lebih akurat dan andal untuk meramalkan inflasi di Indonesia.

Penelitian ini masih sangat terbuka dengan menambahkan variabel-variabel lain yang relevan, seperti jumlah uang beredar, harga komoditas global, atau faktor eksternal lainnya, untuk memperoleh gambaran yang lebih luas dan kompleks terhadap inflasi. Rekomendasi selanjutnya, distribusi *prior* lain seperti *prior* Normal-Wishart atau struktur *Hierarchical* Bayesian dapat dieksplorasi untuk menghasilkan model yang mungkin lebih fleksibel dan mampu menangani ketidakpastian secara lebih baik.

5 Ucapan Terima Kasih

Terima kasih kepada Bank Indonesia dan Badan Pusat Statistik (BPS) yang telah menyediakan data untuk penelitian ini.

6 Daftar Pustaka

- [1] Samuelson, P. A., & Nordhaus, W. D. (2009). *Economics*.
- [2] Bank Indonesia. (2024). *Memahami Suku Bunga Acuan BI: Kunci Ambil Keputusan Keuangan yang Tepat*. Bank Indonesia. <https://www.bi.go.id/id/publikasi/ruang-media/cerita-bi/Pages/data-suku-bunga-bi-saat-ini.aspx>
- [3] Mishkin, F. S. (2019). *The Economics of Money, Banking, and Financial Markets* (12th ed.). Pearson.
- [4] Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2nd ed.). OTexts. <https://otexts.com/fpp2/>
- [5] Gujarati, D. N., Burr Ridge, B., Dubuque, I., Madison, I. (2003). *Basic Econometrics Fourth Edition*. www.mhhe.com
- [6] Zivot, E., & Wang, J. (2006). *Modeling Financial Time Series With S-Plus Second Edition*.
- [7] Santi, V. M., Kurnia, A., & Sadik, K. (2019). Modelling of the number of malarias suffers in Indonesia using Bayesian generalized linear models. *Journal of Physics: Conference Series*, 1402(7). <https://doi.org/10.1088/1742-6596/1402/7/077091>

-
- [8] Karlsson, S. (2013). Forecasting with Bayesian Vector autoregression. In *Handbook of Economic Forecasting* (Vol. 2, pp. 791–897). Elsevier B.V. <https://doi.org/10.1016/B978-0-444-62731-5.00015-4>
 - [9] Domit, S., Monti, F., & Sokol, A. (2019). Forecasting the UK economy with a medium-scale Bayesian VAR. *International Journal of Forecasting*, 35(4), 1669–1678. <https://doi.org/10.1016/j.ijforecast.2018.11.004>
 - [10] Angelini, E., Lalik, M., Lenza, M., & Paredes, J. (2019). Mind the gap: A multi-country BVAR benchmark for the Eurosystem projections. *International Journal of Forecasting*, 35(4), 1658–1668. <https://doi.org/10.1016/j.ijforecast.2018.12.004>
 - [11] Shapovalenko, N. (2021). A BVAR Model for Forecasting Ukrainian Inflation and GDP. *Visnyk of the National Bank of Ukraine*, (251), 14–36. <https://doi.org/10.26531/vnbu2021.251.02>
 - [12] Rahayu, W., Santi, V. M., Siregar, D., & Djati, D. K. (2023). *Hybrid ARIMA-ANN Model for Solving Nonlinearity in Time Series Data* (pp. 70–76). https://doi.org/10.2991/978-94-6463-332-0_9
 - [13] Cryer, J. D., & Chan, K.-S. (2008). *Time Series Analysis With Applications in R Second Edition* (second). Wiley.
 - [14] Santi, V. M., Wahyu, R., & Hadi, I. (2023). Forecasting the Value Of Indonesia's Oil and Gas Imports Using Seasonal Autoregressive Integrated Moving Average Model. *Barekeng*, 17(4), 2027–2058. <https://doi.org/10.30598/barekengvol17iss4pp2047-2058>
 - [15] Box, G. E. P., Jenkins, Gwilym. M., Reinsel, Gregory. C., & Ljung, Greta. M. (2015). *Time Series Analysis: Forecasting and Control* (5th ed.). Wiley.
 - [16] Lutkepohl, H. (2005). *New Introduction to Multiple Time Series Analysis*. Springer-Verlag Berlin.
 - [17] Chan, J. C. C. (2021). Minnesota-type adaptive hierarchical priors for large Bayesian VARs. *International Journal of Forecasting*, 37(3), 1212–1226. <https://doi.org/10.1016/J.IJFORECAST.2021.01.002>
 - [18] Gelman, A., Carlin, J. B., Stern, H. S., Dunson, D. B., Vehtari, A., & Rubin, D. B. (2014). *Bayesian Data Analysis* (Third). CRC Press.
 - [19] Amisano, G., & Giannini, C. (1997). *Topics in Structural VAR Econometrics Second, Revised and Enlarged Edition*. Springer.
 - [20] Lutkepohl, H., & Kratzig, M. (2004). *Applied Time Series Econometrics*. Cambridge University Press.