

BAB III

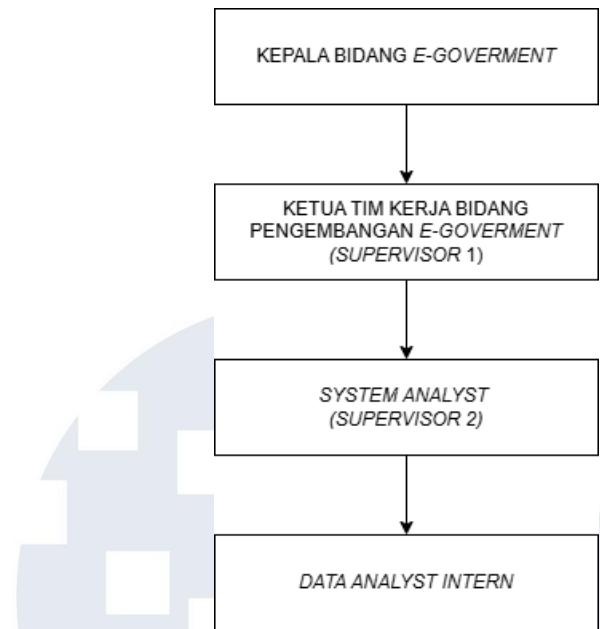
PELAKSANAAN KERJA

3.1 Kedudukan dan Koordinasi

Kedudukan dan koordinasi memegang peranan penting. Penetapan posisi magang disesuaikan dengan bidang keahlian serta kebutuhan instansi. Kejelasan kedudukan serta mekanisme koordinasi yang terstruktur menjadi dasar dalam memastikan setiap kegiatan dan proyek dapat terlaksana secara efektif dan terarah.

3.1.1 Kedudukan

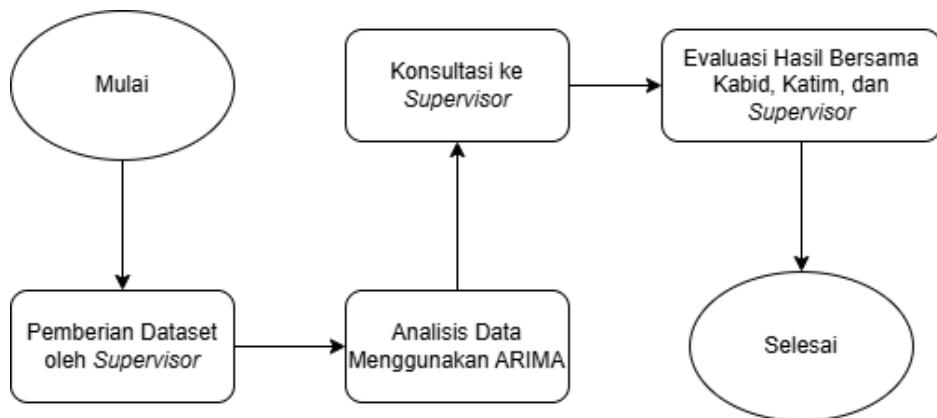
Kegiatan magang dilaksanakan pada bidang *e-Government* Dinas Komunikasi dan Informatika Kota Tangerang, khususnya pada bagian Layanan Publik. Posisi yang diberikan adalah *Data Analyst Intern*, dengan tugas utama yaitu melakukan analisis data terkait stunting di Kota Tangerang. Analisis ini difokuskan pada tiga kecamatan dengan angka stunting tertinggi berdasarkan data historis menggunakan model ARIMA. Dalam pelaksanaan kegiatan magang, posisi *Data Analyst Intern* berada di bawah koordinasi dua *supervisor*, yaitu Ketua Tim Kerja Bidang Pengembangan *e-Government* sebagai *supervisor 1* dan *System Analyst* sebagai *supervisor 2*. Koordinasi dilakukan secara harian, baik melalui diskusi langsung maupun diskusi melalui *WhatsApp* saat *Work from Home*. Seluruh kegiatan berada dalam lingkup tanggung jawab Kepala Bidang *e-Government* yang memimpin keseluruhan proses dan kegiatan di bidang tersebut. Adapun struktur kedudukan selama kegiatan magang dapat dilihat pada Gambar 3.1.



Gambar 3.1 Struktur Kedudukan selama Kegiatan Magang

3.1.2 Koordinasi

Koordinasi selama pelaksanaan magang dilakukan secara terstruktur agar setiap tahap dapat berjalan dengan efektif dan sesuai dengan arahan *supervisor*. Proses kerja dimulai dengan pemberian *dataset* dari *supervisor*. Lalu dilanjutkan dengan melakukan analisis data menggunakan model ARIMA untuk memprediksi tren kasus *stunting* pada tiga kecamatan dengan kasus *stunting* tertinggi berdasarkan data historis. Selama proses analisis berlangsung, hasil sementara dikonsultasikan secara berkala kepada *supervisor* untuk mendapatkan masukan ataupun validasi agar analisis yang dilakukan sesuai dengan kebutuhan instansi. Setelah seluruh proses analisis selesai, hasil akhir dipresentasikan kepada Kepala Bidang *e-Government*, Ketua Tim Kerja Bidang Pengembangan *e-Government* sebagai *supervisor 1*, dan *supervisor 2* untuk memastikan bahwa hasil model sudah akurat dan memenuhi kebutuhan dinas. Tugas dinyatakan selesai setelah seluruh tahapan kerja disetujui oleh Kepala Bidang, *Supervisor 1*, dan *Supervisor 2*. Adapun alur koordinasi kegiatan magang dapat dilihat pada Gambar 3.2.



