

**EVALUASI KINERJA MODEL *SEASONAL AUTOREGRESSIVE  
INTEGRATED MOVING AVERAGE* (SARIMA) DAN *TRIPLE  
EXPONENTIAL SMOOTHING* (TES) UNTUK PERAMALAN JUMLAH  
PENUMPANG PESAWAT DI BANDARA RADIN INTEN II LAMPUNG**

**(Skripsi)**

**Oleh**

**ZAINAB AQILAH**

**2217051149**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2026**

**EVALUASI KINERJA MODEL *SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (SARIMA) DAN *TRIPLE EXPONENTIAL SMOOTHING* (TES) UNTUK PERAMALAN JUMLAH PENUMPANG PESAWAT DI BANDARA RADIN INTEN II LAMPUNG**

Oleh

**ZAINAB AQILAH**

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar  
SARJANA KOMPUTER**

Pada

**Jurusan Ilmu Komputer  
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG  
2026**

## ABSTRAK

### EVALUASI KINERJA MODEL *SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (SARIMA) DAN *TRIPLE EXPONENTIAL SMOOTHING* (TES) UNTUK PERAMALAN JUMLAH PENUMPANG PESAWAT DI BANDARA RADIN INTEN II LAMPUNG

Oleh

ZAINAB AQILAH

Jumlah penumpang pesawat di Bandara Radin Inten II Lampung mengalami fluktuasi setiap tahunnya akibat faktor musiman, kondisi ekonomi, serta perubahan mobilitas masyarakat. Kondisi tersebut menyebabkan perlunya prediksi jumlah penumpang untuk mendukung perencanaan operasional bandara secara efektif. Penelitian ini bertujuan menerapkan dan mengevaluasi metode *Seasonal Autoregressive Integrated Moving Average* (SARIMA) dan *Triple Exponential Smoothing* (TES) dalam memprediksi jumlah penumpang pesawat di Bandara Radin Inten II Lampung. Data yang digunakan berupa data *time series* bulanan jumlah penumpang keberangkatan dan kedatangan periode 2015–2024. Evaluasi model dilakukan menggunakan metrik MAPE, MAE, dan RMSE. Hasil penelitian menunjukkan bahwa model TES multiplikatif memberikan performa yang lebih unggul dengan nilai MAPE sebesar 6,45% untuk penumpang keberangkatan dan 3,51% untuk penumpang kedatangan. Sementara itu, model SARIMA menghasilkan nilai MAPE sebesar 15,00% untuk keberangkatan dan 17,81% untuk kedatangan. Model terbaik kemudian digunakan untuk melakukan peramalan jumlah penumpang periode 2026–2028. Hasil penelitian diharapkan dapat menjadi bahan pertimbangan dalam pengambilan keputusan dan perencanaan operasional Bandara Radin Inten II Lampung.

Kata Kunci: Peramalan, Penumpang Pesawat, SARIMA, *Triple Exponential Smoothing*, *Time Series*.

## **ABSTRACT**

### **PERFORMANCE EVALUATION OF SARIMA DAN TRIPLE EXPONENTIAL SMOOTHING (TES) MODELS FOR FORECASTING THE NUMBER OF AIR PASSENGERS AT RADIN INTEN II AIRPORT, LAMPUNG**

**By**

**ZAINAB AQILAH**

The number of airline passengers at Radin Inten II Airport, Lampung, fluctuates each year due to seasonal factors, economic conditions, and changes in community mobility. These conditions highlight the need for passenger forecasting to support effective airport operational planning. This study aims to implement and evaluate the Seasonal Autoregressive Integrated Moving Average (SARIMA) and Triple Exponential Smoothing (TES) methods in predicting airline passenger numbers at Radin Inten II Airport, Lampung. The data used consists of monthly time series data of departing and arriving passengers for the 2015–2024 period. Model evaluation was conducted using MAPE, MAE, and RMSE metrics. The results showed that the multiplicative TES model provided better performance, with MAPE values of 6.45% for departing passengers and 3.51% for arriving passengers. Meanwhile, the SARIMA model produced MAPE values of 15.00% for departures and 17.81% for arrivals. The best-performing model was then used to forecast passenger numbers for the 2026–2028 period. The results of this study are expected to support decision-making and operational planning at Radin Inten II Airport, Lampung.

**Keywords:** Forecasting, Air Passenger, SARIMA, Triple Exponential Smoothing, Time Series.

Judul Skripsi : **EVALUASI KINERJA MODEL *SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE* (SARIMA) DAN *TRIPLE EXPONENTIAL SMOOTHING* (TES) UNTUK PERAMALAN JUMLAH PENUMPANG PESAWAT DI BANDARA RADIN INTEN II LAMPUNG**

Nama Mahasiswa : **Zainab Aqilah**


Nomor Pokok Mahasiswa : 2217051149

Program Studi : Ilmu Komputer


Fakultas : Matematika dan Ilmu Pengetahuan Alam

**MENYETUJUI**

1. Komisi Pembimbing

  
**Prof. Admi Syarif, Ph.D.**

NIP. 19670103 199203 1 003


  
**Ridho Sholehurrohman, M.Mat.**

NIP. 232111970128101

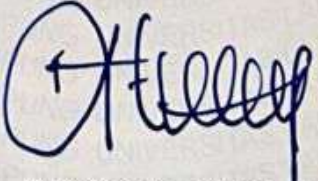
2. Mengetahui

Ketua Jurusan Ilmu Komputer

Ketua Program Studi

  
**Dwi Sakethi, S.Si., M.Kom.**

NIP. 19680611 199802 1 001

  
**Tristiyanto, M.I.S., Ph.D.**

NIP. 198104142005011001

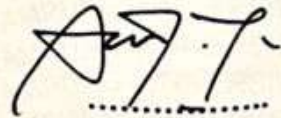
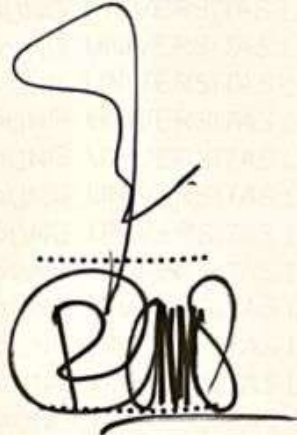
**MENGESAHKAN**

1. Tim Penguji

Ketua : **Prof. Admi Syarif, Ph.D**

Sekretaris : **Ridho Sholehurrohman, M. Mat**

Penguji Utama : **Ir. Andius Dasa Putra, S.T., M.T.,  
Ph.D., IPM**



2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



*Heri Satria*  
**Dr. Eng. Heri Satria, S.Si., M.Si.**  
NIP. 19711001 200501 1 002

Tanggal Lulus Ujian Skripsi : **02 Juni 2026**

## PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Zainab Aqilah

NPM : 2217051149

Dengan ini menyatakan bahwa skripsi yang berjudul "**Evaluasi Kinerja Model *Seasonal Autoregressive Integrated Moving Average (SARIMA)* dan *Triple Exponential Smoothing (TES)* Untuk Peramalan Jumlah Penumpang Pesawat di Bandara Radin Inten II Lampung**" merupakan hasil karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertulis pada skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Apabila di kemudian hari ditemukan bukti bahwa skripsi saya merupakan hasil penjiplakan atau dibuat oleh orang lain maka saya bersedia menerima sanksi sesuai hukum yang berlaku.

Bandar Lampung, 12 Juni 2026



**Zainab Aqilah**

NPM. 2217051149

## RIWAYAT HIDUP



Penulis dilahirkan di Tanjung Karang, Bandar Lampung pada Tanggal 10 Juli 2004. Penulis merupakan anak pertama dari 2 bersaudara. Penulis menyelesaikan pendidikan dasar di SDN 4 Sukajawa pada Tahun 2014 dan SDN 2 Sumberejo pada Tahun 2016, kemudian menyelesaikan pendidikan di SMP Negeri 26 Bandar Lampung pada Tahun 2019 dan SMA Negeri 14 Bandar Lampung pada Tahun 2022.

Untuk jenjang selanjutnya penulis melanjutkan pendidikan di Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur Seleksi Bersama Masuk Perguruan Tinggi (SBMPTN) pada Tahun 2022. Selama menjadi mahasiswa, penulis aktif mengikuti beberapa kegiatan antara lain:

1. Anggota Bidang Internal Himpunan Mahasiswa Jurusan Ilmu Komputer Tahun 2023.
2. Asisten Dosen pada Mata Kuliah Matematika Program Studi D3 Manajemen Informatika Universitas Lampung Tahun 2023.
3. Asisten Dosen pada Mata Kuliah Basis Data Program Studi S1 Ilmu Komputer Tahun 2024.
4. Asisten Dosen pada Mata Kuliah Statistika dan Probabilitas Program Studi S1 Ilmu Komputer PSDKU Tahun 2025.
5. Kerja Praktik (KP) di Badan Pusat Statistik (BPS) Kota Bandar Lampung Tahun 2025.
6. Kuliah Kerja Nyata (KKN) di Desa Sinar Luas Kecamatan Bangun Rejo Kabupaten Lampung Tengah Tahun 2024.

## MOTTO

“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya.  
Setiap proses yang penuh air mata, lelah, dan doa akan berakhir pada hasil terbaik  
pada waktunya.”

*(QS. Al-Baqarah: 286)*

“Aku tidak melihat apa pun selain keindahan”

*(Sayyidah Zainab a.s)*

“Di setiap kesulitan ada kemudahan, di setiap doa ada harapan, dan di setiap  
perjuangan ada pertolongan Allah.”

## **PERSEMBAHAN**

*Alhamdulillahirobbilalamin*

Puji syukur kehadiran Allah Subhanahu Wa Ta'ala atas segala limpahan rahmat dan karunia-Nya, sehingga skripsi ini berhasil diselesaikan dengan baik. Shalawat serta salam selalu tercurahkan kepada Nabi Muhamad Shallahu 'Alaihi wa Aalihi Wa Sallam sebagai suri teladan bagi seluruh umat manusia.

Kupersembahkan karya ini kepada:

### **Kedua Orang Tuaku dan Adik Tercinta**

Untuk Abi dan Umi tercinta yang tidak pernah lelah memanjatkan doa, memberikan kasih sayang, dukungan serta pengorbanan yang tak terhingga. Terima kasih atas setiap usaha, nasihat dan kepercayaan yang selalu menjadi kekuatan bagi penulis untuk terus berjuang hingga sampai pada titik ini.

### **Seluruh Keluarga Besar Ilmu Komputer 2022**

Untuk teman-teman seperjuangan yang telah menjadi bagian dari perjalanan ini.

### **Almamater Tercinta Jurusan Ilmu Komputer FMIPA Universitas Lampung**

Tempat penulis belajar, bertumbuh dan menemukan berbagai pengetahuan serta pengalaman berharga yang menjadi bekal untuk menapaki masa depan.

## SANWACANA

Puji syukur kehadirat Allah Subhanahu Wa Ta'ala atas limpahan nikmat, rahmat, dan karunia-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul: "Evaluasi Kinerja Model *Seasonal Autoregressive Integrated Moving Average (SARIMA)* dan *Triple Exponential Smoothing (TES)* untuk Peramalan Jumlah Penumpang Pesawat di Bandara Radin Inten II Lampung" dengan baik dan lancar. Dalam penyusunan skripsi ini, penulis menyadari bahwa terselesaikannya skripsi tidak terlepas dari bimbingan dan doa dari berbagai pihak. Pada kesempatan ini penulis menyampaikan terima kasih yang sebesar-besarnya kepada:

1. Allah SWT atas segala limpahan rahmat, pertolongan dan kemudahan yang selalu menyertai sehingga skripsi dapat terselesaikan dengan baik.
2. Umi, Abi, dan Adik yang senantiasa memberikan doa, motivasi dan dukungan. Terima kasih telah menjadi kekuatan terbesar bagi penulis meraih gelar Sarjana.
3. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
4. Bapak Dwi Sakethi, S.Si., M.Kom. selaku Ketua Jurusan Ilmu Komputer FMIPA Universitas Lampung.
5. Ibu Yunda Heningtyas, M.Kom. selaku Sekretaris Jurusan Ilmu Komputer FMIPA Universitas Lampung.
6. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D. selaku Kepala Program Studi S1 Ilmu Komputer.
7. Bapak Prof. Admi Syarif, Ph.D. selaku Pembimbing Utama yang telah memberikan bimbingan, arahan, kritik, serta saran yang membangun sehingga skripsi ini dapat terselesaikan dengan baik.

8. Bapak Ridho Sholehurrohman, M.Mat selaku Pembimbing Kedua yang telah meluangkan waktu, tenaga, dan pikiran untuk membimbing penulis menyelesaikan skripsi ini.
9. Bapak Ir. Andius Dasa Putra, S.T., M.T., Ph.D., IPM. selaku Pembahas yang telah memberikan masukan, kritik, serta saran yang bermanfaat demi perbaikan skripsi ini.
10. Seluruh dosen Jurusan Ilmu Komputer FMIPA Universitas Lampung, yang telah memberikan banyak ilmu pengetahuan selama perkuliahan.
11. Ibu Ade Nora selaku staf Jurusan Ilmu Komputer, serta seluruh staf dan karyawan di Jurusan Ilmu Komputer yang telah membantu penulis dalam berbagai urusan administrasi, memberikan pelayanan, serta membantu kelancaran proses akademik selama masa perkuliahan hingga penyelesaian skripsi ini.
12. Sahabat dan Teman – teman penulis, “Senam yang iya iyalah” selaku grup teman kelayapan dari zaman SMA, Fika Oktariana Saputri yang selalu bersama penulis dalam suka maupun duka, baik saat menghadapi stres skripsi maupun sekadar mencari hiburan di sela kesibukan. Dan Rita Irma Yani, selaku partner seperjuangan sejak awal penulisan skripsi, terimakasih selalu setia menemani. Serta teman dekat lainnya yang tidak dapat disebutkan satu per satu.
13. Kepada seseorang yang telah menjadi tempat penulis berbagi cerita, keluh kesah, dan berbagai hal selama proses penyusunan skripsi ini, terima kasih karena pernah hadir dan menemani di beberapa bagian perjalanan ini.
14. Kebersamaan teman-teman Jurusan Ilmu Komputer angkatan 2022.
15. Terakhir, terima kasih kepada wanita manis, sederhana, kuat, dan mandiri, yaitu diri saya sendiri, Zainab Aqilah. Terima kasih atas perjalanan panjang yang telah dilalui hingga sampai di titik ini. Banyak proses yang sudah dilewati dan banyak lelah yang dipendam sendiri. Terima kasih karena tetap berdiri ketika keadaan tidak selalu berpihak, tetap mencoba ketika hasil belum sesuai harapan, dan tetap melangkah meski arah terasa samar. Pada akhirnya, yang paling berat dari skripsi ini bukan hanya tentang revisi, data, atau proses pengerjaannya. Ada hal lain yang tanpa

sadar membuat langkah terasa lebih lambat dari yang seharusnya. Kadang rasanya ingin segera sampai, tetapi keadaan membuat semuanya harus dijalani dengan tempo yang berbeda. Meski begitu, perlahan diri ini tetap belajar untuk terus melangkah sampai akhirnya berhasil berada di titik ini. Bangga atas setiap langkah kecil yang mungkin terlihat sederhana namun penuh perjuangan. Bangga karena tetap berani bermimpi dan membuktikan bahwa proses tidak pernah mengkhianati hasil. *This is your proof that you are stronger than you think.* Selamat untuk pencapaian ini. Selamat telah menyelesaikan satu fase penting dalam hidup. Teruslah melangkah, terus bertumbuh, dan terus menjadi pribadi yang lebih baik setiap harinya. Karena tidak ada yang lebih indah selain melihat diri sendiri berkembang hingga menjadi versi terbaiknya.

Penulis menyadari bahwa skripsi ini masih jauh dari sempurna. Semoga skripsi ini dapat memberikan manfaat dan dapat digunakan sebagaimana mestinya.

Bandar Lampung, 12 Juni 2026  
Penulis

Zainab Aqilah  
NPM. 2217051149

## DAFTAR ISI

	<b>Halaman</b>
<b>DAFTAR ISI</b> .....	<b>xiv</b>
<b>DAFTAR GAMBAR</b> .....	<b>xvii</b>
<b>DAFTAR TABEL</b> .....	<b>xix</b>
<b>I. PENDAHULUAN</b> .....	<b>1</b>
1.1 Latar Belakang .....	1
1.2 Rumusan Masalah .....	5
1.3 Batasan Masalah.....	5
1.4 Tujuan Penelitian .....	5
1.5 Manfaat Penelitian.....	6
<b>II. TINJAUAN PUSTAKA</b> .....	<b>7</b>
2.1 Penelitian Terdahulu .....	7
2.2 Peramalan ( <i>Forecasting</i> ) / Prediksi .....	12
2.3 Deret Waktu ( <i>Time Series</i> ).....	13
2.4 Pola Data Deret Waktu .....	14
2.4.1 Pola Tren ( <i>Trend Pattern</i> ) .....	14
2.4.2 Pola Horizontal ( <i>Horizontal Pattern / Stationary Pattern</i> ) .....	15
2.4.3 Pola Musiman ( <i>Seasonal Pattern</i> ).....	15
2.4.4 Pola Siklis ( <i>Cyclical Pattern</i> ) .....	16
2.4.5 Pola Acak ( <i>Irregular Pattern</i> ).....	17
2.5 Bandara.....	17
2.5.1 Bandara Radin Inten II Lampung .....	17
2.6 Penerbangan Domestik.....	18
2.7 <i>Machine Learning</i> .....	19
2.8 Penanganan Data Anomali dengan Menggunakan <i>Interpolate</i> .....	21
2.9 Stasioneritas.....	22

2.9.1 Stasioner dalam Variansi.....	23
2.9.2 Stasioner dalam Rata-Rata.....	24
2.10 <i>Autocorrelation Function</i> (ACF).....	27
2.11 <i>Partial Autocorrelation Function</i> (PACF).....	30
2.12 Model Autoregresif ( <i>Autoregressive</i> ).....	32
2.13 Model Rata-Rata Bergerak ( <i>Moving Average</i> ).....	33
2.14 Model ARIMA ( <i>Autoregressive Integrated Moving Average</i> ).....	34
2.15 Model SARIMA ( <i>Seasonal Autoregressive Integrated Moving Average</i> ).....	35
2.16 Pemeriksaan Diagnostik.....	39
2.17 <i>Exponential Smoothing</i> .....	42
2.17.1 Model <i>Single Exponential Smoothing</i> (SES).....	42
2.17.2 Model <i>Double Exponential Smoothing</i> (DES).....	43
2.17.3 Model <i>Triple Exponential Smoothing</i> (TES).....	44
2.18 Inisialisasi TES <i>Holt-Winters</i> .....	47
2.19 Evaluasi Performa Model Peramalan.....	48
2.19.1 <i>Mean Absolute Percentage Error</i> (MAPE).....	49
2.19.2 <i>Mean Absolute Error</i> (MAE).....	50
2.19.3 <i>Root Mean Square Error</i> (RMSE).....	51
<b>III. METODOLOGI PENELITIAN .....</b>	<b>52</b>
3.1 Tempat dan Waktu.....	52
3.1.1 Tempat Penelitian.....	52
3.1.2 Waktu Penelitian.....	52
3.2 Alat Pendukung.....	53
3.2.1 Perangkat Keras.....	53
3.2.2 Perangkat Lunak.....	53
3.3 Data.....	53
3.4 Tahapan Penelitian.....	54
3.4.1 Studi Literatur.....	56
3.4.2 Pengumpulan Data.....	56
3.4.3 Pembagian Data ( <i>Splitting Data</i> ).....	56
3.4.4 <i>Explorasi Data</i> .....	57
3.4.5 <i>Pre-processing Data</i> .....	62
<b>IV. HASIL DAN PEMBAHASAN .....</b>	<b>69</b>
4.1. Pemodelan SARIMA Menggunakan Data Tahun 2015–2024.....	69
4.1.1 Analisis Deskriptif.....	69

4.1.2 Visualisasi Plot Data <i>Time Series</i> .....	70
4.1.3 Deteksi Pola Data.....	72
4.1.4 Penanganan Data Anomali.....	73
4.1.5 Normalisasi Data dengan Transformasi <i>Box-Cox</i> .....	77
4.1.6 Uji Stasioneritas Data .....	78
4.1.7 Identifikasi ARIMA Model $(p, d, q)(P, D, Q)s$ dengan Plot ACF dan PACF.....	81
4.1.8 Estimasi Parameter dan Pemilihan Model Terbaik SARIMA .....	83
4.1.9 Uji Diagnostik.....	85
4.1.10 Peramalan ( <i>Forecasting</i> ) Menggunakan Model ARIMA $(1, 1, 1)(0, 0, 1)12$ .....	86
4.1.11 Evaluasi Model Menggunakan Model ARIMA $(1, 1, 1)(0, 0, 1)12$ ..	88
4.2 Pemodelan <i>Triple Exponential Smoothing</i> (TES) .....	89
4.2.1 Penentuan Nilai Awal.....	89
4.2.2 Penentuan Nilai Parameter.....	94
4.2.3 Peramalan ( <i>Forecasting</i> ) Menggunakan Model TES Pada Data Testing .....	108
4.2.4 Evaluasi Model TES .....	110
4.3 Pemilihan Model Terbaik SARIMA dan TES .....	112
4.4 Plot Data Aktual, <i>Fitted Value</i> dan Peramalan Periode Mendatang .....	113
<b>V. KESIMPULAN DAN SARAN .....</b>	<b>128</b>
5.1 Kesimpulan.....	128
5.2 Saran.....	129
<b>DAFTAR PUSTAKA.....</b>	<b>130</b>
<b>LAMPIRAN.....</b>	<b>138</b>

