



Kinerja Peramalan *Autoregressive Integrated Moving Average* dan *Seasonal Autoregressive Integrated Moving Average* dalam Memprediksi Kejadian Gempa Bumi Sumatra

Muhammad A. Firmansyah^{1*}, Cinta R. Oktarina²

¹ Perusahaan Listrik Negara (PLN) Bengkulu, Bengkulu, Indonesia

² Program Studi S2 Statistika, Universitas Bengkulu, Indonesia

*Corresponding Author Email: akbar24muhammad@gmail.com

Article Information

Article History:

Submitted: 12 April 2025

Accepted: 26 June 2025

Published: 30 June 2025

Key Words:

ARIMA

SARIMA

Gempa Bumi

Analisis Deret Waktu

Sumatra

DOI:

<https://doi.org/10.3369/diophantine.v4i1.41099>

Abstract

Sumatra Island is one of the regions in Indonesia with a high level of earthquake risk due to subduction zones and the presence of active faults. This study aims to model and predict the highest magnitude of annual earthquakes in Sumatra Island using the Autoregressive Integrated Moving Average (ARIMA) and Seasonal Autoregressive Integrated Moving Average (SARIMA) methods. The data used are annual magnitudes from 1900 to 2023. Before modeling, a data stationarity test was carried out through the Box-Cox transformation for variance and the Augmented Dickey-Fuller (ADF) test for the mean. After the differencing process, the data was declared stationary to the mean. Initial model identification was carried out by analyzing the ACF and PACF plots, followed by model selection based on parameter significance. Model evaluation used the AIC, BIC, MAE, RMSE, and MAPE criteria. The results of the analysis showed that the SARIMA (1,1,1) (1,1,0)²⁴ model had the best performance based on the AIC, BIC, MAE, and MAPE values. However, in the data testing forecasting stage, the ARIMA (2,1,2) model shows prediction results that are closer to the actual value. This study shows that the combination of using ARIMA and SARIMA can help in modeling earthquake events in Sumatra, with the selection of the best model adjusted based on the forecasting objectives.

1. PENDAHULUAN

Indonesia memiliki tingkat kerentanan gempa bumi yang sangat tinggi, seiring dengan posisinya yang berada pada jalur Sirkum Pasifik. Jalur ini merupakan kawasan aktif secara seismik, di mana sekitar 80% aktivitas gempa bumi dunia terjadi. Rangkaian Sirkum Pasifik membentang dari Pegunungan Andes di Amerika Selatan, melintasi Amerika Tengah, Pegunungan Rocky di Amerika Utara, Kepulauan Aleut, Jepang, Filipina, hingga memasuki wilayah Indonesia melalui Kalimantan, Sulawesi, dan Halmahera, kemudian berlanjut ke Papua, Australia, dan berakhir di Selandia Baru [1]. Gempa bumi sendiri didefinisikan sebagai getaran yang terjadi di permukaan bumi akibat pergeseran lapisan batuan di kerak bumi yang dipicu oleh pergerakan lempeng tektonik. Berdasarkan penyebabnya, gempa bumi dibedakan menjadi tiga kategori, yaitu gempa vulkanik, gempa tektonik, dan gempa runtuh [2].

Pulau Sumatra menjadi salah satu wilayah dengan aktivitas tektonik paling aktif di dunia. Dari 25 daerah rawan gempa di Indonesia, enam di antaranya berlokasi di Pulau Sumatra, yaitu Aceh, Sumatra Utara, Sumatra Barat, Jambi, Bengkulu, dan Lampung [3]. Tingginya aktivitas seismik di Pulau Sumatra tidak terlepas dari kondisi geografisnya, di mana wilayah ini dilintasi oleh jalur sesar aktif, jalur pegunungan berapi, serta zona subduksi lempeng tektonik. Selama kurun waktu 2009 hingga 2018, tercatat sekitar 5,937 kejadian gempa di Pulau Sumatra, dengan 36% di antaranya tergolong sebagai gempa bermagnitudo besar. Selain itu, data historis dalam dua dekade terakhir menunjukkan bahwa gempa besar kerap melanda kawasan ini. Beberapa peristiwa gempa bumi besar di Sumatra antara lain adalah gempa Mentawai tahun 2010 (magnitudo 7.7 M), gempa Nias tahun 2005 (8.6 M), dan gempa besar di Aceh pada 2004 yang menewaskan lebih dari 250,000 orang serta memicu tsunami yang berdampak hingga ke Thailand, Sri Lanka, dan India [4]. Tingkat kerawanan gempa di Pulau Sumatra dipengaruhi oleh dua faktor utama. Faktor pertama adalah keberadaan zona

subduksi sebagai batas antara lempeng India-Australia yang menunjam ke bawah lempeng Eurasia. Faktor kedua adalah keberadaan jalur sesar aktif, yaitu Sumatran Fault Zone (SFZ), yang membelah Pulau Sumatra menjadi dua bagian dan membentang dari Laut Andaman hingga Teluk Semangka sepanjang Pegunungan Bukit Barisan [5].

Untuk meminimalisasi dampak negatif dari gempa bumi, diperlukan pendekatan peramalan terhadap kemungkinan terjadinya peristiwa tersebut. Walaupun hingga saat ini belum tersedia metode yang sepenuhnya akurat dalam memprediksi waktu kejadian gempa, analisis deret waktu tetap menjadi salah satu pendekatan yang banyak digunakan. Penelitian ini berfokus pada peramalan gempa bumi dengan magnitudo terbesar di Pulau Sumatra untuk periode mendatang melalui metode analisis deret waktu. Diharapkan, hasil penelitian ini dapat menjadi referensi tambahan bagi lembaga terkait seperti BMKG dalam melakukan proyeksi kejadian gempa bumi dengan menggunakan metode peramalan berbasis deret waktu yang lebih akurat.

Dalam ranah peramalan deret waktu, terdapat berbagai metode yang dapat diterapkan. Salah satu metode yang banyak digunakan adalah pendekatan Box-Jenkins, yang dikenal dengan model ARIMA (*Autoregressive Integrated Moving Average*). Pendekatan ini mencakup beberapa model dasar seperti AR (*Autoregressive*), MA (*Moving Average*), ARMA (kombinasi AR dan MA untuk data stasioner), ARIMA (untuk data tidak stasioner), serta SARIMA (*Seasonal Autoregressive Integrated Moving Average*), yang ditujukan untuk data yang tidak stasioner dan memiliki pola musiman [6]. Dalam penelitian ini, dilakukan perbandingan antara model ARIMA dan SARIMA guna menentukan model terbaik untuk memprediksi magnitudo gempa di Pulau Sumatra. Model terbaik ditentukan berdasarkan performa terhadap data *training*, sedangkan data *testing* digunakan untuk mengevaluasi akurasi hasil peramalan. Selain itu, analisis juga bertujuan untuk menguji sejauh mana model SARIMA mampu melakukan peramalan dengan baik, meskipun data yang digunakan tidak menunjukkan pola musiman.

2. METODE PENELITIAN

2.1 Data

Data penelitian yang digunakan adalah data sekunder gempa di pulau Sumatra, Indonesia yang diperoleh dari Badan Meteorologi, Klimatologi, dan Geofisika. Data ini terdiri dari tingginya gempa yang terjadi di pulau Sumatra dalam skala magnitudo dari tahun 1900 sampai 2023. Dengan demikian, data ini mencakup periode selama seratus dua puluh empat tahun, yang menghasilkan total 124 data magnitudo tertinggi pada setiap tahunnya. Penelitian ini bertujuan untuk membandingkan model ARIMA dengan SARIMA berdasarkan data gempa di pulau Sumatra dari tahun 1900 sampai 2023 untuk melakukan peramalan dengan data *training* 95% dan *testing* 5% dari data asli yang berjumlah 124.

2.2 Stationeritas Data

Data deret waktu dapat dikategorikan menjadi dua berdasarkan karakteristik stasioneritasnya, yaitu stasioner dalam varians dan stasioner dalam rata-rata jika data tidak memiliki varians yang stabil (tidak stasioner dalam varians), hal ini bisa diketahui dari hasil uji Box-Cox, yaitu ketika nilai lambda tidak mendekati 1. Untuk mengatasi hal tersebut, diperlukan transformasi data menggunakan metode Box-Cox. Sementara itu, untuk menilai stasioneritas dalam rata-rata, dapat dilakukan dengan mengamati pola grafik atau melalui pengujian statistik seperti *Augmented Dickey-Fuller* (ADF). Data dikatakan tidak stasioner dalam rata-rata apabila nilai *p-value* lebih besar atau sama dengan tingkat signifikansi (α). Jika data teridentifikasi tidak stasioner dalam rata-rata, maka perlu dilakukan proses *differencing*.

Differencing bertujuan untuk mengubah data yang semula tidak stasioner terhadap rata-rata menjadi stasioner. Namun, apabila ketidakstasioneran terjadi terhadap varians, maka data harus ditransformasikan menggunakan metode Box-Cox [7]. Penentuan stasioneritas ini sangat penting, karena berpengaruh terhadap pemilihan metode estimasi yang akan digunakan dalam analisis lanjutan.

