

**PERAMALAN CONSTRUCTION COST INDEX (CCI) DI INDONESIA
MENGUNAKAN MODEL SEASONAL ARIMA*****Forecasting Indonesia's Construction Cost Index (CCI) using The Seasonal
Arima Model*****Armelia Indriyani¹, Nanda Azzanina^{*2}****^{1,*2}Institut Teknologi Sumatera****^{*2}Email: nanda.azzanina@at.itera.ac.id*****Abstract***

The construction sector is a crucial pillar of Indonesia's economic development, reflected in its contribution to Gross Domestic Product (GDP). The Construction Cost Index (CCI) is closely related to this sector as an indicator of changes in construction costs over time. Fluctuations in the CCI, influenced by trends, seasonal patterns, and external factors, pose challenges in project cost planning, necessitating an accurate forecasting method. This study applies the Seasonal Autoregressive Integrated Moving Average (SARIMA) to forecast the quarterly CCI for the period 2010–2024, as published by Badan Pusat Statistik (BPS). The analysis includes stationarity testing, model identification using ACF and PACF, parameter estimation, diagnostic testing, and model selection based on MAPE. The best model is SARIMA(1,0,3)(0,1,0)⁴ with a MAPE of less than 10%, indicating excellent accuracy. The results are expected to serve as a reference for cost planning and risk reserves for construction projects in Indonesia.

Keywords: Forecasting, SARIMA, Construction Cost Index, BPS

Abstrak

Sektor konstruksi merupakan pilar penting pembangunan ekonomi Indonesia, tercermin dari kontribusinya terhadap Produk Domestik Bruto (PDB). Construction Cost Index (CCI) berkaitan erat dengan sektor ini sebagai indikator perubahan biaya konstruksi dari waktu ke waktu. Fluktuasi CCI yang dipengaruhi tren, pola musiman, dan faktor eksternal menimbulkan tantangan dalam perencanaan biaya proyek, sehingga diperlukan metode peramalan yang akurat. Penelitian ini menerapkan Seasonal Autoregressive Integrated Moving Average (SARIMA) untuk meramalkan CCI triwulanan periode 2010–2024 yang dipublikasikan Badan Pusat Statistik (BPS). Analisis meliputi uji stasioneritas, identifikasi model melalui ACF dan PACF, estimasi parameter, uji diagnostik, serta pemilihan model berdasarkan MAPE. Model terbaik adalah SARIMA(1,0,3)(0,1,0)⁴ dengan MAPE kurang dari 10% yang menunjukkan akurasi sangat baik. Hasilnya diharapkan menjadi acuan perencanaan biaya dan cadangan risiko proyek konstruksi di Indonesia.

Kata Kunci: Peramalan, SARIMA, Construction Cost Index, BPS

PENDAHULUAN

Sektor industri konstruksi memegang peran strategis dalam pembangunan nasional Indonesia karena berkaitan langsung dengan penyediaan infrastruktur transportasi, perumahan, serta fasilitas publik yang mendukung aktivitas ekonomi dan kesejahteraan masyarakat. Besarnya skala proyek konstruksi membuat aspek biaya menjadi krusial, baik bagi pemerintah maupun pelaku industri, sehingga perubahan biaya dari waktu ke waktu perlu dipantau secara terukur. Indikator yang umum digunakan untuk menggambarkan perubahan biaya konstruksi adalah

Construction Cost Index (CCI). Nilai CCI tidak bergerak secara konstan karena berbagai faktor, seperti perubahan harga bahan bangunan, kebijakan fiskal, serta dinamika ekonomi global, sehingga memunculkan fluktuasi dan ketidakpastian dalam perencanaan anggaran proyek. Selain itu, CCI cenderung membentuk pola musiman, misalnya peningkatan pada triwulan IV seiring percepatan realisasi proyek menjelang akhir tahun anggaran dan penurunan pada triwulan I saat aktivitas pembangunan relatif melambat. Selain komponen musiman, CCI juga menunjukkan tren kenaikan jangka panjang yang mencerminkan meningkatnya biaya konstruksi setiap tahun. Oleh karena itu, peramalan CCI yang akurat diperlukan untuk membantu penyusunan anggaran yang lebih presisi, pengendalian biaya, serta penyediaan cadangan risiko pada proyek konstruksi (AlTalhoni et al., 2024).