Gambar 3.2 Alur Koordinasi Kegiatan Magang

3.2 Tugas yang Dilakukan

Selama menjalankan kegiatan magang, berbagai kegiatan telah dilaksanakan sesuai dengan arahan dan kebutuhan instansi. Setiap tugas dikerjakan melalui tahapan yang terstruktur, mulai dari perencanaan, pelaksanaan, hingga penyelesaian. Seluruh kegiatan dicatat untuk memberikan gambaran yang jelas mengenai proses kerja dan memastikan bahwa setiap tahap dikerjakan dan diselesaikan dengan baik. Detail pekerjaan yang dilakukan selama kegiatan magang dapat dilihat pada Tabel 3.1.

Tabel 3.1 Detail Pekerjaan yang Dilakukan

No.	Kegiatan	Tanggal Mulai	Tanggal Selesai	Koordinasi
1	Mengikuti <i>briefing</i> awal terkait alur kerja dan tujuan proyek	01/07/25	04/07/25	Supervisor
2	Penerimaan dataset <i>stunting</i> dari supervisor	07/07/25	07/07/25	Supervisor
3	Eksplorasi awal terhadap dataset	08/07/25	18/07/25	Supervisor
4	Filter data untuk tiga kecamatan dengan kasus tertinggi	21/07/25	25/07/25	Supervisor
5	Agregasi data menjadi deret waktu mingguan untuk tiga kecamatan tertinggi	28/07/25	01/08/25	Supervisor
6	Penerapan teknik data <i>smoothing</i> menggunakan metode <i>moving average</i>	04/08/25	08/08/25	Supervisor

No.	Kegiatan	Tanggal Mulai	Tanggal Selesai	Koordinasi
7	Visualisasi distribusi jumlah kasus <i>stunting</i> per minggu	11/08/25	15/08/25	<i>Supervisor</i>
8	Pengujian stasioneritas data serta proses <i>differencing</i>	18/08/25	22/08/25	<i>Supervisor</i>
9	Penentuan parameter untuk model manual berdasarkan analisis ACF dan PACF	25/08/25	29/08/25	<i>Supervisor</i>
10	Pelatihan model ARIMA Manual dan Auto ARIMA	01/09/25	04/09/25	<i>Supervisor</i>
11	Evaluasi kinerja model	08/09/25	12/09/25	<i>Supervisor</i>
12	Hasil peramalan untuk delapan minggu ke depan	15/09/25	19/09/25	<i>Supervisor</i>
13	Visualisasi akhir hasil analisis dan peramalan	22/09/25	26/09/25	<i>Supervisor</i>
14	Penyusunan dokumentasi kode	29/09/25	10/10/25	<i>Supervisor</i>
15	Pelaksanaan kegiatan magang sesuai jadwal kerja	01/10/25	10/10/25	<i>Supervisor</i>

3.3 Uraian Pelaksanaan Kerja

Uraian pelaksanaan kerja menjelaskan berbagai aktivitas yang dilakukan selama masa magang, mulai dari proses pelaksanaan, kendala yang ditemukan, dan solusi atas kendala yang ditemukan. Setiap pekerjaan yang dijalankan sesuai dengan arahan instansi dan mengikuti alur kerja yang sudah ditetapkan. Berikut merupakan tahapan dari uraian pelaksanaan kerja:

3.3.1 Proses Pelaksanaan

Proses pelaksanaan kerja magang dijabarkan secara rinci untuk menggambarkan tahapan-tahapan yang dilakukan selama magang. Setiap kegiatan yang dijalankan selalu mengikuti alur kerja, mulai dari pengolahan data hingga penyusunan hasil analisis. Dalam pelaksanaannya, kegiatan analisis data dilakukan menggunakan *Python* sebagai bahasa pemrograman utama dan *Jupyter Notebook* sebagai lingkungan kerja. *Jupyter Notebook* digunakan karena sifatnya yang interaktif sehingga memungkinkan proses

analisis, eksekusi kode, serta penulisan dokumentasi dilakukan secara terstruktur dalam satu tempat [12]. Sementara itu, *Python* dipilih karena memiliki *library* yang luas untuk mendukung proses pembersihan data, analisis, visualisasi, serta pemodelan. *Library* seperti pandas dan numpy membantu dalam manipulasi data, matplotlib digunakan untuk visualisasi, sementara statsmodels dan pmdarima digunakan dalam pembuatan model ARIMA manual dan Auto ARIMA [13]. Seluruh hasil pekerjaan selalu dikonsultasikan kepada *supervisor* untuk memperoleh masukan serta memastikan bahwa setiap langkah yang dikerjakan sudah sesuai dan valid. Berikut rincian tugas yang dilaksanakan dalam proses pelaksanaan magang ini:

3.3.1.1 Mengikuti *briefing* awal terkait alur kerja dan tujuan proyek

Tahap pertama dimulai dengan kegiatan *briefing* dan perkenalan bersama *supervisor* sesuai dengan jadwal pertemuan yang telah ditentukan. Tahap ini merupakan dasar untuk memahami ruang lingkup pekerjaan yang akan dilakukan. Pada tahap ini, dijelaskan bahwa sistem kerja yang diterapkan selama magang adalah *hybrid*, serta seluruh proses dan hasil analisis harus dikonsultasikan kepada *supervisor*. Kemudian, disampaikan alur kerja serta diberikan tugas utama berupa analisis tren *time series* menggunakan model ARIMA pada tiga kecamatan dengan jumlah kasus *stunting* tertinggi di Kota Tangerang berdasarkan data historis. Tugas ini diberikan karena instansi membutuhkan gambaran yang lebih jelas mengenai perkembangan kasus *stunting* dari waktu ke waktu serta prediksi kondisi pada periode mendatang, sehingga dapat membantu dalam proses pengambilan keputusan dan penyusunan strategi intervensi yang lebih tepat. Melalui tahap ini, diperoleh pemahaman yang jelas mengenai ruang lingkup pekerjaan target yang harus dicapai.