2.3 Deret Waktu (*Time series*)

Deret waktu merupakan rangkaian pengamatan yang dikumpulkan secara berurutan pada interval waktu yang spesifik. Karakteristik utama dari deret waktu adalah adanya keterkaitan antara pengamatan yang berurutan. Analisis deret waktu melibatkan metode-metode untuk mengevaluasi data yang memiliki hubungan sepanjang waktu. Ini menuntut pembuatan model stokastik dan dinamis untuk data deret waktu dan penerapan model-model tersebut dalam beragam bidang aplikasi yang penting[6]. Metode klasik dalam analisis deret waktu sebagian besar berakar pada statistik matematis, melibatkan teknik-teknik seperti analisis regresi, metode filter Kalman, dan metode *Autoregressive Moving Average* (ARMA) yang diusulkan oleh Box-Jenkins, di mana ARMA sering menjadi model pilihan[8]. Model ARMA yang berkelanjutan, juga dikenal sebagai model Box-Jenkins, yang dirancang oleh Box dan Jenkins (1970), digunakan untuk memodelkan proses stasioner dengan asumsi Gaussian, yaitu semua distribusi gabungan dari deret waktu adalah normal multivariat [9].

Untuk memilih metode peramalan yang tepat pada data deret waktu, penting untuk terlebih dahulu memahami pola yang terkandung dalam data tersebut. Secara umum, pola data dapat diklasifikasikan menjadi empat kategori, yaitu pola musiman, siklis, tren, dan irregular. Pola musiman mengacu pada fluktuasi yang terjadi secara berulang dalam periode waktu tertentu, misalnya setiap triwulan, kuartal, bulan, minggu, atau hari. Sementara itu, pola siklis berkaitan dengan perubahan jangka panjang dalam data yang biasanya dipengaruhi oleh faktor ekonomi atau siklus bisnis. Pola ini sulit untuk diidentifikasi secara pasti dan kerap kali tidak terpisah dari pola tren. Pola tren sendiri mencerminkan kecenderungan data dalam periode panjang, yang dapat menunjukkan arah kenaikan atau penurunan. Di sisi lain, pola irregular menggambarkan kejadian-kejadian tak terduga dan bersifat acak, namun tetap dapat mempengaruhi fluktuasi dalam deret waktu [10].

Data deret waktu didefinisikan sebagai sekumpulan pengamatan yang dicatat secara berurutan dalam selang waktu yang sama. Jenis data ini sering ditemui dalam kehidupan sehari-hari, karena biasanya dikumpulkan dalam interval waktu tertentu, seperti harian, mingguan, atau bulanan. Dari data deret waktu tersebut, dapat diidentifikasi pola-pola yang kemudian dapat digunakan sebagai dasar dalam:

- a) Membuat keputusan untuk kondisi saat ini;
- b) Melakukan peramalan terhadap keadaan di masa mendatang;
- c) Menyusun perencanaan kegiatan untuk masa depan.

Dalam analisis deret waktu, pola-pola ini umumnya dibedakan menjadi empat tipe, yaitu pola stasioner, tren, musiman (*Seasonal*), dan siklis. Pola stasioner menunjukkan bahwa data tidak mengalami perubahan rata-rata atau varians yang signifikan dari waktu ke waktu. Fluktuasi dalam data stasioner terjadi di sekitar rata-rata yang konstan dan tidak menunjukkan ketergantungan terhadap perubahan waktu maupun varians dari fluktuasi tersebut.

2.4 ARIMA (*Autoregressive Integrated Moving Average*)

Model Box-Jenkins (ARIMA) dapat diklasifikasikan ke dalam tiga jenis model utama, yaitu AR, MA, dan ARMA yang menggabungkan karakteristik dari kedua model tersebut. Sebelum terbentuknya konsep ARIMA, terlebih dahulu dikenal model AR (*Autoregressive*) yang pertama kali diperkenalkan oleh Yule pada tahun 1926, kemudian dikembangkan lebih lanjut oleh Walker. Sementara itu, model *Moving Average* (MA) mulai digunakan sekitar tahun 1973 oleh Slutsky. Wold merupakan salah satu tokoh yang meletakkan dasar teoritis awal terkait kombinasi model AR dan MA untuk membentuk model ARIMA.

1. *Autoregressive* (AR)

Model *Autoregressive* (AR) adalah pendekatan dasar dalam analisis deret waktu yang mengasumsikan bahwa nilai saat ini dipengaruhi oleh nilai-nilai pada periode sebelumnya. Artinya, data masa lalu dapat dimanfaatkan untuk memprediksi data saat ini. Ciri utama model ini adalah adanya hubungan antara nilai saat ini dengan nilai-nilai sebelumnya. Model ini memiliki orde p yang menunjukkan jumlah lag atau keterlambatan yang digunakan dalam membentuk prediksi dan dinotasikan sebagai AR (p) di mana nilai X_t merupakan fungsi

dari nilai-nilai data pada periode sebelumnya, yaitu $t - 1, t - 2, \dots, t - p$. Model AR dapat diformulasikan sebagai berikut:

$$X_t = \mu + \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + e_t \quad (1)$$

2. Moving Average (MA)

Model *Moving Average* (MA) merupakan salah satu model dalam analisis deret waktu yang menghubungkan nilai observasi saat ini dengan kesalahan prediksi (*forecast error*) dari periode sebelumnya. Model ini digunakan untuk memperbaiki ketidakakuratan yang terjadi pada prediksi masa lalu dengan memperhitungkan pengaruh residual terhadap nilai saat ini. Model MA memiliki orde q , yang menunjukkan jumlah lag kesalahan prediksi yang digunakan dalam membentuk nilai prediksi. Model ini dinotasikan sebagai MA (q), dengan persamaan umum sebagai berikut:

$$X_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (2)$$

3. Model ARIMA

Jika suatu deret waktu (*time series*) tidak bersifat stasioner, salah satu cara untuk mengubahnya menjadi stasioner adalah dengan melakukan *differencing*, yaitu mengurangi nilai saat ini dengan nilai sebelumnya. Apabila *differencing* ini dilakukan dan menghasilkan data yang stasioner, maka model peramalan yang digunakan dapat berupa ARMA (p, q) terhadap deret waktu yang telah diselisihkan tersebut. Model ini kemudian dikenal sebagai ARIMA (p, d, q), di mana p menyatakan orde dari komponen AR, d adalah jumlah *differencing* yang diperlukan untuk mencapai stasioneritas, dan q merepresentasikan orde dari komponen MA[11].

Sebagai ilustrasi, misalkan X_t adalah suatu deret waktu yang mengikuti model ARIMA (p, d, q). Jika kita mendefinisikan $wt = (1 - B)^d X_t$ maka wt adalah hasil *differencing* dari X_t sebanyak d kali, di mana d merupakan bilangan bulat non-negatif yang menunjukkan tingkat integrasi. Bentuk umum model ARIMA (p, d, q) dapat dituliskan sebagai berikut:

$$\phi_p(B) = (1 - B)^d X_t = \theta_0 + \theta_q(B) e_t \quad (3)$$

Jika $d=0$, maka model ARIMA berkurang menjadi model ARMA, yang merepresentasikan proses yang sudah stasioner tanpa memerlukan *differencing*. Syarat utama dalam membangun model ARIMA adalah terpenuhinya kondisi stasioneritas dan invertibilitas. Kedua kondisi ini harus berlaku secara independen dan umum, artinya operator $\phi(B)$ dan $\theta(B)$ tidak boleh memiliki orde yang sama [6]. Dengan mengintegrasikan model AR dan MA, ARIMA mampu menangani data deret waktu yang awalnya tidak stasioner dan pola data yang kompleks, yang tidak dapat dijelaskan hanya dengan AR atau MA saja secara terpisah.

2.5 SARIMA (Seasonal Autoregressive Integrated Moving Average)

Model *Seasonal Autoregressive Integrated Moving Average* (SARIMA) merupakan pengembangan dari model ARIMA yang dirancang khusus untuk mengakomodasi data deret waktu yang menunjukkan pola musiman. SARIMA memperluas konsep ARIMA dengan mempertimbangkan tidak hanya komponen non-musiman, tetapi juga komponen musiman dalam data. Pada tahap awal penerapan model SARIMA, dilakukan proses estimasi terhadap parameter-parameter model, yang meliputi komponen MA, AR serta faktor musiman (*Seasonal*) dan non-musiman (*non-Seasonal*). Setelah parameter-parameter tersebut diestimasi, dilakukan uji signifikansi untuk memastikan bahwa semua parameter yang dipilih secara statistik berpengaruh. Jika ditemukan parameter yang tidak signifikan, maka model tersebut dianggap tidak memenuhi kriteria kelayakan dan dinyatakan tidak lolos uji. Setelah seluruh parameter diestimasi dan dilakukan pengujian signifikansi, struktur model SARIMA dapat disusun lebih lanjut. Secara umum, model SARIMA dapat diklasifikasikan menjadi dua tipe utama, yakni model *Seasonal ARIMA* dan model *ARIMA Multiplikatif*. Masing-masing tipe tersebut memiliki karakteristik tersendiri dalam menangani komponen musiman dan non-musiman pada data deret waktu.

