

# Analisis Runtun Waktu untuk Peramalan Banyaknya Kejadian Kecelakaan Lalu Lintas Di Kabupaten Soppeng

Andi Muhammad Fauzan Shadiq

Program Studi Matematika, Universitas Islam Negeri Alauddin Makassar, 60600118025@uin-alauddin.ac.id

Irwan

Program Studi Matematika, Universitas Islam Negeri Alauddin Makassar, irwan.msi@uin-alauddin.ac.id

Khalilah Nurfadilah\*

Program Studi Matematika, Universitas Islam Negeri Alauddin Makassar, khalilah@uin-alauddin.ac.id

\*Corresponding Author

**ABSTRAK.** Analisis runtun waktu merupakan salah satu metode statistika yang banyak digunakan dalam meramalkan kejadian di masa mendatang. Beberapa metode yang populer adalah metode *Autoregressive Integrated Moving Average* (ARIMA) dan *fuzzy time series*. Metode-metode ini dapat diaplikasikan dalam peramalan jumlah kecelakaan lalu lintas sebagai antisipasi terhadap terjadinya, serta adanya peningkatan terhadap jumlah kecelakaan. Tujuan dari penelitian ini adalah mengimplementasikan model ARIMA, serta fuzzy time series dalam data jumlah kecelakaan lalu lintas di Kabupaten Soppeng. Metode yang terbaik dipilih berdasarkan nilai MAPE dan MAD terkecil. Berdasarkan hasil analisis diketahui model *time series* yang terbaik dihasilkan oleh metode *Fuzzy Time Series* model Singh dengan nilai MAPE 12,817% dan MAD 0,77. Model ini kemudian digunakan untuk meramalkan jumlah kecelakaan lalu lintas di kabupaten Soppeng dengan hasil ramalan banyaknya kejadian di setiap bulan adalah 10 kejadian.

**Kata Kunci:** ARIMA, fuzzy-time-series, kecelakaan, lalu lintas, peramalan, Soppeng

## 1. PENDAHULUAN

Kecelakaan lalu lintas ialah salah satu kasus besar di banyak negara, termasuk Indonesia. Kecelakaan lalu lintas menimbulkan ribuan kematian serta puluhan ribu luka-luka tiap tahunnya. Bersumber dari publikasi Badan Pusat Statistik (BPS) tahun 2019, jumlah kecelakaan lalu lintas di Indonesia pada tahun 2019 sebanyak 116411 kasus. Jumlah ini bertambah 6,58% ketimbang tahun sebelumnya yang meraih 109215 kasus. Jumlah kecelakaan lalu lintas dalam sepuluh tahun terakhir mengalami fluktuasi, dengan kenaikan sangat besar terjadi pada tahun 2011 yaitu sebanyak 108000 kasus[1]. Dari data BPS tahun 2021, jumlah kecelakaan di Kabupaten Soppeng pada tahun 2020 ada sebanyak 119 kecelakaan yang terjadi dengan korban luka ringan sebanyak 128, korban

dengan luka berat sebanyak 1 dan korban meninggal dunia sebanyak 37, yang mengakibatkan Kabupaten Soppeng berada di urutan ke- 16 di Sulawesi Selatan[2]. Dalam upaya penanggulangan banyaknya kejadian kecelakaan lalu lintas, maka dilakukan proses peramalan. Langkah ini digunakan sebagai proses antisipasi, sehingga dapat dilakukan langkah konkrit untuk pencegahannya.

Dalam konteks kecelakaan lalu lintas, analisis runtun waktu berperan untuk mengenali pola, serta tren dalam data kecelakaan lalu lintas lebih dahulu, yang selanjutnya dapat digunakan sebagai model untuk memprediksi peristiwa kecelakaan di masa depan. Misalnya, terdapat pola musiman di mana insiden kecelakaan cenderung bertambah sepanjang periode liburan maupun waktu tertentu dalam setahun. Dengan adanya informasi mengenai kejadian kecelakaan lalu lintas, pihak berwenang dan penegak hukum bisa mengambil langkah- langkah yang tepat untuk mengurangi jumlah kecelakaan di Kabupaten Soppeng. Hasil analisis ini dapat pula dijadikan sebagai informasi tambahan untuk membantu dalam perencanaan transportasi serta pengembangan infrastruktur di Kabupaten Soppeng. Peramalan ataupun *forecast* diperlukan dan diterapkan dalam bermacam bidang, mulai dari pendidikan, kesehatan, pembangunan, bisnis sampai ekonomi. Peristiwa peramalan yang baik tergantung pada tiga faktor, yakni seberapa baik ilmuwan data menguasai parameter serta atribut dari set data prediktif, berapa banyak set data yang tersaji, serta apakah hasil yang diprediksi mempengaruhi peramalan[4].

Penelitian ini mencakup 2 metode peramalan, yaitu ARIMA serta Fuzzy Time

Series. ARIMA memodelkan data time series selaku gabungan komponen autoregressive (AR), integrated (I), serta moving average (MA). Model ini digunakan untuk meramalkan data berdasarkan pola historis. Sebaliknya, fuzzy time series, bersumber pada teori logika fuzzy, memungkinkan terdapatnya ketidakpastian serta ambiguitas dalam data time series. Dalam fuzzy time series, variabel time series serta variabel linguistik digunakan untuk mensimulasikan hubungan diantara keduanya. Prosedur ini bisa berfungsi pada saat prosedur tradisional seperti ARIMA tidak mampu mengenali data variasi yang relatif besar.

Adapun penelitian sebelumnya yang berkaitan dengan peramalan kecelakaan lalu lintas yaitu Canseria Yuli dkk.[5] dalam meramalkan kecelakaan lalu lintas di Kota Pontianak pada tahun 2019, Ema Mawaddah[6] dalam meramalkan kecelakaan lalu lintas di Kabupaten Mempawah pada tahun 2023, Mega dan Gebryani Rante[7] dalam meramalkan kecelakaan lalu lintas di Kota Balikpapan pada tahun 2023, Iantazar Rezqitullah dkk.[8] dalam meramalkan kecelakaan lalu lintas di Kota Semarang pada tahun 2017 dan Aleksius[9] dalam meramalkan kecelakaan lalu lintas di Kabupaten Timor Tengah Utara.

## 2. TINJAUAN PUSTAKA

### Fuzzy Time Series

Logika *fuzzy* merupakan logika yang memiliki nilai *fuzzy* antara benar atau salah. Dalam teori logika *fuzzy*, nilai yang salah yaitu benar ataupun salah secara bersama-sama, dengan keberadaan elemen serta tingkatan kesalahannya bergantung pada bobot keanggotaan elemen. Ada Derajat keanggotaan antara 0 sampai 1. Berbeda dengan logika numerik yang cuma mempunyai 2 nilai adalah 1 ataupun 0. Logika fuzzy membolehkan penerjemahan besaran dalam bahasa (linguistik), misalnya kecepatan kendaraan yang sanggup diterjemahkan jadi pelan, agak kencang, kencang, serta sangat kencang.

Logika *fuzzy* memutuskan berapa banyak nilai yang benar serta salah. Berbeda dengan logika tradisional, cuma terdapat 2 metode guna mengevaluasi. Maksudnya, apakah diduga anggota himpunan. Nilai tersebut ada derajat

keanggotaan 0 ataupun 1, yang menampilkan nilai tersebut apakah menggambarkan anggota himpunan[10].

