

BAB I

PENDAHULUAN

1.1 Latar Belakang

Indonesia merupakan salah satu destinasi wisata terkemuka di dunia yang memiliki keberagaman budaya, alam, dan sejarah. Sebagai negara kepulauan yang terletak strategis di kawasan Asia Tenggara, Indonesia memiliki daya tarik yang kuat bagi wisatawan mancanegara (wisman). Setiap tahunnya, jumlah kunjungan wisman terus berkembang. Namun, tidak selamanya jumlah wisman terus meningkat. Menurut Badan Pusat Statistik, terjadi penurunan data wisman yang signifikan pada bulan Maret 2020 yaitu sebanyak 486.155 kunjungan. Sedangkan pada tahun-tahun sebelumnya, jumlah kunjungan wisman selalu berada pada kisaran satu juta kunjungan. Hal tersebut dipengaruhi oleh berbagai faktor seperti kondisi ekonomi global, bencana alam, kebijakan pemerintah, musim, dan faktor sosial-politik.

Kondisi ekonomi global, seperti resesi atau krisis finansial, dapat mengurangi daya beli wisatawan, sementara situasi ekonomi yang baik mendorong lebih banyak orang untuk bepergian. Bencana alam, seperti COVID-19 juga mempengaruhi jumlah kunjungan wisman di suatu negara yang dimana setiap orang diwajibkan untuk mengisolasi diri di kediamannya masing-masing. Kebijakan pemerintah, baik terkait dengan promosi pariwisata, visa, atau insentif bagi sektor pariwisata, juga berperan penting dalam menarik wisatawan. Musim, terutama perbedaan antara musim hujan dan kemarau, mempengaruhi preferensi wisatawan, di mana musim kemarau cenderung lebih diminati untuk perjalanan wisata. Selain itu, faktor sosial-politik seperti stabilitas politik dan keamanan, juga mempengaruhi keputusan wisatawan untuk memilih Indonesia sebagai tujuan wisata.

Salah satu metode peramalan yang dapat digunakan adalah *Fuzzy Time Series* (FTS), yang pertama kali diperkenalkan oleh Song & Chissom pada tahun 1993. FTS merupakan metode peramalan pada data deret waktu yang menggunakan konsep himpunan *fuzzy* sebagai dasar perhitungannya dengan menggabungkan analisis dalam bidang komputasi dan bidang statistik (Lusiana dan Yuliarty, 2020). Metode FTS menggunakan konsep himpunan *fuzzy* sebagai dasar perhitungannya. Kelebihan dari metode ini adalah tidak membutuhkan asumsi-asumsi dibandingkan metode peramalan lainnya, sehingga menjadi pilihan yang relevan terhadap perubahan pola kunjungan. Penggunaan metode FTS dalam peramalan data kunjungan wisman di Indonesia sangat relevan mengingat sifat data yang sering kali tidak pasti dan berfluktuasi karena faktor-faktor di atas.

Adapun FTS memanfaatkan logika *fuzzy* yang memungkinkan nilai keanggotaan berkisar antara 0 hingga 1, sehingga hasil yang diperoleh menjadi lebih akurat (Usmia dkk., 2021). Metode ini mengubah data numerik menjadi nilai

linguistik yang lebih mudah dipahami, sehingga memfasilitasi pengambilan keputusan yang lebih baik dalam sektor pariwisata. Proses perhitungan dalam metode ini juga tidak memerlukan sistem yang kompleks, sehingga lebih mudah untuk dikembangkan dan efektif dalam menyelesaikan masalah terkait data historis (Fauziah dkk., 2016). Seiring berjalannya waktu, FTS semakin berkembang dengan menggabungkan beberapa metode matematika maupun penentuan panjang interval, seperti *Fuzzy Time Series Markov Chain* (FTS-MC) dan *Fuzzy Time Series Chen-Hsu* (FTS Chen-Hsu).

Panjang interval pada FTS sangat mempengaruhi akurasi hasil peramalan. Karena FTS klasik dianggap kurang akurat dalam meramalkan pendaftaran mahasiswa di Universitas Alabama, maka Hsin-Hsi Chen dan Tsu-Kuo Hsu (2004) mengembangkan metode FTS dengan mengandalkan pembagian interval linguistik yang lebih terperinci, memberikan pendekatan yang lebih intuitif dalam meramalkan data dengan mencari selisih data, dan memungkinkan peramalan yang lebih akurat dalam berbagai bidang, yang dikenal sebagai *Fuzzy Time Series Chen-Hsu* (FTS Chen-Hsu).

Kemudian FTS-MC dikembangkan dan diperkenalkan oleh Tsaur (2012) dengan menggabungkan konsep *fuzzy* dengan metode rantai Markov yang digunakan untuk meramalkan nilai tukar mata uang negara Taiwan terhadap Dollar Amerika. Analisis rantai Markov adalah suatu metode yang mempelajari sifat-sifat suatu variabel pada masa sekarang yang didasarkan pada sifat-sifat di masa lalu dalam usaha untuk menafsir sifat-sifat tersebut di masa yang akan datang (Budiharto & Suhartono, 2014). Perbandingan kedua metode ini penting untuk menentukan metode mana yang lebih akurat dalam konteks peramalan kunjungan wisatawan, mengingat perbedaan dalam cara kerja dan asumsi yang mendasarinya.