3.3.1.2 Penerimaan dataset *stunting* dari *supervisor*

Tahap selanjutnya adalah menerima dataset *stunting* dari *supervisor* sebagai bahan untuk melakukan proses analisis. *Dataset* yang diberikan berformat Excel dan berisi informasi mengenai kasus *stunting* anak dengan periode data mulai dari 07 Januari 2024 hingga 03 Agustus 2025. Secara keseluruhan, *dataset* ini memiliki 109.208 baris dan 12 kolom, dengan variabel seperti *id_pengukuran*, *nik_anak*, *nama_anak*, *jenis_kelamin*, *tanggal_lahir*, *berat_badan*, *tinggi_badan*, *kelurahan*, *kecamatan*, *kab_kota*, *tgl_pengukuran*, dan *ket_stunting*. Namun, dalam kegiatan magang ini analisis difokuskan pada tiga variabel utama, yaitu *tgl_pengukuran*, *kecamatan*, dan *ket_stunting*, karena ketiga variabel tersebut merupakan komponen utama yang dibutuhkan untuk pemodelan tren *time series* menggunakan ARIMA. Dataset ini kemudian menjadi dasar untuk proses persiapan data dan tahapan analisis berikutnya.

3.3.1.3 Eksplorasi awal terhadap dataset

Tahap selanjutnya adalah eksplorasi awal terhadap dataset. Tahap ini dilakukan untuk memahami kondisi dasar dataset sebelum masuk ke proses analisis lebih lanjut. Pada tahap ini dilakukan serangkaian pengecekan seperti melihat struktur data, mengidentifikasi duplikasi data, memeriksa nilai kosong, memastikan kesesuaian wilayah analisis, hingga membuat visualisasi distribusi. Proses ini penting dilakukan untuk memastikan bahwa data yang digunakan sudah bersih, konsisten, dan relevan dengan kebutuhan pemodelan *time series* sehingga hasil analisis dapat lebih akurat. Berikut tahapan eksplorasi awal pada dataset:

1) Melihat Struktur Data

Langkah pertama pada eksplorasi dataset adalah memeriksa struktur data menggunakan fungsi `df.info()`. Melalui pemeriksaan

ini dapat melihat informasi dari dataset yang sudah diberikan. Informasi tersebut seperti jumlah baris dan kolom pada dataset, tipe data pada setiap variabel, dan lain-lain. Informasi ini penting karena membantu dalam memahami kondisi awal dataset dan memastikan bahwa tipe data sudah sesuai untuk analisis selanjutnya. Struktur data pada dataset dapat dilihat pada Gambar 3.3.

```
df.info()
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 109208 entries, 0 to 109207
Data columns (total 12 columns):
 #   Column      Non-Null Count  Dtype  
--- 
 0   id_pengukuran 109208 non-null  int64  
 1   nik_anak      109207 non-null  object  
 2   nama_anak     109198 non-null  object  
 3   jenis_kelamin 107933 non-null  object  
 4   tanggal_lahir  109208 non-null  object  
 5   berat_badan   109208 non-null  float64 
 6   tinggi_badan  109202 non-null  float64 
 7   kelurahan     109208 non-null  object  
 8   kecamatan     109208 non-null  object  
 9   kab_kota       109208 non-null  object  
 10  tgl_pengukuran 109208 non-null  datetime64[ns] 
 11  ket_stunting   109208 non-null  object  
dtypes: datetime64[ns](1), float64(2), int64(1), object(8)
memory usage: 10.0+ MB
```

Gambar 3.3 Melihat Stuktur Data

2) Mengidentifikasi dan Menghapus Duplikasi Data

Tahap eksplorasi berikutnya adalah mengidentifikasi apakah terdapat data yang tercatat lebih dari satu kali dengan informasi yang sama. Proses ini penting karena keberadaan data duplikat dapat memengaruhi hasil analisis. Proses identifikasi data duplikat dapat dilihat pada Gambar 3.4.

```
kolom_untuk_cek = [
    'nama_anak', 'jenis_kelamin', 'tanggal_lahir', 'berat_badan',
    'tinggi_badan', 'kelurahan', 'kecamatan', 'kab_kota',
    'tgl_pengukuran', 'ket_stunting'
]

mask_duplikat = df.duplicated(subset=kolom_untuk_cek, keep=False)
df_duplikat_ditemukan = df[mask_duplikat]
```

Gambar 3.4 Identifikasi Data Duplikat

Setelah proses identifikasi dilakukan, ditemukan sebanyak 244 baris yang merupakan duplikasi. Baris-baris tersebut kemudian dihapus untuk memastikan bahwa *dataset* hanya berisi satu entri untuk setiap pengukuran. Penghapusan dilakukan

dengan menyimpan entri pertama dan membuang entri selebihnya. Setelah duplikasi dibersihkan, jumlah baris berkurang dari 109.208 menjadi 108.964 baris. Proses penghapusan duplikasi dapat dilihat pada Gambar 3.5.

```
df.drop_duplicates(subset=kolom_untuk_cek, keep='first', inplace=True)
```