*Fuzzy time series* merupakan suatu konsep baru yang diperkenalkan oleh Song dan Chissom, yang didasarkan pada teori himpunan *fuzzy* serta konsep variabel linguistik dan juga aplikasinya oleh Zadeh. Setelah itu, pada tahun 1996, Chen memperkenalkan prosedur peramalan *fuzzy time series* dengan memakai operasi aritmetika. Pada tahun 2001, Huarng menyajikan model heuristik guna peramalan time series dengan memakai hubungan heuristik yang meninggi serta menyusut untuk meningkatkan peramalan registrasi serta pertukaran di Taiwan. Pada tahun 2007, Singh mengajukan algoritma komputasi simpel yang bisa mengurangi waktu untuk menciptakan persamaan relasional dengan memakai operasi komposisi max-min yang kompleks dan juga mengurangi waktu dalam proses defuzzifikasi pada prosedur Song dan Chissom. Prosedur Singh ini menyelesaikan permasalahan dalam mencari prosedur defuzzifikasi yang sesuai guna menghasilkan nilai output yang pas dengan akurasi yang lebih besar[11]. Secara umum, tahapan yang digunakan pada *fuzzy time series* adalah sebagai berikut:

1. Menentukan himpunan semesta pembicaraan ( $U$ ) data aktual dengan rumus berikut:

$$U = [X_{min}, X_{max}] \quad (2.1)$$

2. Menentukan banyaknya himpunan *fuzzy* dengan rumus sebagai berikut:

- a. Menentukan panjang interval ( $R$ ) dengan rumus sebagai berikut:

$$R = X_{max} - X_{min} \quad (2.2)$$

- b. Hitung rata-rata nilai selisih dengan rumus sebagai berikut:

$$mean = \frac{\sum_{t=1}^{N-1} |x_{t-1} - x_t|}{N-1} \quad (2.3)$$

dengan  $x_t$  adalah nilai amatan di waktu ke- $t$  dan  $N$  adalah jumlah amatan.

- c. Menentukan basis interval ( $K$ ) hasil dari persamaan (3) dengan rumus sebagai berikut:

$$K = \frac{mean}{2} \quad (2.4)$$

- d. Menentukan nilai basis interval.
- e. Menentukan banyaknya himpunan *fuzzy* ( $n$ ) dengan rumus sebagai berikut:

$$n = \frac{R}{K} \quad (2.5)$$

f. Mencari nilai tengah himpunan fuzzy ( $m_i$ ) dengan rumus sebagai berikut :

$$m_i = \frac{(\text{Batas atas } u_i + \text{Batas bawah } u_i)}{2} \quad (2.6)$$

3. Fuzzyfikasi. Proses ini mengganti input sistem yang bernilai numeris jadi variabel linguistik dengan memakai nilai keanggotaan yang tersimpan dalam basis pengetahuan fuzzy. Nilai keanggotaan dari himpunan fuzzy  $u_i$  disederhanakan dengan nilai antara 0, 0.5, dan 1, di mana  $1 \leq i \leq n$  yaitu jumlah himpunan fuzzy. Matriks ini mendefinisikan derajat keanggotaan himpunan fuzzy:

$$\mu_{A_i}(u_i) = \begin{cases} 1 & \text{jika } i = i \\ 0,5 & \text{jika } i = i - 1 \text{ atau } i = i + 1 \\ 0 & \text{jika yang lainnya} \end{cases}$$

4. Membuat *Fuzzy Logical Relationship* (FLR) menurut data aktual. Tahap ini menentukan hubungan logika fuzzy adalah  $A_i \rightarrow A_j$ .  $A_i$  ialah *current state* dan  $X_t$  adalah *next state* pada waktu ke  $t$ .

5. Menciptakan *Fuzzy Logical Relationship Group* (FLRG) yang dilakukan dengan teknik mengelompokkan anggota dari proses fuzzyfikasi yang mempunyai *current state* yang sama, setelah itu kemudian dikelompokkan menjadi satu kelompok pada *next state*. Proses defuzzyfikasi dilakukan dengan mengganti output fuzzy yang diperoleh dari peraturan logika fuzzy sebagai nilai tegas menggunakan nilai keanggotaan yang cocok pada tahapan fuzzyfikasi. Pada tahap ini, output fuzzy akan diganti menjadi nilai tegas untuk menghasilkan nilai peramalan[12].

6. Menghitung akurasi hasil peramalan. Dalam tahapan ini ada tiga ukuran yang umum digunakan untuk menentukan nilai akurasi peramalan [13][14], yaitu:

a. *Mean Absolute Deviation* (MAD)

$$MAD = \left(\frac{1}{n}\right) \sum |A_t - F_t| \quad (2.7)$$

b. *Mean Squared Error* (MSE)

$$MSE = \left(\frac{1}{n}\right) \sum (A_t - F_t)^2 \quad (2.8)$$

c. *Mean Absolute Percentage Error* (MAPE)

$$MAPE = \left(\frac{100}{n}\right) \sum \left| \frac{A_t - F_t}{A_t} \right| \quad (2.9)$$

Nilai MAPE yang dihasilkan mempunyai interpretasi sebagai berikut:

- 1) Jika nilai MAPE kurang dari 10% maka keakuratan peramalannya sangat baik.
- 2) Jika nilai MAPE adalah mulai dari 10% sampai kurang dari 20% maka keakuratan peramalannya cukup baik.
- 3) Jika nilai MAPE adalah mulai dari 20% sampai kurang dari 50% maka keakuratan peramalannya cukup buruk.
- 4) Jika nilai MAPE lebih atau sama dengan 50% maka keakuratan peramalannya buruk.

### Model ARIMA

Diperkenalkan pada tahun 1970 oleh George Box dan Gwilym Jenkins, ARIMA merupakan teknik yang digunakan untuk estimasi sementara. Sistem ARIMA benar-benar sesuai untuk prediksi sementara karena tingkat presisinya yang tinggi. Selain itu, metode ini mampu mengidentifikasi hubungan statistik yang kuat antara variabel prakiraan dan nilai prakiraan. Akan tetapi, metode ini biasanya memiliki tingkat akurasi yang lebih rendah untuk prakiraan jangka panjang[15].

ARIMA secara umum dikomunikasikan sebagai ARIMA(p,d,q), dimana p merupakan permintaan untuk koefisien autokorelasi, d merupakan permintaan atau jumlah differensi yang diterapkan, dan q merupakan permintaan untuk koefisien MA[16].

Peramalan dengan menggunakan model ARIMA(p,d,q) dapat dilakukan dengan rumus:

$$Y_t = \partial_0 + \partial_1 Y_{t-1} + \dots + \partial_p Y_{t-p} - e_t - \lambda_1 e_{t-1} - \dots - \lambda_q e_{t-q} \quad (2.10)$$

Keterangan:

$\partial_0, \partial_1, \dots, \partial_p$  = Koefisien AR

$Y_t$  = Variabel dependen pada waktu t

$Y_{t-1} \dots Y_{t-p}$  = Variabel lag

$e_t, e_{t-1}, \dots, e_{t-q}$  : Residual term

Langkah-langkah penerapan metode ARIMA secara berurutan adalah membuat plot data untuk identifikasi model, mengestimasi parameter model, melakukan pemeriksaan diagnostik, dan kemudian melakukan peramalan.