1. Seasonal Autoregressive (SAR)

Model SAR adalah salah satu komponen utama dalam struktur *Seasonal ARIMA*, yang secara khusus digunakan untuk menangkap pola ketergantungan musiman dalam deret waktu. Model ini memiliki orde

musiman PPP dan dinotasikan sebagai SAR(P)^s. Persamaan umum untuk model SAR dapat dituliskan sebagai berikut:

$$X_t = \phi_1 X_{t-S} + \phi_2 X_{t-2S} + \dots + \phi_P X_{t-PS} \quad (4)$$

di mana X_t adalah nilai pada waktu ke- t , ϕ_i adalah koefisien autoregresif musiman untuk lag ke- i , S menunjukkan jumlah periode musiman (misalnya 12 untuk data bulanan), dan e_t merupakan komponen white noise. Residual e_t diasumsikan saling bebas, berdistribusi normal dengan rata-rata nol dan varians konstan sebesar σ^2 . Dengan struktur ini, model SAR mampu menangkap pola pengulangan musiman yang konsisten dalam data deret waktu, memperkaya kemampuan prediksi jangka panjang dengan mempertimbangkan dinamika musiman yang terjadi secara berkala.

2. *Seasonal Moving Average (SMA)*

Model SMA adalah salah satu komponen dalam struktur *Seasonal ARIMA* yang berfungsi untuk menangkap pola kesalahan musiman (*Seasonal error*) dalam deret waktu. Model ini memiliki orde musiman Q , dan dinotasikan sebagai MA(Q)^s, dengan S menunjukkan periode musimannya (misalnya 12 untuk data bulanan).

Persamaan umum dari model *Seasonal Moving Average* dapat dinyatakan sebagai berikut:

$$X_t = e_t - \theta_1 e_{t-S} - \theta_2 e_{t-2S} - \dots - \theta_Q e_{t-QS} \quad (5)$$

Komponen kesalahan e_t diasumsikan bersifat saling bebas (independen) dan mengikuti distribusi normal dengan rata-rata nol serta varians konstan sebesar σ^2 . Melalui struktur ini, model SMA berfungsi untuk memperbaiki ketidakakuratan prediksi masa lalu dengan memperhitungkan efek musiman dari residual pada lag-lag sebelumnya yang berulang sesuai periode musiman.

3. *Model Seasonal ARIMA*

Musiman dalam konteks deret waktu merujuk pada kecenderungan data untuk menunjukkan pola perulangan dalam interval waktu tertentu, biasanya setahun untuk data bulanan. Model *Seasonal ARIMA* dikembangkan untuk mengatasi permasalahan deret waktu yang mengandung unsur musiman. Model ini menggabungkan dua komponen, yaitu komponen non-musiman (*non-Seasonal*) dan komponen musiman (*Seasonal*). Bagian non-musiman dari metode ini disusun berdasarkan struktur ARIMA biasa, sedangkan bagian musimannya disusun untuk menangkap pola berulang pada periode tertentu. Secara umum, bentuk umum model *Seasonal ARIMA* dinotasikan sebagai ARIMA (p,d,q) (P,Q,S)^s adalah:

$$\phi_p(B)\Phi_P(B)^S = (1-B)^d(1-B)^D X_t = \theta_0(B)\theta_Q(B^S)e_t \quad (6)$$

di mana B adalah operator lag, dan S merupakan panjang siklus musiman, seperti 12 untuk data bulanan.

2.6 *Estimasi Parameter*

Estimasi parameter dalam model deret waktu merupakan proses penentuan nilai parameter yang mewakili karakteristik populasi berdasarkan data sampel. Estimasi ini sangat penting untuk membangun model yang akurat dan dapat diandalkan. Pada tahap ini, parameter dari model seperti MA, AR, faktor musiman, dan faktor non-musiman diestimasi menggunakan teknik statistik. Salah satu metode umum yang digunakan adalah Ordinary Least Squares (OLS), yang bertujuan untuk meminimalkan jumlah kuadrat error [12]. Setelah semua parameter diestimasi, dilakukan pengujian signifikansi untuk setiap parameter. Pengujian ini bertujuan untuk menentukan apakah setiap parameter memberikan kontribusi yang bermakna terhadap model. Biasanya, uji signifikansi dilakukan dengan membandingkan *p-value* masing-masing parameter terhadap tingkat signifikansi tertentu. Parameter yang memiliki *p-value* lebih besar dari taraf signifikansi akan dianggap tidak signifikan dan dinyatakan tidak lolos uji. Secara umum, hipotesis nol (H_0) menyatakan bahwa parameter tersebut tidak berpengaruh secara signifikan terhadap model, dan keputusan untuk menerima atau menolak H_0 didasarkan pada hasil pengujian tersebut.

2.7 Uji Asumsi

1. Uji Autokorelasi

Salah satu asumsi penting dalam model regresi dan deret waktu adalah bahwa residual harus bebas dari autokorelasi. Autokorelasi terjadi ketika nilai residual saling berkaitan antara satu waktu dengan waktu lainnya, sehingga mengganggu keakuratan model. Uji autokorelasi biasanya hanya dilakukan pada data deret waktu (*time series*) karena adanya ketergantungan temporal, dan tidak relevan untuk data cross section di mana seluruh variabel diukur secara serentak dalam satu waktu. Untuk mendeteksi adanya autokorelasi, digunakan uji seperti Q-Statistic atau uji Ljung-Box, yang bertujuan untuk menguji apakah residual dalam model mengikuti pola white noise (yaitu tidak memiliki autokorelasi). Model regresi dapat dikatakan baik ketika terbebas dari autokorelasi. Uji autokorelasi merupakan pengujian dalam analisis deret waktu untuk mendeteksi adanya hubungan (korelasi) antar residual atau observasi yang berdekatan dalam waktu [13]. Jika residual bersifat white noise, maka model dinyatakan memenuhi asumsi tidak adanya autokorelasi, yang merupakan salah satu kriteria penting dalam validasi model deret waktu [14] dengan $H_0: \rho_1 = \rho_2 = \dots = \rho_k$ dan $H_1: \text{Minimal ada satu } \rho_i \neq 0$.

2. Uji Normalitas

Uji normalitas bertujuan untuk menilai apakah data dalam suatu kelompok atau variabel mengikuti distribusi normal. Prosedur ini penting untuk memastikan bahwa data yang digunakan dalam analisis statistik berasal dari populasi yang berdistribusi normal, atau setidaknya mendekati normal. Dalam penerapannya, uji normalitas membantu memverifikasi terpenuhinya salah satu asumsi dasar dalam analisis statistik, sebelum melanjutkan ke tahapan analisis lanjutan. Pengujian normalitas umumnya dianggap tidak terlalu kompleks, terutama jika ukuran sampel cukup besar. Menurut pengalaman empiris beberapa ahli, data dengan jumlah observasi lebih dari 30 ($n > 30$) umumnya sudah dianggap memenuhi asumsi distribusi normal tanpa perlu pengujian tambahan [15]. Namun, untuk memastikan normalitas residual secara formal, dalam penelitian ini digunakan metode Kolmogorov-Smirnov, dengan hipotesis nol (H_0) menyatakan bahwa residual berdistribusi normal, dan hipotesis alternatif (H_1) menyatakan bahwa residual tidak berdistribusi normal.

3. Uji Homoskedastisitas

Uji homoskedastisitas digunakan untuk mengidentifikasi apakah dalam model regresi terdapat kesamaan varians residual untuk seluruh nilai prediktor. Dalam model regresi yang ideal, varians error diharapkan konstan, atau disebut memenuhi asumsi homoskedastisitas [16]. Apabila varians residual berubah-ubah bergantung pada nilai variabel bebas, maka terjadi heteroskedastisitas, yang dapat menyebabkan hasil estimasi menjadi tidak efisien dan menimbulkan kesalahan dalam proses inferensi statistik. Oleh karena itu, penting untuk melakukan pengujian terhadap adanya heteroskedastisitas guna memastikan bahwa model regresi yang dibangun memenuhi asumsi klasik Ordinary Least Squares (OLS). Dalam penelitian ini, uji yang digunakan untuk mendeteksi keberadaan heteroskedastisitas adalah uji Breusch-Pagan atau uji Glejser, bergantung pada pendekatan analisis yang diterapkan. Hipotesis yang diuji adalah H_0 : residual bersifat homoskedastisitas (variens konstan) dan H_1 : residual bersifat heteroskedastisitas (variens tidak konstan).

2.8 Peramalan

Peramalan merupakan proses memperkirakan kondisi di masa depan dengan memanfaatkan informasi yang tersedia, seperti data historis dan wawasan mengenai peristiwa-peristiwa yang berpotensi mempengaruhi variabel yang diamati [17]. Dalam penyusunan model peramalan, upaya dilakukan untuk mengurangi tingkat ketidakpastian yang mungkin muncul, sehingga model yang dihasilkan dapat memberikan estimasi yang lebih mendekati kenyataan. Tujuan utama dari kegiatan peramalan ini adalah menghasilkan prediksi yang akurat dengan meminimalkan tingkat kesalahan yang terjadi dalam proses estimasi, atau yang dikenal dengan istilah *forecast error*. Untuk menilai seberapa baik kinerja suatu model peramalan, digunakan ukuran-ukuran tertentu yang akan dijelaskan sebagai berikut.