Metode yang relevan untuk meramalkan deret waktu yang mengandung tren dan pola musiman adalah *Seasonal Autoregressive Integrated Moving Average* (SARIMA), yaitu pengembangan dari ARIMA yang dirancang untuk menangkap pola berulang pada periode tertentu (Tokan & Hermawan, 2023). Sejumlah kajian menunjukkan bahwa SARIMA efektif dalam memodelkan indeks biaya konstruksi karena mampu mengakomodasi komponen musiman sekaligus tren jangka panjang. Penelitian oleh (Aydinli, 2022) membuktikan bahwa SARIMA menghasilkan peramalan yang akurat pada indeks biaya konstruksi dengan model SARIMA(1,0,2)(2,0,1)¹². Sejalan dengan itu, (AlTalhoni et al., 2024) menegaskan bahwa SARIMA layak digunakan untuk peramalan CCI karena memberikan tingkat kesalahan yang rendah berdasarkan ukuran evaluasi, seperti *Mean Absolute Percentage Error* (MAPE). Dalam penelitian tersebut, model SARIMA(1,0,1)(1,1,1)⁴ menghasilkan nilai MAPE sebesar 3,68% yang menunjukkan akurasi peramalan sangat baik. Meskipun demikian, penelitian yang menerapkan SARIMA untuk peramalan CCI di Indonesia, khususnya pada data triwulanan, masih terbatas sehingga diperlukan kajian yang lebih terfokus untuk menyediakan landasan prediktif yang sesuai dengan karakteristik data nasional.

Secara khusus, penelitian ini berangkat dari kebutuhan untuk menentukan model SARIMA yang paling tepat untuk diterapkan pada data CCI Indonesia serta menghasilkan proyeksi CCI untuk delapan periode berikutnya (dua tahun). Dengan demikian, tujuan penelitian ini adalah membangun model SARIMA terbaik berdasarkan data historis dan menganalisis hasil peramalan CCI Indonesia untuk delapan periode ke depan, sehingga dapat dimanfaatkan sebagai referensi dalam perencanaan anggaran pembangunan yang lebih akurat dan antisipatif terhadap perubahan biaya konstruksi.

METODE

Penelitian ini bersifat kuantitatif dengan pendekatan deret waktu untuk meramalkan CCI Indonesia menggunakan metode SARIMA. Data yang digunakan adalah data sekunder CCI periode triwulan tahun 2010-2024 dari Badan Pusat Statistik (BPS).

a. Model SARIMA

Model SARIMA dinotasikan sebagai SARIMA $(p, d, q) (P, D, Q)^s$ dengan persamaan berikut.

$$\phi_p(B)\Phi_P(B^s)(1-B)^d(1-B^s)^D Z_t = \theta_q(B)\Theta_Q(B^s)a_t \quad (1)$$

Dengan B sebagai operator *backshift*, Z_t menyatakan nilai CCI pada periode ke- t ,

dan a_t adalah galat acak (Febiola et al., 2024).

b. Tahapan Analisis Data

Analisis diawali dengan menyusun data CCI menjadi deret waktu triwulanan dan mengidentifikasi adanya tren dan pola musiman. Selanjutnya melakukan pengujian stasioneritas variansi. Jika variansi data belum stasioner, maka transformasi menggunakan transformasi Box–Cox:

$$T(Z_t) = \begin{cases} \frac{(Z_t)^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln(Z_t), & \lambda = 0 \end{cases} \quad (2)$$

dengan $T(Z_t)$ menyatakan bentuk transformasi yang diterapkan pada Z_t , sedangkan λ merupakan nilai estimasi parameter transformasi. Transformasi dilakukan sampai variansi data cenderung stabil sehingga memenuhi asumsi awal pemodelan (Muzakki et al., 2022).