### 1. Plot data

Plot data bertujuan untuk mengecek kestasioneran data, berkaitan dengan nilai rata-rata dan varians amatan. Dengan kata lain, data stasioner yaitu data yang tidak menampilkan tren peningkatan maupun pengurangan yang ekstrem. Model ARIMA mengasumsikan jika data input wajib stasioner.

### 2. Identifikasi Model

Semacam yang sudah dijabarkan lebih dahulu, model ARIMA cuma bisa diterapkan pada time series yang stasioner. Oleh sebab itu, langkah mula-mula yang mesti dicoba yaitu mengecek apakah data yang digunakan telah stasioner. Jika data tidak stasioner data rata-rata, maka perlu dilakukan proses pembedaan (*differencing*). Proses ini bisa dilakukan dengan memakai koefisien ACF, uji akar unit, serta derajat integrasi. Tidak hanya menentukan  $d$ , pada tahap ini pula ditetapkan jumlah nilai lag residual ( $q$ ) serta nilai lag dependen ( $p$ ) yang akan digunakan dalam model.

Nilai-nilai yang digunakan untuk menentukan derajat  $p$  dan  $q$  dari model ARIMA didasarkan pada plot ACF dan PACF data amatan. Koefisien PACF mengukur korelasi antara nilai-nilai amatan saat ini dengan nilai-nilai amatan sebelumnya, sedangkan pengaruh nilai variabel time lag yang lain dianggap konstan. Secara matematis, koefisien PACF berorde  $p$  didefinisikan sebagai koefisien AR terakhir dari model AR( $p$ ). Tidak hanya itu, untuk memastikan model ARIMA( $p, d, q$ ) dapat pula dilakukan dengan membaca grafik ACF serta PACF dari data yang sudah didifferensikan. Pola yang timbul dalam grafik tersebut bisa digunakan buat memastikan model ARIMA (Cryer, 2008).

### 3. Estimasi Parameter

Setelah diidentifikasi model-model yang mungkin digunakan berdasarkan tahapan sebelumnya, langkah selanjutnya yaitu mengestimasi parameter AR dan MA yang tercantum dalam model. Apabila hanya terdapat proses AR, maka parameter dapat diestimasi menggunakan prosedur kuadrat terkecil. Bila pola MA teridentifikasi, maka estimasi dapat dilakukan dengan prosedur Maximum Likelihood (MLE) atau prosedur kuadrat terkecil, yang keduanya membutuhkan prosedur

optimasi non-linier karena ada komponen MA yang mengakibatkan ketidaklinieran parameter, namun hal ini tidak lagi menjadi kendala disebabkan oleh kemajuan komputasi saat ini.

### 4. Pemeriksaan Diagnostik

Setelah melakukan prosedur estimasi, tahapan selanjutnya adalah pemeriksaan diagnostik. Dalam tahapan ini dilakukan uji kelayakan terhadap model sementara sebelum memutuskan model yang akan digunakan untuk peramalan.

### 5. Melakukan Peramalan

Setelah diperoleh model layak dari tahapan sebelumnya, langkah berikutnya yaitu melakukan peramalan. Menurut karakteristiknya, model time series semacam ini lebih cocok buat peramalan jangka pendek, sebaliknya model struktural lebih sesuai buat peramalan jangka panjang [16].

## 3. METODOLOGI

Data yang digunakan dalam penelitian ini merupakan data sekunder yang bersumber dari Badan Pusat Statistik Kabupaten Soppeng dan Polres Soppeng, berupa data jumlah kecelakaan lalu lintas di bulan Januari 2010 sampai Mei 2022. Dataset ini kemudian dibagi ke dalam data in-sample, yaitu data pada bulan Januari 2010 sampai Desember 2020 sebagai data *in sample*, dan data out-sample, yaitu data bulan Januari 2021 sampai Mei 2022, yang akan digunakan dalam evaluasi hasil ramalan.

### Prosedur Analisis

Prosedur analisis yang digunakan pada penelitian ini adalah sebagai berikut:

1. Mengumpulkan data jumlah kejadian kecelakaan lalu lintas di Kabupaten Soppeng dari Januari 2010 sampai Mei 2022 yang bersumber dari Badan Pusat Statistik (BPS) Kabupaten Soppeng.
2. Melakukan peramalan menggunakan *Fuzzy Time Series*
  - a. Menentukan himpunan semesta  $U$ .
  - b. Mendefinisikan himpunan fuzzy  $A_i$  pada data historis.
  - c. Fuzzyfikasi data historis.
  - d. Membuat *fuzzy logical relationship* (FLR) berdasarkan data historis.

- e. Menetapkan *fuzzy logical relationship group* (FLRG).
  - f. Melakukan defuzzifikasi pada data *fuzzy*.
  - g. Melakukan peramalan.
3. Melakukan peramalan menggunakan metode ARIMA
- a. Mengidentifikasi model ARIMA.
  - b. Estimasi model ARIMA.
  - c. Uji diagnostik.
  - d. Memilih model ARIMA yang layak.
  - e. Melakukan peramalan.
4. Menghitung nilai ketepatan peramalan dengan menggunakan MAD, MSE dan MAPE.

#### 4. PEMBAHASAN

##### *Fuzzy Time Series*

Tahapan analisis *Fuzzy Time Series* dimulai dari menentukan himpunan semesta dari data amatan. Himpunan semesta untuk data yang digunakan yaitu  $U = [1:23]$ . Selanjutnya menentukan banyaknya interval, dengan hasil perhitungan diperoleh jumlah kelas adalah 8,1715 dan dibulatkan menjadi 8. Setelah itu menentukan panjang kelas interval, maka panjang kelas interval yaitu 2,75 maka himpunan semesta ( $u_i$ ) yang terbentuk yaitu  $u_1, u_2, \dots, u_8$ , dengan interval-interval himpunan semesta ( $u_i$ ) dan nilai tengah seperti Tabel 4.1 berikut:

**Tabel 4.1** Panjang interval pada data historis

No.	Panjang Interval	Nilai tengah
1.	$u_1 = [1:3,75]$	2,375
2.	$u_2 = [3,75:6,5]$	5,125
3.	$u_3 = [6,5:9,25]$	7,875
4.	$u_4 = [9,25:12]$	10,625
5.	$u_5 = [12:14,75]$	13,375
6.	$u_6 = [14,75:17,5]$	16,125
7.	$u_7 = [17,5:20,25]$	18,875
8.	$u_8 = [20,25:23]$	21,625