## DAFTAR GAMBAR

<b>Gambar</b>	<b>Halaman</b>
1. Pola data tren. ....	14
2. Pola data horizontal. ....	15
3. Pola data musiman. ....	16
4. Pola data siklis. ....	16
5. Pola data acak. ....	17
6. Kategori <i>machine learning</i> berdasarkan cara belajarnya. ....	19
7. Plot ACF data yang belum stasioner. ....	29
8. Plot ACF data yang stasioner. ....	29
9. Plot PACF data yang belum stasioner. ....	31
10. Plot PACF data yang stasioner. ....	32
11. Alur kerangka tahapan penelitian. ....	55
12. Grafik plot <i>time series</i> data asli jumlah keberangkatan dan kedatangan penumpang pesawat pada tahun 2015-2024. ....	71
13. Dekomposisi data penumpang keberangkatan. ....	72
14. Dekomposisi data penumpang kedatangan. ....	73
15. Plot data keberangkatan setelah transformasi dan diferensiasi pertama. ....	80
16. Plot data kedatangan setelah transformasi dan diferensiasi pertama. ....	80
17. Plot ACF dan PACF penumpang keberangkatan. ....	81
18. Plot ACF dan PACF penumpang kedatangan. ....	82
19. Plot perbandingan data aktual dan <i>forecasting</i> TES model aditif penumpang keberangkatan 2025. ....	98
20. Plot perbandingan data aktual dan <i>forecasting</i> TES model aditif penumpang kedatangan 2025. ....	99
21. Plot perbandingan data aktual dan <i>forecasting</i> TES model multiplikatif penumpang keberangkatan 2025. ....	103

22.	Plot perbandingan data aktual dan <i>forecasting</i> TES model multiplikatif penumpang kedatangan 2025. ....	104
23.	Perbandingan data aktual dan <i>fitted value</i> model SARIMA dan TES pada data training jumlah penumpang keberangkatan tahun 2015–2024. ....	114
24.	Perbandingan data aktual dan <i>fitted value</i> model SARIMA dan TES pada data training jumlah penumpang kedatangan tahun 2015–2024. ....	115
25.	Perbandingan data aktual dan hasil peramalan model SARIMA dan TES pada data testing jumlah penumpang keberangkatan tahun 2025. ....	116
26.	Perbandingan data aktual dan hasil peramalan model SARIMA dan TES pada data testing jumlah penumpang keberangkatan tahun 2025. ....	117
27.	Plot hasil peramalan jumlah penumpang keberangkatan dan kedatangan tahun 2026 menggunakan model TES multiplikatif. ....	120
28.	Plot data aktual (2015–2025) dan hasil peramalan (2026) jumlah penumpang keberangkatan menggunakan model TES multiplikatif. ....	121
29.	Plot data aktual (2015–2025) dan hasil peramalan (2026) jumlah penumpang kedatangan menggunakan model TES multiplikatif. ....	122
30.	Skenario <i>forecast</i> penumpang keberangkatan 2026-2028. ....	123
31.	Skenario <i>forecast</i> penumpang kedatangan 2026-2028. ....	125
32.	Skenario <i>forecast yearly</i> penumpang keberangkatan 2026-2028. ....	126
33.	Skenario <i>forecast yearly</i> penumpang kedatangan 2026-2028. ....	127

## DAFTAR TABEL

<b>Tabel</b>	<b>Halaman</b>
1. Penelitian Terdahulu .....	7
2. Transformasi Pangkat <i>Box Cox</i> .....	23
3. Kriteria atau Standar Tingkat Keakuratan MAPE .....	50
4. Waktu Penelitian .....	52
5. Dataset Penelitian .....	54
6. Deskriptif statistik data jumlah penumpang pesawat .....	69
7. Data anomali ( <i>outlier</i> ) sebelum dilakukan interpolasi linear .....	74
8. Penanganan nilai anomali ( <i>outlier</i> ) menggunakan interpolasi linear .....	75
9. Data anomali yang terindikasi sebagai kesalahan pencatatan .....	75
10. Penanganan data anomali yang terindikasi sebagai kesalahan pencatatan menggunakan interpolasi linear .....	76
11. Hasil uji stasioneritas penumpang keberangkatan .....	78
12. Hasil uji stasioneritas penumpang kedatangan .....	78
13. Hasil <i>differencing</i> pertama ( $d=1$ ) data jumlah penumpang keberangkatan .	79
14. Hasil <i>differencing</i> pertama ( $d=1$ ) data jumlah penumpang kedatangan .....	79
15. Model SARIMA sementara penumpang keberangkatan dan kedatangan ...	83
16. Estimasi parameter model SARIMA sementara penumpang keberangkatan .....	84
17. Estimasi parameter model SARIMA sementara penumpang kedatangan ...	84
18. Tes <i>white noise</i> dan normalitas keberangkatan.....	85
19. Tes <i>white noise</i> dan normalitas kedatangan.....	85
20. Perbandingan data aktual dan hasil peramalan jumlah penumpang keberangkatan dan kedatangan tahun 2025 .....	87
21. Nilai metrik kesalahan model SARIMA keberangkatan .....	88
22. Nilai metrik kesalahan model SARIMA kedatangan.....	88

23.	Percobaan algoritma TES aditif penumpang keberangkatan sebanyak 20 kali .....	95
24.	Data alfa, gamma, beta TES aditif penumpang keberangkatan dengan akurasi sangat baik.....	95
25.	Percobaan algoritma TES aditif penumpang kedatangan sebanyak 20 kali	96
26.	Data alfa, gamma, beta TES aditif penumpang kedatangan dengan akurasi sangat baik .....	97
27.	Percobaan algoritma TES multiplikatif penumpang keberangkatan sebanyak 20 kali .....	100
28.	Data alfa, gamma, beta TES multiplikatif penumpang keberangkatan dengan akurasi sangat baik.....	101
29.	Percobaan algoritma TES multiplikatif penumpang kedatangan sebanyak 20 kali .....	101
30.	Data alfa, gamma, beta TES multiplikatif penumpang kedatangan dengan akurasi sangat baik.....	102
31.	Perbandingan data aktual dan hasil peramalan model TES jumlah penumpang keberangkatan dan kedatangan tahun 2025 .....	109
32.	Nilai metrik kesalahan model TES penumpang keberangkatan dan kedatangan .....	111
33.	Perbandingan nilai metrik kesalahan model terbaik TES dan SARIMA ...	112
34.	Hasil peramalan jumlah penumpang keberangkatan dan kedatangan tahun 2026 – 2028 menggunakan model TES multiplikatif.....	118

# I. PENDAHULUAN

## 1.1 Latar Belakang

Transportasi udara merupakan salah satu moda yang berperan penting dalam mendukung mobilitas manusia dan barang, terutama untuk perjalanan jarak jauh yang membutuhkan efisiensi waktu (Banjarnahor et al., 2021). Salah satu transportasi udara yang sampai sekarang masih beroperasi setiap hari adalah pesawat terbang. Pesawat terbang merupakan salah satu moda transportasi yang memiliki waktu tempuh lebih singkat dibandingkan transportasi darat. Pesawat terbang dianggap sebagai cara yang efisien untuk menghemat waktu saat bepergian ke lokasi yang jaraknya jauh (Ahmad Fadli Ramadhan & Rizal Adi Saputra, 2023). Oleh karena itu, setiap harinya banyak masyarakat yang datang ke bandara dengan tujuan untuk melakukan perjalanan menggunakan pesawat terbang.

Kepadatan penumpang di bandara merupakan faktor penting yang dapat memengaruhi operasional dan pelayanan (Febriana et al., 2022). Data jumlah penumpang tidak hanya mencerminkan tingkat aktivitas bandara, tetapi juga menjadi dasar perencanaan operasional, seperti pengaturan jadwal penerbangan, kapasitas terminal, hingga strategi pengembangan infrastruktur. Ketika terjadi lonjakan atau penurunan jumlah penumpang yang tidak terduga, dampaknya dapat berupa antrean panjang, kepadatan terminal, keterlambatan layanan, hingga penurunan kualitas pelayanan (Al'afi et al., 2020). Oleh karena itu, kemampuan untuk memprediksi jumlah penumpang di masa mendatang menjadi hal yang sangat dibutuhkan dalam mendukung efisiensi dan pengambilan keputusan di sektor penerbangan.

Bandara Radin Inten II Lampung merupakan bandara utama di Provinsi Lampung yang melayani penerbangan domestik. Data dari BPS (Badan Pusat Statistik) Lampung, menunjukkan bahwa jumlah keberangkatan penumpang pesawat domestik di Lampung mengalami perubahan yang cukup signifikan setiap tahunnya, dengan fluktuasi yang dapat mencapai ratusan ribu penumpang terutama pada periode libur nasional dan musim mudik. Perubahan tersebut dipengaruhi oleh berbagai faktor eksternal seperti kondisi ekonomi, kebijakan pemerintah, serta pola perjalanan masyarakat sehingga menyulitkan pengelola bandara dalam memperkirakan kebutuhan sumber daya seperti kapasitas terminal, tenaga kerja, dan jadwal penerbangan.

Berdasarkan data dari Bandar Udara Radin Inten II Bandar Lampung, tahun 2017 tercatat sebagai tahun dengan jumlah penumpang tertinggi sepanjang periode 2015–2024. Pada tahun tersebut, total penumpang mencapai sekitar 2,5 juta jiwa, terdiri atas 1.283.752 penumpang berangkat dan 1.220.095 penumpang tiba. Peningkatan ini menunjukkan tingginya mobilitas masyarakat Lampung pada masa tersebut, yang kemungkinan dipengaruhi oleh pertumbuhan ekonomi daerah dan meningkatnya aktivitas perjalanan domestik. Namun, pada periode 2020 hingga 2021, jumlah penumpang mengalami penurunan drastis akibat pandemi COVID-19, seiring dengan pembatasan mobilitas masyarakat dan pengurangan jadwal penerbangan. Kondisi ini menyebabkan penurunan aktivitas transportasi udara di seluruh Indonesia, termasuk di Bandara Radin Inten II.

Setelah situasi pandemi mulai terkendali, tren pergerakan penumpang kembali menunjukkan peningkatan. Pada tahun 2022 tercatat sekitar 689 ribu penumpang, kemudian naik menjadi 920 ribu penumpang pada 2023, dan mencapai sekitar 1,14 juta penumpang pada 2024. Secara keseluruhan, data tersebut memperlihatkan bahwa jumlah penumpang pesawat di Bandara Radin Inten II bersifat fluktuatif yang menjadi tantangan bagi pihak pengelola bandara dalam memperkirakan kebutuhan sumber daya operasional bandara.

Prediksi jumlah penumpang yang akurat sangat penting untuk perencanaan operasional dan pengambilan keputusan strategis agar bandara dapat

menghindari kepadatan berlebih, keterlambatan layanan, dan inefisiensi operasional (Wu et al., 2021). Informasi prediksi yang tepat membantu pengelola dalam menyesuaikan kapasitas terminal, alokasi tenaga kerja, dan penyusunan jadwal penerbangan. Untuk memenuhi kebutuhan tersebut, pemodelan deret waktu digunakan untuk menangkap pola tren dan musiman pada data historis penumpang (Gu et al., 2024).

Peramalan (*forecasting*) merupakan pendekatan yang digunakan untuk memperkirakan kondisi masa depan berdasarkan pola data historis. Peramalan mempunyai beberapa metode, akan tetapi metode yang paling sering digunakan adalah metode statistik, karena metode statistik menggunakan analisa referensi data-data dimasa lampau sehingga peramalan lebih aktual. Klasifikasi metode *forecasting* statistik/kuantitatif terdiri dari tiga metode yaitu *Associative Forecasting Method* (metode hubungan sebab akibat), *Time Series Forecasting*, dan metode Proyeksi Tren dengan Regresi (Admin, 2022). *Time Series Forecasting* menerapkan analisis pola ikatan antara variabel yang ingin diprediksi dengan variabel waktu (Castán-Lascorz et al., 2022). Dua metode *Time series Forecasting* yang umum digunakan adalah *Autoregressive Integrated Moving Average* (ARIMA) dan *Exponential Smoothing* (Suranto & Fitriani, 2024). Karena data jumlah keberangkatan penumpang di Lampung merupakan data *time series*, pendekatan ini sesuai untuk memodelkan pola pergerakan penumpang di masa mendatang.

Beberapa peneliti telah melakukan penelitian dengan metode SARIMA (*Seasonal AutoRegressive Integrated Moving Average*) dan juga TES (*Triple Exponential Smoothing*) untuk melakukan prediksi. SARIMA (*Seasonal AutoRegressive Integrated Moving Average*) adalah metode statistik yang umum digunakan untuk menganalisis dan memprediksi data deret waktu yang memiliki pola musiman (Kurniasari et al., 2025). TES (*Triple Exponential Smoothing*) adalah pendekatan peramalan yang efektif untuk menangani data yang memiliki sifat musiman dan tren (Kartika et al., 2020). Kelebihan TES meliputi kemampuannya dalam memprediksi pola data yang memiliki pengaruh *seasonal* (musiman) serta perubahan tren secara bersamaan.

Penelitian terdahulu menunjukkan bahwa SARIMA mampu memberikan hasil prediksi yang baik untuk data jumlah penumpang pesawat di beberapa bandara, sebagaimana dibuktikan oleh penelitian (Meliyana et al., 2025) maupun (Aziza et al., 2023) yang keduanya melaporkan bahwa SARIMA mampu memberikan hasil prediksi yang cukup akurat. Sementara itu, TES merupakan metode yang relatif sederhana dan memiliki tingkat kesalahan yang rendah, seperti yang diungkapkan oleh (Faizah et al., 2023).

Namun, sebagian penelitian tersebut masih berfokus pada analisis statistik tradisional seperti SARIMA yang digunakan untuk memodelkan pola musiman, serta *Triple Exponential Smoothing* (TES) yang umumnya diterapkan pada data dengan pola tren dan musiman. Penelitian-penelitian tersebut belum secara spesifik membahas perbandingan kinerja kedua metode tersebut dalam konteks peramalan jumlah penumpang pesawat di Bandara Radin Inten II Lampung. Selain itu, sebagian besar penelitian terdahulu lebih berfokus pada bandara-bandara besar seperti Soekarno–Hatta atau Sultan Hasanuddin, sehingga masih terdapat celah penelitian (*research gap*) mengenai penerapan kedua model prediksi pada bandara di wilayah Lampung yang memiliki karakteristik penumpang dan pola perjalanan yang berbeda.

Dengan demikian, penelitian ini mengusulkan penerapan metode *machine learning* SARIMA dan TES untuk meramalkan jumlah penumpang pesawat di Bandara Radin Inten II Lampung. Penelitian ini menggunakan pendekatan kuantitatif dengan metode *time series forecasting* untuk memperkirakan jumlah penumpang pesawat. Pendekatan ini memungkinkan analisis mendalam terhadap pola historis sekaligus memberikan perbandingan kinerja dua metode peramalan yang memiliki pendekatan berbeda. Kebaruan penelitian ini terletak pada penerapan kedua model secara bersamaan dalam konteks bandara regional Lampung serta evaluasi kinerjanya. Hasil penelitian diharapkan dapat memberikan kontribusi nyata dalam mendukung efisiensi pengelolaan bandara serta menjadi dasar bagi pengambilan keputusan strategis di sektor transportasi udara provinsi Lampung.

## 1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan, maka rumusan masalah dalam penelitian ini adalah:

1. Bagaimana penerapan dan performansi model SARIMA dan *Triple Exponential Smoothing* (TES) dalam memprediksi jumlah penumpang pesawat di Bandara Radin Inten II?
2. Bagaimana prediksi jumlah penumpang pesawat di Bandara Radin Inten II menggunakan model SARIMA dan *Triple Exponential Smoothing* (TES)?

## 1.3 Batasan Masalah

Untuk memfokuskan penelitian dan memastikan kedalaman analisis, maka penelitian ini dibatasi pada:

1. Variabel yang digunakan terbatas pada jumlah penumpang keberangkatan dan kedatangan, tanpa mempertimbangkan faktor eksternal seperti cuaca, dan ekonomi
2. Evaluasi model dilakukan menggunakan metrik kesalahan seperti MAPE (*Mean Absolute Percentage Error*), MAE (*Mean Absolute Error*), dan RMSE (*Root Mean Square Error*)

## 1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah:

1. Menerapkan dan mengevaluasi performansi model SARIMA dan *Triple Exponential Smoothing* (TES) dalam memprediksi jumlah penumpang pesawat di Bandara Radin Inten II Lampung.
2. Menghasilkan prediksi jumlah penumpang pesawat di Bandara Radin Inten II menggunakan model SARIMA dan *Triple Exponential Smoothing* (TES).

### **1.5 Manfaat Penelitian**

Penelitian ini diharapkan dapat memberikan manfaat sebagai berikut:

1. Memberikan informasi terkait hasil prediksi jumlah penumpang pesawat di Bandara Radin Inten II.
2. Memberikan rujukan referensi ataupun opsi dalam menentukan kebijakan serta perencanaan operasional bandara terkait peningkatan atau penurunan jumlah penumpang pesawat berdasarkan hasil prediksi dari penelitian ini.

## II. TINJAUAN PUSTAKA

### 2.1 Penelitian Terdahulu

Terdapat beberapa penelitian terdahulu yang berhubungan dengan penelitian ini yang diuraikan dalam Tabel 1.

**Tabel 1.** Penelitian Terdahulu

Peneliti	Judul	Data	Hasil
(Meliyana et al., 2025)	<i>A Seasonal Arima (SARIMA) Model for Forecasting Domestic Passenger Traffic at Sultan Hasanuddin Airport</i>	Data bulanan jumlah penumpang pesawat domestik yang tercatat pada BPS tahun 2019-2024 (total 64) bulan.	Model SARIMA $(0,1,1)(0,0,1)_{12}$ menghasilkan MAPE 4,5%, menunjukkan akurasi tinggi dan cocok untuk peramalan arus penumpang jangka pendek di Bandara Sultan Hasanuddin.
(Prasojo & Muludi, 2025)	<i>Passenger Density Prediction at the Airport Using LSTM and SARIMA: A Case Study at Radin Inten Airport, Lampung</i>	Data jumlah penumpang harian di Bandara Radin Inten II Lampung periode (2023-2024)	Hasil evaluasi menunjukkan bahwa SARIMA mencapai performa terbaik dalam menangkap pola musiman dengan MAPE sebesar 3,81%.
(Aziza et al., 2023)	<i>PERFORMANCE COMPARISON OF</i>	Data jumlah penumpang pesawat	Model intervensi SARIMA

	<i>SARIMA INTERVENTION AND PROPHET MODELS FOR FORECASTING THE NUMBER OF AIRLINE PASSENGER AT SOEKARNO-HATTA INTERNATIONAL AIRPORT</i>	domestik di Bandara Internasional Soetta yang diperoleh dari situs web Biro Pusat Statistik (BPS) periode bulanan dari tahun 2010-2023	$(0,1,1)(1,0,0)_{12}$ menghasilkan MAPE 28% dan RMSE 433473, menunjukkan kinerja lebih baik dibandingkan model Prophet dalam memprediksi jumlah penumpang domestik di Bandara Soetta selama pandemi COVID-19.
(Durrah et al., 2019)	Peramalan Jumlah Penumpang Pesawat Di Bandara Sultan Iskandar Muda Dengan Metode SARIMA ( <i>Seasonal Autoregressive Integrated Moving Average</i> )	Data sekunder yang diperoleh dari Bandara Sultan Iskandar Muda periode Bulan Januari 2010 hingga Desember 2016.	Model terbaik yang diperoleh yaitu ARIMA $(0,1,1)(0,0,1)_{12}$
(Jamil et al., 2025)	Prediksi Jumlah Penumpang Pesawat Domestik di Bandara Soekarno-Hatta dengan Metode SARIMA untuk Mendukung Pengelolaan Kebijakan Transportasi Publik	Data jumlah penumpang domestik Bandara Soekarno-Hatta periode Januari 2019 – Desember 2023 dari BPS.	Model SARIMA $(0,1,0)(0,0,1)_{12}$ telah teridentifikasi sebagai model terbaik untuk meramalkan jumlah penumpang pesawat di Bandara Soekarno-Hatta untuk Keberangkatan Domestik.

(Sceince, 2017)	<i>Modelling Air Passenger Traffic Flow in Murtala Muhammad International Airport Lagos, Nigeria: A Time Series Approach</i>	Data tahun 2003 – 2013, total 132 observasi bulanan.	ANN memberikan hasil terbaik secara keseluruhan Namun, SARIMA menunjukkan performa baik pada sektor domestik, sedangkan HWES unggul pada sektor internasional.
(Nu et al., 2024)	Peramalan Jumlah Penumpang Domestik Pada Bandar Udara Sultan Syarif Kasim II Dengan Menggunakan Metode <i>Winter's Exponential Smoothing</i>	Data jumlah penumpang domestik Bandar Udara Sultan Syarif Kasim II (2020–2023)	Model TES ( <i>Winter's Exponential Smoothing</i> ) menunjukkan hasil terbaik dengan nilai $\alpha = 0,9$ , $\beta = 0,1$ , $\gamma = 0,9$
(Fahik & Jatipaningrum, 2021)	PERAMALAN JUMLAH PENUMPANG PENERBANGAN INTERNASIONAL DI BANDAR UDARA INTERNASIONAL SOEKARNO HATTA DENGAN METODE <i>HOLT-WINTERS EXPONENTIAL SMOOTHING</i> DAN <i>SEASONAL ARIMA</i>	Data bulanan jumlah penumpang pesawat Bandar Udara Internasional Soekarno Hatta pada periode 2014-2019.	Metode TES ( <i>Holt-Winters Exponential Smoothing</i> ) dengan modifikasi <i>Golden Section</i> menghasilkan peramalan jumlah penumpang internasional Bandara Soekarno-Hatta dengan MAPE 4,407%.
(Faizah et al., 2023)	Peramalan Jumlah Penumpang Pesawat Domestik di Bandara	Data bulanan jumlah penumpang domestik Bandara	Metode Ensemble <i>Holt-Winters Exponential</i>

	Udara Sultan Aji Muhammad Sulaiman Sepinggian Balikpapan dengan <i>Ensembl Holt- Winters Exponential Smoothing</i>	Sultan Aji Muhammad Sulaiman Sepinggian (2018-2023).	<i>Smoothing</i> mampu meramalkan jumlah penumpang pesawat domestik dengan akurasi tinggi, ditunjukkan oleh nilai MAPE sebesar 5,64%.
(Gautama et al., 2024)	Prediksi Jumlah Penumpang Di Bandara Nasional Ahmad Yani Semarang Menggunakan <i>Holt Winter's Exponential Smoothing (HWES)</i>	Data jumlah penumpang pesawat di Bandara Nasional Ahmad Yani Semarang periode 2007-2022.	Hasil penelitian menunjukkan bahwa metode <i>Holt- Winters Exponential Smoothing</i> merupakan metode terbaik dalam meramalkan jumlah penumpang pesawat, ditunjukkan oleh nilai MAPE sebesar 13,98%.