Selanjutnya, dilakukan uji stasioneritas rata-rata menggunakan *Augmented Dickey–Fuller* (ADF) dengan persamaan berikut:

$$\Delta Z_t = \alpha + \beta_t + \gamma Z_{t-1} + \sum_{i=0}^k \delta_i \Delta Z_{t-1} + \varepsilon_t \quad (3)$$

dengan statistik uji berikut.

$$ADF = \frac{\hat{y}}{Std. Error(\hat{y})} \quad (4)$$

Jika hasil uji menunjukkan data belum stasioner, maka dilakukan differencing hingga data stasioner, baik differencing nonmusiman $(1 - B)^d$ maupun differencing musiman $(1 - B^s)^d$ (Rifai & Zhahirulhaq, 2024).

Setelah data stasioner, identifikasi model melalui plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF) untuk menentukan orde nonmusiman (p, q) dan orde musiman (P, Q) . Nilai ACF sampel pada lag k ditentukan dengan persamaan berikut:

$$\hat{\rho}_k = \frac{\hat{Z}_k}{Z_0} = \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (5)$$

dengan $\hat{\rho}_k$ menunjukkan tingkat hubungan linier antara data Z_t dan data yang bergeser k periode Z_{t+k} , sedangkan \bar{Z} adalah nilai rata-rata deret waktu dan n menunjukkan jumlah observasi (Khalilah, 2025). Selanjutnya, nilai PACF dapat dihitung sebagai berikut.

$$\hat{\phi}_{k+1,k+1} = \frac{\hat{\rho}_{k+1} - \sum_{j=1}^{k-1} \hat{\phi}_{kj} \hat{\rho}_{k+1-j}}{1 - \sum_{j=1}^{k-1} \hat{\phi}_{kj} \hat{\rho}_j} \quad (6)$$

Nilai $\hat{\phi}_{k+1,k+1}$ merepresentasikan PACF pada lag $k + 1$. Berdasarkan pola ACF dan PACF, didapatkan beberapa kandidat model SARIMA yang kemudian diestimasi parameternya (Lubis et al., 2021).

Tahap estimasi parameter dilakukan pada setiap kandidat model SARIMA. Parameter yang diperoleh diuji signifikansinya menggunakan uji t berikut.

$$t = \frac{\hat{\beta}_i}{SE(\hat{\beta}_i)} \quad (7)$$

Uji t merupakan perbandingan antara estimasi parameter ke- i yang dinotasikan $\hat{\beta}_i$ dengan galat bakunya yaitu $SE(\hat{\beta}_i)$. Model yang memiliki parameter tidak signifikan dievaluasi kembali hingga diperoleh model yang parameternya signifikan (Anggraini et al., 2025).

Selanjutnya, menguji kelayakan model melalui diagnostik residual menggunakan uji Ljung–Box:

$$Q_* = n(n + 2) \sum_{k=1}^k \frac{\widehat{\rho}_k^2}{n - k} \tag{8}$$

dengan k adalah banyaknya lag yang di uji, dan $\widehat{\rho}_k$ menunjukkan ACF residual pada lag k . Selain itu, normalitas residual diperiksa menggunakan uji Jarque–Bera dengan statistik uji berikut.

$$JB = \frac{n}{6} \left(S^2 + \frac{(K - 3)^2}{4} \right) \tag{9}$$

Pada persamaan (9), S dan K menyatakan *skewness* dan *kurtosis* residual. Model dinyatakan layak apabila residual tidak berautokorelasi dan hasil pemeriksaan residual tidak menunjukkan pelanggaran asumsi yang berarti (Dehbalaei et al., 2023).

Tahap akhir adalah pemilihan model terbaik dan peramalan. Model terbaik dipilih berdasarkan nilai MAPE:

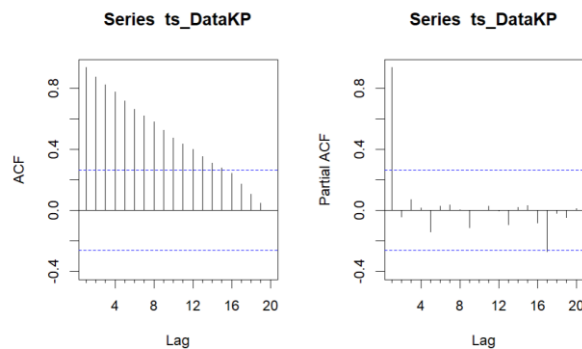
$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \times 100\% \tag{10}$$

Model dengan nilai MAPE terkecil dipilih untuk melakukan peramalan CCI. Hasil peramalan kemudian disajikan dalam bentuk tabel dan grafik agar mudah diinterpretasikan sebagai bahan pertimbangan perencanaan biaya konstruksi (Farida et al., 2021).