Setelah diperoleh himpunan semesta  $u_1, u_2, \dots, u_8$ , maka dapat dihitung nilai  $A_1, A_2, \dots, A_8$ , yang merupakan kumpulan *fuzzy* nilai linguistik dari variabel linguistik. Nilai keanggotaan himpunan *fuzzy* A berkisar antara 0, 0,5, atau 1 dengan  $1 \leq i \leq 8$ . Angka 8 merupakan jumlah kelas interval. Oleh karena itu definisi setiap himpunan *fuzzy*  $A_i$  yang terbentuk adalah seperti berikut:

$$\begin{aligned}
 A_1 &= \left\{ \frac{1}{u_1} + \frac{0,5}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \frac{0}{u_5} + \frac{0}{u_6} + \frac{0}{u_7} + \frac{0}{u_8} \right\} \\
 A_2 &= \left\{ \frac{0,5}{u_1} + \frac{1}{u_2} + \frac{0,5}{u_3} + \frac{0}{u_4} + \frac{0}{u_5} + \frac{0}{u_6} + \frac{0}{u_7} + \frac{0}{u_8} \right\} \\
 A_3 &= \left\{ \frac{0}{u_1} + \frac{0,5}{u_2} + \frac{1}{u_3} + \frac{0,5}{u_4} + \frac{0}{u_5} + \frac{0}{u_6} + \frac{0}{u_7} + \frac{0}{u_8} \right\} \\
 A_4 &= \left\{ \frac{0}{u_1} + \frac{0}{u_2} + \frac{0,5}{u_3} + \frac{1}{u_4} + \frac{0,5}{u_5} + \frac{0}{u_6} + \frac{0}{u_7} + \frac{0}{u_8} \right\} \\
 A_5 &= \left\{ \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \frac{0,5}{u_4} + \frac{1}{u_5} + \frac{0}{u_6} + \frac{0}{u_7} + \frac{0}{u_8} \right\} \\
 A_6 &= \left\{ \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \frac{0,5}{u_5} + \frac{1}{u_6} + \frac{0,5}{u_7} + \frac{0}{u_8} \right\} \\
 A_7 &= \left\{ \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \frac{0}{u_5} + \frac{0,5}{u_6} + \frac{1}{u_7} + \frac{0,5}{u_8} \right\} \\
 A_8 &= \left\{ \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \frac{0}{u_5} + \frac{0}{u_6} + \frac{0,5}{u_7} + \frac{1}{u_8} \right\}
 \end{aligned}$$

Langkah selanjutnya adalah melakukan fuzzifikasi berdasarkan interval yang diperoleh. Nilai linguistik dapat ditentukan oleh banyaknya interval yang telah terbentuk, seperti pada Tabel 4.2 berikut:

**Tabel 4.2** Data fuzzifikasi pada data historis

Tahun	Bulan	Jumlah Kejadian Kecelakaan Lalu Lintas	Fuzzifikasi
2010	Januari	2	$A_1$
	Februar i	4	$A_2$
	Marer	2	$A_1$
	April	4	$A_2$
	Mei	1	$A_1$
	Juni	1	$A_1$
∴	∴	∴	∴
2020	Juli	7	$A_3$
	Agustu s	9	$A_3$
	Septem ber	13	$A_5$
	Oktobe r	15	$A_6$
	Novem ber	12	$A_4$
	Desem ber	16	$A_6$

Proses selanjutnya adalah FLR. FLR diidentifikasi berdasarkan data historis yang telah difuzzifikasikan pada tahap sebelumnya. FLR ditulis  $A_i \rightarrow A_j$ . Maka hasil FLR dari data dilihat pada Tabel 4.3 berikut:

**Tabel 4.3** Data FLR pada data historis

Tahun	Bulan	Fuzzifikasi	FLR
2010	Januari	$A_1$	-
	Februari	$A_2$	$A_1 \rightarrow A_2$
	Maret	$A_1$	$A_2 \rightarrow A_1$
	April	$A_2$	$A_1 \rightarrow A_2$
	Mei	$A_1$	$A_2 \rightarrow A_1$
	Juni	$A_1$	$A_1 \rightarrow A_1$
⋮	⋮	⋮	⋮
2020	Juli	$A_3$	$A_3 \rightarrow A_3$
	Agustus	$A_3$	$A_3 \rightarrow A_3$
	September	$A_5$	$A_3 \rightarrow A_5$
	Oktober	$A_6$	$A_5 \rightarrow A_6$
	November	$A_4$	$A_6 \rightarrow A_4$
	Desember	$A_6$	$A_4 \rightarrow A_6$

Langkah selanjtnya adalah membuat FLRG dengan berdasarkan dari hasil FLR yang telah diperoleh sebelumnya dengan cara mengelompokkan setiap FLR dengan ruas kiri atau  $F_{(t-1)}$  yang sama kemudian menggabungkannya ke dalam kelompok yang sesuai. Hasil FLRG dilihat pada tabel berikut.

**Tabel 4.4** Hasil FLRG Model Chen

Grup	FLRG
1	$A_1 \rightarrow A_1, A_2, A_3, A_4$
2	$A_2 \rightarrow A_1, A_2, A_3, A_4, A_5$
3	$A_3 \rightarrow A_1, A_2, A_3, A_4, A_5, A_6$
4	$A_4 \rightarrow A_1, A_2, A_3, A_4, A_5, A_6$
5	$A_5 \rightarrow A_1, A_2, A_3, A_4, A_5, A_6$
6	$A_6 \rightarrow A_1, A_3, A_4, A_5, A_8$
7	$A_7 \rightarrow -$
8	$A_8 \rightarrow A_6$

Selanjutnya adalah Proses *defuzzifikasi* menggunakan nilai tengah dari masing-masing grup *fuzzy*. Hasil *defuzzifikasi* dapat dilihat pada tabel berikut.

**Tabel 4.5** Defuzzifikasi data *fuzzy time series* model Chen

Grup	FLRG	Nilai ramalan
1	$A_1 \rightarrow A_1, A_2, A_3, A_4$	6,5
2	$A_2 \rightarrow A_1, A_2, A_3, A_4, A_5$	7,875
3	$A_3 \rightarrow A_1, A_2, A_3, A_4, A_5, A_6$	9,25
4	$A_4 \rightarrow A_1, A_2, A_3, A_4, A_5, A_6$	9,25
5	$A_5 \rightarrow A_1, A_2, A_3, A_4, A_5, A_6$	9,25
6	$A_6 \rightarrow A_1, A_3, A_4, A_5, A_8$	11,175
7	$A_7 \rightarrow -$	0
8	$A_8 \rightarrow A_6$	16,125

Nilai peramalan dari defuzzifikasi kemudian langsung diekstrak ke seluruh data berdasarkan hasil fuzzifikasi data sebelumnya. Adapun hasil peramalan untuk keseluruhan data sebagai berikut.

**Tabel 4.6** Hasil peramalan dengan model Chen

Tahun	Bulan	Nilai aktual	Nilai ramalan
2010	Januari	2	-
	Februari	4	6,5
	Maret	2	7,875
	April	4	6,5
	Mei	1	7,875
	Juni	1	6,5
⋮	⋮	⋮	⋮
2020	Juli	7	9,25
	Agustus	9	9,25
	September	13	9,25
	Oktober	15	9,25
	November	12	11,175
	Desember	16	9,25

Tahap selanjutnya adalah ukuran ketepatan peramalan dengan menggunakan MAPE, MAD dan MSE. Hasil ketetapan peramalan bisa dilihat pada Tabel 4.7 berikut:

**Tabel 4.7** Hasil nilai MAPE, MAD dan MSE model Chen

Ukuran ketepatan	Nilai
MAPE	62,764%
MAD	2,998
MSE	13,784

Pada *fuzzy time series* model Lee, hasil pada fuzzifikasi dan FLR sama dengan model *fuzzy time series* sebelumnya. Maka dilanjutkan dengan menentukan FLRG model Lee. Hasil FLRG dilihat pada Tabel 4.8 berikut:

**Tabel 4.8** Hasil FLRG Model Lee

Grup	FLRG
1	$A_1 \rightarrow A_1(4), A_2(7), A_3(2), A_4$
2	$A_2 \rightarrow A_1(5), A_2(16), A_3(10), A_4(4), A_5(2)$
3	$A_3 \rightarrow A_1, A_2(10), A_3(9), A_4(4), A_5(6), A_6(2)$

4	$A_4 \rightarrow A_1, A_2(3), A_3(5), A_4(9), A_5(2), A_6(4)$
5	$A_5 \rightarrow A_1, A_2, A_3(4), A_4(3), A_5, A_6(4)$
6	$A_6 \rightarrow A_1, A_3(3), A_4(3), A_5(2), A_8$
7	$A_7 \rightarrow -$
8	$A_8 \rightarrow A_6$

Hasil defuzzifikasi pada model Lee dapat dilihat pada tabel berikut.