Terdapat beberapa penelitian terdahulu terkait penggunaan metode FTS beserta metode pengembangannya dalam peramalan, seperti yang dilakukan oleh Noviani (2020) yang meramalkan rata-rata harga beras dengan membandingkan metode FTS-MC dengan FTS *Cheng*. Diperoleh nilai MAPE untuk FTS-MC dan FTS *Cheng* berturut-turut adalah 0.52% dan 0.69%, yang berarti FTS-MC lebih akurat dalam meramalkan rata-rata harga beras dibandingkan FTS *Cheng* dengan hasil ketepatan peramalan untuk FTS-MC adalah sebesar 99.48%. Selanjutnya, Latifah dkk. (2024) yang meramalkan jumlah penumpang pesawat di Bandara Internasional Soekarno-Hatta dengan membandingkan metode FTS *Chen-Hsu* dengan FTS *Cheng*. Diperoleh nilai MAPE untuk FTS *Chen-Hsu* dan FTS *Cheng* berturut-turut adalah 2.95% dan 5.64%, yang berarti FTS *Chen-Hsu* lebih akurat dalam meramalkan jumlah penumpang dibandingkan FTS *Cheng* dengan hasil ketepatan peramalan untuk FTS *Chen-Hsu* adalah sebesar 97.05%, yang keduanya terkategori sangat baik.

Berdasarkan hasil dari penelitian sebelumnya, ditunjukkan bahwa metode FTS dapat diterapkan pada berbagai bidang, serta memiliki tingkat akurasi yang

sangat tinggi. Oleh karena itu, peneliti tertarik melakukan penelitian dengan membandingkan dua metode FTS yaitu metode FTS-MC dan *FTS Chen-Hsu* dalam meramalkan data kunjungan wisatawan mancanegara di Indonesia periode Januari 2017 - Juni 2024 dengan melihat nilai *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), dan nilai korelasi. Sehingga, peneliti mengangkat judul “Perbandingan Akurasi Peramalan Metode *Fuzzy Time Series Markov Chain* dan *Chen-Hsu* pada Data Kunjungan Wisatawan Mancanegara di Indonesia.”

1.2 Tujuan dan Manfaat

Tujuan dilakukannya penelitian ini adalah untuk membandingkan akurasi peramalan jumlah kunjungan wisatawan mancanegara di Indonesia periode Januari 2023 – Juni 2024 dengan metode *Fuzzy Time Series Markov Chain* dan metode *Fuzzy Time Series Chen-Hsu*.

Hasil diari penelitian ini diharapkan dapat memberikan manfaat, antara lain:

1. Memberikan kontribusi signifikan terhadap pengembangan metode peramalan dalam sektor pariwisata, khususnya dalam konteks penggunaan *Fuzzy Time Series Markov Chain* dan *Fuzzy Time Series Chen-Hsu*.
2. Membuka peluang untuk penelitian lebih lanjut mengenai penerapan metode *Fuzzy Time Series* dalam berbagai bidang, serta pengembangan metode baru yang dapat meningkatkan akurasi peramalan di masa depan.
3. Menjadi acuan bagi pemangku kepentingan dalam merumuskan kebijakan dan strategi yang lebih efektif dalam meningkatkan kunjungan wisatawan mancanegara ke Indonesia.

1.3 Batasan Masalah

Batasan permasalahan dalam penelitian ini yaitu:

1. Data yang digunakan adalah data bulanan kunjungan wisatawan mancanegara di Indonesia dari periode Januari 2017 hingga Juni 2024. Adapun data dibagi menjadi Data *Training* dengan periode Januari 2017-Desember 2022 dan Data *Testing* dengan periode Januari 2023-Juni 2024.
2. Akurasi hasil peramalan dihitung menggunakan *Mean Absolute Percentage Error* (MAPE), *Root Mean Square Error* (RMSE), serta dilakukan uji Korelasi *Pearson* (r).

1.4 Landasan Teori

1.4.1 Peramalan

Peramalan adalah metode untuk memastikan perilaku terhadap keadaan di masa depan secara lebih baik dan lebih rinci berdasarkan data masa lalu, dengan tujuan mengurangi kesalahan. Jika dilihat dari segi waktu, peramalan dapat

dibagi menjadi tiga jenis, diantaranya peramalan jangka pendek, peramalan jangka menengah, dan peramalan jangka panjang (Wiharja dalam Al-adawiyah, 2021). Menurut Makridakis dkk. (1999) terdapat dua metode peramalan.

1. Metode kualitatif
Peramalan dengan metode kualitatif adalah jenis peramalan yang berlandaskan pada data kualitatif dari masa lalu. Hasil dari peramalan ini cenderung bersifat subjektif karena didasarkan pada pemikiran intuitif, opini, pengetahuan, dan pengalaman individu.
2. Metode Kuantitatif
Peramalan dengan metode kuantitatif adalah jenis peramalan yang berlandaskan pada data kuantitatif dari masa lalu. Metode kuantitatif terbagi menjadi dua kategori, yaitu metode kausal dan metode deret waktu. Penggunaan metode kuantitatif dapat dilakukan jika terdapat tiga syarat, yaitu:
 - a. Tersedia informasi mengenai masa lalu,
 - b. Informasi tersebut dapat diubah menjadi data numerik,
 - c. Dapat diasumsikan bahwa beberapa pola dari masa lalu akan tetap berlanjut di masa depan, yang dikenal sebagai kondisi konstan.

1.4.2 Analisis Deret Waktu

Analisis deret waktu adalah proses yang menggunakan data deret waktu untuk membangun model berdasarkan pola yang terlihat dalam data historis. Analisis ini sangat berguna untuk memahami data masa lalu, sehingga dapat membantu dalam perencanaan untuk masa depan. Deret waktu terdiri dari data yang mencakup suatu objek dalam berbagai periode, seperti harian, mingguan, bulanan, triwulan, dan tahunan. Sebelum melakukan peramalan, penting untuk mengidentifikasi pola dalam data karena ketepatan pengujian data sangat dipengaruhi oleh pemilihan pola deret waktu yang tepat, dimana metode yang digunakan selanjutnya akan disesuaikan dengan pola tersebut untuk mengevaluasi nilai kesalahannya. Ada empat pola data yang mempengaruhi analisis deret waktu, antara lain (Makridakis dkk., 2019):

1. Pola data horizontal
Pola ini terjadi ketika data berfluktuasi di sekitar nilai rata-rata yang tetap atau stasioner. Contohnya adalah penjualan cabe yang tidak menunjukkan peningkatan atau penurunan yang signifikan selama periode tertentu.
2. Pola data musiman
Pola data musiman muncul ketika fluktuasi data menunjukkan kecenderungan untuk berulang secara teratur dari satu periode ke periode berikutnya. Contohnya adalah penjualan suatu produk yang dicatat secara bulanan atau tahunan.