Gambar 3.5 Penghapusan Duplikasi Data

3) Memeriksa Nilai Kosong

Setelah duplikasi data berhasil dibersihkan, langkah selanjutnya adalah memeriksa apakah terdapat nilai kosong (*missing value*) pada kolom-kolom yang menjadi kunci dalam analisis, yaitu `tgl_pengukuran`, `kecamatan`, dan `ket_stunting`. Ketiga kolom ini dipilih karena memiliki peran penting dalam proses pemodelan dan tidak boleh mengandung nilai kosong agar hasil analisis tetap valid. Hasil pemeriksaan menunjukkan bahwa tidak terdapat nilai kosong pada seluruh kolom kunci tersebut. Hal ini terlihat dari jumlah baris sebelum dan sesudah proses penghapusan yang tetap sama, yaitu 108.964 baris. Proses pemeriksaan dan penghapusan nilai kosong dapat dilihat pada Gambar 3.6.

```
: kolom_kunci_final = ['tgl_pengukuran', 'kecamatan', 'ket_stunting']
print(f"Kolom kunci yang diperiksa: {kolom_kunci_final}")

df_cleaned = df.dropna(subset=kolom_kunci_final)
```

Gambar 3.6 Pemeriksaan dan Penghapusan Nilai Kosong

4) Memastikan Kesesuaian Wilayah Analisis

Setelah *dataset* dibersihkan dari duplikasi dan nilai kosong, langkah selanjutnya adalah memastikan bahwa seluruh data yang digunakan benar-benar berasal dari wilayah yang menjadi fokus analisis, yaitu Kota Tangerang. Tahap awal dilakukan dengan menampilkan seluruh daftar kecamatan pada *dataset*. Dari hasil pengecekan, ditemukan bahwa beberapa baris data berasal dari kecamatan di luar wilayah Kota Tangerang, seperti Cengkareng,

Susukan, Grogol Petamburan, Kembangan, Picung, Senen, dan Bayat. Daftar tersebut dapat dilihat pada Gambar 3.7.

```
daftar_kecamatan = df_cleaned['kecamatan'].unique()  
daftar_kecamatan  
  
array(['CILEDUG', 'PERIUK', 'CIPONDOH', 'NEGLASARI', 'BATUCEPER', 'BENDA',  
'PINANG', 'KARAWACI', 'LARANGAN', 'CIBODAS', 'KARANG TENGAH',  
'TANGERANG', 'JATIUNG', 'CENGKARENG', 'SUSUKAN',  
'GROGOL PETAMBURAN', 'KEMBANGAN', 'PICUNG', 'SENEN', 'BAYAT'],  
dtype=object)
```

Gambar 3.7 Daftar Kecamatan pada *Dataset*

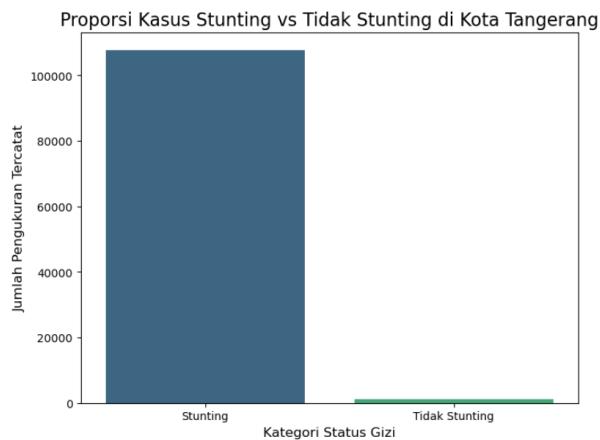
Karena penelitian dan analisis hanya berfokus pada kecamatan-kecamatan yang berada di Kota Tangerang, maka data dari wilayah luar tersebut perlu dihapus agar tidak memengaruhi hasil analisis. Hasil proses penyaringan menunjukkan bahwa terdapat 92 baris data yang berasal dari kecamatan di luar Kota Tangerang, dan seluruh baris tersebut telah dihapus. Setelah dihapus, *dataset* ini berisi 13 kecamatan yang ada di Kota Tangerang. Proses penghapusan dapat dilihat pada Gambar 3.8.

```
kecamatan_kota_tangerang = [  
    'BATUCEPER', 'BENDA', 'CIBODAS', 'CILEDUG', 'CIPONDOH',  
    'JATIUNG', 'KARANG TENGAH', 'KARAWACI', 'LARANGAN',  
    'NEGLASARI', 'PERIUK', 'PINANG', 'TANGERANG'  
]  
  
df_tangerang = df_cleaned[df_cleaned['kecamatan'].isin(kecamatan_kota_tangerang)].copy()  
  
kecamatan_tersisa = df_tangerang['kecamatan'].unique()  
kecamatan_tersisa
```

Gambar 3.8 Penghapusan Kecamatan di Luar Kota Tangerang

5) Visualisasi Distribusi

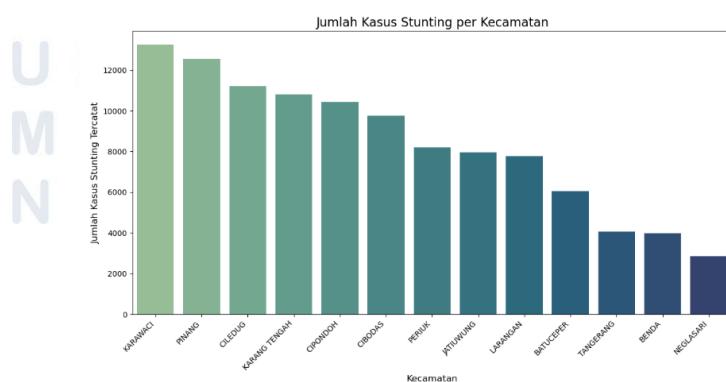
Pada tahap ini dilakukan visualisasi untuk melihat bagaimana distribusi kategori *stunting* dan tidak *stunting*. Hasil visualisasi ini menjadi dasar penting sebelum masuk ke tahap pemodelan. Visualisasi distribusi kategori *stunting* dapat dilihat pada Gambar 3.9.