**Tabel 4.9** Defuzzifikasi data *fuzzy time series* model Lee

Grup	FLRG	Nilai ramalan
1	$A_1 \rightarrow A_1(4), A_2(7), A_3(2), A_4$	5,125
2	$A_2 \rightarrow A_1(5), A_2(16), A_3(10), A_4(4), A_5(2)$	6,537
3	$A_3 \rightarrow A_1, A_2(10), A_3(9), A_4(4), A_5(6), A_6(2)$	8,728
4	$A_4 \rightarrow A_1, A_2(3), A_3(5), A_4(9), A_5(2), A_6(4)$	10,167
5	$A_5 \rightarrow A_1, A_2, A_3(4), A_4(3), A_5, A_6(4)$	10,837
6	$A_6 \rightarrow A_1, A_3(3), A_4(3), A_5(2), A_8$	10,625
7	$A_7 \rightarrow -$	-
8	$A_8 \rightarrow A_6$	16,125

Adapun nilai peramalan untuk data adalah sebagai berikut.

**Tabel 4.10** Hasil peramalan dengan model Lee

Tahun	Bulan	Nilai aktual	Nilai ramalan
2010	Januari	2	-
	Februari	4	5,125
	Maret	2	6,537
	April	4	5,125
	Mei	1	6,537
	Juni	1	5,125
2020	Juli	7	8,728
	Agustus	9	8,728
	Septem- ber	13	8,728
	Oktober	15	10,837
	Novemb- er	12	10,625
	Desembe- r	16	10,167

Hasil ketetapan peramalan pada model Lee bisa dilihat pada tabel berikut.

**Tabel 4.11** Hasil nilai MAPE, MAD dan MSE pada model Lee

Ukuran Ketepatan	Nilai
MAPE	54,56%
MAD	2,768
MSE	12,682

Pada *fuzzy time series* model Heuristic, hasil pada fuzzifikasi dan FLR sama dengan model *fuzzy time series* sebelumnya. Maka dilanjutkan dengan menentukan FLRG model Heuristic. Hasil dari FLRG dapat dilihat pada tabel berikut.

**Tabel 4.12** Hasil FLRG Model Heuristic

FLRG	Heuris- tic ↑ atau ↓	FLRG Heuristic
$A_1 \rightarrow A_1, A_2, A_3, A_4$	↑	$A_1 \rightarrow A_1, A_2, A_3, A_4$
$A_2 \rightarrow A_1, A_2, A_3, A_4, A_5$	↓	$A_1 \rightarrow A_1$
$A_3 \rightarrow A_1, A_2, A_3, A_4, A_5, A_6$	↑	$A_2$
$A_4 \rightarrow A_1, A_2, A_3, A_4, A_5,$	↓	$\rightarrow A_2, A_3, A_4, A_5$
$A_5 \rightarrow A_1, A_2, A_3, A_4, A_5,$	↑	$A_2 \rightarrow A_1, A_2$
$A_6 \rightarrow A_1, A_3, A_4, A_5, A_8$	↓	$A_3 \rightarrow A_3$
$A_7 \rightarrow -$	↑	$A_3, A_4, A_5, A_6$
$A_8 \rightarrow A_6$	↓	$A_3 \rightarrow A_1, A_2, A_3$
	↑	$A_4 \rightarrow A_4, A_5, A_6$
	↓	$A_4 \rightarrow A_1, A_2, A_3, A_4$
	↑	$A_5 \rightarrow A_5, A_6$
	↓	$A_5 \rightarrow A_1, A_2, A_3, A_4,$
	↑	$A_6 \rightarrow A_8$
	↓	$A_6 \rightarrow A_1, A_3, A_4, A_5$
	↑	$A_7 \rightarrow -$
	↓	$A_7 \rightarrow -$
	↑	$A_8 \rightarrow A_8$
	↓	$A_8 \rightarrow A_6$

Hasil defuzzifikasi pada model Heuristic dapat dilihat pada tabel berikut.

**Tabel 4.13** Defuzzifikasi data *fuzzy time series* model Heuristic

FLRG	Heuris- tic ↑ atau ↓	FLRG Heuristic	Defuzzifikasi
$A_1 \rightarrow A_1, A_2, A_3, A_4$	↑	$A_1 \rightarrow A_1, A_2, A_3, A_4$	6,5
$A_3, A_4$	↓	$A_1 \rightarrow A_1$	2,375

$A_2$	$\uparrow$	$A_2$	9,25
$\rightarrow A_1, A_2,$		$\rightarrow A_2, A_3, A_4, A_5$	
$A_3, A_4, A_5$	$\downarrow$	$A_2 \rightarrow A_1, A_2$	3,75
$A_3$	$\rightarrow$	$A_3$	12
$A_1, A_2, A_3,$	$\uparrow$	$A_3, A_4, A_5, A_6$	
$A_4, A_5, A_6$	$\downarrow$	$A_3$	5,125
$A_4$		$A_1, A_2, A_3$	
$\rightarrow A_1, A_2,$	$\uparrow$	$A_4$	13,375
$A_3, A_4, A_5,$		$\rightarrow A_4, A_5, A_6$	
$A_6$	$\downarrow$	$A_4$	6,5
$A_5$	$\uparrow$	$\rightarrow A_1, A_2, A_3, A_4$	
$\rightarrow A_1, A_2,$		$A_5 \rightarrow A_5, A_6$	14,75
$A_3, A_4,$	$\downarrow$	$A_5$	
$A_5, A_6$		$\rightarrow A_1, A_2, A_3,$	7,875
$A_6$	$\uparrow$	$A_4, A_5$	
$\rightarrow A_1, A_3,$		$A_6 \rightarrow A_8$	21,625
$A_4, A_5, A_8$	$\downarrow$	$A_6$	8,5625
$A_7 \rightarrow -$	$\uparrow$	$\rightarrow A_1, A_3, A_4, A_5$	
	$\downarrow$	$A_7 \rightarrow -$	
$A_8 \rightarrow A_6$	$\uparrow$	$A_7 \rightarrow -$	
	$\downarrow$	$A_8 \rightarrow A_8$	21,625
		$A_8 \rightarrow A_6$	16,125

Adapun hasil peramalan untuk keseluruhan data sebagai berikut.