3. Pola data tren
Pola data tren terjadi ketika terdapat penurunan atau peningkatan yang konsisten dalam data selama periode waktu yang panjang. Sebagai contoh, penjualan emas yang cenderung mengalami kenaikan seiring berjalannya waktu.
4. Pola data siklis
Pola data siklis muncul ketika data menunjukkan tren yang mencakup fluktuasi musiman dengan durasi yang lebih lama. Pola ini ditandai oleh pergerakan yang tidak selalu berulang pada interval yang sama. Contohnya dapat dilihat pada data penjualan mobil.

1.4.3 Logika dan Himpunan *Fuzzy*

Logika *fuzzy* diperkenalkan oleh Prof. Lotfi A. Zadeh (1965). Konsep ini dapat dipahami sebagai sistem yang menghubungkan *input* dan *output*, di mana sistem ini menggunakan metode untuk mengolah data menjadi informasi yang berguna (Gelley dalam Yunita, 2016).

Adapun komponen-komponen yang perlu diperhatikan dalam sistem *fuzzy* yaitu sebagai berikut (Hidayat dan Gernowo, 2015).

1. Variabel *fuzzy*, yaitu variabel yang hendak dibahas dalam suatu sistem *fuzzy*.
2. Himpunan *fuzzy*, yaitu suatu grup yang mewakili kondisi atau keadaan tertentu dalam suatu variabel *fuzzy*.
3. Semesta pembicaraan, yaitu keseluruhan nilai yang boleh untuk dioperasikan dalam suatu variabel *fuzzy*.

Domain, yaitu keseluruhan nilai yang diizinkan dalam semesta pembicaraan dan boleh dioperasikan di himpunan *fuzzy*.

Menurut Cox (Kusumadewi & Purnomo dalam Yunita, 2016), ada beberapa alasan mengapa logika *fuzzy* dipilih dalam pengambilan keputusan:

1. Konsep logika *fuzzy* sederhana, berbasis teori himpunan, dan efektif dalam memodelkan fungsi yang kompleks.
2. Logika *fuzzy* fleksibel dan menggunakan bahasa sehari-hari, sehingga lebih mudah dipahami.
3. Logika *fuzzy* mampu menangani data yang mungkin tidak akurat, terutama jika data tersebut cukup homogen.

Himpunan *fuzzy* adalah pengelompokan objek yang dikelompokkan berdasarkan variabel linguistik, yang dinyatakan melalui fungsi keanggotaan dalam suatu semesta. Nilai keanggotaan dalam himpunan *fuzzy* berkisar antara $[0,1]$, sehingga kebenaran suatu item tidak hanya terbatas pada dua kategori, yaitu benar atau salah. Dalam hal ini, nilai 0 menunjukkan kondisi salah, nilai 1 menunjukkan kondisi benar, dan terdapat juga nilai-nilai di antara keduanya yang mencerminkan tingkat (Kusumadewi dan Guslawudin, 2005). Secara matematis, definisi himpunan *fuzzy* dapat dijelaskan sebagai berikut:

Definisi 1.4.3.1. Misalkan U adalah himpunan semesta dan $u_A : U \rightarrow [0,1]$ disebut sebagai fungsi keanggotaan himpunan *fuzzy* A pada himpunan semesta U . Suatu himpunan *fuzzy* A atas himpunan U didefinisikan sebagai (Hans-Jurgen, 1996):

$$A = \{(u; \mu_A(u)) \mid u \in U\}$$

Cara lain untuk menyatakan himpunan *fuzzy* selain pada definisi di atas, yaitu:

$$A = \sum_{j=1}^k \frac{\mu_A(u_j)}{u_j}$$

1.4.4 Fuzzy Time Series

Fuzzy Time Series (FTS) adalah pendekatan inovatif yang dikembangkan untuk menangani masalah yang berkaitan dengan data linguistik. Metode ini mengintegrasikan variabel linguistik dengan penerapan logika *fuzzy* dalam analisis data deret waktu, sehingga dapat mengatasi ketidakpastian yang ada dalam data. Konsep dasar FTS pertama kali diperkenalkan oleh Song dan Chissom pada tahun 1993, di mana nilai-nilai dalam FTS direpresentasikan melalui himpunan *fuzzy*. Berikut definisi FTS (Song dan Chissom, 1993):

Definisi 1.4.4.1. Misalkan himpunan semesta $U(t)$ ($t = 0,1,2,\dots$) sebuah *subset* dari bilangan riil sebagai semesta pembicara pada himpunan *fuzzy* $f_i(t)$ ($t = 0,1,2,\dots$) yang terdefinisi. Jika $F(t)$ merupakan kumpulan dari $f_i(t)$ ($t = 0,1,2,\dots$), maka $F(t)$ dinamakan FTS pada $U(t)$

Definisi 1.4.4.2. Misalkan $F(t-1) = A_i$ dan $F(t) = A_j$. Hubungan antara 2 pengamatan berturut-turut $F(t)$ dan $F(t-1)$ disebut sebagai suatu hubungan logika *fuzzy* (*Fuzzy Logical Relationship* (FLR)), dapat dituliskan sebagai $A_i \rightarrow A_j$, dimana A_i disebut dengan sisi kiri dan A_j disebut sebagai sisi kanan dari FLR.

Definisi 1.4.4.3. Semua FLR dapat dikelompokkan lebih lanjut menjadi kelompok FLR yang berbeda berdasarkan sisi kiri yang sama dari FLR. Sebagai contoh, terdapat 2 FLR dengan sisi kiri yang sama (A_p): $A_j \rightarrow A_{j1}$ dan $A_i \rightarrow A_{j2}$. Maka 2 FLR ini dapat dikelompokkan ke dalam suatu *Fuzzy Logical Relationship Group* (FLRG).