Gambar 3.9 Visualisasi Distribusi Kategori *Stunting*

3.3.1.4 Filter data untuk tiga kecamatan dengan kasus tertinggi

Pada tahap ini dilakukan proses analisis untuk mengetahui kecamatan mana saja yang memiliki jumlah kasus *stunting* paling tinggi di Kota Tangerang. Pertama, dilakukan perhitungan jumlah kasus *stunting* berdasarkan kecamatan menggunakan data yang sudah melalui tahap pembersihan sebelumnya. Hasil perhitungan tersebut kemudian divisualisasikan dalam bentuk grafik batang yang menampilkan jumlah kasus pada seluruh 13 kecamatan. Visualisasi ini memberikan gambaran awal mengenai kecamatan mana yang memiliki jumlah kasus relatif tinggi dan mana yang lebih rendah. Jumlah kasus di 13 kecamatan Kota Tangerang dapat dilihat pada Gambar 3.10.



Gambar 3.10 Jumlah Kasus di 13 Kecamatan Kota Tangerang

Setelah itu, dilakukan identifikasi tiga kecamatan dengan jumlah kasus tertinggi dengan mengambil tiga nilai teratas dari hasil perhitungan. Berdasarkan data yang tersedia, tiga kecamatan dengan kasus *stunting* paling tinggi adalah Karawaci, Pinang, dan Ciledug. Proses ini penting untuk membantu dalam menentukan area prioritas yang memerlukan perhatian lebih dalam. Tiga kecamatan dengan jumlah kasus *stunting* tertinggi berdasarkan data historis dapat dilihat pada Gambar 3.11.



Gambar 3.11 Tiga Kecamatan dengan Kasus *Stunting* Tertinggi

3.3.1.5 Agregasi data menjadi deret waktu mingguan untuk tiga kecamatan tertinggi

Pada tahap ini dilakukan proses agregasi data menjadi deret waktu mingguan untuk tiga kecamatan dengan jumlah kasus *stunting* tertinggi, yaitu Karawaci, Pinang, dan Ciledug. Tujuan dari tahap ini adalah untuk mengubah data pengukuran harian menjadi data mingguan sehingga pola tren *stunting* dapat terlihat lebih jelas dan lebih stabil untuk kebutuhan pemodelan *time series*. Untuk setiap kecamatan, data terlebih dahulu dikelompokkan berdasarkan tanggal pengukuran, kemudian dihitung jumlah kasus *stunting* yang tercatat pada setiap minggu. Jika terdapat minggu tertentu tanpa data, maka nilai minggu tersebut diisi dengan angka nol agar deret waktu tetap

berurutan. Proses agregasi ini dilakukan pada tiga kecamatan tersebut. Dengan hasil agregasi ini, setiap kecamatan akan memiliki deret waktu mingguan yang siap digunakan untuk tahap analisis dan pemodelan prediktif. Proses agregasi data menjadi mingguan dapat dilihat pada Gambar 3.12.

```
weekly = df_karawaci.resample('W', on='tgl_pengukuran').size().reset_index(name='jumlah_stunting')
weekly = weekly.set_index('tgl_pengukuran')
weekly = weekly.asfreq('W', fill_value=0)
```

Gambar 3.12 Proses Agregasi Mingguan

3.3.1.6 Penerapan teknik data *smoothing* menggunakan metode *moving average*

Setelah data kasus *stunting* diubah menjadi deret waktu mingguan, langkah berikutnya adalah melakukan data *smoothing* menggunakan metode *moving average*. Tujuan utama dari *smoothing* ini adalah untuk menstabilkan fluktuasi mingguan yang sangat acak (*volatile*), sehingga pola tren jangka panjang dapat terlihat lebih jelas dan model prediksi dapat bekerja lebih optimal. Pada dasarnya, data mingguan kasus *stunting* sering mengalami naik turun yang tajam karena jumlah pengukuran setiap minggu tidak selalu konsisten. Kondisi ini dapat membuat model kesulitan mengenali pola yang sebenarnya. Oleh karena itu digunakan *moving average* dengan jendela (*window*) selama 3 minggu. Metode ini menghitung rata-rata dari minggu sebelumnya, minggu berjalan, dan minggu sesudahnya, sehingga menghasilkan garis tren yang lebih halus. Selain itu, proses *smoothing* juga menangani nilai kosong yang muncul akibat perhitungan rata-rata pada bagian awal atau akhir deret waktu. Nilai kosong tersebut diisi kembali (*backfill* dan *forward fill*) agar tidak ada celah dalam deret waktu yang dapat mengganggu proses pemodelan. Proses *smoothing* ini dilakukan pada tiga kecamatan tersebut. Melalui *smoothing* ini, deret waktu mingguan menjadi lebih stabil dan siap

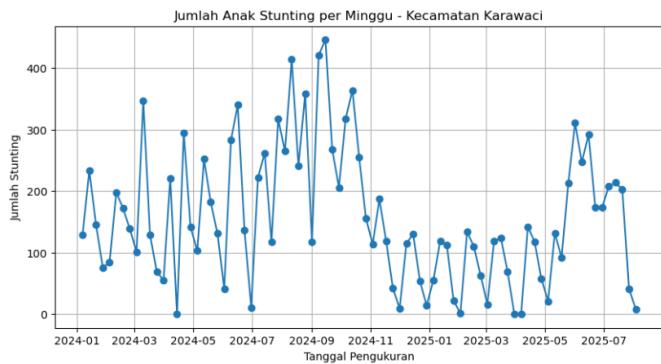
digunakan pada tahap pemodelan. Proses *smoothing* dapat dilihat pada Gambar 3.13.

```
weekly['jumlah_stunting_smoothed'] = (  
    weekly['jumlah_stunting']  
    .rolling(window=3, center=True)  
    .mean()  
    .fillna(method='bfill')  
    .fillna(method='ffill')  
)
```