HASIL DAN PEMBAHASAN

Identifikasi Plot Deret Waktu

Tahap awal adalah mengidentifikasi pola data melalui analisis plot ACF dan PACF yang bertujuan untuk melihat ada tidaknya ketergantungan antar periode (lag), serta indikasi tren maupun komponen musiman yang memengaruhi kestasioneran data.



Gambar 1. Plot ACF dan PACF

Berdasarkan Gambar 1, terlihat bahwa nilai korelasi menurun secara perlahan (*tailing off*) dan tidak langsung terputus pada beberapa lag awal. Pola ini menunjukkan bahwa data belum stasioner dan masih mengandung tren dan/atau musiman. Dengan demikian, model peramalan yang direkomendasikan adalah SARIMA karena dapat mengakomodasi komponen nonmusiman (ARIMA) sekaligus komponen musiman.

Uji Stasioneritas

Berdasarkan Gambar 1, data belum stasioner baik terhadap variansi maupun rata-rata. Ketidakstasioneran variansi terlihat dari adanya kecenderungan perubahan sebaran data seiring waktu yang disertai pola tren meningkat, sehingga dilakukan transformasi Box–Cox untuk menstabilkan variansi. Hasil transformasi Box–Cox sebagai berikut.

Tabel 1. Hasil Transformasi Box–Cox

Tahun-Triwulan	Construction Cost Index (CCI)
2010-Q1	5,723
2010-Q2	5,802
⋮	⋮
2023-Q3	9,929
2023-Q4	10,082

Kemudian menguji stasioner terhadap rata-rata dengan uji ADF untuk data yang sudah melalui proses transformasi sebelumnya. Hasil dari uji ADF sebagai berikut.


Tabel 2. Hasil Uji ADF

Keterangan	P-Value
Sebelum <i>Differencing</i>	0,8783
Sesudah Satu Kali <i>Differencing</i> Musiman	0,03094

Dari Tabel 2 menunjukkan bahwa sebelum dilakukan *differencing* data belum stasioner secara rata-rata, sehingga diperlukan proses *differencing*. Dalam pemodelan SARIMA, *differencing* yang dilakukan terlebih dahulu adalah *differencing* musiman. Setelah dilakukan satu kali *differencing* musiman, uji ADF diulang dan hasilnya data telah stasioner secara rata-rata.

Identifikasi Model

Selanjutnya melakukan identifikasi model untuk menentukan kandidat parameter (p, d, q) $(P, D, Q)^s$ pada SARIMA. Proses ini dilakukan dengan menganalisis pola *cut-off* atau *tailing-off* pada plot ACF dan PACF dari data yang telah stasioner. Berikut plot ACF dan PACF setelah data stasioner.



Gambar 2. Plot ACF dan PACF Setelah Data Stasioner

Berdasarkan Gambar 2, terlihat bahwa plot ACF *cut-off* di lag pertama sampai ketiga, maka diperoleh MA(1), MA(2), dan MA(3) untuk bagian nonmusiman. Sedangkan pada plot PACF *cut-off* di lag pertama dan kedua, sehingga diperoleh AR(1) dan AR(2) untuk bagian nonmusiman. Dikarenakan bagian nonmusiman sudah stasioner, maka tidak dilakukan *differencing* sehingga model nonmusiman yang terbentuk adalah (1,0,3), (2,0,2), (2,0,1), (1,0,3), (1,0,2), (1,0,1).

Selanjutnya untuk bagian musiman diidentifikasi dalam bentuk triwulan atau lag kelipatan empat. Pada Gambar 2, tidak terjadi *cut-off* pada plot ACF maupun plot PACF, sehingga diperoleh MA(0)⁴ dan AR(0)⁴. Namun dikarenakan terdapat *differencing* musiman satu kali, maka model musiman yang dapat dibentuk adalah (0,1,0)⁴.