1.4.5 Fuzzifikasi dan Defuzzifikasi

Fuzzifikasi adalah proses yang mengubah variabel *non-fuzzy* (numerik) menjadi variabel *fuzzy* (linguistik). Sementara itu, tujuan dari defuzzifikasi adalah untuk mengonversi setiap hasil yang dinyatakan dalam bentuk himpunan *fuzzy* menjadi suatu bilangan riil. Nilai riil yang diperoleh dari proses defuzzifikasi ini kemudian digunakan sebagai hasil peramalan (Kusumadewi dan Guslawudin, 2005).

1.4.6 Rantai Markov

Rantai Markov pertama kali diperkenalkan oleh ilmuwan Rusia, A. A. Markov, pada tahun 1906. Rantai Markov adalah metode yang digunakan untuk menganalisis karakteristik suatu variabel saat ini berdasarkan sifat-sifat dari masa lalu untuk memperkirakan karakteristik variabel tersebut di masa depan.

Jika $X_n = i$, maka proses ini terjadi pada keadaan i pada waktu n . Dengan asumsi bahwa setiap kali proses ini berada di *state* i , terdapat peluang P_{ij} untuk berpindah ke *state* j . Dengan demikian, dapat dinyatakan pada Pers. (1.1) berikut:

$$P\{X_{n+1} = j \mid X_n = i, X_{n-1} = i_{n-1}, \dots, X_1 = i_1, X_0 = i_0\} = P_{ij} \quad (1.1)$$

untuk semua *state* $i_0, i_1, \dots, i_n - 1, i, j, n \geq 0$. Persamaan tersebut diartikan dalam konteks rantai Markov sebagai distribusi bersyarat dari *state* yang akan datang X_{n+1} , yang diperoleh dari *state* sebelumnya $X_0, X_1, \dots, X_n - 1$ dan *state* sekarang X_n , dan tidak bergantung pada *state* sebelumnya tetapi bergantung pada *state* sekarang.

Probabilitas transisi untuk *state* tersebut dapat ditulis pada Pers. (1.2) berikut:

$$P_{ij} = \frac{M_{ij}}{M_i}; i, j = 1, 2, \dots, k \quad (1.2)$$

dengan,

P_{ij} adalah probabilitas transisi satu langkah dari *state* A_i ke A_j .

M_{ij} adalah banyak transisi *state* $A_i \rightarrow A_j$.

M_i adalah banyaknya data yang termasuk dalam *state* A_i .

Sehingga matriks probabilitas transisi R dapat ditulis pada Pers. (1.3) berikut:

$$R = \begin{pmatrix} P_{11} & \cdots & P_{1k} \\ \vdots & \ddots & \vdots \\ P_{k1} & \cdots & P_{kk} \end{pmatrix} \quad (1.3)$$

Dari matriks R , terdapat beberapa definisi yang dapat diturunkan. Jika $P_{ij} > 0$, maka *state* A_j dapat diakses dari *state* A_i . Selain itu, jika *state* A_i dan A_j saling dapat diakses, maka dapat dikatakan bahwa A_i berkomunikasi dengan A_j (Ross, 2003).

1.4.7 Fuzzy Time Series Markov Chain

Fuzzy Time Series Markov Chain (FTS-MC) diperkenalkan oleh Tsaur (2012) untuk meramalkan nilai tukar mata uang Taiwan terhadap Dolar Amerika. Dalam penelitiannya, Tsaur mengintegrasikan metode FTS dengan analisis rantai Markov yang memanfaatkan keunggulan FTS dalam mengelompokkan data

secara efektif, serta kemampuan analisis rantai Markov dalam memberikan hasil dengan probabilitas yang tinggi.

Adapun langkah-langkah dari metode FTS-MC adalah sebagai berikut (Safitri, 2022).

1. Mengumpulkan data historis dan menentukan himpunan semesta U . Himpunan semesta U dapat didefinisikan pada Pers. (1.4) berikut:

$$U = [D_{min}, D_{max}] \quad (1.4)$$

dengan d_{min} merupakan data terkecil, dan d_{max} merupakan data terbesar.

2. Menentukan jumlah kelas dan panjang interval. Pada tahap ini akan dilakukan perhitungan dari jumlah kelas pada data historis dengan menggunakan rumus *Sturges* pada Pers. (1.5) berikut:

$$k = 1 + 3,3 \times \log(n) \quad (1.5)$$

dengan n adalah banyaknya data historis.

Kemudian mencari panjang interval dengan menggunakan rumus pada Pers. (1.6) berikut:

$$l = \frac{[(D_{max}-D_{min})]}{k} \quad (1.6)$$

dengan l adalah panjang interval dan k adalah jumlah kelas.

Selanjutnya masing-masing interval dapat dibuat ke dalam bentuk seperti pada Pers. (1.7) berikut:

$$\begin{aligned} u_1 &= [D_{min}; D_{min} + l] \\ u_2 &= [D_{min} + l; D_{min} + 2l] \\ u_3 &= [D_{min} + 2l; D_{min} + 3l] \\ &\vdots \\ u_k &= [D_{min} + (k - 1)l; D_{min} + kl] \end{aligned} \quad (1.7)$$

3. Menentukan himpunan *fuzzy* untuk seluruh himpunan semesta U . Pembentukan himpunan *fuzzy* untuk masing-masing interval linguistik dinyatakan pada Pers. (1.8) berikut:

$$A_i = \left\{ \frac{\mu_{A_i}(u_1)}{u_1} + \dots + \frac{\mu_{A_i}(u_k)}{u_k} \right\} \quad (1.8)$$

dimana μ_{ij} adalah fungsi keanggotaan u_j di A_i yang ditentukan pada Pers. (1.9) berikut:

$$\mu_{Ai}(uj) = \begin{cases} 1; i = j \\ 0,5; i = j - 1 \text{ atau } i = j + 1 \\ 0; \text{lainnya} \end{cases} \quad (1.9)$$