**Tabel 4.14** Hasil peramalan dengan model Heuristic

Tahun	Bulan	Nilai aktual	Nilai ramalan
2010	Januari	2	-
	Februari	4	6,50
	Maret	2	3,75
	April	4	6,50
	Mei	1	3,75
	Juni	1	6,50
$\vdots$	$\vdots$	$\vdots$	$\vdots$
2020	Juli	7	5,125
	Agustus	9	12,000
	Septemb er	13	12,000
	Oktober	15	14,750
	Novemb er	12	8,563
	Desembe r	16	13,375

Hasil ketetapan peramalan pada model Heuristic bisa dilihat pada tabel 4.15. Pada *fuzzy time series* model Singh, hasil pada fuzzifikasi dan FLR sama dengan model *fuzzy time series* sebelumnya.

**Tabel 4.15** Hasil nilai MAPE, MAD dan MSE model Heuristic

Ukuran Ketetapan	Nilai
MAPE	41,532%
MAD	2,079
MSE	6,150

Maka dilanjutkan dengan menentukan FLRG model Singh. Hasil dari FLRG pada program R dapat dilihat pada Tabel 4.16 berikut:

**Tabel 4.16** Hasil FLRG pada model Singh

Grup	FLRG
1	$A_1 \rightarrow A_1, A_2, A_3, A_4$
2	$A_2 \rightarrow A_1, A_2, A_3, A_4, A_5$
3	$A_3 \rightarrow A_1, A_2, A_3, A_4, A_5, A_6$
4	$A_4 \rightarrow A_1, A_2, A_3, A_4, A_5, A_6$
5	$A_5 \rightarrow A_1, A_2, A_3, A_4, A_5, A_6$
6	$A_6 \rightarrow A_1, A_3, A_4, A_5, A_8$
7	$A_7 \rightarrow -$
8	$A_8 \rightarrow A_6$

Berdasarkan hasil defuzzifikasi model Singh pada program R maka nilai peramalannya disajikan dalam Tabel 4.17 berikut:

**Tabel 4.17** Hasil peramalan pada model Singh

Tahun	Bulan	Nilai aktual	Nilai ramalan
2010	Januari	2	NA
	Februari	4	NA
	Maret	2	NA
	April	4	5,125
	Mei	1	2,375
	Juni	1	1,882
$\vdots$	$\vdots$	$\vdots$	$\vdots$
2020	Juli	7	7,802
	Agustus	9	8,135
	Septemb er	13	13,375
	Oktober	15	16,042
	Novemb er	12	10,813
	Desembe r	16	15,563

Hasil ketetapan peramalan pada model Singh bisa dilihat pada Tabel 4.18 berikut:

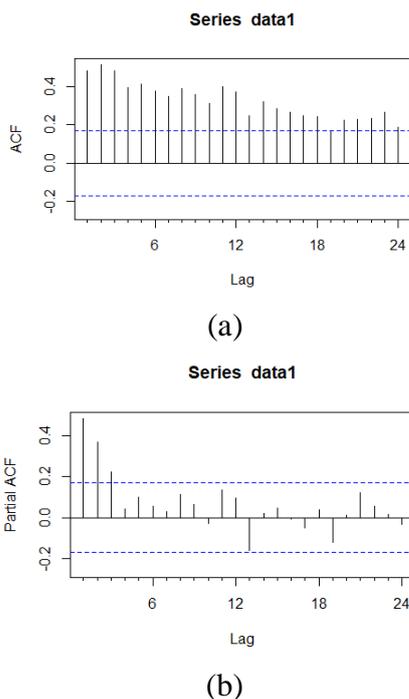
**Tabel 4.18** Hasil nilai MAPE, MAD dan MSE model Singh

Ukuran Ketetapan	Nilai
MAPE	12,84%
MAD	0,735

MSE	0,716
-----	-------

**Model ARIMA**

Tahapan peramalan dengan metode ARIMA terdiri atas 4 langkah, yaitu Identifikasi Model, Estimasi parameter, Uji diagnostik, dan peramalan. Tahap identifikasi model berdasarkan data historis yang diolah dengan menggunakan program R diperoleh grafik ACF dan PACF-nya pada Gambar 4.1 berikut:



**Gambar 4.1.** (a) Grafik ACF data historis, (b) Grafik PACF data historis

Untuk mengetahui apakah data tersebut stationer atau belum maka dilakukan *Augmented Dickey Fuller test* (ADF Test). Dengan menggunakan program R, diperoleh hasil uji dalam Tabel 4.19 berikut:

**Tabel 4.19** Hasil ADF test data

Nilai Dickey-Fuller	-3.7481
Lag order	5
p-value	0.02371*
Hipotesis Alternatif	Stasioner

Karena p-valuenya kurang dari 0.05 maka disimpulkan bahwa data telah stasioner dalam rata-rata.

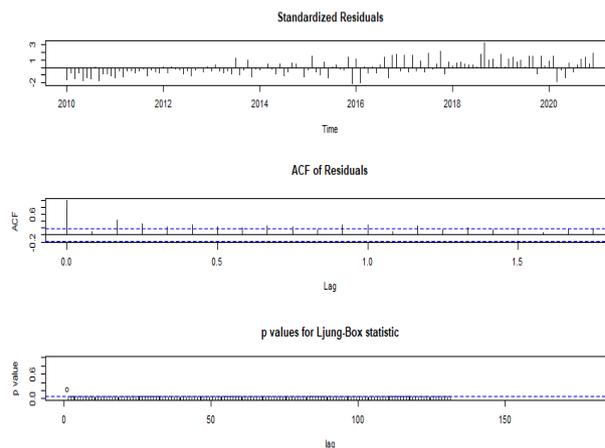
Tahap selanjutnya adalah estimasi model. Selanjutnya yaitu membuat model ARIMA. Model ARIMA yang didapat berdasarkan grafik ACF dan PACF pada data historis adalah model ARIMA (0,0,1) setelah diolah menggunakan

program R, maka hasilnya ada pada Tabel 4.20 berikut:

**Tabel 4.20** Model ARIMA (0,0,1)

Estimasi $\sigma^2$	14,58
Log Likelihood	-364,2
AIC	732,4

Selanjutnya adalah uji diagnostik dan uji *White Noise*. Maka hasil uji *White Noise* dilihat pada gambardan tabel berikut.