- | | | |
|--|--|--|
| <p>1. ME (<i>Mean Error</i>)</p> $\frac{1}{n} \sum_{i=1}^n e_i$ | <p>2. MSE (<i>Mean Squared Error</i>)</p> $\frac{1}{n} \sum_{i=1}^n e_i^2$ | <p>3. RMSE (<i>Root Mean Squared Error</i>)</p> $\sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2}$ |
| <p>4. MAE (<i>Mean Absolute Error</i>)</p> $\frac{1}{n} \sum_{i=1}^n e_i $ | <p>5. MPE (<i>Mean Percentage Error</i>)</p> $\frac{1}{n} \sum_{i=1}^n \frac{e_i}{y_i} \times 100$ | <p>6. MAPE (<i>Mean Absolute Percentage Error</i>)</p> $\frac{1}{n} \sum_{i=1}^n e_i \times 100$ |
| <p>7. MASE (<i>Mean Absolute Scaled Error</i>)</p> $\frac{\frac{1}{n} \sum_{i=1}^n e_i }{\frac{1}{n-1} \sum_{i=2}^n y_i - y_{i-1} }$ | | |

Semakin kecil nilai kesalahan yang dihasilkan oleh ukuran-ukuran evaluasi peramalan, maka semakin baik pula kualitas model yang digunakan. Di antara berbagai ukuran yang tersedia, MAPE (*Mean Absolute Percentage Error*) sering dipilih karena mengukur tingkat ketepatan model dalam bentuk persentase kesalahan relatif terhadap nilai sebenarnya, sehingga lebih mudah untuk diinterpretasikan dalam konteks praktis. Dalam proses pemilihan model deret waktu, seringkali terdapat beberapa kandidat model yang mampu merepresentasikan pola data dengan baik. Untuk menentukan model yang paling sesuai atau optimal, salah satu pendekatan yang dilakukan adalah dengan membandingkan nilai error residual berdasarkan ukuran forecast error yang telah dibahas sebelumnya. Model dengan nilai forecast error yang lebih kecil dianggap memiliki performa prediksi yang lebih baik.

Selain membandingkan menggunakan ukuran kesalahan prediksi, evaluasi model juga dapat dilakukan dengan melihat nilai kriteria informasi seperti AIC (*Akaike Information Criterion*) dan BIC (*Bayesian Information Criterion*). AIC dan BIC digunakan untuk memilih model terbaik dengan mempertimbangkan keseimbangan antara kualitas fit model dan kompleksitas model. Secara umum, model yang menghasilkan nilai AIC dan BIC paling kecil dianggap lebih baik dan lebih sederhana. Dalam konteks model ARIMA, untuk menghitung nilai AIC dan BIC, digunakan formula $k = p + q$ jika model tidak memiliki konstanta, atau $k = p + q + 1$ jika model mengandung suku konstan. Nilai k menunjukkan jumlah parameter yang digunakan dalam model, yang penting dalam perhitungan kriteria informasi tersebut.

1. Akaike Information Criterion (AIC)

Akaike Information Criterion (AIC) merupakan salah satu ukuran yang digunakan untuk menilai kualitas suatu model statistik dalam memperkirakan data. AIC mengukur keseimbangan antara tingkat kebaikan model terhadap data (goodness of fit) dan kompleksitas model yang digunakan. Secara matematis, AIC dirumuskan sebagai:

$$AIC = -2\log(\text{maximum likelihood}) + 2k \tag{14}$$

Tujuan dari penggunaan AIC adalah untuk memilih model dengan nilai AIC terkecil, karena nilai ini mencerminkan keseimbangan antara kecocokan model terhadap data dan kompleksitasnya. AIC mendorong pemilihan model yang cukup sederhana namun tetap mampu merepresentasikan struktur data secara akurat, sehingga membantu menghindari overfitting.

2. Bayesian Information Criterion (BIC)

Bayesian Information Criterion (BIC), juga dikenal sebagai Schwarz Criterion, adalah metode alternatif untuk pemilihan model yang mirip dengan AIC, tetapi memberikan penalti lebih besar terhadap kompleksitas model. BIC dinyatakan dengan rumus:

$$BIC = -2\log(\text{maximum likelihood}) + k \log n \tag{15}$$

Seperti AIC, BIC juga memilih model dengan nilai terkecil. Namun, karena penalti terhadap jumlah parameter pada BIC lebih berat dibandingkan AIC (melalui $\log n$), BIC cenderung lebih konservatif dalam

memilih model, terutama pada ukuran sampel yang besar. BIC lebih memprioritaskan model yang benar-benar sederhana dan hanya memasukkan parameter yang benar-benar diperlukan.

3. HASIL DAN PEMBAHASAN

Pada subbab ini dibahas hasil analisis data terkait kejadian gempa bumi dengan magnitudo tertinggi yang terjadi setiap tahun di wilayah Sumatra, mulai dari tahun 1900 hingga tahun 2023. Analisis dilakukan untuk menentukan model terbaik dalam memprediksi magnitudo gempa bumi tahunan di wilayah tersebut, menggunakan pendekatan model deret waktu ARIMA dan SARIMA. Tujuan dari analisis ini adalah untuk memperoleh model prediksi yang akurat sehingga dapat membantu memperkirakan pola kejadian gempa bumi di masa mendatang di kawasan Sumatra.

3.1 Statistika Deskriptif Kejadian Gempa Bumi di Sumatra

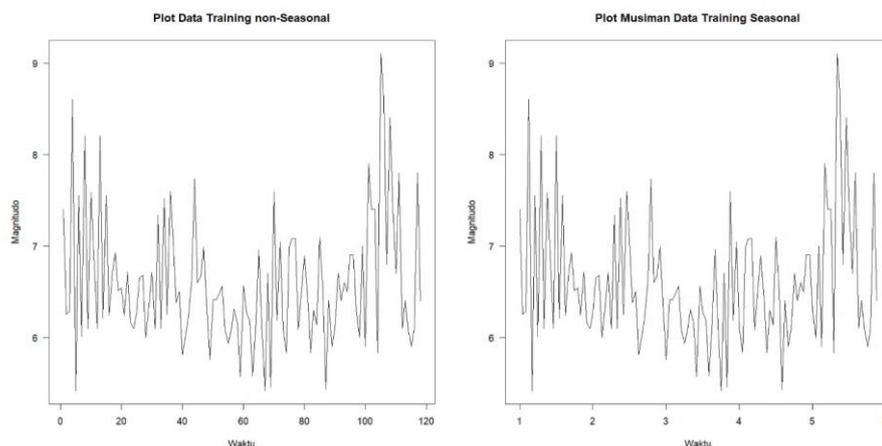
Berdasarkan Tabel 1 dapat dilihat bahwa, data gempa bumi Sumatra menunjukkan bahwa magnitudo gempa tertinggi bervariasi dari 5.420 (SR) hingga 9.100 (SR) setiap tahunnya, dengan rata-rata magnitudo sekitar 6.608 (SR). Nilai tengah atau median dari data adalah 6.449 (SR), yang berarti setengah dari magnitudo gempa berada di bawah 6.449 (SR) dan setengah lainnya berada di atas 6.449 (SR). Kuartil pertama dan ketiga, yang masing-masing mewakili 25% dan 75% dari data, adalah 6.100 dan 6.938.

Tabel 1. Tabel Ringkasan Gempa Bumi di Sumatra

Ringkasan Gempa Bumi	Magnitudo (SR)
Min.	5.420
1st Qu.	6.100
Median	6.449
Mean	6.608
3rd Qu.	6.938
Max.	9.100

3.2 Identifikasi Data

Data dibagi menjadi 95% data *training* (118 Data) dan 5% data *testing* (6 Data) dengan jumlah total 124 data. Berdasarkan Gambar 1, *plot data training time series* untuk model *non-seasonal* dan *seasonal* tidak menunjukkan adanya tren yang jelas. Pola fluktuasi data relatif stabil dari awal hingga akhir. Meskipun pada *plot seasonal* digunakan frekuensi 24, tidak tampak perubahan pola yang menunjukkan adanya komponen musiman. Hal ini mengindikasikan bahwa data tidak memiliki pola musiman yang signifikan. Pada kedua gambar tersebut ada beberapa data yang menjurai baik ke atas maupun ke bawah yang mengindikasikan kedua data tersebut tidak stasioner dalam varian.



Gambar 1. *Plot menggunakan Data Training 95%*

Berdasarkan Gambar 1, terlihat bahwa pada *plot* data *training* non-musiman, fluktuasi magnitudo gempa bumi berlangsung secara acak tanpa menunjukkan adanya tren naik maupun turun yang konsisten sepanjang periode pengamatan. Rentang nilai magnitudo berkisar antara 5,5 hingga 9,1 SR dengan pola pergerakan yang stabil terhadap rata-rata, meskipun perlu pengujian lebih lanjut untuk memastikan stasioneritas terhadap varians. Sementara itu, pada *plot* musiman yang menggunakan frekuensi 24, pola data menunjukkan karakteristik yang hampir serupa dengan *plot* non-musiman, yakni tidak tampak adanya pola berulang yang mengindikasikan komponen musiman yang kuat. Baik pada *plot* non-*Seasonal* maupun *Seasonal*, fluktuasi terjadi secara acak tanpa pola periodik tertentu, sehingga dapat disimpulkan bahwa data tidak mengandung tren maupun musiman yang signifikan. Indikasi awal ini mengarahkan bahwa data kemungkinan bersifat stasioner terhadap rata-rata, tetapi konfirmasi formal tetap diperlukan melalui uji stasioneritas seperti *Augmented Dickey-Fuller* (ADF) sebelum pemodelan lebih lanjut menggunakan ARIMA atau SARIMA dilakukan.