Berdasarkan Pers. (1.8) dan (1.9) diperoleh himpunan *fuzzy* dimana $A_1, A_2, A_3, \dots, A_k$ pada Pers. (1.10) berikut:

$$\begin{aligned}
 A_1 &= \left\{ \frac{1}{u_1} + \frac{0.5}{u_2} + \frac{0}{u_3} + \frac{0}{u_4} + \dots + \frac{0}{u_k} \right\} \\
 A_2 &= \left\{ \frac{0.5}{u_1} + \frac{1}{u_2} + \frac{0.5}{u_3} + \frac{0}{u_4} + \dots + \frac{0}{u_k} \right\} \\
 A_3 &= \left\{ \frac{0}{u_1} + \frac{0.5}{u_2} + \frac{0}{u_3} + \frac{0.5}{u_4} + \dots + \frac{0}{u_k} \right\} \\
 &\vdots \\
 A_k &= \left\{ \frac{0}{u_1} + \frac{0}{u_2} + \frac{0}{u_3} + \dots + \frac{0.5}{u_{k-1}} + \frac{1}{u_k} \right\}
 \end{aligned} \tag{1.10}$$

4. Melakukan fuzzifikasi terhadap data historis.
Pada langkah ini bertujuan untuk menemukan himpunan *fuzzy* yang sesuai untuk setiap data. Jika sebuah data historis yang dikumpulkan berada pada interval u_i , maka data tersebut difuzzifikasi ke dalam A_i .
5. Menentukan *Fuzzy Logical Relationship* (FLR) dan *Fuzzy Logical Relationship Group* (FLRG) berdasarkan Definisi 1.4.4.2 dan 1.4.4.3.
6. Menentukan matriks probabilitas transisi R berdasarkan FLRG yang telah diperoleh pada tahap sebelumnya. Matriks probabilitas transisional ini berdimensi $n \times n$, dengan n merupakan banyaknya himpunan *fuzzy*.
7. Menghitung hasil peramalan awal.

Dari matriks probabilitas transisi yang diperoleh pada tahap sebelumnya, nilai peramalan awal dapat dihitung dengan aturan sebagai berikut:

- Aturan 1. Jika FLRG dari A_i adalah kosong ($A_i \rightarrow \emptyset$), maka peramalan dari $F(t)$ adalah m_i , yaitu titik tengah dari interval u_i yang dituliskan dalam Pers. (1.11) berikut:

$$F(t) = m_i \tag{1.11}$$

- Aturan 2. Jika FLRG dari A_i adalah satu ke satu ($A_i \rightarrow A_k$ dengan $P_{ij} = 0$ dan $P_{ik} = 1, j \neq k$), maka peramalan dari $F(t)$ adalah m_k , yaitu titik tengah dari interval u_k yang dituliskan dalam Pers. (1.12) berikut:

$$F(t) = m_k P_{ik} = m_k \tag{1.12}$$

- Aturan 3. Jika FLRG dari A_j adalah satu ke banyak ($A_j \rightarrow A_1, A_2, \dots, A_n; j = 1, 2, \dots, n$), jika kumpulan data $Y(t-1)$ pada saat $t-1$ yang berada pada state A_j , maka hasil peramalan dari $F(t)$ dituliskan dalam Pers. (1.13) berikut:

$$\begin{aligned}
 F(t) &= m_1 P_{j1} + m_2 P_{j2} + \dots + m_{j-1} P_{j(j-1)} + Y(t-1) P_j \\
 &\quad + m_{j+1} P_{j(j+1)} + \dots + m_n P_{jn}
 \end{aligned} \tag{1.13}$$

dengan $m_1, m_2, \dots, m_{j-1}, m_{j+1}, \dots, m_n$ merupakan titik tengah dari $u_1, u_2, \dots, u_{j-1}, u_{j+1}, \dots, u_n$ dan m_j didistribusikan ke $Y(t-1)$ agar diperoleh informasi dari state A_j saat $t-1$.

8. Menyesuaikan kecenderungan nilai peramalan untuk memperkecil kesalahan peramalan. Berikut ini beberapa aturan penyesuaian untuk nilai peramalan:

- Aturan 4. Jika $A_i \rightarrow A_i + s$ dan terjadi perpindahan transisi naik ke *state* $A_i + s$ dengan $1 \leq s \leq n - i$, maka nilai penyesuaian K_t diperoleh dengan Pers. (1.14) berikut.

$$K_t = \left(\frac{l}{2}\right) s \quad (1.14)$$

dengan s merupakan banyaknya perpindahan transisi naik.

- Aturan 5. Jika $A_i \rightarrow A_i - v$ dan terjadi perpindahan transisi menurun ke *state* $A_i - v$ dengan $1 \leq v \leq i - 1$, maka nilai penyesuaian K_t diperoleh dengan Pers. (1.15) berikut.

$$K_t = -\left(\frac{l}{2}\right) v \quad (1.15)$$

dengan v merupakan banyaknya perpindahan transisi menurun.

- Aturan 6. Jika $A_i \rightarrow A_i$ atau tidak terjadi perpindahan transisi *state*, maka nilai penyesuaian K_t adalah 0.