Berdasarkan identifikasi model, maka diperoleh model SARIMA sementara adalah SARIMA(2,0,3)(0,1,0)⁴, SARIMA(2,0,2)(0,1,0)⁴, SARIMA(2,0,1)(0,1,0)⁴, SARIMA(1,0,3)(0,1,0)⁴, SARIMA(1,0,2)(0,1,0)⁴, dan SARIMA(1,0,1)(0,1,0)⁴.

Uji Signifikansi Parameter

Langkah selanjutnya, melakukan uji signifikansi parameter untuk menyeleksi model yang layak. Uji signifikansi dilakukan dengan membandingkan nilai *p-value* masing-masing parameter model terhadap tingkat signifikansi. Berikut hasil analisis pengujian signifikansi parameter dari beberapa model sementara.

Tabel 3. Hasil Uji Signifikansi Parameter

Model	Parameter	P-Value	Keterangan
SARIMA(2,0,3)(0,1,0) ⁴	AR(1)	15,95 × 10 ⁻⁶	Signifikan
	AR(2)	7,30 × 10 ⁻¹	Tidak Signifikan
	MA(1)	2,20 × 10 ⁻¹⁶	Signifikan
	MA(2)	97,65 × 10 ⁻⁸	Signifikan
	MA(3)	14,76 × 10 ⁻⁷	Signifikan
SARIMA(2,0,2)(0,1,0) ⁴	AR(1)	32,52 × 10 ⁻²	Tidak Signifikan
	AR(2)	11,63 × 10 ⁻²	Tidak Signifikan
	MA(1)	48,58 × 10 ⁻⁵	Signifikan
	MA(2)	33,90 × 10 ⁻²	Tidak Signifikan
SARIMA(2,0,1)(0,1,0) ⁴	AR(1)	67,43 × 10 ⁻⁷	Signifikan
	AR(2)	29,61 × 10 ⁻²	Tidak Signifikan
	MA(1)	2,20 × 10 ⁻¹⁶	Signifikan

SARIMA(1,0,3)(0,1,0) ⁴	AR(1)	58,06 × 10 ⁻¹⁰	Signifikan
	MA(1)	2,20 × 10 ⁻¹⁶	Signifikan
	MA(2)	58,61 × 10 ⁻⁶	Signifikan
	MA(3)	80,71 × 10 ⁻⁶	Signifikan
SARIMA(1,0,2)(0,1,0) ⁴	AR(1)	2,20 × 10 ⁻¹⁶	Signifikan
	MA(1)	82,53 × 10 ⁻⁹	Signifikan
	MA(2)	41,92 × 10 ⁻²	Tidak Signifikan
SARIMA(1,0,1)(0,1,0) ⁴	AR(1)	2,20 × 10 ⁻¹⁶	Signifikan
	MA(1)	2,20 × 10 ⁻¹⁶	Signifikan

Berdasarkan Tabel 3, diketahui bahwa model yang memenuhi uji signifikansi parameter adalah model SARIMA(1,0,3)(0,1,0)⁴ dan SARIMA(1,0,1)(0,1,0)⁴.

Uji Diagnostik

Uji diagnostik terdiri dari uji *white noise* dan uji normalitas residual. Uji *white noise* dilakukan dengan menggunakan uji Ljung–Box. Kriteria yang harus dipenuhi agar residual *white noise* adalah jika *p-value* memiliki nilai lebih besar dari α (5%). Berikut hasil uji *white noise*.

Tabel 4. Hasil Uji White Noise

Model	P-Value
SARIMA(1,0,3)(0,1,0) ⁴	0,8702
SARIMA(1,0,1)(0,1,0) ⁴	0,3526

Berdasarkan Tabel 4, diketahui bahwa nilai *p-value* lebih dari α (5%) sehingga kedua model memenuhi asumsi residual *white noise*. Kemudian melakukan uji normalitas residual dengan menggunakan uji Jarque – Bera. Mekanisme pengambilan keputusan berdasarkan pada nilai *p-value* yang diperoleh. Jika nilai *p-value* lebih dari α (5%), maka residual berdistribusi normal. Hasil dari uji distribusi normal sebagai berikut.