Penelitian-penelitian dalam Tabel 1 menunjukkan bahwa metode peramalan deret waktu seperti SARIMA dan TES telah banyak diterapkan dalam memprediksi jumlah penumpang pesawat di berbagai bandara. Secara umum, SARIMA dapat memberikan akurasi tinggi pada data bulanan yang memiliki pola musiman, sedangkan TES cenderung lebih efektif pada data dengan pola tren yang bergerak secara stabil. Meskipun demikian, tingkat keberhasilan setiap model tetap dipengaruhi oleh karakteristik data dan periode pengamatan yang digunakan, sehingga belum ada metode tunggal yang selalu unggul di semua kondisi.

Pada penelitian yang menerapkan SARIMA, (Meliana et al., 2025) memperoleh model terbaik  $ARIMA\{(0,1,1)(0,0,1)\}^{12}$  dengan nilai MAPE

sebesar 4,5%, yang membuktikan bahwa model SARIMA menyediakan alat prediksi yang andal untuk memperkirakan arus penumpang domestik jangka pendek di bandara. Tingkat akurasi tinggi juga dicapai pada studi (Prasojo & Muludi, 2025) melalui analisis data harian di Bandara Radin Inten II Lampung, di mana SARIMA mampu menangkap pola musiman harian dengan MAPE 3,81%, meskipun dibandingkan dengan model berbasis *machine learning* lainnya. Performa SARIMA dalam mengikuti fluktuasi musiman juga tercermin dalam temuan (Aziza et al., 2023) pada prediksi jumlah penumpang domestik Bandara Soekarno-Hatta, yang menghasilkan model intervensi SARIMA  $(0,1,1)(1,0,0)^{12}$  dengan MAPE sebesar 28% dan RMSE 433.473, serta memberikan hasil lebih baik dibandingkan *Prophet* berdasarkan MAPE dan RMSE yang lebih rendah. Kemampuan yang konsisten dalam memodelkan data berkala juga terlihat dari studi (Durrah et al., 2019) dan (Jamil et al., 2025), yang sama-sama mengidentifikasi pola musiman yang kuat dalam data penumpang bandara dan dapat diestimasi secara stabil dengan pendekatan SARIMA. Bahkan pada konteks yang lebih luas, (Sceince, 2017) membandingkan kinerja ANN, SARIMA, dan *Holt-Winters* pada data penumpang bandara di Nigeria; meskipun ANN memberikan hasil paling unggul secara keseluruhan, SARIMA tetap menunjukkan performa solid pada sektor domestik yang memiliki musiman cukup kuat.

Metode *Triple Exponential Smoothing (Holt-Winters)* juga banyak diterapkan dalam peramalan jumlah penumpang pesawat karena dapat mengikuti perubahan pola data dari waktu ke waktu, termasuk kecenderungan tren dan variasi musiman. (Nu et al., 2024) menunjukkan bahwa model *Winter's Exponential Smoothing* dengan parameter  $\alpha=0,9$ ,  $\beta=0,1$ , dan  $\gamma=0,9$  memberikan hasil peramalan terbaik pada data penumpang domestik periode 2020–2023. (Fahik & Jatipaningrum, 2021) melaporkan bahwa *Holt-Winters* dengan modifikasi *Golden Section* menghasilkan akurasi sangat baik dengan MAPE sebesar 4,407%. Peningkatan ketepatan prediksi juga terlihat pada penelitian (Faizah et al., 2023) melalui pendekatan Ensemble *Holt-Winters*

dengan MAPE 5,64%. Kinerja *Holt-Winters Exponential Smoothing* sebagai metode peramalan yang andal kembali dibuktikan dengan diperolehnya MAPE sebesar 13,98% pada studi (Gautama et al., 2024). Temuan-temuan ini menunjukkan bahwa *Triple Exponential Smoothing (Holt-Winters)* konsisten menjadi metode yang efektif untuk meramalkan data jumlah penumpang bandara dengan pola tren dan musiman.

## 2.2 Peramalan (*Forecasting*) / Prediksi

Peramalan/*forecasting* merupakan salah satu metode yang digunakan untuk memprediksi atau meramalkan suatu hal yang belum pernah terjadi (Dewi et al., 2022). Prediksi merupakan suatu kegiatan meramalkan secara terstruktur mengenai sesuatu yang mungkin terjadi dimasa akan datang yang bersumber pada informasi dari masa lalu dan sekarang yang dimiliki, agar kesalahannya dapat diperkecil (Dewi et al., 2022).

Peramalan (*forecasting*) merupakan alat bantu yang penting dalam perencanaan yang efektif dan efisien (Setiawan, 2021). Peramalan adalah proses untuk memperkirakan beberapa kebutuhan dimasa yang akan datang. *Forecasting* merupakan proses prediksi nilai-nilai masa depan dari sebuah variabel berdasarkan dengan data *time series* yang ada (Rahman et al., 2025). Peramalan memiliki estimasi nilai atau karakteristik masa depan yaitu prediksi (*prediction*), peramalan (*forecast*), dan kecenderungan (*trend*). Menurut Makridakis (1999), teknik peramalan terbagi menjadi dua bagian, yaitu pertama metode peramalan subjektif dan metode objektif (Syahanifadhel et al., 2023). Metode peramalan subjektif mempunyai model kualitatif sedangkan metode peramalan objektif mempunyai dua model, yaitu model *time series* dan kausal (Wardani et al., 2020). Model kualitatif memasukkan faktor-faktor subjektif dalam model peramalannya, model ini biasanya digunakan ketika data historis tidak tersedia dan akan sangat bermanfaat jika data kuantitatif yang akurat sulit diperoleh (Mahara, 2021). Contoh dari metode ini adalah metode *delphi*, opini juri eksekutif dan survei pasar konsumen.

### 2.3 Deret Waktu (*Time Series*)

Analisis deret waktu diperkenalkan pada tahun 1970 oleh George E.P. Box dan Gwilym M. Jenkins melalui bukunya yang berjudul *Time Series Analysis: Forecasting and Control*. Sejak saat itu, deret waktu mulai banyak dikembangkan. Deret waktu (*time series*) merupakan serangkaian data pengamatan yang terjadi berdasarkan indeks waktu secara berurutan dengan interval waktu tetap. *Time Series* merupakan data yang dikumpulkan, dicatat, atau diobservasi sepanjang waktu secara berurutan dengan beberapa periode waktu termasuk tahun, kuartal, bulan, minggu dan pada beberapa kasus hari atau jam (Maysosa et al., 2023). *Time Series* adalah metode predictive yang digunakan sebagai penentu pola berdasarkan data historinya yang dikumpulkan secara sistematis menurut waktu kejadian (Rahman et al., 2025).

*Time series* berfokus pada pemahaman akan dataset yang tersedia dan yang berhubungan dengan faktor eksternal. Data *time series* di analisis untuk menemukan pola variasi masa lalu yang dapat dipergunakan untuk memperkirakan nilai untuk masa depan (*forecast*) karena dengan mengamati data runtut waktu akan terlihat empat komponen yang akan mempengaruhi pola data masa lalu dan sekarang yang benderung berulang di masa mendatang. *Time series* dibagi menjadi dua, yang pertama adalah *Time Series Analysis* dan yang kedua adalah *Time Series Forecasting* (Maysosa et al., 2023).


Model *time series* merupakan model yang digunakan untuk memprediksi masa depan dengan menggunakan data historis. Dengan kata lain model *time series* mencoba melihat apa yang terjadi pada suatu kurun waktu tertentu dan menggunakan data masa lalu untuk memprediksi. Contoh dari model *time series* ini antara lain yaitu *Moving Average*, *Exponential Smoothing* dan *Proyeksi Trend*.

## 2.4 Pola Data Deret Waktu

Pola data deret waktu merupakan komponen utama yang perlu dipahami sebelum melakukan proses peramalan. Untuk menentukan metode peramalan pada data deret waktu perlu diketahui pola dari data tersebut sehingga peramalan data dapat dilakukan dengan metode yang sesuai. Menurut *Hyndman dan Athanasopoulos (2021)*, data deret waktu dapat diuraikan menjadi beberapa komponen utama, yaitu tren (*trend*), horizontal (*stationary*), musiman (*seasonal*), siklis (*cyclical*) dan acak (*irregular*). Namun, Menurut Hanke, J. E dan Wichern, D. W. dikutip oleh (Garini & Anbiya, 2022) pada data *time series* terdapat empat macam pola yaitu tren, horizontal, musiman, siklis dan pola acak. Pola-pola ini berfungsi untuk menggambarkan perilaku data dari waktu ke waktu, sehingga membantu peneliti dalam menentukan metode peramalan yang paling sesuai.

### 2.4.1 Pola Tren (*Trend Pattern*)

Pola tren menunjukkan arah pergerakan data dalam jangka panjang. Tren menggambarkan apakah data meningkat, menurun, atau tetap stabil (Das & Barman, 2025). Dalam konteks transportasi udara, tren positif dapat terlihat dari peningkatan jumlah penumpang pesawat setiap tahunnya akibat pertumbuhan ekonomi dan peningkatan mobilitas masyarakat. Jenis pola tren dapat dilihat pada Gambar 1.

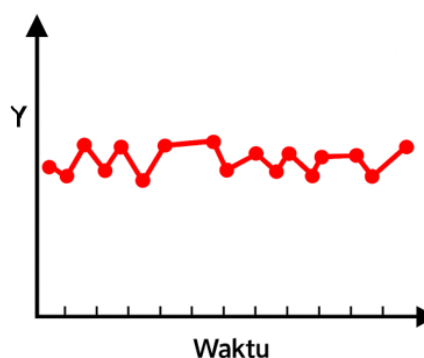


Gambar 1. Pola data tren.

Sumber: (Fariza, 2017)

### 2.4.2 Pola Horizontal (*Horizontal Pattern / Stationary Pattern*)

Dalam konteks analisis deret waktu, pola data horizontal memiliki nilai rata-rata data cenderung tetap konstan sepanjang waktu, data tidak menunjukkan kecenderungan yang konsisten naik atau turun selama periode waktu yang diamati, tidak ada fluktuasi berulang pada interval waktu tertentu, seperti harian, bulanan, atau tahunan (Rosidah et al., 2024). Pola data horizontal/stasioner dapat dilihat pada Gambar 2.

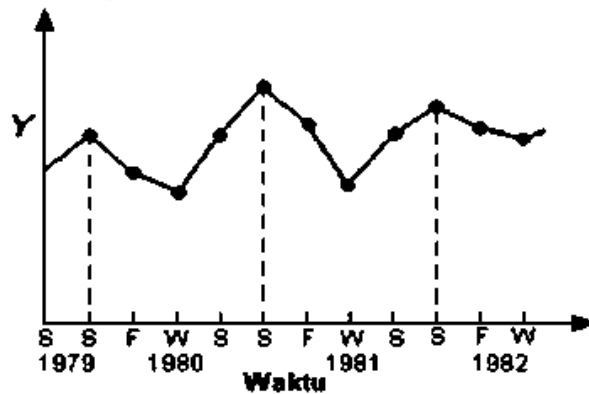


Gambar 2. Pola data horizontal.

Sumber: (Arumsari & Dani, 2021)

### 2.4.3 Pola Musiman (*Seasonal Pattern*)

Pola musiman menggambarkan fluktuasi data yang berulang teratur dalam setiap periode tertentu, dan dipengaruhi oleh faktor musiman (misalnya misalnya tahunan, semesteran, kuartalan, bulanan atau mingguan (Ferdiansyah, 2018). Fluktuasi ini biasanya dipengaruhi oleh faktor waktu tertentu seperti hari raya, musim liburan, atau periode mudik (Hyndman & Athanasopoulos, 2021). Pada data penumpang pesawat, pola musiman dapat terlihat dari meningkatnya jumlah penerbangan pada bulan-bulan tertentu. Untuk jenis pola ini dapat dilihat pada Gambar 3.




Gambar 3. Pola data musiman.

Sumber: (Arumsari & Dani, 2021)

#### 2.4.4 Pola Siklis (*Cyclical Pattern*)

Pola siklis merujuk pada fluktuasi atau perubahan berulang dalam data yang memiliki periode waktu yang lebih panjang dari satu tahun dan tidak selalu berulang pada interval waktu yang sama (Rosidah et al., 2024). Pola siklis mirip dengan pola musiman, tetapi terjadi dalam periode yang tidak tetap dan sering dipengaruhi oleh faktor ekonomi makro, seperti inflasi, kebijakan pemerintah, atau kondisi industri penerbangan. Jenis pola data ini dapat dilihat pada Gambar 4.




Gambar 4. Pola data siklis.

Sumber: (Arumsari & Dani, 2021)

### 2.4.5 Pola Acak (*Irregular Pattern*)

Pola *irregular* merupakan kejadian yang tidak terduga dan bersifat acak, tetapi kemunculannya dapat mempengaruhi fluktuasi data *time series*. Pola ini bersifat sporadis atau gerakan dengan pola yang tidak teratur dan tidak dapat diperkirakan yang terjadi dalam waktu singkat (Fariza, 2017). Jenis pola ini dapat dilihat pada Gambar 5.



Gambar 5. Pola data acak.

Sumber: (Fariza, 2017)

## 2.5 Bandara

Bandara merupakan area di daratan dan/atau perairan dengan batas-batas tertentu yang digunakan sebagai tempat pesawat mendarat dan lepas landas, masuk dan keluar penumpang, bongkar muat barang, perpindahan transportasi intra dan antar, dilengkapi dengan fasilitas keamanan dan keselamatan penerbangan, serta fasilitas dasar dan fasilitas pendukung lainnya (Ahmad Fadli Ramadhan & Rizal Adi Saputra, 2023).

### 2.5.1 Bandara Radin Inten II Lampung

Bandar Udara Radin Inten II merupakan bandara yang melayani Kota Bandar Lampung dan wilayah sekitarnya di Provinsi Lampung, Indonesia. Bandara ini sebelumnya dikenal sebagai Bandara Branti, dan namanya diambil dari pahlawan nasional asal Lampung, Radin Intan II, salah satu tokoh penting pada masa Kesultanan Lampung.

Bandara Radin Inten II berlokasi di Desa Branti Raya, Kecamatan Natar, Kabupaten Lampung Selatan. Lokasi ini menjadikan bandara sebagai pintu gerbang utama aktivitas penerbangan di Provinsi Lampung (Wikipedia, 2025)

Pada tahun 2025, melalui Keputusan Menteri Perhubungan Nomor KM 37 Tahun 2025, Bandara Radin Inten II kembali ditetapkan sebagai bandara berstatus internasional. Status ini menjadi momentum penting bagi pengembangan transportasi udara di Lampung. Namun demikian, meskipun status internasional telah disahkan, operasional penerbangan internasional masih menunggu pemenuhan beberapa persyaratan, seperti dokumen pertimbangan dari Kementerian Pertahanan serta rekomendasi terkait area kepabeanan, imigrasi, dan karantina. Artinya, bandara belum melayani rute internasional secara penuh hingga seluruh persyaratan dipenuhi (Detiksumbagsel, 2025).


Saat ini, Bandara Radin Inten II terutama melayani penerbangan domestik menuju berbagai kota besar seperti Jakarta, Batam, Palembang, Yogyakarta, Bandung, dan lainnya. Aktivitas penerbangan domestik menjadi penyumbang utama mobilitas penumpang di bandara ini.

## **2.6 Penerbangan Domestik**

Dalam KBBI, domestik memiliki arti sesuatu yang berhubungan dengan atau mengenai permasalahan dalam negeri. Menurut *International Civil Aviation Organization* (ICAO), penerbangan domestik adalah jenis penerbangan yang dilakukan sepenuhnya dalam wilayah kedaulatan suatu negara, baik titik keberangkatan maupun tujuan berada di dalam negara yang sama, tanpa melintasi perbatasan internasional (Jamil et al., 2025). Menurut Undang-Undang Penerbangan di Indonesia (UU No.1 Tahun 2009 Tentang Penerbangan, 2009) penerbangan domestik adalah jenis penerbangan yang dilakukan antar bandara di wilayah kedaulatan Negara Republik Indonesia, tanpa melewati wilayah udara negara lain.

## 2.7 Machine Learning

Menurut Christopher, *machine learning* merupakan cabang ilmu yang berfokus pada pengembangan algoritma dan metode statistik yang memungkinkan komputer menyelesaikan tugas tertentu tanpa perlu instruksi eksplisit. Sistem ini belajar dari pola dan proses inferensi berdasarkan data. Melalui algoritma *machine learning*, komputer membangun model matematis dari data pelatihan (*training data*) guna menghasilkan prediksi secara otomatis tanpa harus diprogram secara langsung untuk setiap tugas tertentu (Pratama, 2020). Berdasarkan cara belajarnya, *machine learning* dibagi menjadi empat kategori utama, yaitu:



Gambar 6. Kategori *machine learning* berdasarkan cara belajarnya.

### A. *Supervised Learning*

*Supervised learning* adalah metode pembelajaran yang memiliki tujuan untuk prediksi variabel target menggunakan data baru dengan data lain pada lokasi terdekat (Hartawan et al., 2023). Model mempelajari pola dari data pelatihan untuk kemudian diterapkan pada data baru. 2023). *Supervised learning* umumnya digunakan untuk menyelesaikan dua permasalahan yaitu klasifikasi (bertujuan mengklasifikasikan data baru dengan akurat) dan regresi (bertujuan memprediksi). (Behboudi et al., 2024).

### B. *Unsupervised Learning*

*Unsupervised learning* bekerja dengan data tanpa label untuk menemukan struktur atau pola tersembunyi. (Anshuman Sing, 2025)

Algoritma yang sering digunakan antara lain clustering (pengelompokan) dan reduksi dimensi. (Wikipedia, 2025).

#### C. *Semi Supervised Learning*

*Semi-supervised learning* memanfaatkan kombinasi data berlabel dan tidak berlabel. Metode ini bermanfaat saat pelabelan data mahal atau terbatas (Zhang et al., 2023).

#### D. *Reinforcement Learning*

*Reinforcement learning* melibatkan agen yang belajar melakukan tindakan dalam suatu lingkungan melalui mekanisme reward dan penalty. Agen berupaya memaksimalkan total reward jangka panjang.

(Cho et al., 2023)

Dalam konteks prediksi jumlah penumpang pesawat, metode seperti SARIMA (*Seasonal Autoregressive Integrated Moving Average*) dan *Triple Exponential Smoothing* (TES) termasuk dalam kategori *Supervised Learning*, karena model dilatih menggunakan data historis (input) untuk memprediksi nilai di masa depan (output). Walaupun keduanya berasal dari pendekatan statistik klasik, metode ini sering dimasukkan dalam kategori *machine learning tradisional* atau *data-driven forecasting*, karena keduanya menggunakan data masa lalu untuk mempelajari pola tren dan musiman tanpa perlu aturan eksplisit dari pengguna. *Machine learning* memiliki peran penting karena mampu mengenali pola kompleks dalam data historis seperti tren kenaikan jumlah penumpang, fluktuasi musiman, serta pengaruh faktor eksternal seperti hari libur atau kondisi ekonomi.

Meskipun banyak metode *machine learning* modern yang digunakan dalam peramalan seperti *Support Vector Regression* (SVR) dan *Artificial Neural Networks* (ANN), penelitian ini memanfaatkan metode statistik berbasis *machine learning tradisional* yaitu SARIMA (*Seasonal Autoregressive Integrated Moving Average*) dan *Triple Exponential Smoothing* (TES). Kedua metode ini efektif untuk data historis jumlah penumpang karena memiliki kemampuan menangkap pola tren dan musiman secara eksplisit.

Dalam penelitian ini, metode SARIMA dan TES digunakan untuk membandingkan kinerja keduanya dalam memprediksi jumlah penumpang pesawat di Bandara Radin Inten II berdasarkan data historis tahun 2015–2024. SARIMA diharapkan dapat menangkap pola musiman dan fluktuasi, sedangkan TES diterapkan untuk mengikuti kecenderungan tren serta variasi musiman dalam data penumpang. Perbandingan ini diharapkan dapat memberikan gambaran mengenai efektivitas kedua metode dalam menghasilkan prediksi yang akurat pada konteks penerbangan domestik. Hasil prediksi dari kedua metode kemudian dibandingkan dengan data aktual tahun 2025 untuk mengetahui akurasi dan kinerja model dalam konteks data transportasi udara.