9. Menghitung nilai peramalan akhir dari kecenderungan nilai peramalan yang telah disesuaikan dengan menggunakan Pers. (1.16) berikut.

$$F'(t) = F(t) + K_t \quad (1.16)$$

1.4.8 Fuzzy Time Series Chen-Hsu

Perbedaan FTS ini dengan metode klasik yaitu terletak pada jumlah interval yang dimodifikasi dengan pembagian jumlah frekuensi tertinggi. Sehingga metode yang diusulkan Chen dan Hsu ini dapat memberikan nilai yang baik dalam melakukan peramalan. Berikut merupakan metode FTS *Chen-Hsu*:

1. Mendefinisikan himpunan semesta U .
Pendefinisian himpunan semesta U pada FTS *Chen-Hsu* sama dengan FTS-MC.
2. Menentukan jumlah kelas dan panjang interval.
Untuk pembentukan interval pada FTS *Chen-Hsu* juga sama dengan FTS-MC.
3. Melakukan penyesuaian interval.
Penyesuaian interval pada FTS *Chen-Hsu* dilakukan dengan mengurutkan interval data terbesar sampai data tekecil. Kemudian akan di tentukan tiga interval pertama dengan data terbanyak, dimana interval kelas dengan jumlah data terbesar pertama akan dibagi menjadi 4 interval kelas dengan lebar interval yang sama. Interval kelas dengan jumlah data terbesar kedua akan dibagi menjadi 3 interval kelas dengan lebar interval yang sama, dan interval kelas yang memiliki jumlah data terbesar ketiga akan dibagi menjadi 2 interval dengan lebar interval yang sama.
4. Menentukan himpunan *fuzzy* dari setiap data.

Langkah-langkah yang digunakan pada metode ini sama seperti proses menentukan himpunan *fuzzy* pada FTS-MC. Sehingga diperoleh Pers. (1.10).

5. Melakukan fuzzifikasi terhadap data historis.
Langkah-langkah yang digunakan pada metode ini juga sama dengan langkah-langkah pada FTS-MC.
6. Menentukan *Fuzzy Logical Relationship* (FLR).
Dalam menentukan FLR, dapat digunakan langkah-langkah yang sama untuk menentukan himpunan *fuzzy* pada FTS MC. Sebagai contoh, dua himpunan *fuzzy* berurut yaitu $A_i(t-1)$ dan $A_j(t)$, maka dapat dibentuk suatu FLR yaitu $A_i \rightarrow A_j$, dimana A_i dikatakan sebagai sisi kiri dan A_j dikatakan sebagai sisi kanan.
7. Menentukan nilai peramalan.
Sebelum menentukan defuzzifikasi, terlebih dahulu setiap interval kelas dibagi menjadi 3 sub-interval dengan lebar interval yang sama, dimana titik 0.25 $((b-a)/4)$ dan titik 0.75 $((b-a) * 3/4)$ dari tiap interval dikatakan sebagai titik peramalan *downward* dan *upward*. Sedangkan untuk titik 0.5 $((b-a)/2)$ dari tiap interval dikatakan sebagai titik peramalan *middle*. Selanjutnya menentukan selisih dari data yang dilambangkan dengan *DIFF*, lalu menghitung nilai *DIFF* dengan menggunakan Pers. (1.17) berikut:

$$DIFF = (Y_{t-1} - Y_{t-2}) - (Y_{t-2} - Y_{t-3}) \quad (1.17)$$

dimana Y_t merupakan data ke- t .

Untuk menentukan kecenderungan dan menghitung nilai peramalan akan digunakan beberapa aturan berikut. Asumsikan suatu FLR $A_i \rightarrow A_j$, dimana A_i menyatakan himpunan *fuzzy* data ke $t-1$ dan A_j menyatakan himpunan *fuzzy* data ke- t , maka:

(a) Untuk data yang dianalisa tidak memiliki data ke $t-3$, maka:

- [Aturan 7] Jika $\frac{|Y_2 - Y_1|}{2}$ lebih besar dibandingkan setengah interval kelas A_j , maka nilai peramalannya cenderung *upward* dan berada pada titik 0.75 dari interval tersebut.
- [Aturan 8] Jika $\frac{|Y_2 - Y_1|}{2}$ sama nilainya dengan setengah interval kelas A_j , maka nilai peramalannya berada pada titik tengah (*middle*) dari interval tersebut.
- [Aturan 9] Jika $\frac{|Y_2 - Y_1|}{2}$ lebih kecil dibandingkan setengah interval kelas A_j , maka nilai peramalannya cenderung *downward* dan berada pada titik 0.25 dari interval tersebut.

(b) Untuk *DIFF* bernilai positif, maka:

- [Aturan 10] Jika $(DIFF \times 2 + Y_{t-1})$ atau $(Y_{t-1} + DIFF \times 2)$ berada pada interval kelas A_j , maka nilai peramalannya cenderung *upward* dan berada pada titik 0.75 dari interval tersebut.
- [Aturan 11] Jika $(DIFF / 2 + Y_{t-1})$ atau $(Y_{t-1} + DIFF / 2)$ berada pada interval kelas A_j , maka nilai peramalannya cenderung *downward* dan berada pada titik 0.25 dari interval tersebut.
- [Aturan 12] Jika tidak memenuhi kedua kasus di atas maka nilai peramalannya berada pada titik tengah (*middle*) dari interval kelas A_j .

(c) Untuk *DIFF* bernilai negatif, maka:

- [Aturan 13] Jika $(DIFF / 2 + Y_{t-1})$ atau $(Y_{t-1} + DIFF / 2)$ berada pada interval kelas A_j , maka nilai peramalannya cenderung *downward* dan berada pada titik 0.25 dari interval tersebut.
- [Aturan 14] Jika $(DIFF \times 2 + Y_{t-1})$ atau $(Y_{t-1} + DIFF \times 2)$ berada pada interval kelas A_j , maka nilai peramalannya cenderung *upward* dan berada pada titik 0.75 dari interval tersebut.
- [Aturan 15] Jika tidak memenuhi kedua kasus di atas maka nilai ramalan nya berada pada titik tengah (*middle*) dari interval kelas A_j .