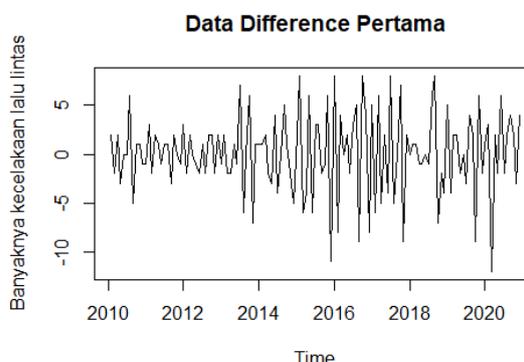


**Gambar 4.2** Plot Uji Diagnostik Model ARIMA (0,0,1)

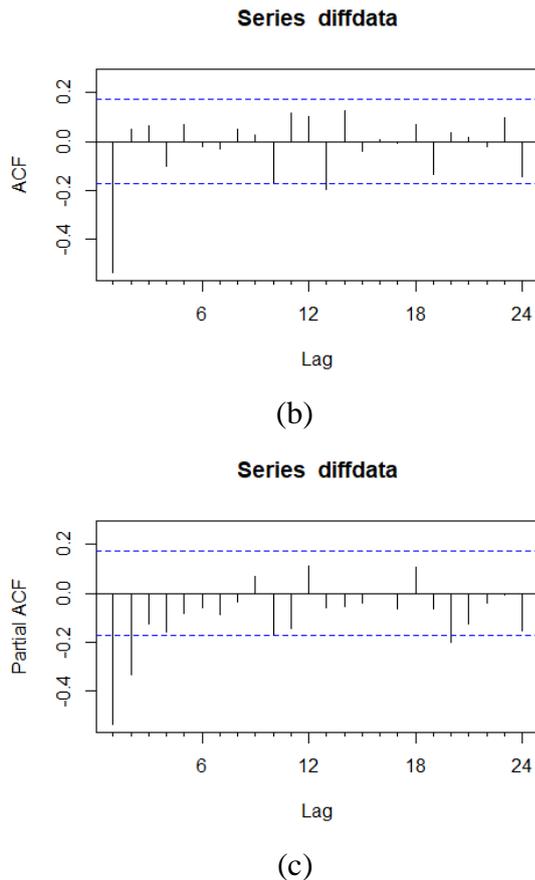
**Tabel 4.21** Hasil Uji WhiteNoise Model ARIMA (0,0,1)

$\chi^2$	1,5033
df	1
p-value	0.2202

Tahap selanjutnya adalah verifikasi. Data *difference* diperlukan untuk melakukan verifikasi pada model awal. Dengan menggunakan program R, hasil plot, grafik ACF dan PACF data *difference* dilihat pada gambar berikut.



(a)



**Gambar 4.3** (a) Plot data *difference*, (b) Plot ACF data *difference*, (c) Plot PACF data *difference*

Sehingga didapatkan model pembanding ARIMA (0,1,1). Untuk mengetahui data tersebut benar-benar stationer, maka dilakukan *Augmented Dickey Fuller test* (ADF Test), maka dengan menggunakan program R maka hasilnya pada tabel berikut.

**Tabel 4.22** Hasil ADF test data *difference*

Nilai Dickey-Fuller	-6.4887
Lag order	5
p-value	0.01
Hipotesis Alternatif	Stasioner

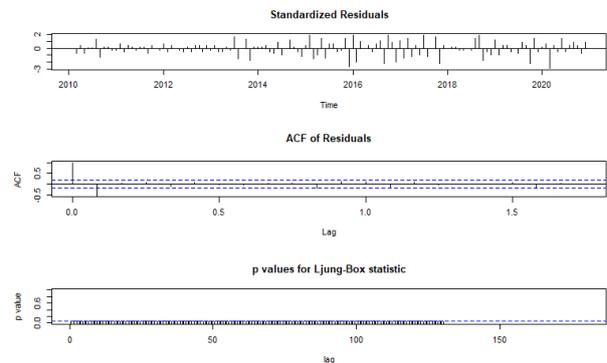
Karena p-value nya adalah 0.01 maka sudah stasioner.

Untuk menentukan model ARIMA (0,1,1), dengan menggunakan program R maka hasilnya adalah pada tabel berikut.

**Tabel 4.23** Model ARIMA (0,1,1)

Koefisien MA1	-1,000
Estimasi $\sigma^2$	17,56
Log Likelihood	-371,66
aic	745,32

Selanjutnya adalah uji diagnostik dan uji *WhiteNoise* pada data *difference*. Maka hasil dari uji diagnostik dan uji *WhiteNoise* dapat dilihat pada gambar dan tabel berikut.



**Gambar 4.4.** Hasil Uji Diagnostik Model ARIMA (0,1,1)

**Tabel 4.24** Hasil Uji *White Noise* Model ARIMA (0,1,1)

$\chi^2$	38,092
df	1
p-value	6,75e-10*

Dengan ini error model ARIMA (0,1,1) memenuhi asumsi *white noise*.

Dari perhitungan diperoleh nilai *error* atau MS (*Mean Square*) model ARIMA (0,0,1) sebesar 14,58, sedangkan nilai error model perbandingan ARIMA (0,1,1) sebesar 17,56. Model ARIMA (0,0,1) dapat diterima karena mempunyai nilai *error* yang lebih kecil.

Setelah memiliki Model ARIMA yang layak untuk digunakan dalam peramalan. Untuk hasil peramalan data dilakukan peramalan untuk 12 periode dengan menggunakan program R dengan menggunakan model ARIMA (0,0,1) dapat dilihat pada tabel berikut.

**Tabel 4.25** Hasil peramalan 12 periode yang akan datang

Tahun	Bulan	Hasil Peramalan
2021	Januari	13,256
	Februari	13,335
	Maret	13,413
	April	13,491
	Mei	13,570
	Juni	13,648
	Juli	13,726
	Agustus	13,805
	September	13,883
	Oktober	13,961

November	14,040
Desember	14,118

Hasil ketetapan peramalan dengan menggunakan program R dapat dilihat pada tabel dibawah ini.

**Tabel 4.26** Hasil nilai MAPE, MAD dan MSE model ARIMA

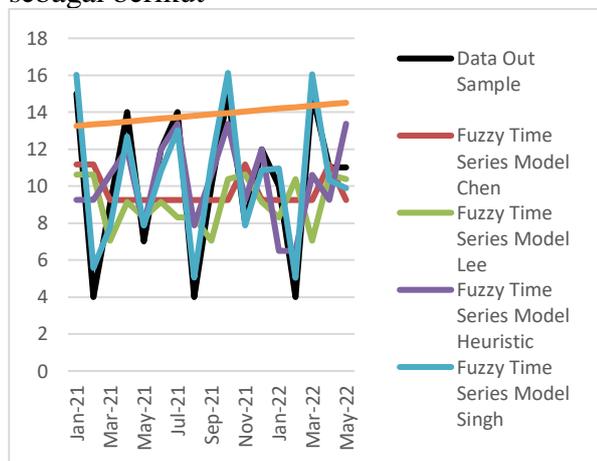
Ukuran Ketetapan	Nilai
MAPE	63,00302%
MAD	3,1864
MSE	-

Hasil tingkat keakuratan peramalan pada beberapa model *time series* dapat dilihat pada tabel berikut:

**Tabel 4.27** Hasil tingkat keakuratan peramalan pada beberapa model *time series*

Model Time Series	MAPE	MAD	MSE
Fuzzy Time Series model Chen	62,76%	2,998	13,784
Fuzzy Time Series model Lee	54,56%	2,768	12,682
Fuzzy Time Series model Heuristic	41,53%	2,079	6,15
Fuzzy Time Series model Singh	12,84%*	0,735*	0,716*
Model ARIMA	63,00302%	3,1864	-

Adapun Plot data *out sample* dengan data peramalan beberapa model *time series* adalah sebagai berikut



**Gambar 4.5** Data *out sample* dengan data peramalan beberapa model *time series*

Dengan demikian *Fuzzy Time Series* model Singh adalah model *time series* terbaik.