## 2.8 Penanganan Data Anomali dengan Menggunakan *Interpolate*

Data anomali salah satunya *outlier* merupakan data yang memiliki nilai yang menyimpang secara signifikan dibandingkan dengan pola umum dari keseluruhan data. Keberadaan *outlier* dapat disebabkan oleh berbagai faktor, seperti kesalahan pencatatan (*human error*), kesalahan alat ukur, maupun kejadian khusus yang memang terjadi secara nyata. Dalam konteks data *time series*, *outlier* perlu diperhatikan karena dapat memengaruhi pola data serta menurunkan akurasi model peramalan yang digunakan.

Data anomali merupakan bagian dari data yang tidak konsisten dengan sebagian besar data lainnya dan dapat mengindikasikan adanya *noise* atau kesalahan dalam data. Sementara itu, dalam analisis runtun waktu, keberadaan *outlier* dapat mengganggu identifikasi pola tren maupun musiman sehingga perlu dilakukan penanganan yang tepat (Han et.,al 2012).

Penanganan data anomali dapat dilakukan melalui beberapa pendekatan, antara lain dengan tetap mempertahankan data anomali dalam model apabila mencerminkan kondisi nyata, menghapus data anomali, mengganti nilai anomali dengan nilai yang lebih representatif, maupun memodelkannya menggunakan pendekatan tertentu seperti menggunakan interpolasi linear

atau metode imputasi lainnya. Pemilihan metode penanganan disesuaikan dengan penyebab munculnya anomali dalam data (Prasetyo et al., 2024).

### 1. Interpolasi Linear

Interpolasi merupakan teknik yang digunakan untuk memperkirakan nilai yang hilang berdasarkan pola atau tren dari data yang ada di sekitarnya. Interpolasi linear memperkirakan nilai yang hilang dengan menghubungkan pengamatan yang berdekatan dengan garis lurus (Moritz & Bartz-beielstein, 2017). Dengan menggunakan interpolasi, kita dapat mengisi celah dalam data atau memperoleh perkiraan nilai di antara titik-titik yang telah diamati (Widianti & Pratama, 2024). Adapun persamaan dari interpolasi linear dari suatu data dapat dirumuskan persamaan berikut (Blu et al., 2004):

$$X_t = X_{t-1} + \frac{(X_{t+1} - X_{t-1})}{2} \quad (1)$$

dengan:

$X_t$  : nilai data pada waktu ke- $t$  yang ingin diestimasi (data yang hilang)

$X_{t-1}$  : nilai data pada waktu sebelum  $t$

$X_{t+1}$  : nilai data pada waktu setelah  $t$

## 2.9 Stasioneritas

Stasioneritas adalah keadaan dimana fluktuasi data berada disekitar nilai rata-rata yang tetap, tidak bergantung pada waktu dan variansi itu sendiri (Makridakis et al., 1993).

Penentuan stasioner sangatlah penting karena berhubungan dengan apakah data dapat langsung diestimasi atau tidak. Kondisi stasioner terdiri atas dua hal yang harus dipenuhi, yaitu stasioner dalam variansi dan stasioner dalam rata-rata.

### 2.9.1 Stasioner dalam Variansi

Data dikatakan stasioner dalam variansi yaitu apabila data berfluktuasi dengan varian yang tetap dari waktu ke waktu. Apabila kondisi stasioner dalam variansi tidak terpenuhi, maka digunakan transformasi agar data tersebut stasioner dengan menggunakan transformasi *Box-Cox*. Transformasi pangkat pada data merupakan transformasi yang ditemukan *Box* dan *Cox*. *Box Cox* mempertimbangkan kelas transformasi berparameter tunggal, yaitu  $\lambda$  yang dipangkatkan pada variabel respon  $Z_t$ , sehingga didapatkan transformasinya  $Z_t^\lambda$  dengan  $\lambda$  adalah parameter yang harus diduga. Pada transformasi *Box Cox* hal pertama yang harus dilakukan adalah menduga parameter  $\lambda$ . *Box* dan *Cox* pada tahun 1964 memperkenalkan transformasi pangkat dengan rumus (Wei, 2014) :

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

Dengan  $Z_t$  adalah deret waktu periode ke- $t$  dan  $\lambda$  adalah parameter transformasi *Box-Cox* (Arumsari & Dani, 2021).

Beberapa penggunaan nilai  $\lambda$  dengan bentuk transformasinya dapat dilihat pada Tabel 2.

**Tabel 2.** Transformasi Pangkat *Box Cox*

Nilai $\lambda$ (lamda)	Transformasi
-1	$\frac{1}{Z_t}$
-0.5	$\frac{1}{\sqrt{Z_t}}$
0	$\ln Z_t$
0.5	$\sqrt{Z_t}$
1	$Z_t$ (tanpa transformasi)

Transformasi hanya boleh dilakukan untuk deret  $Z_t$  yang positif, transformasi dilakukan sebelum melakukan *differencing* dan pemodelan deret waktu.

### 2.9.2 Stasioner dalam Rata-Rata

Jika diperoleh data deret waktu yang belum stasioner dalam rata-rata, data tidak dapat digunakan untuk mendapatkan model SARIMA terbaik, tetapi terlebih dahulu distasionerkan. Data dikatakan stasioner dalam rata-rata yaitu apabila diagram deret waktu berfluktuasi di sekitar garis yang sejajar sumbu waktu ( $t$ ), atau jika plot data berfluktuasi disekitar suatu nilai mean yang konstan. Cara yang dapat dilakukan untuk menstasionerkan data yang tidak stasioner dalam rata-rata yaitu dengan menggunakan metode *differencing* (pembedaan) terhadap data asli ( $Z_t$ ).

Metode *differencing* diperoleh dengan cara mengurangi nilai pengamatan pada waktu  $t$  dengan nilai pengamatan pada waktu sebelumnya dan membentuk suatu data baru. Jika hasil *differencing* tersebut disimbolkan dengan  $W_t$ , maka secara umum *differencing* orde 1 dapat ditulis sebagai berikut (Arumsari & Dani, 2021):

$$W_t = Z_t - Z_{t-1} \quad (3)$$

Persamaan (3) dapat dituliskan kembali menggunakan operator *backshift* ( $B$ ). Operator ini berfungsi menggeser suatu nilai satu periode ke belakang dan didefinisikan sebagai berikut (Makridakis, 1999):

$$BZ_t = Z_{t-1} \quad (4)$$

Melalui definisi tersebut, nilai  $Z_{t-1}$  pada persamaan (3) dapat digantikan dengan bentuk operator menjadi  $BZ_t$ . Dengan demikian, proses *differencing* orde pertama dapat dinyatakan dalam bentuk operator *backshift* sebagai:

$$W_t = Z_t - BZ_t = (1 - B)Z_t \quad (5)$$

dengan:

1 : mewakili nilai sekarang ( $Z_t$ )

$B$  : pembeda / operator yang memundurkan satu periode ( $Z_t - 1$ )

$(1 - B)$ : operasi yang mengambil selisih  $Z_t - Z_{t-1}$

$Z_t$  : nilai pengamatan pada periode  $t$

$Z_{t-1}$  : nilai pengamatan pada periode  $t-1$

Keterhubungan antara persamaan (3), (4), dan (5) terletak pada fungsi operator  $B$  sebagai representasi matematis dari pergeseran data ke periode sebelumnya. Persamaan (5) menjelaskan bahwa operator  $B$  mengubah nilai pada periode  $t$  menjadi nilai pada periode  $t-1$ . Berdasarkan definisi tersebut, persamaan (3), yang mendeskripsikan *differencing* sebagai selisih antara dua periode berurutan, dapat direformulasi menjadi persamaan (4), sehingga proses *differencing* dapat dituliskan dalam bentuk operator polinomial  $(1 - B)$ . Penulisan ini memberikan bentuk yang lebih ringkas dan memudahkan proses generalisasi pada *differencing* orde yang lebih tinggi.

Notasi  $B$  pada  $Z_t$  mempunyai pengaruh menggeser data satu periode ke belakang. Proses *differencing* pada orde pertama merupakan selisih antara data ke  $t$  dengan data ke  $t-1$ , dengan rumus (Katabba, 2021):

$$\Delta Z_t = Z_t - Z_{t-1} \quad (6)$$

dengan:

$\Delta Z_t$  : pembedaan orde 1

Dengan menggunakan persamaan (5) maka persamaan (6) menjadi

$$\begin{aligned} \Delta Z_t &= Z_t - BZ_t \\ &= (1 - B)Z_t \end{aligned}$$

Adapun proses *differencing* pada orde kedua adalah

$$\begin{aligned}
 \Delta^2 Z_t &= \Delta Z_t - \Delta Z_{t-1} \\
 &= (Z_t - Z_{t-1}) - (Z_{t-1} - Z_{t-2}) \\
 &= Z_t - 2Z_{t-1} + Z_{t-2} \\
 &= Z_t - 2BZ_t + B^2Z_t \\
 &= (1 - 2B + B^2)Z_t \\
 &= (1 - B)^2 Z_t
 \end{aligned}$$

Sehingga *differencing* untuk ordo ke- $d$  dapat didefinisikan

$$\Delta^d Z_t = (1 - B)^d Z_t \quad (7)$$

Kestasioneran suatu data secara pasti dapat dilihat dengan menggunakan uji statistik yaitu uji *unit root*. Uji *unit root* terdiri atas uji *Augment Dickey-Fuller* (ADF), uji *Phillips-Perron* (PP), uji *Kwiatkowski Phillips Schmidt Shin* (KPSS). Uji *unit root* yang digunakan pada penelitian ini adalah uji *Augmented Dickey-Fuller* (ADF). Uji ini dipilih karena secara umum merupakan metode standar dalam analisis deret waktu, termasuk dalam pemodelan ARIMA dan SARIMA (Hyndman & Athanasopoulos, 2021). Selain itu, uji ADF juga mampu mengidentifikasi keberadaan *unit root* dengan mempertimbangkan lag autoregresif dalam data. Persamaan regresinya adalah sebagai berikut:

$$\Delta Z_t = \mu + \beta t + \delta Z_{t-1} + \sum_{i=1}^m \phi_i \Delta Z_{t-1} + \alpha_t \quad (8)$$

dengan:

$Z_t$  : data deret waktu pada waktu ke- $t$

$\Delta Z_t = Z_t - Z_{t-1}$  : selisih (*differencing*)

$\mu$  : konstanta

$\beta t$	: komponen tren waktu
$\delta Z_{t-1}$	: bagian untuk uji akar unit
$\phi_i$	: koefisien lag perbedaan
$m$	: jumlah lag
$\alpha_t$	: <i>error</i> (gangguan acak)

Hipotesis:  $H_0$  : data tidak stasioner (memiliki *unit root*)

$H_1$  : data stasioner (tidak memiliki *unit root*)

Kriteria pengambilan keputusan: Jika nilai *p-value*  $< \alpha$  (biasanya 0,05), maka  $H_0$  ditolak sehingga data dinyatakan stasioner.

## 2.10 Autocorrelation Function (ACF)

*Autocorrelation Function* (ACF) adalah langkah awal dalam menguji adanya korelasi. ACF menunjukkan korelasi antara data saat ini dan data di beberapa lag sebelumnya. Menganalisis suatu time series terhadap prosedur statistik yang dilakukan tidak dipengaruhi oleh bertambahnya waktu. Tapi, adanya proses siklus, tren, dan lain sebagainya bisa diolah pada analisis ini (Rohmah, 2019). Koefisien autokorelasi ialah fungsi yang memperlihatkan bahwa besarnya korelasi antara observasi waktu disimbolkan dengan  $Z_t$  dengan observasi waktu terdahulu disimbolkan  $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k}$ . Pada model SARIMA, ACF digunakan terutama untuk membantu mengidentifikasi orde komponen *Moving Average* (MA) yakni jumlah lag yang harus dipertimbangkan dalam elemen MA ( $q$ ) pada model ARIMA atau SARIMA. Misalnya, jika ACF menunjukkan *cut-off* pada lag tertentu (terjadi korelasi signifikan sampai lag  $m$ , lalu menurun drastis), maka model MA dengan orde  $q \approx m$  mungkin cocok. ACF diperoleh berdasarkan pengumpulan data dengan rumus pada persamaan 9:

$$r_k = \hat{p}_k = \text{corr}(Z_t, Z_{t+k})$$

$$= \frac{\sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z})}{\sum_{t=1}^n (Z_t - \bar{Z})^2} \quad (9)$$

Dimana  $r_k$  adalah koefisien autokorelasi pada lag  $k$ ,  $n$  adalah jumlah observasi,  $k$  adalah selisih waktu (lag),  $Z_t$  adalah data pada waktu ke- $t$ ,  $Z_{t+k}$  adalah data pada waktu ke- $t+k$ , dan  $\bar{Z}$  adalah rata-rata dari  $Z_t$ . Grafik ACF dapat digunakan untuk mendeteksi kestasioneran data. Jika grafik ACF cenderung turun lambat (*dies down*), maka data tersebut dikatakan belum stasioner dalam rata-rata (Makridakis et al., 1993).

Untuk mempermudah dalam melihat apakah suatu ACF signifikan atau tidak, dapat dibuat plot dari ACF dan disandingkan dengan galat bakunya (*standard error*). Plot dari ACF disebut dengan *correlogram*. Dalam membuat suatu *correlogram*, terlebih dahulu dihitung nilai galat baku dari ACF tersebut. Galat baku digunakan untuk melihat apakah ACF berbeda secara nyata dengan nol. Persamaan 10 adalah rumus untuk menghitung galat baku dari  $r_k$ :

$$S_{rk} = \sqrt{\frac{1 + 2 \sum_{j=1}^{k-1} r_j^2}{n}} \quad (10)$$

dengan:

$S_{rk}$  : *standard error* autokorelasi pada saat lag  $k$

$r_j$  : autokorelasi pada saat lag  $j$

$k$  : time lag

$n$  : banyaknya observasi dalam *time series*

Pada uji autokorelasi,  $H_0$  didefinisikan dengan  $\rho_k = 0$  yaitu tidak ada autokorelasi, sedangkan  $H_1$  adalah  $\rho_k \neq 0$  yaitu ada autokorelasi antar pengamatan. Statistik uji yang digunakan dalam uji autokorelasi adalah statistik  $t$  yang dirumuskan pada persamaan 11:

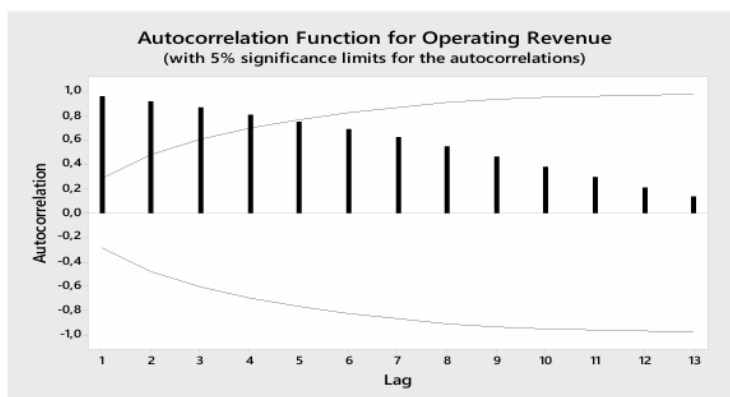
$$t_{rk} = \frac{r_k}{S_{rk}} \quad (11)$$

dengan:

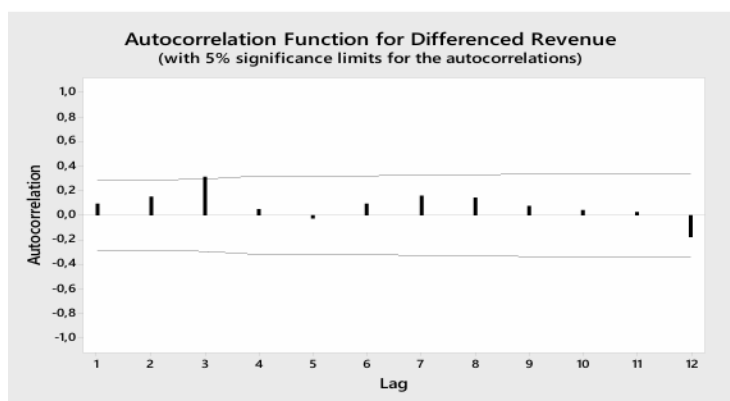
$t_{rk}$  : nilai uji  $t$  autokorelasi

$r_k$  : autokorelasi pada saat *lag*  $k$

Diagram ACF dapat digunakan sebagai alat untuk mengidentifikasi kesetasioneran data. Jika diagram ACF cenderung turun lambat atau turun secara linear, maka dapat disimpulkan data belum stasioner dalam rata-rata. Berikut merupakan contoh plot PACF pada data yang belum stasioner dan telah stasioner (Katabba, 2021).



Gambar 7. Plot ACF data yang belum stasioner.



Gambar 8. Plot ACF data yang stasioner.

### 2.11 Partial Autocorrelation Function (PACF)

*Partial Autocorrelation Function* (PACF) menunjukkan korelasi murni antara data saat ini dan lag tertentu, tanpa dipengaruhi lag di antaranya. PACF yaitu menghitung tingkat kerapatan dari  $Z_t$  dengan  $Z_{t-k}$  jika dampak dari time lag  $1, 2, \dots, k-1$  diasumsikan terpecah. PACF merupakan *function* yang menunjukkan besarnya korelasi parsial antara pengamatan pada waktu ke  $t$  (dinotasikan dengan  $Z_t$ ) dengan pengamatan pada waktu-waktu yang sebelumnya (dinotasikan dengan  $Z_{t-1}, Z_{t-2}, \dots, Z_{t-k}$ ).

Nilai dari PACF dapat digunakan untuk menentukan orde dari model *Autoregressive* (AR) yakni parameter  $p$  (dan  $P$  untuk musimannya dalam SARIMA). Apabila PACF menunjukkan *cut-off* pada lag  $p$  (korelasi signifikan di lag  $p$  lalu menurun), maka model AR dengan orde  $p$  adalah kandidat yang layak. Sebagai contoh, apabila PACF menunjukkan bahwa hanya lag 1 signifikan dan setelah itu koefisien tak signifikan, maka AR(1) bisa dipertimbangkan. Berikut ini persamaan yang digunakan untuk mendapatkan nilai *partial autocorrelation function* lag ke- $k$  dengan menentukan hasil  $\phi_{kk}$ :

$$\phi_{kk} = \text{corr}(Z_t, Z_{t-k} | Z_{t-1}, Z_{t-2}, \dots, Z_{t-k+1}) \quad (12)$$

Nilai  $\phi_{kk}$  dapat ditentukan melalui persamaan Yule-Walker:

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \dots + \phi_{kk}\rho_{j-k} \quad (13)$$

untuk  $j=1, 2, \dots, k$ , berlaku persamaan berikut:

$$\begin{aligned} \rho_1 &= \phi_{k1}\rho_0 + \phi_{k2}\rho_1 + \dots + \phi_{kk}\rho_{k-1} \\ \rho_2 &= \phi_{k1}\rho_1 + \phi_{k2}\rho_0 + \dots + \phi_{kk}\rho_{k-2} \\ &\vdots \\ \rho_k &= \phi_{k1}\rho_{k-1} + \phi_{k2}\rho_{k-2} + \dots + \phi_{kk}\rho_0 \end{aligned}$$

Sistem persamaan diatas dapat ditulis dalam bentuk matriks berikut:

$$\begin{bmatrix} \rho_1 \\ \rho_2 \\ \vdots \\ \rho_k \end{bmatrix} = \begin{bmatrix} 1 & \rho_1 & \rho_2 & \cdots & \rho_{k-1} \\ \rho_1 & 1 & \rho_1 & \cdots & \rho_{k-2} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \rho_{k-1} & \rho_{k-2} & \rho_{k-3} & \cdots & 1 \end{bmatrix} \begin{bmatrix} \phi_{k1} \\ \phi_{k2} \\ \vdots \\ \phi_{kk} \end{bmatrix} \quad (14)$$

Persamaan yang lebih efisien untuk menyelesaikan persamaan Yule-Walker:

$$\phi_{kk} = \frac{\rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j}}{1 - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_j} \quad (15)$$

dengan:

$\phi_{kk}$  : nilai PACF pada lag ke- $k$

$\rho_k$  : nilai ACF pada lag ke- $k$


Taksiran kesalahan baku (*standard error*) dari  $\phi_{kk}$  adalah:

$$S_{\phi_{kk}} = \sqrt{\frac{1}{n}} \quad (16)$$


Nilai statistik uji t untuk uji  $\phi_{kk} = 0$  atau  $\phi_{kk} \neq 0$  adalah :

$$t_{\phi_{kk}} = \frac{\phi_{kk}}{S_{\phi_{kk}}} \quad (17)$$

Berikut ini merupakan contoh gambar plot PACF yang belum stasioner dan yang sudah stasioner (Katabba, 2021).



Gambar 9. Plot PACF data yang belum stasioner.



Gambar 10. Plot PACF data yang stasioner.

## 2.12 Model Autoregresif (*Autoregressive*)

Model autoregresif disingkat AR adalah model yang menyatakan bahwa data pada periode sekarang dipengaruhi oleh data pada periode sebelumnya. Model *Autoregresif* dengan ordo  $p$  disingkat dengan ARIMA  $(p,0,0)$ . Bentuk umum dari model ini adalah sebagai berikut (Wei, 2014):

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \alpha_t \quad (18)$$

dimana:

$Z_t$  : Nilai variabel pada waktu ke- $t$

$\phi_1, \phi_2, \phi_p$  : koefisien parameter autoregresif (AR) ke- $p$

$Z_{t-1}, Z_{t-2}, Z_{t-p}$  : nilai masa lalu dari *time series* yang bersangkutan pada waktu

$p$  : orde dari model AR

$\alpha_t$  : suatu proses *white noise* atau galat pada waktu ke- $t$  / nilai kesalahan pada waktu ke- $t$

Persamaan 18 dapat ditulis menggunakan operator  $B$  (*backshift*) sebagai berikut:

$$\begin{aligned}
Z_t &= \phi_1 B Z_t + \phi_2 B^2 Z_t + \dots + \phi_p B^p Z_t + \alpha_t \\
Z_t - \phi_1 B Z_t - \phi_2 B^2 Z_t - \dots - \phi_p B^p Z_t &= \alpha_t \\
Z_t(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) &= \alpha_t \tag{19}
\end{aligned}$$

atau

$$\phi_p(B)Z_t = \alpha_t \tag{20}$$

dan  $\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$  disebut operator  $AR(p)$ .