1.4.9 Akurasi Model

Secara umum, evaluasi peramalan dilakukan dengan membandingkan hasil peramalan dengan data historis. Metode peramalan yang menghasilkan penyimpangan atau kesalahan terkecil dianggap sebagai metode yang paling akurat untuk digunakan. Dalam penelitian ini, peneliti menggunakan metrik *Mean Absolute Percentage Error* (MAPE) dan *Root Mean Square Error* (RMSE) untuk mengukur seberapa besar penyimpangan yang terjadi antara data hasil peramalan dan data historis.

a. *Mean Absolute Percentage Error* (MAPE)

MAPE adalah rata-rata persentase kesalahan absolut yang dihitung dengan mencari nilai absolut galat di setiap periode, kemudian membaginya dengan nilai pengamatan aktual atau dapat dituliskan ke dalam Pers. (1.18) berikut.

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{Y(t) - F(t)}{Y(t)} \right| \quad (1.18)$$

dimana Y_t adalah nilai sebenarnya, F_t adalah nilai peramalan, dan n adalah banyaknya data historis. Semakin kecil nilai MAPE, semakin baik kinerja model tersebut. Skala untuk menilai akurasi model berdasarkan nilai MAPE dapat dilihat pada Tabel 1 berikut (Lewis dalam Hidayati dkk., 2022).

Tabel 1. Kriteria Peramalan Berdasarkan Nilai MAPE

Nilai MAPE	Kriteria Peramalan
< 10%	Sangat Baik
11 – 20%	Baik
21 – 50%	Cukup Baik
> 51%	Buruk

b. *Root Mean Square Error (RMSE)*

RMSE digunakan untuk menilai seberapa baik model prediktif mendekati nilai aktual dengan menghitung rata-rata kesalahan kuadrat dari ramalan model. Model peramalan dianggap semakin akurat apabila nilai RMSE semakin kecil. Adapun rumus yang digunakan untuk menghitung nilai RMSE tertulis dalam Pers. (1.19) berikut.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (F'(t) - Y(t))^2}{n}} \quad (1.19)$$

dengan n adalah banyaknya data historis, $Y(t)$ adalah data aktual pada periode ke- i dan $F'(t)$ adalah nilai hasil peramalan pada data ke- i (Sugiyanto dan Hapsari, 2016).

c. *Koefisien Korelasi Pearson (r)*

Korelasi mengacu pada ukuran sejauh mana dua variabel berkaitan. Koefisien Korelasi *Pearson* (r) menunjukkan tingkat kekuatan dan arah hubungan linier dari dua variabel, yaitu variabel independen (X) dan variabel dependen (Y) (Kristantri dkk., 2022). Dalam hal ini variabel X merupakan data observasi kunjungan wisman sedangkan variabel Y adalah data peramalan kunjungan wisman. Adapun rumus yang digunakan dalam uji Korelasi *Pearson* tertulis dalam Pers. (1.20) berikut (Romadhoni dkk., 2021).

$$r = \frac{n\sum xy - (\sum x)(\sum y)}{\sqrt{[n\sum x^2 - (\sum x)^2][n\sum y^2 - (\sum y)^2]}} \quad (1.20)$$

dimana r adalah nilai korelasi *pearson*, n adalah jumlah data, x adalah nilai data observasi, dan y adalah nilai data peramalan.

Tingkat kekuatan hubungan dua variabel berdasarkan nilai koefisien korelasi dapat dilihat pada Tabel 2 berikut (Sugiyono, 2007).

Tabel 2. Tingkat Kekuatan Hubungan Data Kunjungan Wisman

Interval Koefisien	Tingkat Kekuatan
0.00 - $\pm$ 0.199	Sangat Rendah
$\pm$ 0.20 - $\pm$ 0.399	Rendah
$\pm$ 0.40 - $\pm$ 0.599	Sedang
$\pm$ 0.60 - $\pm$ 0.799	Kuat
$\pm$ 0.80 - $\pm$ 1.00	Sangat Kuat

Tabel 2 menunjukkan bahwa semakin nilai korelasi mendekati 1 atau -1, maka hubungan antara kedua variabel tersebut semakin kuat. Nilai koefisien korelasi (r) berada pada rentang -1 dan 1 dengan nilai optimal 1 dan nilai 0 menunjukkan tidak ada korelasi.

1.4.10 Kunjungan Wisatawan Mancanegara

Kunjungan wisatawan mancanegara (wisman) merujuk pada kedatangan individu dari negara lain dengan tujuan rekreasi, bisnis, atau tujuan lainnya di suatu negara. Menurut *World Tourism Organization* (UNWTO), wisman adalah orang yang melakukan perjalanan ke negara lain selama lebih dari 24 jam, tetapi kurang dari satu tahun, untuk tujuan non-kerja (UNWTO, 2020). Kunjungan ini dapat memberikan dampak yang signifikan terhadap ekonomi, budaya, dan lingkungan negara tuan rumah.

Dari segi ekonomi, kunjungan wisman memiliki kontribusi yang besar. Para wisatawan mengeluarkan uang untuk akomodasi, makanan, transportasi, dan berbagai aktivitas rekreasi, yang semuanya berkontribusi pada pendapatan nasional dan penciptaan lapangan kerja. Penelitian oleh Balaguer dan Cantavella-Jordá (2002) menunjukkan bahwa sektor pariwisata dapat berfungsi sebagai pendorong pertumbuhan ekonomi, terutama di negara-negara berkembang. Selain itu, kedatangan wisatawan juga dapat mendorong investasi dalam infrastruktur dan layanan publik, yang pada akhirnya akan meningkatkan kualitas hidup masyarakat setempat.

Tidak hanya dampak ekonomi, kunjungan wisman juga berpengaruh terhadap aspek sosial dan budaya. Interaksi antara wisatawan dan penduduk lokal dapat memperkaya pengalaman budaya serta meningkatkan pemahaman antarbudaya. Namun, terdapat risiko bahwa budaya lokal dapat terdampak atau bahkan luntur akibat pengaruh pariwisata (Cohen, 1984). Oleh karena itu, pengelolaan pariwisata yang bijaksana sangat penting untuk meminimalkan dampak negatif dan memaksimalkan manfaat sosial dan budaya. Meski banyak keuntungan yang ditawarkan oleh kunjungan wisman, pengelolaannya juga menghadapi berbagai tantangan.