Tabel 5. Hasil Uji Jarque–Bera

Model	P-Value
SARIMA(1,0,3)(0,1,0) ⁴	2,20 × 10 ⁻¹⁶
SARIMA(1,0,1)(0,1,0) ⁴	2,20 × 10 ⁻¹⁶

Dari Tabel 5, nilai *p-value* kurang dari α (5%), sehingga secara statistik residual tidak berdistribusi normal. Namun, dikarenakan tujuan pada penelitian ini adalah untuk mencari model SARIMA yang baik untuk peramalan, maka asumsi yang lebih utama adalah residual bersifat *white noise*, sehingga model tetap dianggap layak digunakan untuk peramalan walau uji normalitas tidak memenuhi.

Pemilihan Model Terbaik

Kandidat model yang digunakan pada penelitian ini, yaitu SARIMA(1,0,3)(0,1,0)⁴ dan SARIMA(1,0,1)(0,1,0)⁴. Model terbaik adalah model yang memiliki nilai MAPE paling rendah. Hasil MAPE ditampilkan sebagai berikut.

Tabel 6. Hasil MAPE

Model	MAPE
SARIMA(1,0,3)(0,1,0) ⁴	0,437%
SARIMA(1,0,1)(0,1,0) ⁴	0,497%

Berdasarkan Tabel 6, model SARIMA(1,0,3)(0,1,0)⁴ memiliki nilai MAPE terkecil, yaitu 0,437% sehingga model ini ditetapkan sebagai model terbaik berdasarkan evaluasi kesalahan.

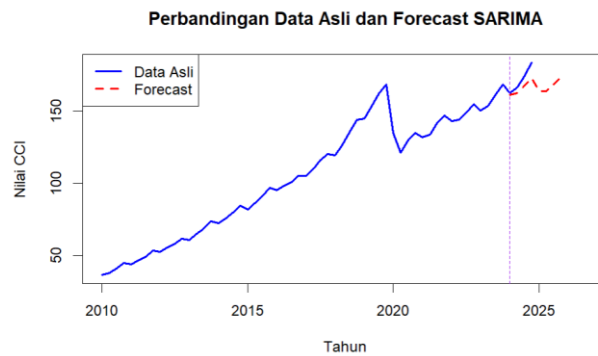
Peramalan

Peramalan dilakukan dengan menggunakan model yang terpilih, SARIMA(1,0,3)(0,1,0)⁴. Berikut hasil peramalan untuk dua tahun kedepan.

Berdasarkan Tabel 7, diketahui bahwa nilai CCI di Indonesia memiliki nilai tertinggi setiap periode triwulan IV 2024. Berikut perbandingan grafik peramalan nilai CCI di Indonesia dengan data asli.

Tabel 7. Hasil Peramalan

Periode	Peramalan
2024-Q1	161,2300
2024-Q2	162,3323
2024-Q3	167,7220
2024-Q4	172,7872
2025-Q1	163,7768
2025-Q2	163,9233
2025-Q3	168,7431
2025-Q4	173,4410



Gambar 3. Grafik Perbandingan Data Asli dengan Hasil Peramalan

Berdasarkan Gambar 3, hasil peramalan model SARIMA yang ditunjukkan dengan garis merah putus-putus untuk periode tahun 2024-2025 relatif mengikuti pola data *testing*, meskipun terdapat sedikit perbedaan nilai. Hal ini menunjukkan bahwa model SARIMA mampu menangkap pola musiman dan tren jangka panjang dengan baik, tetapi masih ada potensi bias positif dalam peramalan.

KESIMPULAN

Berdasarkan hasil dan pembahasan peramalan nilai CCI di Indonesia periode Triwulan I 2010 hingga Triwulan IV 2024, dapat disimpulkan bahwa metode SARIMA cukup efektif digunakan untuk memodelkan dan meramalkan CCI. Model terbaik yang diperoleh adalah SARIMA(1,0,3)(0,1,0)⁴. Dengan bentuk matematis sebagai berikut :

$$Z_t = Z_{t-4} + \phi_1[(Z_{t-1} - \mu) - (Z_{t-5} - \mu)] + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \theta_3 a_{t-3} \quad (11)$$