Beberapa bentuk model persamaan dapat dihasilkan tergantung pada nilai orde ( $p$ ) yang digunakan. Dengan demikian, model tersebut disebut sebagai  $AR(p)$ . Apabila  $p = 2$ , maka model yang digunakan adalah  $AR(2)$ .

### 2.13 Model Rata-Rata Bergerak (*Moving Average*)

Model rata-rata bergerak (*Moving Average*) disingkat MA menyatakan hubungan antara nilai pengamatan dari kesalahan peramalan sekarang dan masa lalu yang berurutan, persamaan itu dinamakan *moving average model*. Model *moving average* dengan ordo  $q$  disingkat  $MA(q)$  atau  $ARIMA(0,0,q)$ . Bentuk umum dari model ini sebagai berikut (Wahyuni et al., 2021):

$$Z_t = \alpha_t - \theta_1 \alpha_{t-1} - \theta_2 \alpha_{t-2} - \dots - \theta_q \alpha_{t-q} \tag{21}$$

dimana:

$Z_t$  : Nilai variabel pada waktu ke- $t$

$\theta_1, \theta_2, \theta_q$  : koefisien parameter *moving average* (MA) ke- $q$

$\alpha_{t-1}, \alpha_{t-2}, \alpha_{t-q}$  : nilai residual pada waktu  $t, t-1, t-2, \dots, t-q$

$\alpha_t$  : suatu proses *white noise* atau galat pada waktu ke- $t$

Persamaan 21 dapat ditulis menggunakan operator  $B$  (*backshift*) sebagai berikut:

$$Z_t = \alpha_t(1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) \quad (22)$$

atau

$$\theta_q(B)\alpha_t = Z_t \quad (23)$$

dengan  $\theta_q(B) = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q)$  merupakan operator MA( $q$ ).

## 2.14 Model ARIMA (*Autoregressive Integrated Moving Average*)

Model *Autoregressive Integrated Moving Average* (ARIMA) atau *Box-Jenkins* merupakan gabungan antara model *Autoregressive* orde  $p$  dan model *moving average* orde  $q$ , yang diterapkan pada data yang telah dibedakan sebanyak  $d$  kali untuk mencapai stasioneritas (Meliyana et al., 2025).

Bentuk umum model ARIMA( $p, d, q$ ) dinyatakan sebagai berikut:

$$\phi_p(B)(1 - B)^d Z_t = \theta_0 + \theta_q(B)\alpha_t \quad (24)$$

dengan,  $\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$

dan  $\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$ .

dimana:

$Z_t$  : nilai variabel pada waktu ke- $t$

$B$  : operator *backshift*

$(1 - B)^d$  : Operator *differencing* orde non-musiman, digunakan untuk membuat data menjadi stasioner

$\phi_1, \phi_2, \dots, \phi_p$  : Koefisien *autoregressive* (AR) dengan orde ke- $p$

- $\theta_0, \theta_2, \dots, \theta_q$  : Koefisien *moving average* (MA) dengan orde ke- $q$
- $\alpha_t$  : nilai galat (*error*) pada waktu  $t$  dengan asumsi *white noise*
- $p$  : orde AR
- $q$  : orde MA
- $d$  : banyaknya pembedaan atau *differencing* yang digunakan untuk menghilangkan tren

Parameter  $\theta_0$  mempunyai peran yang berbeda untuk  $d = 0$  dan  $d > 0$ . Untuk  $d = 0$ , data asli telah stasioner dan  $\theta_0$  merupakan rata-rata proses, yaitu  $\theta_0 = (1 - \phi_1 - \phi_2 - \dots - \phi_p)\mu$ . Sedangkan untuk  $d \geq 1$ , data asli tidak stasioner dan  $\theta_0$  merupakan istilah *trend* deterministik yang biasanya dihilangkan.

### 2.15 Model SARIMA (*Seasonal Autoregressive Integrated Moving Average*)

Metode/model SARIMA merupakan pengembangan dari metode *Box-Jenkins* (ARIMA) yang menambahkan komponen musiman (Chen et al., 2018). Metode ini terkenal karena akurasi yang tinggi dalam peramalan jangka pendek hingga menengah dan digunakan untuk memodelkan data deret waktu yang memiliki pola musiman. Analisis *time series* model SARIMA dapat digunakan untuk melakukan estimasi maupun peramalan pada masa yang akan datang. Model ini mampu mengenali tren jangka panjang dan pola berulang yang muncul pada periode tertentu, sehingga cocok digunakan untuk data penumpang pesawat yang memiliki pola musiman (misalnya meningkat saat liburan dan menurun di bulan tertentu). Model ini memperhitungkan komponen autoregresif (AR), diferensiasi (I), dan *moving average* (MA), serta faktor musiman yang berulang secara periodik.

Secara umum model SARIMA dinotasikan sebagai berikut (Wei, 2014):

$$\text{ARIMA}(p, d, q)(P, D, Q)^s \quad (25)$$

dimana:

$(p, d, q)$  : bagian non-musiman dari model

$(P, D, Q)$  : bagian musiman dari model

$P$  : orde musiman AR

$D$  : banyaknya musiman yang di *differencing*

$Q$  : orde musiman MA

$s$  : jumlah periode permusiman

Bentuk umum model SARIMA adalah sebagai berikut:

$$\Phi_P(B^s)\phi_p(B)(1-B)^d(1-B^s)^D Z_t = \theta_q(B)\Theta_Q(B^s)\alpha_t \quad (26)$$

dengan,

$$Z_t = \begin{cases} Z_t - \mu; & d = 0 \text{ atau } D = 0 \\ Z_t & ; \text{lainnya} \end{cases}$$

$p, d, q$  : orde AR, *differencing*, dan MA non-musiman

$P, D, Q$  : orde AR, *differencing*, dan MA musiman

$\phi_p(B)$  : faktor AR non-musiman

$\theta_q(B)$  : faktor MA non-musiman

$\Phi_P(B^s)$  : faktor AR musiman

$\Theta_Q(B^s)$  : faktor MA musiman

$(1-B)^d$  : orde *differencing* non-musiman

$(1 - B^S)^D$  : orde *differencing* musiman

$\mu$  : rata-rata  $Z_t$

$S$  : jumlah periode permusim

Model SARIMA terdiri dari dua bagian utama:

1. Non-musiman ( $p, d, q$ ) :

- $p$  (*Order of Autoregression*): Menyatakan jumlah lag (penundaan) yang digunakan untuk memodelkan hubungan antara variabel dengan nilai-nilai masa lalu (*autocorrelation*).
- $d$  (*Degree of Differencing*): Menentukan jumlah diferensiasi yang diperlukan untuk menjadikan data stasioner (menghilangkan tren).
- $q$  (*Order of Moving Average*): Menyatakan jumlah lag dari residual model sebelumnya yang digunakan untuk memprediksi nilai saat ini.

Parameter non-musiman ( $p, d, q$ ) dipilih untuk memodelkan hubungan linier ( $p$ ), memastikan stasioneritas ( $d$ ), dan mengatasi gangguan ( $q$ ), yang diidentifikasi melalui grafik PACF dan ACF.

2. Musiman ( $P, D, Q, s$ ) :

- $P$  (*Order of Seasonal Autoregression*): Menyatakan jumlah lag musiman yang digunakan untuk memodelkan hubungan musiman dalam data.
- $D$  (*Degree of Seasonal Differencing*): Bilangan bulat yang menunjukkan jumlah diferensiasi musiman yang diperlukan untuk menjadikan data musiman stasioner.
- $Q$  (*Order of Seasonal Moving Average*): Menyatakan jumlah lag musiman dari residual model musiman sebelumnya.

- $s$  (*Seasonal Periodicity*): Menunjukkan panjang periode musiman, misalnya 12 untuk data bulanan dengan musiman tahunan.

Parameter musiman ( $P, D, Q, s$ ) digunakan untuk menangkap pola musiman ( $P$ ), menghilangkan tren musiman non-stasioner ( $D$ ), mengelola gangguan musiman ( $Q$ ), dan menentukan panjang periode musiman ( $s$ ) yang disesuaikan dengan karakteristik data.

$P$  dan  $Q$  menunjukkan lag musiman untuk AR dan MA. Nilai-nilai ini dapat tetap atau iteratif, bergantung pada jeda musiman yang relevan (MI Rizki & Taqiyyuddin, 2021; Sirisha dkk., 2022). Pemilihan parameter SARIMA didasarkan pada analisis pola dan karakteristik data deret waktu.

Parameter-parameter SARIMA dioptimalkan dengan menggunakan *Akaike Information Criterion* (AIC) dan *Bayesian Information Criterion* (BIC) yang digunakan untuk menilai keseimbangan antara kompleksitas model dan akurasi prediksi. AIC dan BIC merupakan ukuran statistik yang digunakan untuk menilai seberapa baik suatu model deret waktu sesuai dengan data tanpa terlalu kompleks. Kedua kriteria ini membantu dalam proses pemilihan model terbaik, misalnya dalam menentukan kombinasi parameter  $(p, d, q)$  dan  $(P, D, Q, s)$  pada model SARIMA.

AIC dihitung dengan rumus:

$$AIC = 2k - 2 \ln(L) \quad (27)$$

dimana:

$k$  : jumlah parameter dalam model (termasuk konstanta, AR, MA, dan komponen musiman).

$L$  : nilai *likelihood* (kemungkinan) model

AIC yang lebih rendah menunjukkan model yang lebih baik dalam hal keseimbangan antara kecocokan model dan kompleksitasnya. Model dengan AIC yang lebih tinggi cenderung *overfitting* (terlalu kompleks) atau *underfitting* (terlalu sederhana) (Prasojo & Muludi, 2025).

Kriteria lain yang digunakan adalah *Bayesian Information Criterion* (BIC). BIC memiliki fungsi serupa dengan AIC, namun memberikan penalti yang lebih besar terhadap jumlah parameter model. Rumus BIC adalah sebagai berikut:

BIC dihitung dengan rumus:

$$BIC = k \ln(n) - 2 \ln(L) \quad (28)$$

dimana:

$n$  : jumlah observasi data

$k$  : jumlah parameter dalam model

Nilai AIC dan BIC yang paling rendah menunjukkan model SARIMA yang paling optimal untuk digunakan dalam peramalan jumlah penumpang pesawat.

## 2.16 Pemeriksaan Diagnostik

Pemeriksaan diagnostik dapat dibagi menjadi dua bagian, yaitu uji signifikansi parameter dan uji asumsi residual (meliputi uji normalitas dan uji asumsi (*white noise*)).

### 1. Uji Signifikansi Parameter

Pengujian signifikansi parameter digunakan untuk menguji apakah suatu parameter model layak masuk dalam model atau tidak. Secara umum, misalkan  $\theta$  adalah suatu parameter pada model dan  $\hat{\theta}$  adalah nilai taksiran parameter tersebut, serta  $SE(\hat{\theta})$  adalah *standard error* dari nilai taksiran, maka uji signifikan dapat dilakukan dengan tahapan sebagai berikut:

Hipotesis	: $H_0$ : parameter model tidak signifikan
	$H_1$ : parameter model signifikan
Statistik Uji t	: $t_{hitung} = \frac{\hat{\theta}}{SE(\hat{\theta})}$
Kriteria Penolakan	: Tolak $H_0$ jika $ t_{hitung}  > \frac{t_a}{2}$ ; $df = n - n_p, n_p$ merupakan banyaknya parameter atau dengan menggunakan nilai- $p$ ( $p$ -value), yakni tolak $H_0$ jika nilai- $p < \alpha$

## 2. Uji Asumsi Residual

Uji asumsi residual digunakan untuk menentukan model SARIMA yang terbaik, dimana harus dipilih model yang harus memenuhi 2 asumsi residual yaitu berdistribusi normal dan *white noise*.

### 1. Uji *White Noise*

Menurut (Wei, 2014) yang dikutip oleh (Marisa, 2025) suatu proses  $\{\alpha_t\}$  dinamakan *white noise process* (proses yang bebas dan identik) apabila data terdiri dari variabel acak yang berurutan tidak saling berkorelasi dan mengikuti distribusi tertentu. Rata-rata  $E(\alpha_t) = \mu_a$  dari proses ini diasumsikan bernilai nol dan mempunyai variansi yang konstan yaitu  $Var(\alpha_t) = \sigma_a^2$  dan nilai kovariansi untuk proses ini  $Y_k = Covv(\alpha_t, \alpha_{t+k}) = 0$  untuk  $k \neq 0$ .

Berdasarkan definisi tersebut, dapat dikatakan bahwa suatu *white noise process*  $\{\alpha_t\}$  adalah stasioner dengan beberapa sifat berikut.

Fungsi autokovariansi

$$\gamma_k = \begin{cases} \sigma_a^2, & \text{untuk } k = 0 \\ 0, & \text{untuk } k \neq 0 \end{cases} \quad (29)$$

Fungsi autokorelasi

$$\rho_k = \begin{cases} 1, & \text{untuk } k = 0 \\ 0, & \text{untuk } k \neq 0 \end{cases} \quad (30)$$

Fungsi aurokorelasi parsial

$$\rho_k = \begin{cases} 1, & \text{untuk } k = 0 \\ 0, & \text{untuk } k \neq 0 \end{cases} \quad (31)$$

Pada proses *white noise* digunakan pengujian **Ljung-Box** untuk melihat apakah residual dalam proses *white noise* sudah memenuhi atau belum, dengan persamaan:

$$Q = n(n + 2) \sum_{k=1}^K \frac{\rho_k^2}{n - K} \quad (32)$$

dengan:

$n$  : jumlah data

$k$  : nilai lag ke- $k$

$K$  : maksimum lag

$\rho_k$  : nilai fungsi autokorelasi *lag-k*

Hipotesis :  $H_0$ : residual memenuhi *white noise*

$H_1$ : residual tidak memenuhi *white noise*

Kriteria penolakan : Tolak  $H_0$  jika  $Q > X_{(\alpha/df:K-k)}^2$  ( $K$  berarti pada *lag K* dan  $k$  adalah jumlah parameter) atau nilai *p-value*  $< \alpha$  (nilai  $\alpha = 0,05$ ).

Dengan demikian, suatu deret waktu disebut *white noise* jika rata-rata dan variansinya konstan dan saling bebas.

## 2. Uji Normalitas

Normalitas merupakan salah satu asumsi untuk mengetahui apakah data yang diperoleh berasal dari populasi yang berdistribusi normal atau tidak berdasarkan data yang diperoleh dari sampel berskala ordinal, interval

ataupun rasio, yang nantinya akan diuji menggunakan statistik parametrik (Katabba, 2021).

Salah satu uji yang digunakan adalah uji *Kolmogorov-Smirnov*. *Kolmogorov-Smirnov* merupakan uji normalitas yang umum digunakan karena dinilai lebih sederhana dan tidak menimbulkan perbedaan persepsi. Uji *Kolmogorov-Smirnov* dilakukan dengan tingkat signifikan 0,05. Pengujian ini dapat dilakukan dengan melihat profitabilitas dari *Kolmogorov-Smirnov Z statistic*. Pengambilan keputusan uji *Kolmogorov-Smirnov* sebagai berikut (Katabba, 2021).

Hipotesis :  $H_0: F(x) = F_0(x)$  Residual berdistribusi normal (untuk semua  $x$ ) / tidak berautokorelasi

$H_1: F(x) \neq F_0(x)$  Residual berdistribusi normal (untuk beberapa  $x$ ) / residual brautokorelasi

Statistik Uji :  $D_{hitung} = \sup_x |S(x) - F_0(x)|$

Kriteria penolakan : Tolak  $H_0$  jika  $D_{hitung} > D_{\alpha,n}$  atau  $p\text{-value} < \alpha$  dengan menggunakan  $\alpha = 0.05$ .

## 2.17 Exponential Smoothing

Pemulusan model (*exponential smoothing*) adalah suatu model prakiraan rata – rata bergerak yang melakukan pembobotan menurun secara eksponensial terhadap nilai observasi yang lebih tua (Makridakis, et al.,1999).

### 2.17.1 Model *Single Exponential Smoothing* (SES)

Metode *single exponential smoothing* digunakan jika data tidak memiliki komponen musiman dan tren. Misalkan dimiliki sampel data deret waktu  $x_1, x_2, \dots, x_t$  yang tidak memiliki komponen tren dan musiman, dan diinginkan nilai ramalan untuk  $k$  waktu ke depan (*lead time*) (Mulyana, 2004).

Rumus untuk *smoothing* level adalah sebagai berikut (Montgomery, et al., 2008):

$$S_t = \alpha x_t + (1 - \alpha)S_{t-1} \quad (33)$$

Keterangan:

$S_t$  : nilai *smoothing* level pada tahun ke- $t$

$\alpha$  : parameter *smoothing* level yang besarnya  $0 < \alpha < 1$

$x_t$  : nilai aktual periode ke- $t$ .

$S_{t-1}$  : nilai *smoothing* level pada tahun ke  $t - 1$

### 2.17.2 Model *Double Exponential Smoothing* (DES)

Salah satu varian dari *Double Exponential Smoothing* adalah *Double Exponential Smoothing* yang diusulkan oleh Holt. *Double Exponential Smoothing* (DES) karya Holt merupakan metode penghalusan nilai tren dengan menggunakan parameter yang berbeda dari parameter yang digunakan pada data asli, di mana parameter yang digunakan dalam metode ini adalah dua parameter penghalusan yaitu alfa ( $\alpha$ ) dan beta ( $\beta$ ) dengan nilai antara 0 dan 1 (Adriani et al., 2023), (Komang et al., 2023). DES digunakan dalam pemulusan data yang mengandung komponen tren tetapi tidak mengandung komponen musiman (Valenino et al., 2025).

Rumus untuk *smoothing* level DES adalah sebagai berikut (Mulyana, 2004):

$$(S_t) = \alpha x_t + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (34)$$

Rumus untuk *smoothing* pola tren DES adalah sebagai berikut:

$$(b_t) = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1} \quad (35)$$

Keterangan:

- $x_t$  : nilai aktual periode ke- $t$
- $S_t$  : nilai *smoothing* level periode ke- $t$
- $\alpha$  : parameter *smoothing* level yang besarnya  $0 < \alpha < 1$
- $\beta$  : parameter *smoothing* pola tren pada tahun ke- $t$  yang besarnya  
 $0 < \beta < 1$
- $S_{t-1}$  : nilai *smoothing* level pada tahun ke  $t - 1$
- $b_{t-1}$  : nilai *smoothing* pola tren pada bulan ke  $t - 1$

### 2.17.3 Model *Triple Exponential Smoothing* (TES)

Metode *Triple Exponential Smoothing* atau yang dikenal juga sebagai metode *Holt-Winters* merupakan gabungan dari metode *Holt* dan metode *Winters*, yang digunakan untuk peramalan jika data memiliki komponen tren dan musiman. *Triple Exponential Smoothing Holt-Winters* dapat digunakan untuk data yang nonstasioner (Mulyana, 2004). Metode ini merupakan *exponential smoothing* yang menggunakan tiga parameter pemulusan yaitu  $\alpha$ ,  $\beta$ , dan  $\gamma$  di mana digunakan nilai parameter  $\alpha$  sebagai parameter *smoothing* keseluruhan dari data, sedangkan  $\beta$  merupakan parameter untuk *smoothing* tren dan  $\gamma$  merupakan parameter untuk komponen musiman (Rosadi, 2013). Nilai  $\alpha$ ,  $\beta$ , dan  $\gamma$  berada diantara 0 sampai dengan 1 yang ditentukan dengan nilai akurasi prakiraan terkecil karena semakin kecil nilai akurasi prakiraan maka prakiraan akan semakin baik. Metode ini dibagi menjadi dua model, yaitu model aditif dan multiplikatif. Perhitungan dengan model aditif dilakukan jika plot data asli menunjukkan fluktuasi musim yang relatif stabil, sedangkan model multiplikatif digunakan jika plot data asli menunjukkan fluktuasi musim yang bervariasi (Tambuwun et al., 2023).

### A. Model TES *Holt-Winters* Aditif

Pada model musiman aditif, fluktuasi musiman dari data terlihat stabil, tidak tergantung kepada rata – rata dari data (Rosadi, 2013). Pola musiman aditif tidak tergantung pada level atau rata – rata sehingga bersifat konstan.

Rumus untuk *smoothing* level aditif sebagai berikut (Rosadi, 2013):

$$S_t = \alpha(x_t - I_{t-1}) + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (36)$$

Rumus untuk *smoothing* pola tren aditif sebagai berikut:

$$b_t = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1} \quad (37)$$

Rumus untuk *smoothing* pola musiman aditif sebagai berikut:

$$I_t = \gamma(x_t - S_t) + (1 - \gamma)I_{t-1} \quad (38)$$

Rumus untuk menentukan prediksi data pada periode  $n$  yang akan datang (Sugawara & Nikaido, 2014):

$$F_{t+n} = S_t + nb_t + I_{t-l+[(n-1) \bmod l]+1} \quad (39)$$

Keterangan:

$\gamma$  : parameter *smoothing* pola musiman yang besarnya  $0 < \gamma < 1$

$x_t$  : nilai aktual periode ke- $t$

$F_t$  : nilai yang ingin diprediksi

$S_t$  : nilai *smoothing* level periode ke- $t$

$n$  : periode waktu yang akan diprediksi

$b_t$  : nilai *smoothing* pola tren pada tahun ke- $t$

$I_t$  : nilai *smoothing* pola musiman

$l$  : panjang musiman ( $l = 3, l = 4, l = 6$  atau  $l = 12$ )

$\alpha$  : parameter *smoothing* level yang besarnya  $0 < \alpha < 1$

$S_{t-1}$  : nilai *smoothing* level pada tahun ke  $t - 1$

$b_{t-1}$  : nilai *smoothing* pola tren pada bulan ke  $t - 1$

$\beta$  : parameter *smoothing* pola tren pada tahun ke- $t$  yang besarnya  
 $0 < \beta < 1$

### B. Model TES *Holt-Winters* Multiplikatif

Pada model multiplikatif, amplitudo dari fluktuasi musiman terlihat berubah – ubah, tergantung kepada rata – rata dari data (Rosadi, 2013). Pola musiman multiplikatif membesar dengan mengikuti ukuran data.