Salah satu tantangan utama adalah keberlanjutan pariwisata, di mana meningkatnya jumlah wisatawan dapat memberikan tekanan pada sumber daya alam dan lingkungan (Gössling et al., 2006). Oleh karena itu, penting untuk menerapkan praktik pariwisata berkelanjutan yang mempertimbangkan aspek lingkungan, sosial, dan ekonomi dalam pengembangan sektor pariwisata. Dengan demikian, peramalan terhadap kunjungan wisman ke Indonesia sangat diperlukan dan diharapkan dapat membantu pemerintah Indonesia dalam mengambil keputusan mengenai proses pembangunan sektor wisata, sehingga pembangunan yang dilakukan tepat sasaran, efektif, dan efisien.

BAB II METODE PENELITIAN

2.1 Sumber Data

Penelitian ini dilakukan dengan menggunakan data sekunder yaitu data kunjungan wisatawan mancanegara di Indonesia yang diperoleh secara *online* dari situs web Badan Pusat Statistik (BPS) dan dapat diakses melalui <https://www.bps.go.id/>. Data tersebut merupakan data kunjungan bulanan dengan periode yang digunakan dalam penelitian diambil dari Januari 2017 hingga Juni 2024. Data yang digunakan dalam penelitian ini berjumlah 90 data dan dapat dilihat pada Lampiran 1.

2.2 Tahapan Penelitian

Adapun metode analisis pada penelitian ini terbagi menjadi empat, yaitu sebagai berikut.

1. Melakukan analisis deskriptif untuk menangkap pola data historis. Dalam hal ini adalah rata-rata jumlah kunjungan wisman di Indonesia periode Januari 2017 – Juni 2024.
2. Melakukan peramalan dengan metode *Fuzzy Time Series Markov Chain*
 - a. Menginput data yang akan digunakan pada proses data *training* untuk data kunjungan wisman di Indonesia yaitu periode Januari 2017 – Desember 2022.
 - b. Menentukan himpunan semesta U . Persamaan yang digunakan adalah Pers. (1.4).
 - c. Menentukan jumlah kelas dan panjang interval. Persamaan yang digunakan adalah Pers. (1.5) dan (1.6).
 - d. Menentukan himpunan *fuzzy*.
 - e. Melakukan fuzzifikasi data historis.
 - f. Menentukan FLR dan FLRG.
 - g. Membuat matriks probabilitas transisi Markov. Pada langkah ini persamaan yang digunakan yakni Pers. (1.2) dan (1.3).

$$P_{ij} = \frac{M_{ij}}{M_i}; i, j = 1, 2, \dots, k \quad (1.2)$$

$$R = \begin{pmatrix} P_{11} & \cdots & P_{1k} \\ \vdots & \ddots & \vdots \\ P_{k1} & \cdots & P_{kk} \end{pmatrix} \quad (1.3)$$

- h. Menghitung nilai peramalan awal metode FTS-MC. Pada langkah ini persamaan yang digunakan yakni Pers. (1.11) - (1.13).

$$F(t) = \begin{cases} m_i ; A_i \rightarrow \emptyset \\ m_k ; A_i \rightarrow A_k \\ P_{j1} + \dots + m_{j+1}P_{j(j+1)} + \dots + m_nP_{jn} ; A_i \rightarrow A_1, \dots, A_n \end{cases} \quad (1.13)$$

- i. Menghitung nilai kecenderungan peramalan. Persamaan yang digunakan adalah Pers. (1.14) hingga (1.15).

$$K_t = \left(\frac{l}{2}\right) s \quad (1.14)$$

$$K_t = -\left(\frac{l}{2}\right) v \quad (1.15)$$

- j. Menghitung nilai peramalan yang disesuaikan (nilai peramalan akhir).

3. Melakukan peramalan dengan metode *Fuzzy Time Series Chen-Hsu*

- Menginput data yang akan digunakan pada proses data *training* untuk data kunjungan wisman di Indonesia yaitu periode Januari 2017 – Desember 2022.
- Mendefinisikan himpunan semesta U .
- Menentukan interval menggunakan rumus *Sturges* dan mendistribusikan data pada tiap interval.
- Melakukan penyesuaian interval.
- Menentukan himpunan *fuzzy*.
- Melakukan fuzzifikasi data historis.
- Menentukan FLR.
- Menentukan nilai peramalan yang disesuaikan (peramalan akhir) dari metode FTS *Chen-Hsu*.
- Menghitung tingkat keakuratan hasil peramalan data *training* kedua metode dengan metrik MAPE. Pada langkah ini persamaan yang digunakan adalah Pers. (1.18).

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{Y(t)-F(t)}{Y(t)} \right| \quad (1.18)$$

- Menghitung tingkat keakuratan hasil peramalan data *training* kedua metode dengan metrik RMSE. Pada langkah ini persamaan yang digunakan adalah Pers. (1.19).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (F'(t)-Y(t))^2}{n}} \quad (1.19)$$

- Membandingkan tingkat keakuratan peramalan data *training* kedua metode.

4. Membandingkan tingkat keakuratan dari hasil peramalan
Mengulangi tahapan yang telah diterapkan kedua metode pada data yang akan digunakan dalam proses data *testing* yaitu periode Januari 2023 – Juni 2024. Setelah mendapatkan nilai peramalan, dilakukan perhitungan tingkat keakuratan hasil peramalan data *testing* kedua metode dengan metrik MAPE, RMSE, serta melakukan uji Korelasi *Pearson* menggunakan Pers. (1.20). Kemudian, membandingkan tingkat keakuratan antara metode *Fuzzy Time Series Markov Chain* dengan *Fuzzy Time Series Chen-Hsu*.