**Evaluasi Kinerja Model**

Hasil peramalan pada data *out sample* adalah sebagai berikut

**Tabel 4.28** Hasil Peramalan Data *Out Sample* pada *Fuzzy Time Series* Model Singh

Tahun	Bulan	Jumlah Kejadian Kecelakaan Lalu Lintas	Nilai ramalan
2021	Januari	15	NA
	Februari	4	NA
	Maret	9	NA
	April	14	14,656
	Mei	7	7,438
	Juni	12	11,281
	Juli	14	14,156
	Agustus	4	4,844
	September	10	10,188
	Oktober	15	14,156
	November	8	7,438
	Desember	12	11,781
2022	Januari	10	10,344
	Februari	4	4,344
	Maret	15	14,313
	April	11	11,563
	Mei	11	11,865

Maka ukuran ketetapan untuk *fuzzy time series* model Singh adalah sebagai berikut

**Tabel 4.29** Hasil nilai MAPE, MAD dan MSE Data *Out Sample* pada *Fuzzy Time Series* Model Singh

Ukuran Ketetapan	Nilai
MAPE	6,077%
MAD	0,531
MSE	0,340

Berdasarkan hasil tersebut, pada *fuzzy time series* model Singh didapatkan nilai MAPE dibawah 10%, sehingga model *fuzzy time series* model Singh pada peramalan kejadian kecelakaan lalu lintas mempunyai kinerja yang sangat bagus.

**5. KESIMPULAN**

Peramalan terhadap banyaknya kejadian kecelakaan lalu lintas telah dilakukan dengan menggunakan metode ARIMA, serta Fuzzy time series. Metode Fuzzy time series yang digunakan empat model, sehingga secara keseluruhan, model yang digunakan dalam proses analisis pada penelitian ini adalah

sebanyak lima model. Berdasarkan kriteria ketepatan model yang digunakan, yaitu nilai MAPE, MAD, dan MSE, diperoleh hasil bahwa metode fuzzy time series dengan model Singh menghasilkan nilai kriteria galat terendah, yaitu MAPE dan MAD paling rendah adalah *fuzzy Time Series* model Singh dengan MAPE adalah 12,817% dan MAD adalah 0,77. Model ini kemudian digunakan untuk meramalakan banyaknya kejadian kecelakaan di Kabupaten Soppeng. Hasil peramalan jumlah kejadian kecelakaan lalu lintas di Kabupaten Soppeng dengan menggunakan model *time series* terbaik yaitu *Fuzzy Time Series* model Singh untuk 10 periode diperoleh pada Table 4.30 berikut:

**Tabel 4.30** Peramalan *Fuzzy Time Series* model Singh untuk 10 periode kedepan

Periode	Nilai Peramalan
1	10,9250
2	10,4028
3	10,97115
4	10,04808
5	10,97115
6	10,04808
7	10,97115
8	10,04808
9	10,97115
10	10,04808

## 6. DAFTAR PUSTAKA

- [1] Badan Pusat Statistik, Statistik Transportasi Darat 2020. Jakarta: Badan Pusat Statistik, 2020.
- [2] Badan Pusat Statistik, Kabupaten Soppeng dalam Angka 2021. Soppeng: Badan Pusat Statistik, 2021.
- [3] Badan Pusat Statistik, *Provinsi Sulawesi Selatan Dalam Angka 2021*. Makassar: Badan Pusat Statistik, 2021.
- [4] K. Auliasari, M. Kertaningtyas, and M. Kriswantono, “Penerapan Metode Peramalan untuk Identifikasi Potensi Permintaan Konsumen,” 2019.
- [5] C. Y. Ismayanti, D. Kusnandar, and N. Imro’ah, “Verifikasi Model ARIMA pada Peramalan Jumlah Kecelakaan Lalu Lintas Kota Pontianak Menggunakan Statistical Process Control,” *Buletin Ilmiah Mat. Stat. dan Terapannya (Bimaster)*, vol. 08, no. 3, pp. 421–428, 2019.
- [6] E. M. Intisari, “Penerapan Model Deret Waktu ARIMA pada Data Kecelakaan Lalu Lintas Di Kabupaten Mempawah,” *Buletin Ilmiah Mat. Stat dan Terapannya (Bimaster)*, vol. 12, no. 4, pp. 325–334, 2023.
- [7] M. Silfiani and G. R. Lembang, “Perbandingan Peramalan Jumlah Kasus Kecelakaan Lalu Lintas Kota Balikpapan dengan Linear Trend Analysis dan Double Exponential Smoothing,” *Journal of Mathematics & Information Technology*, vol. 1, no. 1, pp. 14–18, 2023, Accessed: May 28, 2024. [Online]. Available: <https://journal.itk.ac.id/index.php/equiva/article/view/757>
- [8] I. R. Maharsi, Moch. A. Mukid, and Y. Wilandari, “Peramalan Jumlah Kecelakaan di Kota Semarang Tahun 2017 menggunakan metode runtun waktu (Studi Kasus : Data Jumlah Kecelakaan Lalu Lintas di Kota Semarang Periode Januari 2012 – Desember 2016),” *JURNAL GAUSSIAN*, vol. 6, no. 3, pp. 355–364, 2017, doi: <https://doi.org/10.14710/j.gauss.6.3.355-364>.
- [9] A. Madu, “Perbandingan Metode Trend Projection Dan Metode Backpropagation dalam Meramalkan Jumlah Korban Kecelakaan Lalu Lintas yang Meninggal Dunia di Kabupaten Timor Tengah Utara, Nusa Tenggara Timur,” *Jurnal Mercumatika*, vol. 1, no. 1, pp. 44–58, Oct. 2016.
- [10] S. N. Hasanah and N. I. Widiastuti, “REPRESENTASI EMOSI MENGGUNAKAN LOGIKA FUZZY PADA PERMAINAN BONNY’S TOOTH BOOTH,” *Jurnal Ilmiah Komputer dan Informatika (KOMPUTA)*, vol. 68, no. 2, 2014.
- [11] K. Nugroho, “Model Analisis Prediksi Menggunakan Metode Fuzzy Time Series,” *Jurnal Ilmiah INFOKAM*, vol. 12, no. 1, pp. 46–50, 2016.
- [12] Ipan, Syaripuddin, and D. Andi Nohe, “Perbandingan Model Chen dan Model

Lee pada Metode Fuzzy Time Series untuk Peramalan Produksi Kelapa Sawit Provinsi Kalimantan Timur,” Prosiding Seminar Nasional Matematika, Statistika, dan Aplikasinya, no. 2, pp. 81–95, 2022.

- [13] S. Wardah and Iskandar, “Analisis Peramalan Penjualan Produk Keripik Pisang Kemasan Bungkus (Studi Kasus : Home Industry Arwana Food Tembilahan),” *Jurnal Teknik Industri*, vol. 11, no. 3, pp. 135–142, Sep. 2016.
- [14] F. Rachim, Tarno, and Sugito, “Perbandingan Fuzzy Time Series dengan Metode Chen dan Metode S. R. Singh (Studi Kasus : Nilai Impor di Jawa Tengah Periode Januari 2014 – Desember 2019),” *JURNAL GAUSSIAN*, vol. 9, no. 3, pp. 306–315, 2020, [Online]. Available: <https://ejournal3.undip.ac.id/index.php/gaussian/>
- [15] N. Salwa et al., “Peramalan Harga Bitcoin Menggunakan Metode ARIMA (Autoregressive Integrated Moving Average),” *Journal of Data Analysis*, vol. 1, no. 1, pp. 21–31, 2018.
- [16] Zulhamidi and R. Hardianto, “Peramalan Penjualan Teh Hijau dengan Metode Arima (Studi Kasus pada PT. MK),” *Jurnal PASTI*, vol. 11, no. 3, pp. 231–244, 2017.