Gambar 3.13 Proses *Smoothing*

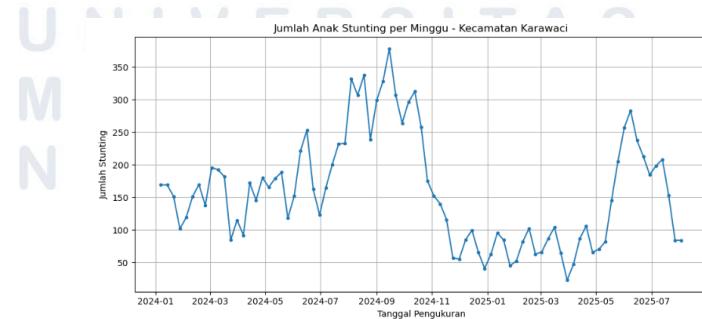
3.3.1.7 Visualisasi distribusi jumlah kasus *stunting* per minggu

Visualisasi deret waktu mingguan digunakan untuk memahami bagaimana perkembangan kasus *stunting* di tiga kecamatan dari waktu ke waktu. Grafik ini menampilkan perubahan jumlah anak *stunting* per minggu, sehingga pola tren, lonjakan kasus, maupun penurunan dapat terlihat dengan lebih jelas. Untuk visualisasi yang pertama adalah visualisasi untuk kecamatan Karawaci. Pola yang muncul terlihat sangat fluktuatif dengan perubahan nilai dari minggu ke minggu. Pada beberapa minggu, jumlah kasus dapat meningkat sangat tinggi, sementara pada minggu lainnya turun drastis hingga mendekati angka nol. Kondisi tersebut menghasilkan grafik yang “bergerigi” dan penuh *noise*, sehingga menyulitkan dalam membaca pola sebenarnya. Pada tahap ini, dilakukan visualisasi data jumlah anak *stunting* mingguan sebagai input utama. Proses analisis dilakukan dengan membandingkan dua grafik, yaitu sebelum dan sesudah dilakukan *smoothing* menggunakan metode *moving average*. Output dari tahap ini berupa visualisasi tren. Grafik visualisasi tren untuk Kecamatan Karawaci sebelum data *smoothing* dapat dilihat pada Gambar 3.14.



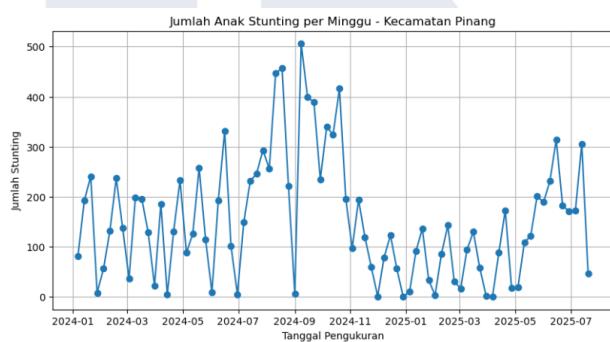
Gambar 3.14 Visualisasi Tren Kecamatan Karawaci Sebelum Data *Smoothing*

Setelah dilakukan *smoothing* menggunakan *moving average*, grafik menjadi lebih stabil dan mudah dibaca. Lonjakan-lonjakan tajam pada grafik sebelumnya mereda, sehingga pola pergerakan mingguan terlihat lebih halus. Proses *smoothing* ini juga menghilangkan nilai-nilai nol yang muncul akibat ketidakseimbangan laporan mingguan, sehingga grafik menjadi lebih realistik dan mencerminkan kondisi lapangan dengan lebih baik. Pada awal tahun 2024, nilai kasus berada pada kisaran 100–200. Memasuki pertengahan hingga akhir 2024, terjadi peningkatan signifikan hingga mencapai puncak di atas 350 kasus. Setelah itu, grafik menunjukkan tren penurunan yang cukup tajam pada akhir 2024 hingga awal 2025. Namun pada pertengahan 2025, terlihat adanya kenaikan kembali. Grafik visualisasi tren untuk Kecamatan Karawaci setelah data *smoothing* dapat dilihat pada Gambar 3.15.



Gambar 3.15 Visualisasi Tren Kecamatan Karawaci Setelah Data *Smoothing*

Untuk yang kedua adalah kecamatan Pinang. Sama seperti sebelumnya pola kasus *stunting* mingguan di Kecamatan Pinang sangat tidak stabil. Garis grafik bergerak naik dan turun secara tajam, sehingga tampak acak. Fluktuasi yang sangat drastis ini menyebabkan grafik mentah sulit digunakan untuk membaca tren jangka panjang. Grafik visualisasi tren untuk Kecamatan Pinang sebelum data *smoothing* dapat dilihat pada Gambar 3.16.