3.3 Pengujian Kestasioneran Data

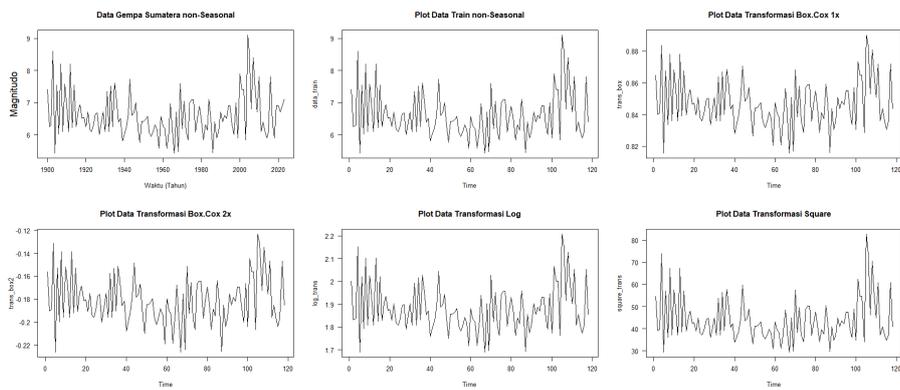
Pengecekan kebenaran kestasioneran data tidak hanya dapat dilihat berdasarkan *plot* data akan tetapi juga dengan melakukan uji statistik Transformasi Box-Cox untuk pengujian kestasioneran varian, sedangkan uji ADF untuk pengujian kestasioneran rata-rata. Berdasarkan Tabel 2, uji varians menggunakan transformasi Box-Cox sebanyak 3 kali baik menggunakan data *training* non-*Seasonal* maupun *Seasonal* tidak terdapat adanya perubahan dalam nilai lambda (λ) yang mengidentifikasi bahwa data *training* tidak stasioner dalam varians. Berdasarkan *plot* Gambar 2 dan Gambar 3 mengenai perbandingan antara data sebelum transformasi dan setelah transformasi, baik menggunakan transformasi Box-Cox, Log, maupun Square tidak terlihat adanya perbedaan baik dari data *training* maupun data lengkap. Maka transformasi box cox tidak akan digunakan dalam penelitian ini dan menjadi batasan masalah.

Tabel 2. Tabel Uji Varians dan Rataan

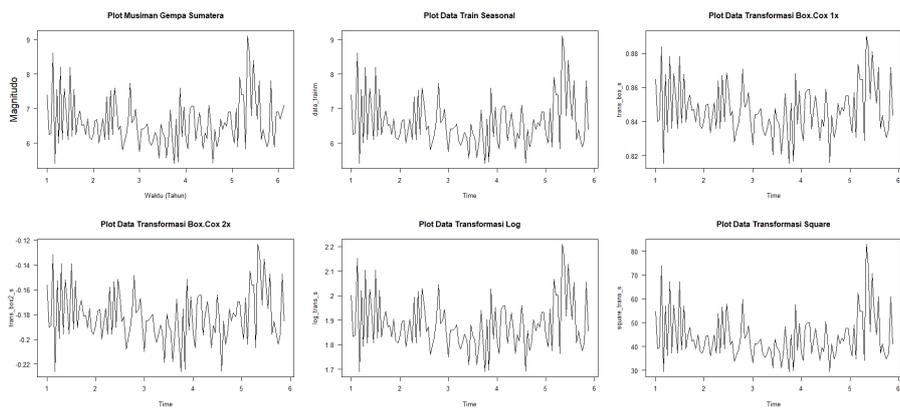
Transformasi Box-Cox	Nilai			Keputusan	
	λ Non- <i>Seasonal</i>	λ <i>Seasonal</i>			
Sebelum Transformasi	-0.9999242	-0.9999242		TS	
Transformasi Pertama	-0.9999242	-0.9999242		TS	
Transformasi Kedua	-0.9999242	-0.9999242		TS	
Transformasi Ketiga	-0.9999242	-0.9999242		TS	
Uji <i>Augmented Dickey-Fuller</i>	ADF (t δ) Non- <i>Seasonal</i>	ADF (t δ) <i>Seasonal</i>	t _{tabel}	p-value	Keputusan
Sebelum <i>Differencing</i>	-3.0047	-3.0047	1,966	0.01	TS
Setelah <i>Differencing</i>	-6.6522	-6.6522		0.01	S

Keterangan: TS = Tidak Stasioner, S = Stasioner

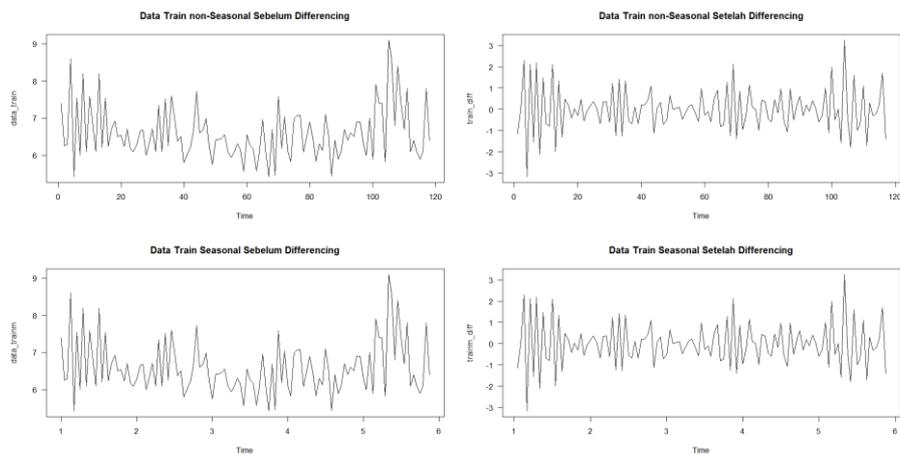
Berdasarkan Tabel 2, uji stasioneritas varians melalui transformasi Box-Cox menunjukkan bahwa baik pada data non-*Seasonal* maupun *Seasonal*, nilai lambda (λ) yang diperoleh sebesar -0,9999242 di seluruh tahap transformasi. Nilai ini mengindikasikan bahwa transformasi yang dilakukan tidak mampu mengubah sifat ketidakstasioneran varians, sebagaimana ditunjukkan oleh keputusan hasil uji yang tetap menyatakan data tidak stasioner (TS) pada semua tahap. Dengan demikian, transformasi Box-Cox tidak efektif dalam mengatasi masalah varians pada data ini. Selanjutnya, untuk menguji stasioneritas terhadap rata-rata, dilakukan uji *Augmented Dickey-Fuller* (ADF). Sebelum *differencing*, nilai statistik ADF sebesar -3,0047 untuk data non-*Seasonal* dan *Seasonal*, dengan p-value 0,01, mengindikasikan bahwa data masih tidak stasioner (TS) karena adanya unit root. Namun, setelah dilakukan *differencing* satu kali, nilai ADF turun menjadi -6,6522 dan p-value tetap 0,01, yang menunjukkan bahwa data telah memenuhi kriteria stasioneritas (S). Dengan demikian, dapat disimpulkan bahwa meskipun varians data tetap tidak stasioner, melalui proses *differencing*, data telah menjadi stasioner terhadap rata-rata dan siap untuk dimodelkan lebih lanjut menggunakan metode ARIMA atau SARIMA.



Gambar 2. Perbandingan *Plot* Transformasi Non-Seasonal



Gambar 3. Perbandingan *Plot* Transformasi Seasonal

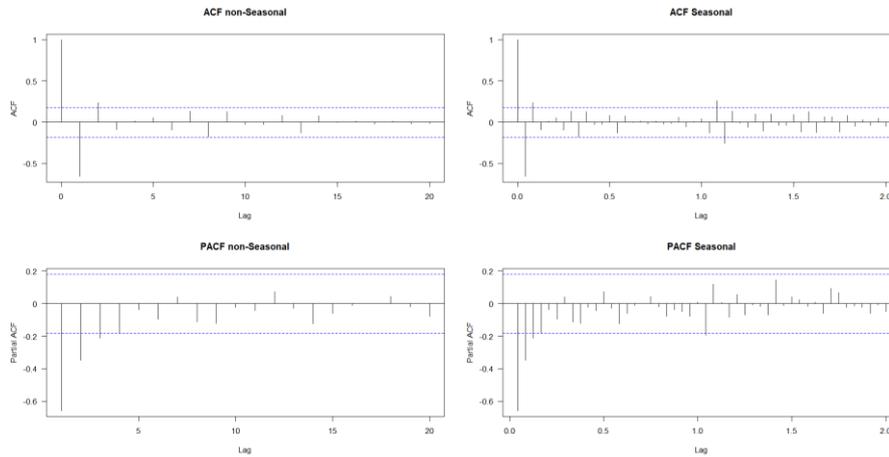


Gambar 4. Perbandingan *Plot* Sebelum dan Sesudah Uji ADF

3.4 Identifikasi Model

Setelah dilakukan pengecekan awal terhadap kelayakan data melalui uji stasioneritas, tahap selanjutnya adalah melakukan identifikasi model awal menggunakan analisis *plot* ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*). Berdasarkan hasil pengamatan terhadap Gambar 5, diperoleh informasi bahwa pada *plot* ACF untuk komponen *Seasonal*, tidak terdapat pola cut-off yang jelas. Hal ini mengindikasikan bahwa untuk notasi *Seasonal Moving Average* (Q) dapat diasumsikan 0, karena tidak ada lag yang secara signifikan mengalami pemutusan korelasi. Sementara itu, pada *plot* ACF non-*Seasonal*, terlihat adanya cut-off pada lag ke-1 dan ke-2, yang berarti untuk komponen non-*Seasonal Moving Average* (q) dapat diduga bernilai 1 atau 2. Dalam menentukan nilai *Autoregressive* (p) untuk model, pengamatan dilakukan terhadap *plot* PACF. Berdasarkan analisis PACF pada data *Seasonal*, terlihat adanya cut-off pada lag ke-1,