Rumus untuk *smoothing* level multiplikatif adalah sebagai berikut (Rosadi, 2013):

$$S_t = \alpha \left( \frac{x_t}{I_{t-l}} \right) + (1 - \alpha)(S_{t-1} + b_{t-1}) \quad (40)$$

Rumus untuk *smoothing* pola tren multiplikatif sebagai berikut (Valenino et al., 2025):

$$b_t = \beta \left( \frac{S_t}{S_{t-1}} \right) + (1 - \beta)b_{t-1} \quad (41)$$

Rumus untuk *smoothing* pola musiman multiplikatif sebagai berikut:

$$I_t = \gamma \left( \frac{x_t}{S_t} \right) + (1 - \gamma)I_{t-1} \quad (42)$$

Rumus untuk menentukan prediksi data pada periode  $n$  yang akan datang (Sugawara & Nikaido, 2014):

$$F_{t+n} = (S_t + nb_t)I_{t-l+[(n-1) \bmod l]+1} \quad (43)$$

Keterangan:

$\gamma$  : parameter *smoothing* pola musiman yang besarnya  $0 < \gamma < 1$

- $x_t$  : nilai aktual periode ke- $t$   
 $F_t$  : nilai yang ingin diprediksi  
 $S_t$  : nilai *smoothing* level periode ke- $t$   
 $n$  : periode waktu yang akan diprediksi  
 $b_t$  : nilai *smoothing* pola tren pada tahun ke- $t$   
 $I_t$  : nilai *smoothing* pola musiman  
 $l$  : panjang musiman ( $l = 3, l = 4, l = 6$  atau  $l = 12$ )  
 $\alpha$  : parameter *smoothing* level yang besarnya  $0 < \alpha < 1$   
 $S_{t-1}$  : nilai *smoothing* level pada tahun ke  $t - 1$   
 $b_{t-1}$  : nilai *smoothing* pola tren pada bulan ke  $t - 1$   
 $\beta$  : parameter *smoothing* pola tren pada tahun ke- $t$  yang besarnya  $0 < \beta < 1$

### 2.18 Inisialisasi TES *Holt-Winters*

Pada metode TES *Holt-Winters* terdapat proses inisialisasi yaitu penentuan nilai awal dari suatu prediksi.

Rumus untuk penentuan nilai awal pada *smoothing* model aditif sebagai berikut (Rosadi, 2013):

$$S_l = \left(\frac{1}{l}\right) (x_1 + x_2 + \dots + x_l) \quad (44)$$

Rumus untuk penentuan nilai awal pada *smoothing* pola tren model aditif sebagai berikut:

$$b_l = \frac{1}{l} \left( \frac{x_{l+1} - x_1}{l} + \frac{x_{l+2} - x_2}{l} + \dots + \frac{x_{l+l} - x_l}{l} \right) \quad (45)$$

Rumus untuk penentuan nilai awal pada *smoothing* pola musiman model aditif sebagai berikut:

$$I_k = (x_k - S_l) \quad (46)$$

Rumus untuk penentuan nilai awal pada *smoothing* pola musiman model multiplikatif sebagai berikut:

$$I_k = \left( \frac{x_k}{S_l} \right) \quad (47)$$

Keterangan:

$b_l$  : nilai awal *smoothing* level pola tren

$I_k$  : nilai awal *smoothing* pola musiman ( $k = 1, 2, \dots, l$ )

$l$  : panjang musiman ( $l = 3, l = 4, l = 6$  atau  $l = 12$ )

$x_l$  : data ke -  $l$

$S_l$  : nilai awal *smoothing* level

## 2.19 Evaluasi Performa Model Peramalan

Evaluasi performa model peramalan merupakan tahap penting dalam analisis deret waktu (*time series forecasting*) untuk menilai seberapa baik model yang dikembangkan mampu menggambarkan pola data historis dan menghasilkan prediksi yang akurat terhadap jumlah penumpang pesawat. Tujuan dari tahap ini adalah untuk mengevaluasi kinerja dan efektivitas metode yang digunakan, seperti *Seasonal ARIMA* (SARIMA) dan *Triple Exponential Smoothing* (TES), sehingga dapat diketahui model mana yang memberikan hasil prediksi paling optimal.

Metode peramalan yang baik tidak memiliki tingkat kesalahan yang besar. Semakin kecil tingkat kesalahan, maka hasil ramalan akan semakin mendekati data aktual. Dalam memilih model terbaik, apabila terdapat hanya satu model yang cocok untuk peramalan, maka model tersebut merupakan model terbaik dan dapat digunakan tanpa melihat tingkat

kesalahan. Namun apabila lebih dari satu model yang cocok maka untuk memilih model terbaik dapat dilihat dari tingkat kesalahan terkecil.

Banyak cara dalam menghitung kesalahan prediksi. Pada penelitian ini menggunakan *Mean Absolute Percentage Error* (MAPE), *Mean Absolute Error* (MAE), dan *Root Mean Square Error* (RMSE), untuk menghitung tingkat kesalahan prediksi.

### 2.19.1 *Mean Absolute Percentage Error* (MAPE)

Pengertian *Mean Absolute Percentage Error* (MAPE) adalah Pengukuran statistik tentang akurasi peramalan (prediksi) pada metode peramalan (Setiawan, 2021). MAPE merupakan rata-rata diferensiasi absolut antara nilai peramalan dan aktual, yang dinyatakan sebagai persentase nilai aktual. Dengan kata lain, MAPE menghitung rata-rata kesalahan absolut antara nilai sebenarnya dan prediksi dalam suatu periode. Suatu metode dikatakan berkinerja dengan baik apabila menghasilkan nilai MAPE kurang dari 10%, atau dengan kata lain, semakin kecil MAPE maka semakin baik kinerja dari metode yang digunakan. MAPE dipilih karena didalamnya terdapat informasi tentang besaran persentase kesalahan pada suatu output hasil peramalan terhadap permintaan riil selama beberapa periode tertentu yang hasilnya akan memberikan informasi mengenai besaran persentase kesalahan termasuk terlalu tinggi ataupun terlalu rendah (Ahmad, 2020). Berikut ini adalah rumus perhitungan MAPE (Listiowarni et al., 2020):

$$MAPE = \frac{1}{n} \left( \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \right) \times 100\% \quad (48)$$

dimana:

$n$  : jumlah data

$Z_t$  : nilai pengamatan pada periode ke- $t$  /data/nilai aktual pada periode ke- $t$

$\hat{Z}_t$  : nilai peramalan waktu ke- $t$  /data hasil prediksi pada periode ke- $t$

Kriteria keakuratan dari metode perhitungan kesalahan menggunakan MAPE dapat dilihat pada Tabel 3.

**Tabel 3.** Kriteria atau Standar Tingkat Keakuratan MAPE

Nilai MAPE	Kriteria Peramalan
<10%	Kemampuan peramalan sangat baik
10-20%	Kemampuan peramalan baik
20-50%	Kemampuan peramalan cukup
>50%	Kemampuan peramalan buruk

### 2.19.2 Mean Absolute Error (MAE)

*Mean Absolute Error* (MAE) merupakan salah satu metrik yang umum digunakan untuk menilai rata-rata besar kesalahan dalam suatu prediksi. Metrik ini tidak memperhatikan arah kesalahan, sehingga tidak membedakan apakah hasil prediksi terlalu tinggi atau terlalu rendah (Anamisa et al., 2024). Perhitungan MAE dilakukan dengan mengambil rata-rata dari selisih absolut antara nilai prediksi dan nilai aktual. Nilai MAE yang lebih rendah menunjukkan akurasi perkiraan yang lebih baik, karena mencerminkan kesalahan yang lebih kecil antara hasil yang diprediksi dan hasil yang sebenarnya (Bakar et al., 2022). Berikut ini adalah rumus perhitungan MAE:

$$MAE = \frac{1}{n} \sum_{t=1}^n |Z_t - \hat{Z}_t| \quad (49)$$

dimana:

$n$  : jumlah data

$Z_t$  : nilai pengamatan pada periode ke- $t$  /data/nilai aktual pada periode ke- $t$

$\hat{Z}_t$  : nilai peramalan waktu ke- $t$  /data hasil prediksi pada periode ke- $t$

### 2.19.3 Root Mean Square Error (RMSE)

*Root Mean Square Error* adalah metode untuk menghitung perbedaan antara nilai prediksi dan nilai sebenarnya. RMSE dihitung dengan mengambil akar kuadrat dari *Mean Square Error*. Nilai metode ini antara 0 sampai  $\infty$ . Apabila model memiliki nilai RMSE yang rendah dapat diartikan lebih akurat dibandingkan model dengan nilai RMSE yang tinggi. Berikut adalah rumus perhitungan RMSE (Rohman et al., 2025), (Gu et al., 2024) :

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2} \quad (50)$$

dimana:

$n$  : jumlah data

$Z_t$  : nilai pengamatan pada periode ke- $t$  /data/nilai aktual pada periode ke- $t$

$\hat{Z}_t$  : nilai peramalan waktu ke- $t$  /data hasil prediksi pada periode ke- $t$

### III. METODOLOGI PENELITIAN

#### 3.1 Tempat dan Waktu

##### 3.1.1 Tempat Penelitian

###### A. Tempat Pengumpulan Data

Data yang digunakan pada penelitian ini diperoleh dari *website* BPS Provinsi Lampung pada tahun 2015-2024 (<https://lampung.bps.go.id/>) : Statistik Transportasi (Data Tabel Jumlah Penumpang Pesawat Menurut Bulan (jiwa)). Data tahun 2025 diperoleh dari publikasi Berita Resmi Statistik (BRS) BPS Provinsi Lampung.

###### B. Tempat Penelitian

Penelitian ini dilakukan di Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung yang terletak di Jalan Soemantri Bonjonegoro No.1 Gedung Meneng, Bandar Lampung.

##### 3.1.2 Waktu Penelitian

Penelitian ini dilaksanakan mulai bulan Oktober hingga bulan Februari 2026. Rincian waktu dapat dilihat pada Tabel 4.

**Tabel 4.** Waktu Penelitian

No	Jenis Kegiatan	BULAN PENELITIAN PELAKSANAAN					
		November	Desember	Januari	Februari	Maret	April
1	Pengumpulan Data dan Penulisan Laporan Bab 1-3						
2	Pengumpulan Data						
3	Seminar Usul						

No	Jenis Kegiatan	BULAN PENELITIAN PELAKSANAAN					
		November	Desember	Januari	Februari	Maret	April
4	Preprocessing Data						
5	Pembagian Data Training dan Data Testing						
6	Model SARIMA dan TES						
7	Pengujian						
8	Perbandingan Hasil Peramalan						
9	Penulisan Laporan Bab 4-5						
10	Seminar Hasil Penelitian						

### 3.2 Alat Pendukung

#### 3.2.1 Perangkat Keras

- A. Processor: 12th-Gen Intel(R) Core(TM) i5-1235U (12CPUs)
- B. Memori: 8192MB RAM
- C. System Type: 64-bit operating system

#### 3.2.2 Perangkat Lunak

- A. Sistem Operasi: Windows 11 Pro
- B. Google Colab
- C. Microsoft Word 365
- D. Microsoft Excel 365
- E. Draw.io

### 3.3 Data

Data yang digunakan pada penelitian ini adalah data sekunder yang diperoleh dari *website* Badan Pusat Statistik (BPS) Provinsi Lampung yang berupa data jumlah penumpang pesawat di Bandara Radin Inten II Lampung pada tahun 2015-2024. Data yang digunakan bersifat bulanan, mencakup jumlah penumpang pesawat yang datang ke dan berangkat dari Bandara Radin Inten

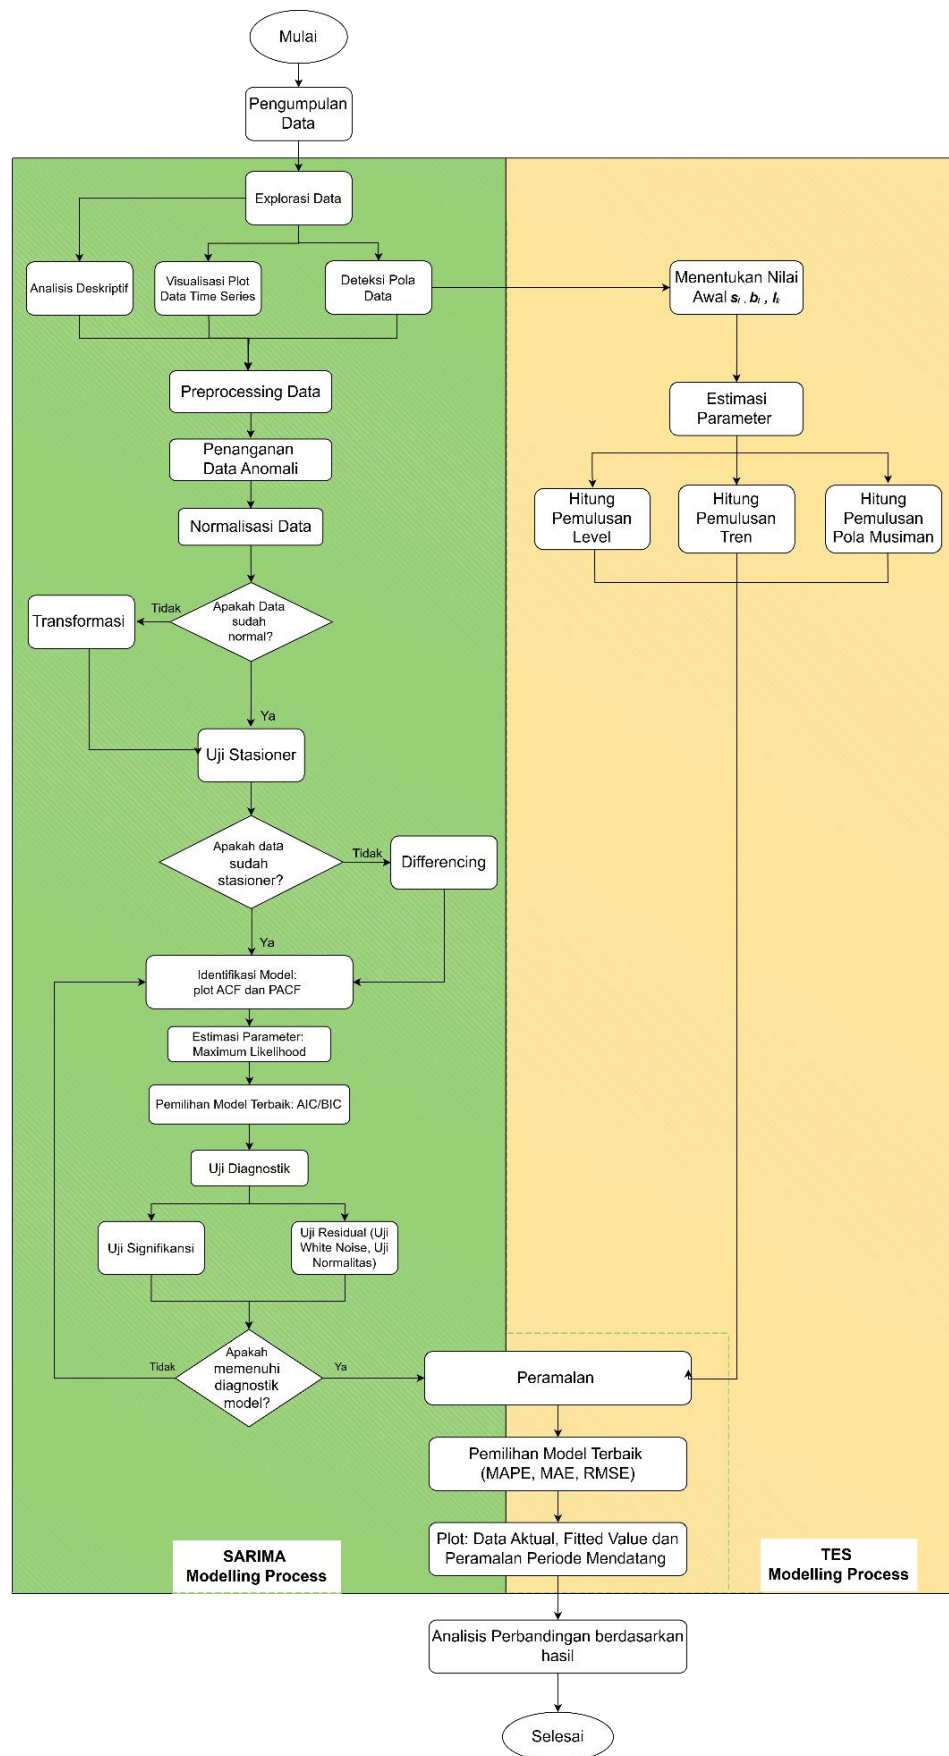
II Lampung dengan penerbangan domestik. Total data yang diperoleh sebanyak 120 record. Adapun detail data dapat dilihat pada Tabel 5.

**Tabel 5.** Dataset Penelitian

Tahun	Bulan	Bandara	Jml_Penumpang	
			Berangkat	Tiba
2015	1	Radin Inten II	47987	50567
2015	2	Radin Inten II	47589	45170
2015	3	Radin Inten II	50027	50136
2015	4	Radin Inten II	46301	45838
2015	5	Radin Inten II	51889	50970
2015	6	Radin Inten II	54817	55936
2015	7	Radin Inten II	42544	51219
2015	8	Radin Inten II	58789	51250
2015	9	Radin Inten II	54855	49620
2015	10	Radin Inten II	52518	51450
2015	11	Radin Inten II	52297	52615
2015	12	Radin Inten II	57984	57424
2016	1	Radin Inten II	67549	66279
2016	2	Radin Inten II	66136	64957
2016	3	Radin Inten II	71366	71140
2016	4	Radin Inten II	72420	72329
2016	5	Radin Inten II	79222	80500
2016	6	Radin Inten II	76631	72041
2016	7	Radin Inten II	87899	83911
2016	8	Radin Inten II	75710	70227
2016	9	Radin Inten II	73220	72529
2016	10	Radin Inten II	74813	74372
2016	11	Radin Inten II	76767	75546
2016	12	Radin Inten II	95956	93130
2017	1	Radin Inten II	88164	78950
2017	2	Radin Inten II	76767	73562
2017	3	Radin Inten II	94570	90105
2017	4	Radin Inten II	86557	820022
2017	5	Radin Inten II	105516	96994
2017	6	Radin Inten II	91007	95781
2017	7	Radin Inten II	133685	118124
2017	8	Radin Inten II	107517	103353

### 3.4 Tahapan Penelitian

Dalam penelitian ini ada beberapa tahapan yang dilakukan digambarkan pada Gambar 11.



Gambar 11. Alur kerangka tahapan penelitian.

Gambar 11 memperlihatkan alur proses pemodelan peramalan yang terdiri dari dua pendekatan, yaitu SARIMA pada area berwarna hijau dan TES pada area berwarna kuning. Kedua metode tersebut digunakan untuk memodelkan data *time series* hingga menghasilkan nilai peramalan. Proses ini kemudian diakhiri dengan evaluasi hasil peramalan dan perbandingan untuk menentukan metode yang memiliki kinerja terbaik.

Berikut adalah penjelasan dari tahapan penelitian pada Gambar 11.

### 3.4.1 Studi Literatur

Tahapan pertama pada penelitian ini adalah mencari referensi mengenai penelitian-penelitian terdahulu sesuai dengan objek ataupun metode yang digunakan sebagai referensi untuk penelitian yang akan dilakukan.

### 3.4.2 Pengumpulan Data

Data yang dikumpulkan adalah data bulanan jumlah penumpang pesawat di Lampung yang didapatkan dari situs badan pusat statistik (BPS) yang bersumber dari Bandara Radin Inten II Lampung. Proses pengumpulan data dilakukan dengan menyalin ke dalam file baru. Rentang data yang diambil tahun 2015-2024. Jumlah data terkumpul 120 dataset. Format pada data yaitu, numerik dan kategorik.

### 3.4.3 Pembagian Data (*Splitting Data*)

Untuk memastikan model dapat memprediksi data yang tidak terlihat sebelumnya, data dibagi menjadi dua bagian: data latih (*training*) dan data uji (*testing*). Pembagian ini dilakukan tanpa pengacakan (*shuffle=False*) untuk mempertahankan urutan waktu yang penting dalam model prediksi deret waktu.

1. Data Latih (*Training*) : Menggunakan 80% dari data (data hingga Desember 2024)
2. Data Uji (*Testing*) : Menggunakan 20% dari data (data tahun 2025)

Dengan pembagian data ini, model dapat dilatih pada data sebelumnya (tahun 2024) dan diuji pada data yang lebih baru (tahun 2025), yang memastikan bahwa prediksi dilakukan pada data yang belum pernah dilihat sebelumnya.