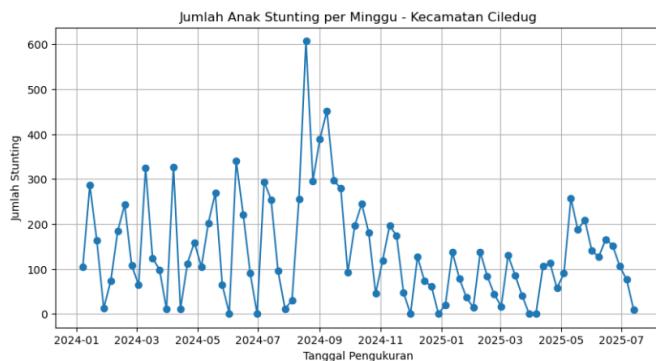
Gambar 3.16 Visualisasi Tren Kecamatan Pinang Sebelum Data *Smoothing*

Setelah dilakukan *smoothing*, grafik menjadi lebih stabil dan mudah dipahami. Lonjakan yang sebelumnya sangat ekstrem kini tampak lebih wajar, dan titik-titik nol yang mengganggu sudah cukup rata. Dari hasil *smoothing*, terlihat bahwa Kecamatan Pinang mengalami pola yang cukup jelas dengan kondisi relatif stabil pada awal 2024, kemudian terjadi peningkatan besar pada pertengahan hingga akhir 2024, sebelum akhirnya mengalami penurunan yang signifikan pada awal 2025. Namun, grafik juga menunjukkan adanya kecenderungan peningkatan kembali menjelang pertengahan 2025. Grafik visualisasi tren untuk Kecamatan Pinang setelah data *smoothing* dapat dilihat pada Gambar 3.17.



Gambar 3.17 Visualisasi Tren Kecamatan Pinang Sesudah Data *Smoothing*

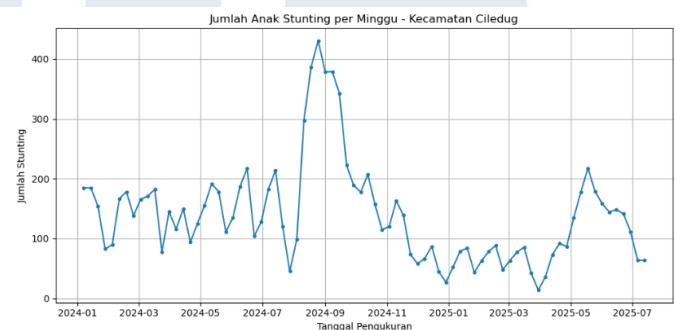
Selanjutnya adalah kecamatan Ciledug. Fluktuasi pada Kecamatan Ciledug terlihat lebih ekstrem dibandingkan dua kecamatan sebelumnya. Garis grafik sering kali turun hingga menyentuh angka nol, lalu kembali melonjak ke angka ratusan dalam waktu yang sangat singkat. Pola yang tidak beraturan ini menandakan adanya ketidakkonsistenan. Grafik mentah ini menjadi sulit digunakan untuk melihat tren yang sebenarnya. Grafik visualisasi tren untuk Kecamatan Ciledug sebelum data *smoothing* dapat dilihat pada Gambar 3.18.



Gambar 3.18 Visualisasi Tren Kecamatan Ciledug Sebelum Data *Smoothing*

Setelah dilakukan *smoothing*, grafik Kecamatan Ciledug menjadi jauh lebih stabil dan lebih mudah dibaca. Lonjakan ekstrem yang sebelumnya mencapai angka 600 kini tampak lebih wajar, dengan nilainya turun menjadi sekitar 430. *Smoothing* berhasil mengurangi pengaruh data yang terlalu ekstrem, tetapi tetap

mempertahankan bentuk utama dari tren yang terjadi. Pola yang muncul setelah *smoothing* memperlihatkan gambaran yang lebih jelas dengan kondisi relatif stabil pada awal tahun, kemudian terjadi lonjakan besar pada periode Agustus-Oktober 2024, lalu terjadi penurunan signifikan pada akhir tahun. Selain itu, terlihat pula adanya kenaikan kedua yang lebih kecil sekitar Mei 2025. Dengan hasil *smoothing* ini, grafik menjadi lebih mudah dibaca dan siap digunakan sebagai dasar dalam proses pemodelan dan peramalan. Grafik visualisasi tren untuk Kecamatan Ciledug setelah data *smoothing* dapat dilihat pada Gambar 3.19.



Gambar 3.19 Visualisasi Tren Kecamatan Ciledug Sesudah Data *Smoothing*

3.3.1.8 Pengujian stasioneritas data serta proses *differencing*

Sebelum melakukan pemodelan deret waktu, data yang digunakan harus bersifat stasioner. Data yang tidak stasioner dapat menghasilkan model yang tidak stabil dan kurang akurat dalam memprediksi tren. Oleh karena itu, dilakukan uji stasioneritas menggunakan *Augmented Dickey-Fuller* (ADF Test) pada tiga kecamatan. Jika belum stasioner, dilakukan proses *differencing* untuk menstabilkan varians. Secara keseluruhan, tahapan ini menggunakan data mingguan kasus *stunting* dari masing-masing kecamatan sebagai input. Data tersebut kemudian diuji menggunakan *Augmented Dickey-Fuller* (ADF Test) dan dilakukan proses *differencing* untuk memenuhi syarat kestasioneran. Output dari tahapan ini adalah nilai *p-value* serta penentuan jumlah *differencing* (*d*) yang akan digunakan dalam

pemodelan ARIMA pada setiap kecamatan. Berikut merupakan proses uji stasioneritas pada tiga kecamatan:

1) Kecamatan Karawaci

Pada Kecamatan Karawaci, proses uji stasioneritas dilakukan pada data dengan total 83 minggu. Sebanyak 67 minggu digunakan sebagai data latih awal, sementara 16 minggu sisanya digunakan untuk validasi. Hasilnya menunjukkan bahwa data kondisi awal belum stasioner dengan *p-value* sebesar 0.488. Setelah dilakukan *differencing* pertama, *p-value* turun menjadi 0.1717, namun nilai ini masih berada di atas batas signifikansi 0.05, sehingga data masih belum stasioner. Pada tahap *differencing* kedua, *p-value* turun menjadi 0.0069, menunjukkan bahwa data telah stasioner. Dengan demikian, diferensiasi sebanyak dua kali ($d=2$) ditetapkan sebagai nilai *differencing* yang digunakan untuk pemodelan ARIMA Manual untuk Kecamatan Karawaci. Hasil dari uji stasioner pada Kecamatan Karawaci dapat dilihat pada Gambar 3.20.

```
--- Uji Stasioneritas ADF (Otomatis d) ---
ADF Test (d=0) p-value: 0.48870337332741315
Data belum stasioner (d=0), mencoba d=1...
ADF Test (d=1) p-value: 0.17176525843453566
Data masih belum stasioner (d=1), mencoba d=2...
ADF Test (d=2) p-value: 0.00693826517579493
Data stasioner setelah 2 differencing (d=2)

====> Nilai 'd' yang akan digunakan: 2 <====
```