Melalui model tersebut, diperoleh hasil peramalan untuk delapan periode (dua tahun) ke depan yang menunjukkan tren peningkatan, dengan kenaikan yang terlihat menonjol pada setiap Triwulan IV. Hasil peramalan juga menunjukkan adanya lonjakan nilai CCI, yaitu sebesar 172,7872 pada tahun 2024 dan 173,4410 pada tahun 2025. Validitas model diuji melalui perbandingan antara data *training* (hasil peramalan) dan data *testing* (data aktual) yang menunjukkan perbedaan relatif kecil, sehingga hasil ramalan dinilai cukup

representatif untuk digunakan. Perbedaan yang masih muncul antara nilai ramalan dan nilai aktual dianggap wajar karena peramalan bersifat proyeksi dan bukan nilai pasti.

SARAN

Adapun saran untuk penelitian selanjutnya adalah melakukan evaluasi lebih lanjut guna meminimalkan bias ramalan sehingga hasil prediksi dapat mendekati nilai aktual secara lebih presisi, serta mempertimbangkan penerapan metode alternatif atau pengembangan model lain yang berpotensi menghasilkan tingkat kesalahan prediksi lebih rendah dan akurasi peramalan yang lebih baik.

DAFTAR PUSTAKA

- AlTalhoni, A., Liu, H., & Abudayyeh, O. (2024). Forecasting Construction Cost Indices: Methods, Trends, and Influential Factors. *Buildings*, 14 (10).
- Anggraini, Y., Subairi, M., & Yudistira, I. (2025). Penerapan Model ARIMA-GARCH pada Peramalan Jumlah Kunjungan Wisatawan Mancanegara di Indonesia. *JMT : Jurnal Matematika Dan Terapan*, 7 (1), 6-16.
- Aydınlı, S. (2022). *Time series analysis of building construction cost index in Türkiye*. 5 (4), 218-227.
- Dehbalaei, F. N., Azari, A., & Akhtari, A. A. (2023). Development of a linear-nonlinear hybrid special model to predict monthly runoff in a catchment area and evaluate its performance with novel machine learning methods. *Applied Water Science*, 13 (5), 1-23.
- Farida, Y., Yusi, S., & Yuliati, D. (2021). Forecasting The Number of Aircraft Passengers at Juanda International Airport Using Exponential Smoothing Event-Based Method. *Barekeng*, 15 (4), 709-718.
- Febiola, A., Dewi, A., Fazarin, F. M., Ramadhani, F., Khaffi, M. A., Akbar, R., & Dalimunthe, D. Y. (2024). Perbandingan Metode ARIMA dan SARIMA Dalam Peramalan Jumlah Penumpang Bandara Provinsi Kepulauan Bangka Belitung. *Jambura Journal of Mathematics*, 6 (2), 160-168.
- Khalilah, A. (2025). Analisis Volatilitas Saham Sektor Telekomunikasi Menggunakan Model Generalized Autoregressive Conditional Heteroscedasticity (Garch). Studi kasus : saham XL Axiata , Indosat , Telkom dan Smartfren yang terdaf. *Jurnal Matematika, Komputasi dan Statistika*, 5, 939-948.
- Lubis, R. M. F., Situmorang, Z., & Rosnelly, R. (2021). Autoregressive Integrated Moving Average (ARIMA-Box Jenkins) Pada Peramalan Komoditas Cabai Merah di Indonesia. *Jurnal Media Informatika Budidarma*, 5 (2), 485.
- Muzakki, A. F., Aditama, D., & Gita Anugrah, I. (2022). Penerapan Metode Autoregressive Integrated Moving Average Untuk Memprediksi Penggunaan Barang Medis Pada Logistik Medis Rumah Sakit Muhammadiyah Gresik. *Indexia*, 4 (1), 1.
- Rifai, N. A. K., & Zhahirulhaq, M. A. (2024). Forecasting Inflation in Indonesia. *IMF Working Papers*, 04 (1), 37-45.
- Tokan, L. F., & Hermawan, A. (2023). Implementasi Model SARIMA Untuk Memprediksi Produksi Minyak Kelapa Sawit. *Jurnal Fasilkom*, 13 (3), 456-463.