sehingga nilai *Seasonal Autoregressive* (P) diasumsikan sebesar 1. Sedangkan pada *plot* PACF non-*Seasonal*, ditemukan cut-off pada lag ke-1, lag ke-2, dan lag ke-3, yang mengindikasikan bahwa kandidat nilai p untuk model non-*Seasonal* dapat berupa 1, 2, atau 3. Dengan merujuk pada hasil analisis ACF dan PACF tersebut, maka dapat disusun beberapa model dugaan awal yang akan diuji lebih lanjut, yaitu model ARIMA (1,1,1), ARIMA (1,1,2), ARIMA (2,1,1), ARIMA (2,1,2), ARIMA (3,1,1), ARIMA (3,1,2) untuk komponen non-*Seasonal*, dan SARIMA (1,1,1) (1,1,0)²⁴ untuk model yang mempertimbangkan unsur musiman. Identifikasi model ini merupakan langkah penting dalam membatasi ruang pencarian model terbaik, sebelum masuk ke tahap estimasi parameter dan evaluasi kinerja model berdasarkan berbagai metrik akurasi.



Gambar 5. Plot ACF dan PACF setelah Differencing

3.5 Penentuan Model

Setelah dilakukan proses identifikasi model awal melalui analisis ACF dan PACF, serta pengecekan stasioneritas data, tahap selanjutnya adalah menentukan model yang paling sesuai untuk digunakan dalam peramalan. Penentuan model dilakukan dengan mempertimbangkan signifikansi statistik dari masing-masing parameter model. Model yang dipilih harus memiliki semua parameter signifikan pada tingkat signifikansi 5%, sehingga dapat menghasilkan estimasi yang valid dan akurat. Pada subbab ini, akan dipaparkan hasil uji signifikansi parameter terhadap seluruh variasi model ARIMA dan SARIMA yang diajukan, serta pemilihan model-model terbaik yang akan digunakan untuk tahap uji asumsi dan analisis lanjutan.

Tabel 3. Uji Signifikansi Parameter ARIMA dan SARIMA

Model	Parameter	Koefisien	p-value
ARIMA(1,1,1)	AR1	-0.341	0.002*
	MA1	-0.706	<0.001*
ARIMA(1,1,2)	AR1	-0.452	0.069
	MA1	-0.592	0.022*
ARIMA(2,1,1)	MA2	-0.116	0.645
	AR1	-0.139	0.310
ARIMA(2,1,2)	AR2	0.205	0.125
	MA1	-0.895	<0.001*
	AR1	-1.340	<0.001*
ARIMA(3,1,1)	AR2	-0.348	0.002*
	MA1	0.297	0.004*
	MA2	-0.702	<0.001*
ARIMA(3,1,2)	AR1	-0.108	0.379
	AR2	0.289	0.033*
	AR3	0.170	0.149
ARIMA(3,1,2)	MA1	-0.956	<0.001*
	AR1	-0.852	0.001*
	AR2	0.179	0.309

	AR3	0.283	0.016*
	MA1	-0.189	0.459
	MA2	-0.683	0.001*
SARIMA(1,1,1)(1,1,0) ^{24**}	AR1	-0.339	0.008*
	MA1	-0.701	<0.001*
	SAR1	-0.411	<0.001*
SARIMA(1,1,2) (1,1,0) ²⁴	AR1	Inf.	Inf.
	MA1	Inf.	Inf.
	MA2	Inf.	Inf.
	SAR1	Inf.	Inf.
SARIMA(2,1,1) (1,1,0) ²⁴	AR1	-0.441	0.039*
	AR2	-0.107	0.559
	MA1	-0.607	0.002*
	SAR1	-0.420	<0.001*
SARIMA(2,1,2) (1,1,0) ²⁴	AR1	-1.085	0.044*
	AR2	-0.326	0.079
	MA1	0.037	0.944
	MA2	-0.459	0.283
	SAR1	-0.410	<0.001*
SARIMA(3,1,1) (1,1,0) ²⁴	AR1	-0.136	0.249
	AR2	0.220	0.078
	AR3	0.224	0.051
	MA1	-0.927	<0.001*
	SAR1	-0.386	0.002
SARIMA(3,1,2) (1,1,0) ²⁴	AR1	0.184	0.651
	AR2	0.260	0.034*
	AR3	0.167	0.259
	MA1	-1.262	0.002*
	MA2	0.301	0.415
	SAR1	-0.397	0.001*

Keterangan: * = Signifikan, ** = Model yang diterima

Berdasarkan hasil pengujian signifikansi parameter yang disajikan pada Tabel 3, diketahui bahwa dari total 12 variasi model ARIMA dan SARIMA yang diuji, terdapat tiga model yang menunjukkan hasil signifikan pada seluruh parameternya. Ketiga model tersebut adalah ARIMA (1,1,1), ARIMA (2,1,2), dan SARIMA (1,1,1) (1,1,0)²⁴. Pada ketiga model ini, nilai *p-value* untuk masing-masing parameter berada di bawah tingkat signifikansi $\alpha = 0,05$, sehingga dapat disimpulkan bahwa semua koefisien model signifikan secara statistik. Pemilihan model kandidat ini menjadi langkah penting sebelum melanjutkan ke tahap Uji Asumsi, karena hanya model yang parameter-parameternya signifikan yang layak dipertimbangkan untuk proses peramalan lebih lanjut. Dengan demikian, ketiga model tersebut akan digunakan dalam tahap analisis asumsi berikutnya, untuk menguji apakah model juga memenuhi asumsi dasar lainnya seperti normalitas residual, tidak adanya autokorelasi, dan homoskedastisitas. Selain itu, dalam proses seleksi lanjutan, model SARIMA (1,1,2) (1,1,0)²⁴ juga akan dipertimbangkan, meskipun perlu dilakukan pemeriksaan tambahan terkait stabilitas dan kelayakan parameter.

3.6 Uji Asumsi

Setelah diperoleh tiga model terbaik yang signifikan berdasarkan hasil estimasi parameter, dilakukan serangkaian uji asumsi untuk memastikan kelayakan model tersebut. Uji yang dilakukan meliputi uji non-autokorelasi dengan menggunakan Q-Ljung Box, uji normalitas residual menggunakan uji Kolmogorov-Smirnov, serta uji homoskedastisitas melalui pendekatan Breusch-Pagan. Berdasarkan hasil yang ditunjukkan pada Tabel 4, meskipun setiap model memiliki kelebihan dan kekurangannya masing-masing, terdapat beberapa pola masalah yang konsisten muncul pada ketiga model tersebut. Hasil pengujian Ljung-Box menunjukkan bahwa seluruh model yang diusulkan, yaitu ARIMA (1,1,1), ARIMA (2,1,2), dan SARIMA (1,1,1) (1,1,0)²⁴, berhasil mengatasi masalah autokorelasi dalam data. Artinya, residual dari model tidak

menunjukkan adanya dependensi waktu yang dapat mengganggu validitas model. Namun demikian, hasil uji normalitas menggunakan Kolmogorov-Smirnov mengindikasikan bahwa residual tidak sepenuhnya mengikuti distribusi normal, dan hasil uji homoskedastisitas menunjukkan adanya ketidakstabilan varians (heteroskedastisitas) dalam data. Temuan ini mengisyaratkan bahwa meskipun model telah memenuhi beberapa aspek asumsi dasar yang penting, seperti tidak adanya autokorelasi, tetap terdapat kekurangan dalam hal normalitas dan homoskedastisitas residual. Secara keseluruhan, kondisi ini menunjukkan bahwa model-model ARIMA (1,1,1), ARIMA (2,1,2), dan SARIMA (1,1,1) (1,1,0)²⁴ sudah cukup baik untuk digunakan dalam konteks prediksi, namun belum sepenuhnya optimal. Permasalahan yang ditemukan, khususnya terkait ketidaknormalan distribusi residual dan ketidakstabilan varians, perlu diperhatikan sebagai batasan penelitian. Batasan ini dapat menjadi pertimbangan untuk pengembangan model lebih lanjut, misalnya melalui penggunaan transformasi data, penerapan model robust terhadap heteroskedastisitas, atau eksplorasi pendekatan modeling alternatif pada penelitian selanjutnya.