#### **3.4.4 Explorasi Data**

*Explorasi* data adalah tahapan awal terhadap data. Tahapan ini bertujuan untuk memahami karakteristik dasar data sebelum dilakukan pemodelan.

##### **A. Analisis Deskriptif**

Analisis deskriptif yaitu tahap awal dalam eksplorasi data yang bertujuan untuk memberikan gambaran umum mengenai karakteristik dasar data deret waktu. Pada tahap ini dilakukan perhitungan nilai-nilai statistik seperti rata-rata, median, maksimum, minimum, standar deviasi, dan rentang data.

Tujuannya adalah untuk mengetahui bagaimana distribusi data jumlah penumpang pesawat dari waktu ke waktu serta mengidentifikasi adanya nilai ekstrem dalam data. Dengan melakukan analisis deskriptif, peneliti dapat memahami kondisi awal dataset sebelum melakukan pemrosesan lanjutan dan pemodelan peramalan.

##### **B. Visualisasi Plot Data *Time Series***

Visualisasi plot deret waktu merupakan proses menampilkan data berdasarkan urutan waktu dalam bentuk grafik garis (*time series plot*). Grafik ini memperlihatkan hubungan antara waktu (biasanya sumbu X) dan jumlah penumpang pesawat (sumbu Y) per bulan atau per tahun dengan tujuan agar pola dan tren pada data dapat terlihat secara lebih jelas dan intuitif.

Tujuan utama visualisasi data adalah untuk mempermudah peneliti dalam mengenali arah tren, fluktuasi musiman, serta adanya anomali pada data. Melalui visualisasi, pola peningkatan, penurunan, atau

periode stabil dapat diamati dengan cepat sehingga membantu dalam menentukan pendekatan model peramalan yang sesuai.

Visualiasasi plot deret waktu juga membantu mendeteksi apakah data sudah stasioner atau masih memiliki pola yang harus dihilangkan dengan *differencing*. Melalui plot deret waktu, peneliti dapat menilai:

- Apakah tren naik atau turun secara konsisten dari tahun ke tahun,
- Apakah terdapat pola berulang (*seasonality*) seperti lonjakan penumpang saat liburan,
- Dan apakah terdapat anomali atau data ekstrem.

### C. Deteksi Pola Data

Deteksi pola data yaitu tahap untuk mengidentifikasi bentuk pola yang muncul pada data deret waktu setelah dilakukan visualisasi. Tahapan ini bertujuan untuk memastikan apakah data memiliki pola tren (*trend*), pola horizontal (*stationary*), pola musiman (*seasonal*), pola siklis (*cyclical*), atau pola acak (*irregular*).

- Pola tren menunjukkan kecenderungan data meningkat atau menurun secara konsisten.
- Pola horizontal menunjukkan bahwa nilai data cenderung stabil dan berfluktuasi di sekitar rata-rata tanpa adanya kecenderungan naik atau turun.
- Pola musiman menunjukkan pengulangan pola pada interval waktu tertentu (misalnya setiap akhir tahun).
- Pola siklis menggambarkan fluktuasi jangka panjang akibat faktor ekonomi atau kebijakan.
- Pola acak menunjukkan variasi yang tidak beraturan akibat faktor tak terduga.

Melalui deteksi pola, peneliti dapat menentukan apakah model SARIMA perlu memasukkan komponen musiman dan seberapa banyak proses *differencing* yang diperlukan agar data menjadi stasioner. Tahapan ini menjadi tahapan awal untuk model TES. Model

TES digunakan apabila data menunjukkan adanya pola tren dan pola musiman secara bersamaan. Oleh karena itu, melalui tahap ini dapat dipastikan bahwa data memang memiliki karakteristik yang sesuai untuk dimodelkan menggunakan TES, karena metode ini dirancang untuk mengakomodasi komponen level, tren, dan musiman dalam satu model peramalan.

#### D. Menentukan Nilai Awal $S_t$ , $b_t$ , dan $I_k$

Tahapan ini adalah tahapan selanjutnya untuk model TES. Pada tahap ini dilakukan penentuan nilai awal komponen pemulusan yang akan digunakan sebagai dasar perhitungan pada periode selanjutnya. Dalam metode TES, terdapat tiga komponen utama yang harus diinisialisasi, yaitu:

- **Level ( $S_t$ )**  
Merupakan nilai dasar data pada periode awal yang menggambarkan rata-rata kondisi aktual data.
- **Trend ( $b_t$ )**  
Menunjukkan arah perubahan data dari waktu ke waktu, apakah mengalami kecenderungan meningkat atau menurun.
- **Indeks Musiman ( $I_k$ )**  
Menggambarkan pengaruh pola musiman yang berulang pada periode tertentu, misalnya pola bulanan dalam satu tahun.

Penentuan nilai awal ini sangat penting karena akan mempengaruhi hasil pemulusan dan akurasi peramalan pada periode berikutnya. Nilai awal level biasanya diperoleh dari rata-rata data pada satu siklus musim pertama, nilai awal tren dihitung berdasarkan perubahan rata-rata antarperiode awal, sedangkan indeks musiman diperoleh dari perbandingan nilai data terhadap rata-rata musimannya.

Nilai awal yang tepat akan membantu model TES dalam menangkap komponen level, tren, dan musiman secara optimal sehingga proses peramalan dapat menghasilkan prediksi yang lebih akurat.

### E. Estimasi Parameter $\alpha$ , $\beta$ dan $\gamma$

Tahapan estimasi parameter merupakan proses untuk memperoleh nilai konstanta pemulusan terbaik pada model TES. Parameter yang diestimasi meliputi parameter level ( $\alpha$ ), parameter tren ( $\beta$ ), dan parameter musiman ( $\gamma$ ), yang masing-masing memiliki nilai antara 0 dan 1.

Proses estimasi parameter dilakukan untuk memperoleh kombinasi nilai parameter yang mampu menghasilkan kinerja peramalan terbaik berdasarkan karakteristik data. Pada penelitian ini, estimasi parameter dilakukan menggunakan bahasa pemrograman *Python* melalui mekanisme optimasi otomatis sehingga nilai parameter diperoleh secara objektif tanpa penentuan manual.

Penentuan parameter optimal didasarkan pada hasil evaluasi akurasi menggunakan MAPE, MAE dan RMSE. Kombinasi parameter yang menghasilkan nilai MAPE, MAE, dan RMSE paling kecil dipilih sebagai parameter terbaik dan selanjutnya digunakan dalam proses pemulusan dan peramalan dengan model TES.

### F. Perhitungan Pemulusan Level

Tahapan perhitungan pemulusan level merupakan proses untuk memperbarui nilai dasar data pada setiap periode menggunakan model TES. Komponen level menggambarkan kondisi rata-rata data pada waktu tertentu setelah mempertimbangkan pengaruh tren dan musiman.

Perhitungan pemulusan level dilakukan secara berulang pada setiap periode pengamatan dengan memanfaatkan data aktual, nilai tren sebelumnya, serta indeks musiman yang telah diperoleh. Proses ini bertujuan untuk menghasilkan nilai level yang telah dipuluskan

sehingga mampu merepresentasikan kondisi data yang lebih stabil dibandingkan data asli.

Hasil perhitungan pemulusan level ini selanjutnya digunakan pada tahap perhitungan pemulusan tren dan komponen musiman dalam model TES.

### **G. Perhitungan Pemulusan Tren**

Tahapan pemulusan tren bertujuan untuk memperbarui nilai kecenderungan arah data pada setiap periode dalam model TES. Komponen tren menunjukkan apakah data mengalami peningkatan atau penurunan dari waktu ke waktu setelah mempertimbangkan pengaruh level yang telah diperbarui.

Perhitungan pemulusan tren dilakukan dengan memanfaatkan selisih antara nilai level saat ini dan level periode sebelumnya, kemudian dikombinasikan dengan nilai tren sebelumnya. Proses ini dilakukan secara berulang pada setiap periode sehingga nilai tren dapat menyesuaikan perubahan pola data secara dinamis.

Nilai tren yang diperoleh pada tahap ini akan digunakan bersama dengan komponen level dan musiman dalam proses perhitungan peramalan pada periode berikutnya.

### **H. Perhitungan Pemulusan Pola Musiman**

Tahapan pemulusan pola musiman bertujuan untuk memperbarui nilai indeks musiman pada setiap periode dalam model TES. Komponen musiman digunakan untuk menangkap pola berulang yang terjadi dalam interval waktu tertentu, misalnya pola bulanan dalam satu tahun.

Pemulusan musiman dilakukan dengan membandingkan data aktual terhadap komponen level yang telah diperbarui, kemudian dikombinasikan dengan indeks musiman sebelumnya. Proses ini dilakukan secara berulang pada setiap periode sehingga nilai indeks

musiman dapat menyesuaikan perubahan pola musiman yang terjadi dari waktu ke waktu.

Nilai indeks musiman yang telah diperbarui ini selanjutnya digunakan bersama komponen level dan tren dalam proses perhitungan peramalan untuk periode mendatang.

### **3.4.5 Pre-processing Data**

*Pre-processing* Data dilakukan guna meningkatkan kinerja dari data yang akan digunakan. Tahapan ini meliputi proses berikut:

#### **A. Penanganan Data Anomali**

Tahap ini dilakukan untuk menangani nilai data yang menunjukkan lonjakan ekstrem dan diduga sebagai kesalahan pencatatan berdasarkan hasil visualisasi deret waktu. Nilai anomali tersebut berpotensi mempengaruhi proses pemodelan dan menghasilkan estimasi parameter yang tidak akurat.

Penanganan data anomali dilakukan menggunakan metode interpolasi linear. Metode ini memperkirakan nilai pengganti dengan membentuk garis lurus antara dua titik data yang berdekatan, yaitu periode sebelum dan sesudah nilai anomali. Pendekatan ini dipilih karena mampu mempertahankan kecenderungan pola data secara proporsional tanpa menimbulkan perubahan pola yang drastis.

Penggunaan interpolasi linear bertujuan untuk menjaga kontinuitas deret waktu serta memastikan bahwa data yang digunakan dalam pemodelan tetap mengikuti pola tren dan musiman yang terbentuk.

#### **B. Normalisasi Data**

Pada tahap ini dilakukan uji normalitas yang bersifat opsional. Data yang tidak stasioner dalam variansi dapat menyebabkan ketidaknormalan. Oleh karena itu, uji normalitas dalam tahap

normalisasi data ini digunakan sebagai indikasi variansi stasioner. Jika data tidak normal, maka dilakukan *transformasi*.

### C. Uji Stasioner

Uji ini dilakukan khusus untuk SARIMA untuk memastikan mean dan varians data tidak berubah terhadap waktu. Visualisasi data di tahap awal digunakan untuk melihat apakah data cenderung meningkat/menurun (ada tren) atau tidak.

Jika pola bergerak naik/turun tajam, kemungkinan belum stasioner dalam *mean* dan jika data belum stasioner dalam *mean* maka dilakukan *differencing*. Jika fluktuasi semakin besar/kecil, kemungkinan belum stasioner dalam variansi. Dan jika data belum stasioner dalam variansinya maka dilakukan transformasi *Box-Cox*.

Setelah itu, dilakukan uji *Augmented Dickey-Fuller* (ADF) untuk menguji stasioneritas secara statistik. Jika *p-value*  $< 0.05$ , maka data stasioner. Jika hasil uji menunjukkan bahwa data stasioner, maka analisis dapat dilanjutkan ke tahap identifikasi model. Namun, jika data belum stasioner, maka dilakukan *differencing* tambahan hingga data menjadi stasioner.

### D. Identifikasi Model $(p, d, q)(P, D, Q)^s$

Tahap ini bertujuan untuk menentukan orde dari model SARIMA, yaitu nilai  $p, d, q, P, D, Q$ , dan  $s$  yang paling sesuai dengan karakteristik data.

Proses identifikasi dilakukan melalui analisis plot *Autocorrelation Function* (ACF) dan *Partial Autocorrelation Function* (PACF). Grafik ACF dan PACF untuk menentukan:

- $p$ : orde *autoregressive* (AR)
- $d$ : tingkat differencing non-musiman
- $q$ : orde *moving average* (MA)
- $P, D, Q$ : komponen musiman (seasonal)
- $s$ : periode musiman (misal 12 untuk data bulanan)

Plot ACF digunakan untuk melihat pola keterkaitan (autokorelasi) antar data pada lag tertentu. Jika ACF menurun secara lambat, hal ini menunjukkan adanya tren dan data belum stasioner. Jika ACF terputus pada lag ke- $q$ , maka kemungkinan besar model memiliki komponen MA( $q$ ).

Plot PACF digunakan untuk melihat keterkaitan parsial antar data setelah pengaruh lag sebelumnya dihilangkan. Jika PACF terputus pada lag ke- $p$ , maka kemungkinan besar model memiliki komponen AR( $p$ ).

Selain itu, karena model SARIMA mempertimbangkan komponen musiman (*seasonal*), maka pola ACF dan PACF juga dianalisis pada lag kelipatan periode musiman ( $s$ ) untuk menentukan nilai  $P$ ,  $D$ , dan  $Q$ .

Hasil analisis ini digunakan untuk memilih beberapa kandidat model SARIMA yang kemudian akan dievaluasi lebih lanjut pada tahap estimasi parameter dan uji diagnostik.

#### **E. Estimasi Parameter**

Setelah kandidat model ditentukan (misalnya SARIMA( $p,d,q$ )( $P,D,Q$ ) $s$ ), langkah berikutnya adalah melakukan estimasi parameter menggunakan metode *Maximum Likelihood Estimation* (MLE). Hasil estimasi akan menunjukkan seberapa besar pengaruh setiap komponen AR, MA, dan musiman terhadap data.

Parameter yang signifikan secara statistik ( $p\text{-value} < 0,05$ ) menunjukkan bahwa komponen tersebut penting untuk dipertahankan dalam model.

#### **F. Pemilihan Model Terbaik menggunakan AIC/BIC**

Tahapan ini dilakukan setelah proses identifikasi model dan estimasi parameter untuk menentukan kombinasi parameter terbaik dari beberapa kandidat model SARIMA. Setiap model diuji dengan

menghitung nilai AIC dan BIC sebagai dasar pemilihan model yang paling optimal. Kedua kriteria ini digunakan untuk menilai keseimbangan antara tingkat kecocokan model (*goodness of fit*) dan kompleksitas model.

Semakin kecil nilai AIC dan BIC, maka semakin baik model tersebut karena menunjukkan keseimbangan yang optimal antara ketepatan model dan kesederhanaannya. Model dengan nilai AIC dan BIC terendah kemudian dipilih sebagai model terbaik, yang selanjutnya akan diuji melalui tahap uji diagnostik untuk memastikan kelayakannya sebelum digunakan dalam peramalan.

#### **G. Uji Diagnostik Model**

Tahapan ini dilakukan untuk memastikan bahwa residual (selisih antara nilai aktual dan hasil model) bersifat acak (*white noise*) dan tidak lagi memiliki pola tertentu. Tahapan ini diuji untuk syarat kesesuaian model SARIMA. Syarat tersebut adalah data memiliki residual yang *white noise* dan berdistribusi normal.

*White noise residual* dilakukan menggunakan uji **Ljung-Box** yang digunakan untuk menguji apakah residual independen secara statistik. Jika nilai *p-value*  $> 0,05$ , maka residual dianggap acak dan model sudah memadai. Selanjutnya, dilakukan pemeriksaan distribusi residual untuk melihat apakah residual berdistribusi normal. Apabila model belum memenuhi asumsi residual acak atau normal, maka dilakukan penyesuaian model, seperti mengubah orde  $p$ ,  $d$ ,  $q$ , atau komponen musiman, hingga diperoleh model yang paling sesuai.

#### **H. Peramalan (*Forecasting*)**

Tahapan ini dilakukan setelah model TES melalui proses estimasi parameter dan perhitungan komponen level, tren, dan musiman secara iteratif, serta model SARIMA melewati proses uji diagnostik dan

dinyatakan memenuhi asumsi residual yang bersifat acak. Pada tahap ini, kedua model digunakan untuk menghasilkan nilai peramalan (*forecast*) berdasarkan data pelatihan yang tersedia. Model SARIMA menghasilkan nilai *fitted* (nilai estimasi pada data pelatihan) serta nilai *forecast* untuk data pengujian tahun 2025. Sementara itu, model *Triple Exponential Smoothing* (TES) menghasilkan nilai *fitted* dan *forecast* berdasarkan parameter pemulusan terbaik serta hasil pembaruan komponen level, tren, dan musiman. *Fitted value* adalah nilai hasil model pada data historis untuk melihat seberapa baik model mengikuti pola masa lalu. Hasil peramalan ini akan memberikan gambaran awal mengenai respons model terhadap pola musiman dan kecenderungan jangka panjang pada data jumlah penumpang pesawat di Bandara Radin Inten II.

#### **I. Pemilihan Model Terbaik Berdasarkan Metrik Evaluasi Kesalahan**

Tahap evaluasi dilakukan setelah nilai peramalan dihasilkan oleh kedua model. Evaluasi dilakukan dengan cara membandingkan nilai prediksi dari masing-masing model dengan nilai aktual tahun 2025 dan bertujuan untuk mengetahui seberapa baik model dalam menghasilkan nilai peramalan yang mendekati data aktual.

Dalam penelitian peramalan jumlah penumpang pesawat, evaluasi dilakukan dengan membandingkan hasil peramalan terhadap data aktual menggunakan sejumlah ukuran kesalahan (*error metrics*), dalam penelitian ini menggunakan *Mean Absolute Percentage Error* (MAPE), *Mean Absolute Error* (MAE), dan *Root Mean Square Error* (RMSE).

Masing-masing metrik dihitung dengan membandingkan hasil peramalan terhadap nilai aktual tahun 2025. Model terbaik dipilih berdasarkan hasil perbandingan nilai metrik evaluasi tersebut. Model dengan nilai MAPE, MAE, dan RMSE paling kecil dianggap sebagai

model dengan kinerja paling optimal dalam melakukan peramalan jumlah penumpang pesawat periode mendatang tahun 2026 – 2028.

#### **J. Plotting Data Aktual, *Fitted Value* dan Peramalan/Prediksi**

Tahapan ini dilakukan setelah proses pemilihan model terbaik berdasarkan metrik evaluasi kesalahan. Plotting dilakukan untuk memberikan visualisasi mengenai kinerja kedua model. Pada tahap ini, seluruh hasil pemodelan divisualisasikan dalam bentuk grafik untuk memudahkan interpretasi pola dan kinerja model. Grafik yang ditampilkan meliputi data aktual, *fitted value*, serta hasil peramalan (*forecasting*) dari periode testing dan periode peramalan masa depan tahun 2026 – 2028.

Plot data aktual digunakan sebagai acuan untuk melihat pola historis jumlah penumpang pesawat di Bandara Radin Inten II. *Fitted value* digunakan untuk menunjukkan seberapa baik model mengikuti pola historis pada data pelatihan. Sementara itu, nilai peramalan menggambarkan estimasi jumlah penumpang pesawat pada periode yang belum diamati, termasuk data testing tahun 2025 dan hasil perkiraan tahun 2026 – 2028. Plot ini membantu melihat bagaimana model memperkirakan nilai di luar data historis serta seberapa dekat prediksi tahun 2025 dengan data aktual pada periode yang sama. Dan apakah model mampu menangkap pola musiman, tren jangka panjang, serta tingkat fluktuasi yang ada pada data penumpang pesawat di Bandara Radin Inten II.

Melalui grafik ini, dapat terlihat dengan jelas apakah model SARIMA maupun TES mampu mengikuti pola data aktual, apakah terjadi penyimpangan signifikan, serta mana di antara kedua model yang kurvanya paling mendekati data aktual. Visualisasi ini juga mendukung analisis perbandingan hasil dan menjadi dasar dalam menarik kesimpulan mengenai model yang paling efektif untuk peramalan jumlah penumpang pesawat di masa mendatang.

## K. Analisis Perbandingan

Tahapan ini merupakan langkah penting untuk menilai secara objektif kinerja model SARIMA dan TES dalam menghasilkan peramalan jumlah penumpang pesawat. Analisis dilakukan dengan mengacu pada grafik hasil plotting, nilai metrik evaluasi kesalahan, serta pola prediksi pada periode testing dan hasil peramalan tahun 2026 – 2028.

Pada tahap ini, perbandingan dilakukan dari dua sisi, yaitu hasil evaluasi numerik dan hasil evaluasi visual. Secara numerik, nilai metrik evaluasi kesalahan seperti MAPE, MAE dan RMSE digunakan untuk mengetahui model mana yang memiliki tingkat kesalahan paling kecil dan akurasi tertinggi. Secara visual, dibandingkan apakah *fitted value* dari masing-masing model mengikuti pola data aktual dengan baik, serta mana yang memberikan prediksi paling mendekati data aktual tahun 2025 pada periode testing.

Analisis kemudian dilanjutkan pada hasil peramalan tahun 2026 – 2028 untuk mengetahui stabilitas model pada data masa depan. Perbandingan ini memberikan gambaran apakah model tetap dapat mempertahankan akurasi saat digunakan untuk periode prediksi yang lebih jauh, tidak hanya pada data pengujian.

Hasil analisis perbandingan ini kemudian digunakan untuk menentukan model mana yang paling layak diterapkan untuk peramalan jumlah penumpang pesawat di Bandara Radin Inten II Lampung, pada periode mendatang.

## V. KESIMPULAN DAN SARAN

### 5.1 Kesimpulan

1. Model SARIMA dan *Triple Exponential Smoothing* (TES) sama-sama dapat digunakan untuk melakukan peramalan jumlah penumpang pesawat di Bandara Radin Inten II Lampung. Namun, model TES multiplikatif menunjukkan performa yang lebih baik dibandingkan SARIMA, yang ditunjukkan oleh nilai MAPE, MAE, dan RMSE yang lebih rendah pada variabel keberangkatan maupun kedatangan. Dengan MAPE sebesar 6,45% pada variabel keberangkatan dan 3,51% pada variabel kedatangan, yang termasuk dalam kategori akurasi tinggi. Hal ini menunjukkan bahwa pemilihan metode yang sesuai dengan karakteristik pola data sangat berpengaruh terhadap tingkat akurasi peramalan, sehingga model TES multiplikatif dipilih sebagai model terbaik dalam penelitian ini.
2. Hasil peramalan menunjukkan bahwa jumlah penumpang pesawat domestik di Bandara Radin Inten II Lampung pada tahun 2026 diperkirakan mengalami fluktuasi antar bulan dengan pola yang relatif stabil, dan masih sejalan dengan kondisi akhir tahun sebelumnya, di mana jumlah penumpang kedatangan dan keberangkatan menunjukkan pola yang relatif seimbang, meskipun terdapat perbedaan pada periode tertentu. Dalam jangka menengah (2026–2028), hasil skenario menunjukkan bahwa jumlah penumpang baik keberangkatan maupun kedatangan memiliki kecenderungan stabil hingga meningkat, tergantung pada kondisi yang diasumsikan. Skenario pesimis menunjukkan kondisi stagnan, sedangkan skenario moderat dan optimis memperlihatkan adanya peningkatan jumlah penumpang dengan laju yang berbeda. Hal ini mengindikasikan bahwa jumlah penumpang berpotensi terus bertumbuh pada kondisi normal hingga optimis, serta memberikan gambaran rentang kemungkinan yang dapat digunakan dalam perencanaan operasional bandara.

## 5.2 Saran

1. Pihak pengelola Bandara Radin Inten II Lampung dapat menggunakan hasil peramalan dalam penelitian ini sebagai bahan pertimbangan dalam perencanaan operasional, seperti pengaturan jadwal penerbangan, penyediaan fasilitas, serta pengelolaan sumber daya manusia agar sesuai dengan pola fluktuasi dan kecenderungan perubahan jumlah penumpang yang diperkirakan terjadi pada periode mendatang. Serta mempertimbangkan strategi peningkatan konektivitas penerbangan dan efisiensi operasional guna mengantisipasi perubahan jumlah penumpang pada periode mendatang.
2. Untuk meningkatkan akurasi peramalan di masa mendatang, penelitian selanjutnya dapat mempertimbangkan penggunaan data dengan periode yang lebih panjang atau penambahan variabel eksternal, seperti faktor ekonomi, kebijakan transportasi, maupun kondisi luar biasa seperti pandemi.

## DAFTAR PUSTAKA

- Admin. (2022). Forecasting : Pengertian, Fungsi, Metode dan Perbedaanya dengan Planning. *Universitas Medan Area*.
- Adriani, D., Dewi, R., Saleh, L., Heryadi, D. Y., Sarie, F., Sudipa, I. G. I., & Rahim, R. (2023). Using Distance Measure to Perform Optimal Mapping with the K-Medoids Method on Medicinal Plants, Aromatics, and Spices Export. *Journal of Wireless Mobile Networks, Ubiquitous Computing, and Dependable Applications*, 14(3), 103–111. <https://doi.org/10.58346/JOWUA.2023.I3.008>
- Ahmad, F. (2020). *PENENTUAN METODE PERAMALAN PADA PRODUKSI PART NEW GRANADA BOWL ST Di PT . X*. 7(1), 31–39.
- Ahmad Fadli Ramadhan, & Rizal Adi Saputra. (2023). Prediksi Jumlah Penumpang Bandar Udara Halu Oleo Kendari Menggunakan Multi-layer Perceptron. *JOINTER : Journal of Informatics Engineering*, 4(02), 33–38. <https://doi.org/10.53682/jointer.v4i02.229>
- Al’afi, A. M., Widiart, W., Kurniasari, D., & Usman, M. (2020). Peramalan Data Time Series Seasonal Menggunakan Metode Analisis Spektral. *Jurnal Siger Matematika*, 1(1), 10–15. <https://doi.org/10.23960/jsm.v1i1.2484>
- Anshuman Sing, M. G. (2025). *Machine Learning Roadmap for 2025*. 2025. <https://www.scaler.com/blog/machine-learning-roadmap/>
- Arumsari, M., & Dani, A. (2021). Peramalan Data Runtun Waktu menggunakan Model Hybrid Time Series Regression – Autoregressive Integrated Moving Average. *Jurnal Siger Matematika*, 2(1), 1–12. <https://doi.org/10.23960/jsm.v2i1.2736>
- Aziza, V. N., Hilali, F., & Maghfiroh, F. A. (2023). *PERFORMANCE COMPARISON OF SARIMA INTERVENTION AND PROPHET MODELS FOR FORECASTING THE NUMBER OF AIRLINE PASSENGER AT SOEKARNO-HATTA INTERNATIONAL AIRPORT*. 17(4), 2107–2120.

- Bakar, N. N. A., Bazmohammadi, N., Çimen, H., & Uyanik, T. (2022). Data-driven ship berthing forecasting for cold ironing in maritime transportation. *Applied Energy*, 326(September), 119947. <https://doi.org/10.1016/j.apenergy.2022.119947>
- Behboudi, N., Moosavi, S., & Ramnath, R. (2024). *Recent Advances in Traffic Accident Analysis and Prediction: A Comprehensive Review of Machine Learning Techniques*. <http://arxiv.org/abs/2406.13968>
- Blu, T., Thévenaz, P., Unser, M., & Interpolation, A. P. (2004). *Linear Interpolation Revitalized*. 13(5), 710–719.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- Castán-Lascorz, M. A., Jiménez-Herrera, P., Troncoso, A., & Asencio-Cortés, G. (2022). A new hybrid method for predicting univariate and multivariate time series based on pattern forecasting. *Information Sciences*, 586, 611–627. <https://doi.org/10.1016/j.ins.2021.12.001>
- Chen, P., Niu, A., Liu, D., Jiang, W., & Ma, B. (2018). Time Series Forecasting of Temperatures using SARIMA: An Example from Nanjing. *IOP Conference Series: Materials Science and Engineering*, 394(5). <https://doi.org/10.1088/1757-899X/394/5/052024>
- Cho, I., Rajendran, P. K., Kim, T., & Har, D. (2023). Reinforcement Learning for Predicting Traffic Accidents. *5th International Conference on Artificial Intelligence in Information and Communication, ICAIIC 2023*, 684–688. <https://doi.org/10.1109/ICAIIIC57133.2023.10067034>
- Das, P., & Barman, S. (2025). *Perspective Chapter: An Overview of Time Series Decomposition and Its Applications*. 1–15. <https://doi.org/10.5772/intechopen.1009268>
- Detiksumbagsel. (2025). *Bandara Radin Inten II Lampung Kembali Berstatus Internasional*. <https://www.detik.com/sumbagsel/berita/d-8057349/bandara-radin-inten-ii-lampung-kembali-berstatus-internasional>
- Dewi, S. P., Nurwati, N., & Rahayu, E. (2022). Penerapan Data Mining Untuk Prediksi Penjualan Produk Terlaris Menggunakan Metode K-Nearest Neighbor. *Building of Informatics, Technology and Science (BITS)*, 3(4),

- 639–648. <https://doi.org/10.47065/bits.v3i4.1408>
- Durrah, F. I., Parhusip, T. P., & Rusyana, A. (2019). *Peramalan Jumlah Penumpang Pesawat Di Bandara Sultan Iskandar Muda Dengan Metode SARIMA ( Seasonal Autoregressive Integrated Moving Average )*. September 2018. <https://doi.org/10.24815/jda.v1i1.11847>
- Fahik, D. S., & Jatipaningrum, M. T. (2021). *BANDAR UDARA INTERNASIONAL SOEKARNO HATTA DENGAN METODE HOLT-WINTERS EXPONENTIAL SMOOTHING DAN SEASONAL ARIMA*. 6(1), 77–87.
- Faizah, C. N., Izzah, D. N., Afyiah, S. J., & Silfiani, M. (2023). *Peramalan Jumlah Penumpang Pesawat Domestik di Bandara Udara Sultan Aji Muhammad Sulaiman Sepinggian Balikpapan dengan Ensembel Holt-Winters Exponential Smoothing*. 59–67.
- Fariza, A. (2017). Analisis Deret Waktu (Time Series Analysis). *Politeknik Elektronika Negeri Surabaya*, 2.
- Febriana, F., Salim, Y., & Darwis, H. (2022). *Buletin Sistem Informasi dan Teknologi Islam Implementasi Analisis Volume Capacity Ratio untuk Memprediksi Kepadatan Lalu Lintas di Kota Makassar INFORMASI ARTIKEL ABSTRAK*. 3(3), 219–224.
- Ferdiansyah, R. (2018). *ANALISIS MODEL PERENCANAAN DAN PENGENDALIAN PERSEDIAAN BABY PRODUCT STUDI KASUS DI PT. MULTI INDOCITRA*, *Tbk*. 10(1), 26–40.
- Garini, F. C., & Anbiya, W. (2022). Application of GARCH Forecasting Method in Predicting The Number of Rail Passengers (Thousands of People) in Jabodetabek Region. *Jurnal Matematika, Statistika Dan Komputasi*, 18(2), 198–223. <https://doi.org/10.20956/j.v18i2.18382>
- Gautama, R. P., Fadlurohman, A., Arum, P. R., & Dhani, R. (2024). *Prediksi Jumlah Penumpang Di Bandara Nasional Ahmad Yani Semarang Menggunakan Holt Winter ' s Exponential Smoothing ( HWES )*.
- Gu, W., Guo, B., Zhang, Z., & Lu, H. (2024). Civil Aviation Passenger Traffic Forecasting: Application and Comparative Study of the Seasonal Autoregressive Integrated Moving Average Model and Backpropagation

- Neural Network. *Sustainability (Switzerland)* , 16(10).  
<https://doi.org/10.3390/su16104110>
- Hartawan, M. S., Erkamim, M., Rachmawati, S., Santi, N. C., Legito, L., & Sepriano, S. (2023). Penerapan Algoritma Supervised Learning untuk Klasifikasi Program Keluarga Harapan. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 3(2), 83–91.  
<https://doi.org/10.57152/malcom.v3i2.873>
- Jamil, B., Huwaisalt, A., Rakhman, D. A., & Febriani, D. (2025). *Prediksi Jumlah Penumpang Pesawat Domestik di Bandara Soekarno-Hatta dengan Metode SARIMA untuk Mendukung Pengelolaan Kebijakan Transportasi Publik*. 1(1), 132–144.
- Kartika, D. D., Candra, D., Novitasari, R., & Setiawan, F. (2020). *SELAT BALI MENGGUNAKAN METODE EXPONENTIAL SMOOTHING HOLT-WINTERS*. 02(01), 12–17.
- Katabba, Y. I. (2021). *Metode Seasonal Autoregressive Integrated Moving Average ( SARIMA ) untuk Memprediksi Jumlah Penumpang Kereta Api di Pulau Sumatera*.
- Komang, I., Ganda Wiguna, A., Luh, N., Ayu, P., Utami, C., Gede, W., Parwita, S., Putu, I., Eka, A., Udayana, D., Gede, I., Sudipa, I., & Dan, F. T. (2023). Rainfall Forecasting Using the Holt-Winters Exponential Smoothing Method. *Jurnal Info Sains : Informatikan Dan Sains*, 13(01), 2023.  
<http://ejournal.seaninstitute.or.id/index.php/InfoSains>
- Kurniasari, D., Salsabila, A. D., Usman, M., & Warsono, W. (2025). Enhancing Weather Forecasting in Bandar Lampung: A Hybrid SARIMA-LSTM Approach. *JTAM (Jurnal Teori Dan Aplikasi Matematika)*, 9(1), 206.  
<https://doi.org/10.31764/jtam.v9i1.27188>
- Listiowarni, I., Dewi, N. P., & Hapantenda, A. K. W. (2020). *Jurnal Politeknik Caltex Riau PERBANDINGAN METODE DOUBLE EXPONENTIAL SMOOTHING DAN DOUBLE MOVING AVERAGE UNTUK PERAMALAN HARGA*. 6(2), 158–169.
- Mahara, D. O. (2021). Analisis Faktor-Faktor yang Mempengaruhi Jumlah Penduduk Miskin dengan Geographically Weighted Regression (GWR)

- Adaptive Kernel Bisquare dan Adaptive Kernel Tricube(Studi Kasus: Jumlah Penduduk Miskin Privinsi Jawa Tengah 2020). *Jurnal Universitas Islam Indonesia*, 7(1), 33–40.
- Marisa. (2025). *Jurnal Matematika , Komputasi dan Statistika ISSN : 2503 – 2984 ANALISIS METODE SEASONAL AUTOREGRESSIVE INTEGRATED MOVING AVERAGE ( SARIMA ) DAN PENERAPANNYA UNTUK MERAMALKAN PENJUALAN* Diterbitkan oleh Jurusan Matematika FMIPA UHO *Jurnal Matematika , Komp. 5*(April), 848–856.
- Makridakis, S., Andriyanto, U. S., Wheelwright, S. C., Basith, A., & MsGee, V. E. (1993). *Metode dan aplikasi peramalan*. Erlangga.
- Makridakis, S., Steven C Wheelwright., Victor E Mc.Gee. 1999. *Metode dan Aplikasi Peramalan*. Edisi Kedua. Jilid 1. Binarupa Aksara : Jakarta
- Makridakis, S., Wheelwright, S. C., & McGee, V. E. (1999). *Metode dan Aplikasi Peramalan*. Jakarta: Erlangga.
- Maysofa, L., Syaliman, K. U., & Sapriadi. (2023). Implementasi Sistem Informasi Implementasi Forecasting Pada Penjualan Inaura Hair Care Dengan Metode Single Exponential Smoothing Forecasting. *Jurnal Testing Dan Implementasi Sistem Informasi*, 1(2), 82–91.
- Meliyana, S. M., Hafid, H., Mar'ah, Z., & Muthahharah, I. (2025). A Seasonal ARIMA (SARIMA) Model for Forecasting Domestic Passenger Traffic at Sultan Hasanuddin Airport. *Quantitative Economics and Management Studies*, 6(1), 144–153. <https://doi.org/10.35877/454ri.qems3935>
- Montgomery, Douglas & Jennings, Cheryl & Kulahci, Murat. (2008). *Introduction to Time Series Analysis and Forecasting*.
- Moritz, S., & Bartz-beielstein, T. (2017). *imputeTS : Time Series Missing Value Imputation in R*. 9(June), 207–218.
- Mulyana. (2004). *Buku Ajar Analisis Deret Waktu*. FMIPA Universitas Padjadjaran Jurusan Statistika.
- Nu, M., Rizki, E. N., Karim, A. A., & Sari, R. K. (2024). *Peramalan Jumlah Penumpang Domestik Pada Bandar Udara Sultan Syarif Kasim II Dengan Menggunakan Metode Winter ' s Exponential Smoothing*. 3(1), 57–66.
- Prasetyo, T., Putri, R. A., Ramadhani, D., Angraini, Y., & Notodiputro, K. A.

- (2024). *COMPARISON OF THE PERFORMANCE OF THE ARIMA , MULTI-LAYER PERCEPTRON , AND RANDOM FOREST METHODS IN FORECASTING PRECIOUS METAL FUTURES PRICES THAT CONTAIN OUTLIERS*. 11(2). <https://doi.org/10.25126/jtiik.20241127392>
- Prasojo, D. Y., & Muludi, K. (2025). *Passenger Density Prediction at the Airport Using LSTM and SARIMA : A Case Study at Radin Inten Airport , Lampung*. 9(4).
- Pratama, R. R. (2020). Analysis of Machine Learning Models on Human Activity Recognition. *MATRIK: Journal of Management, Information Engineering and Computer Engineering*, 19(2), 302–311.
- Rahman, A., Djanggu, N. H., Wahyudi, T., Industri, J. T., Teknik, F., & Tanjungpura, U. (2025). *Implementasi Time Series Analysis Dan Pemodelan Machine Learning Arima Guna Peternakan Bong Sun Tin*. 9(2), 196–202.
- Rizki, M. I., & Taqiyuddin, T. A. (2021). Penerapan Model SARIMA untuk Memprediksi Tingkat Inflasi di Jurnal Sains <https://doi.org/10.24014/jsms.v7i2.13168>
- Rohmah, I. K. (2019). *Prediksi Laju Inflasi Menggunakan Metode ARIMA Kalman Filter di Surabaya*
- Rohman, U., Asri, J. S., Ariessanti, H. D., & Wahyu, S. (2025). *Perbandingan Algoritma Regresi Linear Sederhana dan Regresi Polinomial Dalam Prediksi Jumlah*. 12(1), 7–15.
- Rosadi, D. (2013). *Ekonometrika dan Analisis Runtun Waktu Terapan Dengan Eviews*.
- Rosidah, K., Alfian, A., & Isro'il, A. (2024). Peramalan Tingkat Pengangguran Di Kota Lamongan Menggunakan Metode Pemulusan Eksponensial Ganda Brown. *MATHunesa: Jurnal Ilmiah Matematika*, 12(3), 569–578. <https://doi.org/10.26740/mathunesa.v12n3.p569-578>
- Sceince, J. O. F. (2017). *Modelling Air Passenger Traffic Flow in Murtala Muhammad International Airport Lagos , Nigeria : A Time Series Approach*. 4(2), 263–283.
- Setiawan, I. (2021). *Rancang Bangun Aplikasi Peramalan Persediaan Stok Barang Menggunakan Metode Weighted Moving Average (Wma) Pada Toko Barang*

- Xyz. Jurnal Teknik Informatika*, 13(3), 1–9.
- Sirisha, U. M., Belavagi, M. C., & Attigeri, G. (2022). Profit Prediction Using ARIMA, SARIMA and LSTM Models Time Series Forecasting: <https://doi.org/10.1109/ACCESS.2022.3224938>
- Sugawara, E., & Nikaido, H. (2014). Forecasting: Principles & Practice. *Antimicrobial Agents and Chemotherapy*, 58(12), 7250–7257. [robjhyndman.com/uwa%5Cnhttp://robjhyndman.com/papers/forecasting-age-specific-breast-cancer-mortality-using-functional-data-models/](http://robjhyndman.com/papers/forecasting-age-specific-breast-cancer-mortality-using-functional-data-models/)
- Suranto, P. S., & Fitriani, R. R. (2024). Perbandingan Metode Single Exponential Smoothing dan Regresi Linear dalam Menentukan Forecasting Permintaan Produk. *STRING (Satuan Tulisan Riset Dan Inovasi Teknologi)*. <https://doi.org/10.30998/string.v8i3.19319>
- Syahanifadhel, M. V., Basuki, D. E., Hasna, B. A., & Azzam, A. (2023). Analisis Perencanaan Produksi Pada Produk Kemeja Pola Menggunakan Metode Forecasting Dan Master Production Schedule Untuk Penjadwalan Produksi Pada CV. Jodion Unggul Perkasa. *Jurnal Teknik Industri: Jurnal Hasil Penelitian Dan Karya Ilmiah Dalam Bidang Teknik Industri*, 9(1), 95. <https://doi.org/10.24014/jti.v9i1.21890>
- Tambuwun, P. F. A., Nainggolan, N., & Langi, Y. A. R. (2023). *d ' CartesiaN Jurnal Matematika dan Aplikasi Peramalan Banyaknya Penumpang Bandar Udara Internasional Sam Ratulangi Manado Dengan Metode Winter ' s Exponential Smoothing dan Seasonal ARIMA*.
- UU No.1 Tahun 2009 tentang Penerbangan. (2009).
- Valenino, D., Supit, F., Nainggolan, N., & Manurung, T. (2025). Penerapan Metode Holt-Winters ( Triple Exponential Smoothing ) Dengan Damped Parameter Untuk Peramalan Nilai Tukar Petani ( NTP ) Pada Subsektor Hortikultura Di Provinsi Sulawesi Utara. 14(2).
- Wahyuni, D., Lusiana, R. A., Zeleansi, Z., Deti, D., & ... (2021). Aplikasi Model Arima Dalam Memprediksi Jumlah Kasus Penyebaran Covid-19 Di Provinsi Kepulauan Bangka Belitung. *Proceedings of ...*, 112–117. <https://journal.ubb.ac.id/index.php/snppm/article/download/2717/1589>
- Wardani, N. K., Afandi, M. R., & Riani, L. P. (2020). Analisis Forecasting

- Demand Dengan Metode Linear Exponential Smoothing (Studi Pada: Produk Batik Fendy, Klaten). *Jurnal Ekonomi Dan Pendidikan*, 16(2), 81–89.  
<https://doi.org/10.21831/jep.v16i2.33714>
- Wei, W. W. S. (2014). *Time Series Analysis : Univariate and Multivariate Methods , 2nd edition , 2006. January 2006.*
- Widianti, A., & Pratama, I. (2024). *PENANGANAN MISSING VALUES DAN PREDIKSI DATA TIMBUNAN*. 9(2), 242–251.
- Wikipedia. (2025a). *Bandar Udara Internasional Radin Inten II*.
- Wikipedia. (2025b). *Machine Learning*.  
[https://en.wikipedia.org/wiki/Machine\\_learning](https://en.wikipedia.org/wiki/Machine_learning)
- Wu, D. C. W., Ji, L., He, K., & Tso, K. F. G. (2021). Forecasting Tourist Daily Arrivals With A Hybrid Sarima–Lstm Approach. *Journal of Hospitality and Tourism Research*, 45(1), 52–67. <https://doi.org/10.1177/1096348020934046>
- Zhang, L., Dong, Y., Farah, H., Zgonnikov, A., & Arem, B. Van. (2023). *Data-driven Semi-supervised Machine Learning with Surrogate Safety Measures for Abnormal Driving Behavior Detection*. August, 1–19.  
<https://doi.org/10.1177/03611981241306752>