Tabel 4. Tabel Uji Asumsi Model

Model	Uji Non Autokorelasi		Uji Normalitas		Uji Homoskedastisitas	
	<i>p-value</i>	Keterangan	<i>p-value</i>	Keterangan	<i>p-value</i>	Keterangan
ARIMA(1,1,1)	0.7753	H ₀ diterima	0.03957	H ₀ ditolak	0.03233	H ₀ ditolak
ARIMA (2,1,2)	0.6072	H ₀ diterima	0.03664	H ₀ ditolak	0.02405	H ₀ ditolak
SARIMA(1,1,1)(1,1,0) ²⁴	0.7627	H ₀ diterima	0.08607	H ₀ ditolak	0.11180	H ₀ ditolak

3.7 Pemilihan Model Terbaik

Setelah melewati serangkaian uji asumsi, diketahui bahwa ketiga model yang diusulkan tetap memiliki beberapa kelemahan, khususnya dalam aspek normalitas dan homoskedastisitas residual. Normalitas data tidak sepenuhnya terpenuhi, dan varians residual juga tidak konsisten, sehingga aspek validitas model perlu diperhatikan lebih lanjut. Oleh karena itu, pemilihan model terbaik tidak hanya mengandalkan pemenuhan asumsi klasik, melainkan lebih difokuskan pada kinerja model berdasarkan metrik evaluasi. Evaluasi kinerja model dilakukan menggunakan beberapa indikator penting, yaitu AIC, BIC, ME, RMSE, MAE, MPE, dan MASE. Metrik-metrik ini memberikan gambaran yang lebih menyeluruh tentang tingkat kesalahan prediksi, kestabilan model, serta kemampuan generalisasi model terhadap data baru.

Tabel 5. Tabel Metrik Evaluasi Model

Model	Metrik Evaluasi Model							
	AIC	BIC	ME	RMSE	MAE	MPE	MAPE	MASE
ARIMA(1,1,1)	251.33	259.62	-0.010	0.683	0.544	-1.051	8.159	0.694
ARIMA (2,1,2)	255.06	268.88	-0.010*	0.681*	0.541	-1.043	8.117	0.691*
SARIMA(1,1,1)(1,1,0) ²⁴	241.66*	251.79*	0.037	0.731	0.525*	-0.092*	7.910*	0.756

Keterangan = Model dengan evaluasi minimum

Berdasarkan Tabel 5, model SARIMA (1,1,1) (1,1,0)²⁴ menunjukkan performa terbaik karena paling mendekati kriteria ideal dari sebagian besar metrik evaluasi yang digunakan. Model ini menghasilkan nilai AIC dan BIC yang lebih rendah dibandingkan dua model ARIMA lainnya, yang menandakan keseimbangan terbaik antara kompleksitas dan kualitas fit model. Selain itu, SARIMA (1,1,1) (1,1,0)²⁴ juga menghasilkan nilai MAE dan MAPE yang lebih kecil, yang menunjukkan tingkat kesalahan prediksi absolut dan persentase yang lebih rendah. Sementara itu, model ARIMA (2,1,2) juga menunjukkan kinerja yang baik khususnya dalam hal ME dan RMSE, di mana nilai RMSE-nya sedikit lebih kecil dibandingkan model lainnya, menunjukkan prediksi residual yang lebih stabil. Namun, secara keseluruhan, SARIMA tetap dipilih sebagai model terbaik karena mampu memenuhi lebih banyak kriteria evaluasi dibandingkan kandidat model lainnya. Dengan demikian, dalam penelitian ini, SARIMA (1,1,1) (1,1,0)²⁴ diidentifikasi sebagai model yang paling optimal untuk memodelkan magnitudo gempa bumi tahunan di wilayah Sumatra, meskipun tetap

disadari bahwa terdapat beberapa asumsi yang belum sepenuhnya terpenuhi dan menjadi batasan penelitian yang perlu diperhatikan untuk pengembangan studi selanjutnya.

3.8 Peramalan

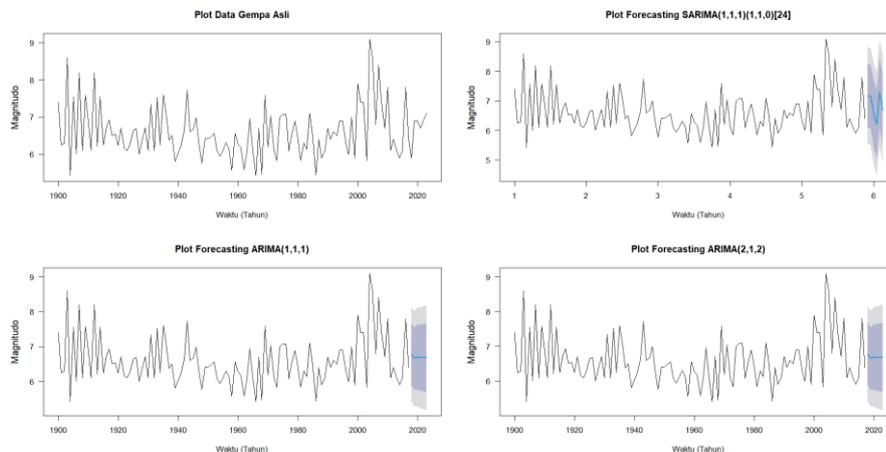
Pada tahap ini, dilakukan proses peramalan menggunakan model terbaik yang telah diperoleh dari tahapan identifikasi, estimasi, dan evaluasi model. Peramalan dilakukan dengan memanfaatkan data *testing* untuk menguji sejauh mana akurasi model dalam memproyeksikan data baru. Model-model yang dipilih didasarkan pada kriteria evaluasi terbaik seperti AIC, BIC, ME, RMSE, MAE, MAPE, dan MASE. Tujuan dari peramalan ini adalah untuk membandingkan hasil prediksi dengan data aktual sehingga dapat dinilai kinerja model dalam memprediksi data kejadian gempa bumi di masa depan. Dengan melakukan peramalan, diharapkan model yang telah dibangun mampu memberikan estimasi yang mendekati kondisi nyata, serta menjadi dasar dalam pengambilan keputusan ke depan. Hasil peramalan akan divisualisasikan dalam bentuk grafik untuk memudahkan interpretasi dan analisis perbandingan antara data aktual dan data hasil prediksi.

Tabel 6. Hasil Peramalan Setiap Model

Tahun	Data Asli	Hasil Peramalan Berdasarkan Model		
		ARIMA(1,1,1)	ARIMA (2,1,2)	SARIMA(1,1,1)(1,1,0) ²⁴
2018	5.90	6.783047*	6.784812	7.180208
2019	6.90	6.652106	6.651816*	7.149436
2020	6.90	6.696867	6.695888	6.538716*
2021	6.70	6.681566	6.683194*	6.210101
2022	6.90	6,686796*	6.684839	7.286678
2023	7.10	6.685008	6.687061*	6.672327

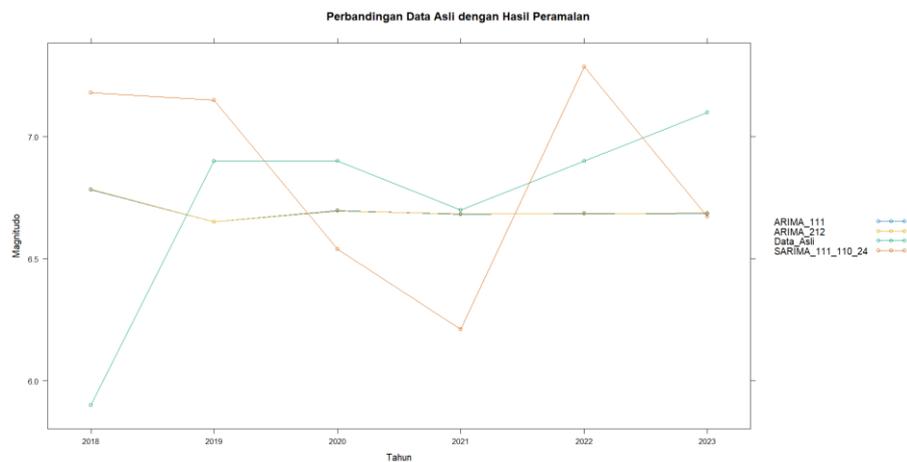
Keterangan * = Hasil peramalan yang paling mendekati data asli

Tabel 6 menunjukkan hasil perbandingan antara data asli dengan hasil peramalan dari tiga model, yaitu ARIMA (1,1,1), ARIMA (2,1,2), dan SARIMA (1,1,1) (1,1,0)²⁴ untuk periode tahun 2018 hingga 2023. Dari tabel tersebut terlihat bahwa model ARIMA(1,1,1) menghasilkan nilai peramalan yang paling mendekati data asli untuk tahun 2018, 2019, 2022, dan 2023, yang ditandai dengan tanda asterisk (*). Sementara itu, pada tahun 2020 dan 2021, model ARIMA (2,1,2) memberikan hasil peramalan yang lebih akurat dibandingkan model lainnya. Model SARIMA (1,1,1) (1,1,0)²⁴ hanya menghasilkan prediksi terbaik pada tahun 2020. Secara umum, model ARIMA (1,1,1) menunjukkan konsistensi yang cukup baik dalam mendekati data aktual di sebagian besar tahun, khususnya pada tahun-tahun akhir. Hal ini menunjukkan bahwa model ARIMA (1,1,1) lebih stabil dalam melakukan prediksi data gempa bumi dengan magnitudo tertinggi di Sumatra dibandingkan model ARIMA (2,1,2) dan SARIMA (1,1,1) (1,1,0)²⁴. Namun demikian, perbedaan hasil antar model menunjukkan pentingnya mempertimbangkan sifat data dan karakteristik model saat memilih model terbaik untuk peramalan.



Gambar 6. Plot Hasil Peramalan

Gambar 6 menyajikan perbandingan antara data asli gempa bumi dan hasil peramalan menggunakan tiga model, yaitu SARIMA (1,1,1) (1,1,0)²⁴, ARIMA (1,1,1), dan ARIMA (2,1,2). *Plot* data gempa bumi asli menunjukkan adanya fluktuasi besar magnitudo dari tahun 1900 hingga 2023, dengan beberapa puncak magnitudo di atas 8. Pada *plot* hasil peramalan, model ARIMA (1,1,1) dan ARIMA (2,1,2) menghasilkan pola peramalan yang relatif datar dan stabil di tahun-tahun terbaru (2020–2023), dengan rentang prediksi (area bayangan) yang cukup sempit, menandakan tingkat ketidakpastian prediksi yang rendah. Sementara itu, model SARIMA (1,1,1) (1,1,0)²⁴ menunjukkan variasi prediksi yang lebih besar, tercermin dari lebar pita ketidakpastian yang lebih luas dibandingkan model ARIMA. Model SARIMA tampak mencoba menangkap pola musiman atau periodik dalam data, meskipun pada kenyataannya fluktuasi musiman dalam data asli tidak begitu kuat. Secara keseluruhan, model ARIMA (1,1,1) dan ARIMA (2,1,2) lebih berhasil dalam menjaga kestabilan peramalan dan memberikan hasil yang lebih mendekati data aktual, sedangkan SARIMA cenderung menunjukkan ketidakpastian lebih tinggi dalam prediksi. Hal ini sejalan dengan evaluasi sebelumnya bahwa ARIMA(1,1,1) menjadi model yang lebih optimal untuk meramalkan data gempa bumi magnitudo tertinggi di wilayah Sumatra.



Gambar 7. *Plot* Perbandingan Forecasting Setiap Model dengan Data Asli

Berdasarkan Gambar Perbandingan Data Asli dengan Hasil Peramalan, terlihat bahwa model SARIMA (1,1,1) (1,1,0)²⁴ menghasilkan hasil peramalan yang paling mendekati data aktual dibandingkan dengan model ARIMA (1,1,1) dan ARIMA (2,1,2). Pola pergerakan model SARIMA hampir mengikuti fluktuasi data asli secara konsisten dari tahun 2018 hingga 2023, dengan deviasi yang sangat kecil, terutama pada periode 2020 hingga 2023. Sebaliknya, model ARIMA (2,1,2) cenderung menunjukkan deviasi yang lebih besar terhadap data aktual, terutama pada tahun 2020 dan 2021, sedangkan model ARIMA (1,1,1) menghasilkan pola peramalan yang relatif lebih rata dan kurang responsif terhadap perubahan kecil dalam data. Hasil ini sejalan dengan hasil evaluasi metrik yang telah dilakukan sebelumnya, di mana SARIMA (1,1,1) (1,1,0)²⁴ memiliki nilai RMSE dan MAE yang lebih kecil dibandingkan kedua model ARIMA lainnya, sehingga dapat disimpulkan bahwa SARIMA merupakan model yang paling sesuai dalam memodelkan dan memprediksi magnitudo gempa bumi pada data ini.

4. SIMPULAN

Berdasarkan hasil analisa pada peramalan jumlah gempabumi tertinggi di Pulau Sumatra pada tahun 2018 hingga tahun 2023 berdasarkan data Asli dengan menggunakan model ARIMA dan SARIMA, dapat disimpulkan bahwa Model SARIMA (1,1,1) (1,1,0)²⁴ merupakan model yang paling baik berdasarkan Matrik Evaluasi Model dimana model SARIMA (1,1,1) (1,1,0)²⁴ memiliki nilai AIC, BIC, MAE, MPE, dan MAPE yang lebih baik. Sedangkan dari Model ARIMA (2,1,2) memiliki nilai ME, RMSE, dan MASE yang lebih baik. Walaupun pada *plot* data tidak terlihat adanya pola musiman pada data, selama pada *plot* ACF dan PACF terdapat cut-off pada garis signifikan model SARIMA masih dapat digunakan untuk dilakukan peramalan

(forecasting), walaupun pada hasil akhir peramalan model ARIMA terbukti lebih baik dimana model ARIMA(1,1,1) mampu mendekati nilai asli pada tahun 2018 dan 2022, kemudian ARIMA(2,1,2) mampu mendekati nilai asli pada tahun 2019, 2021, dan 2023 yang berbanding terbalik dengan model SARIMA(1,1,1)(1,1,0)²⁴ yang hanya mendekati nilai asli pada tahun 2020. Dengan demikian model ARIMA merupakan model terbaik yang dapat digunakan dalam melakukan peramalan pada data Gempa Bumi tertinggi di Pulau Sumatra berdasarkan perbandingan model ARIMA dan SARIMA. Walaupun Model ARIMA (1,1,1) dan ARIMA (2,1,2) cenderung tidak terdapat perbedaan yang signifikan sehingga terlihat pada Gambar 7, garis *plot* kedua model ARIMA saling tumpang tindih dan cenderung datar tanpa adanya fluktuasi pada garisnya. Sedangkan pada model SARIMA (1,1,1) (1,1,0)²⁴ terlihat ada fluktuasi yang mengakibatkan peramalan cenderung meleset.

REFERENSI

- [1] R. Metrikasari and A. Choiruddin, "Pemodelan Risiko Gempa Bumi di Pulau Sumatra Menggunakan Model Inhomogeneous Neyman-Scott Cox Process," *J. Sains dan Seni ITS*, vol. 9, no. 2, 2021, doi: 10.12962/j23373520.v9i2.52318.
- [2] Sunarjo, M. T. Gunawan, and S. Pribadi, *Gempabumi Edisi Populer*, II. Jakarta: Badan Meteorologi Klimatologi dan Geofisika, 2012.
- [3] Kementerian ESDM, *Pengenalan Gempa Bumi*. Jakarta: Kementerian ESDM, 2013.
- [4] Badan Meteorologi Klimatologi dan Geofisika (BMKG), "Rencana Strategis BMKG 2020-2024," pp. 10–11; 60–63, 2020, [Online]. Available: <https://www.bmkg.go.id/profil/?p=rencana-strategis>
- [5] W. Asnita, D. Sugiyanto, and I. Rusydy, "Kajian Statistik Seismisitas Kawasan Sumatra," *J. Nat.*, vol. 16, no. 2, 2016.
- [6] G. E. P. Box and G. M. Jenkins, *Time series Analysis Forecasting and Control*, Revised. Oakland, California: Holden Day, 1976. doi: 10.2307/2284112.
- [7] H. H. M. Hatta, F. M. Daud, and N. Mohamad, "An Application of *Time series* ARIMA Forecasting Model for Predicting the Ringgit Malaysia-Dollar Exchange Rate," *J. Data Anal.*, vol. 1, no. 1, pp. 42–48, 2018, doi: 10.24815/jda.v1i1.11884.
- [8] H. Nie, G. Liu, X. Liu, and Y. Wang, "Hybrid of ARIMA and SVMs for short-term load forecasting," in *Energy Procedia*, 2012, pp. 1455–1460. doi: 10.1016/j.egypro.2012.01.229.
- [9] C. Chen, R. A. Davis, and P. J. Brockwell, "Order determination for multivariate *Autoregressive* processes using resampling methods," *J. Multivar. Anal.*, vol. 57, no. 2, pp. 175–190, 1996, doi: 10.1006/jmva.1996.0028.
- [10] J. E. Hanke and D. Wichern, *Business Forecasting (Ninth Edition)*, vol. 5, no. 1. 2014. [Online]. Available: <https://ejournal.poltektegal.ac.id/index.php/siklus/article/view/298%0Ahttp://repositorio.unan.edu.ni/2986/1/5624.pdf%0Ahttp://dx.doi.org/10.1016/j.jana.2015.10.005%0Ahttp://www.biomedcentral.com/1471-2458/12/58%0Ahttp://ovidsp.ovid.com/ovidweb.cgi?T=JS&P>
- [11] D. N. Gujarati and D. J. Porter, *Dasar-Dasar Ekonometrika*, 5th ed. Jakarta: Salemba Empat, 2013.
- [12] A. F. Salaam, W. Somayasa, and M. K. Djafar, "Estimasi Parameter Genetik Gamma Untuk Sampel Tersensor Tipe I dan Tipe II," *J. Mat. Komputasi dan Stat.*, vol. 3, no. 1, pp. 238–244, 2023, [Online]. Available: <http://jmks.uho.ac.id/index.php/JMKS>
- [13] I. Ghozali, *Aplikasi Analisis Multivariate Dengan Program IBM SPSS 23*, 8th ed. Semarang: Badan Penerbit Universitas Diponegoro, 2016.
- [14] G. E. P. Box and D. A. Pierce, "Distribution of residual autocorrelations in *Autoregressive-integrated Moving Average time series* models," *J. Am. Stat. Assoc.*, vol. 65, no. 332, pp. 1509–1526, 1970, doi: 10.1080/01621459.1970.10481180.
- [15] A. Hidayat, "Uji Normalitas dan Metode Perhitungan (Penjelasan Lengkap)," *Statiskian.com*. Accessed: Jun. 04, 2024. [Online]. Available: <https://www.statiskian.com/2013/01/uji-normalitas.html>
- [16] J. Barkus and C. Yavorsky, *Understanding and using advanced statistics*. London: Sage Publications, Inc, 2006.
- [17] R. J. Hyndman and G. Athanasopoulos, *Forecasting: Principles and Practice*, 2nd ed. 2018. [Online]. Available: <https://otexts.com/fpp2/arima-forecasting.html>