Gambar 3.20 Uji Stasioner Kecamatan Karawaci

2) Kecamatan Pinang

Pada Kecamatan Pinang, proses uji stasioneritas dilakukan dengan total 81 minggu data. Sebanyak 65 minggu digunakan sebagai data latih awal, sementara 16 minggu terakhir digunakan sebagai data validasi. Hasil uji ADF pada data tanpa *differencing* menunjukkan nilai *p-value* sebesar 0.7561, yang menandakan bahwa data masih belum stasioner. Setelah

dilakukan *differencing* pertama, *p-value* turun drastis menjadi 0.0100, berada di bawah ambang signifikansi 0.05. Nilai tersebut menunjukkan bahwa data stasioner pada *differencing* pertama. Oleh karena itu, nilai *differencing* yang digunakan untuk pemodelan ARIMA Manual pada Kecamatan Pinang adalah $d=1$. Hasil dari uji stasioner pada Kecamatan Pinang dapat dilihat pada Gambar 3.21.

```
--- Uji Stasioneritas ADF (Otomatis d) ---
ADF Test (d=0) p-value: 0.7561348753731296
Data belum stasioner (d=0), mencoba d=1...
ADF Test (d=1) p-value: 0.010066529554325535
Data stasioner setelah 1 differencing (d=1)

==> Nilai 'd' yang akan digunakan: 1 <==
```

Gambar 3.21 Uji Stasioner Kecamatan Pinang

3) Kecamatan Ciledug

Pada Kecamatan Ciledug, proses uji stasioneritas dilakukan dengan total 80 minggu data yang tersedia. Sebanyak 64 minggu digunakan sebagai data latih awal, sementara 16 minggu terakhir digunakan sebagai data validasi. Hasil uji stasioneritas menggunakan bahwa data asli (tanpa *differencing*) memiliki *p-value* sebesar 0.7920 dan belum stasioner. Ketika dilakukan *differencing* pertama, nilai *p-value* turun menjadi 0.00038. Nilai ini sudah berada di bawah 0.05, yang berarti data telah mencapai kondisi stasioner hanya dengan satu kali *differencing*. Karena itu, nilai *differencing* yang digunakan untuk pemodelan ARIMA Manual pada kecamatan Ciledug adalah $d=1$. Hasil dari uji stasioner pada Kecamatan Ciledug dapat dilihat pada Gambar 3.22.

```

--- Uji Stasioneritas ADF (Otomatis d) ---
ADF Test (d=0) p-value: 0.792014812811519
Data belum stasioner (d=0), mencoba d=1...
ADF Test (d=1) p-value: 0.000385814598558163
Data stasioner setelah 1 differencing (d=1)

====> Nilai 'd' yang akan digunakan: 1 <===

```

Gambar 3.22 Uji Stasioner Kecamatan Ciledug

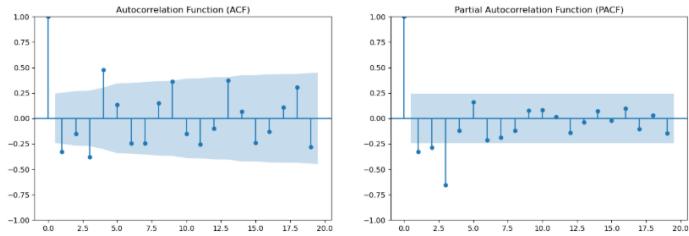
3.3.1.9 Penentuan parameter untuk model manual berdasarkan analisis ACF dan PACF

Setelah data berhasil distasionerkan melalui proses *differencing*, langkah selanjutnya adalah menganalisis grafik ACF (*Autocorrelation Function*) dan PACF (*Partial Autocorrelation Function*). Analisis ini penting untuk menentukan nilai parameter p dan q pada model ARIMA secara manual. Nilai p mewakili *autoregressive* (AR), sedangkan q mewakili *moving average* (MA). Pola pada grafik ACF dan PACF membantu mengidentifikasi lag mana yang memiliki pengaruh signifikan pada deret waktu. Pada tahap ini, input yang digunakan adalah grafik ACF dan PACF hasil dari proses *differencing* sebelumnya. Proses yang dilakukan adalah menganalisis pola lag pada grafik tersebut untuk melihat mana yang berada di dalam atau di luar batas signifikansi. Output dari tahap ini adalah penentuan nilai parameter p dan q yang akan digunakan dalam penyusunan model ARIMA Manual untuk tiga kecamatan. Berikut merupakan proses menentukan nilai p dan q pada tiga kecamatan:

1) Kecamatan Karawaci

Grafik PACF pada Kecamatan Karawaci menunjukkan bahwa lag ke-1, ke-2, dan ke-3 berada di luar zona biru. Hal ini menunjukkan bahwa ketiga lag tersebut memiliki pengaruh signifikan, sehingga komponen *autoregressive* (AR) yang paling sesuai adalah $p = 3$. Sementara itu, pada grafik ACF, lag ke-1 serta lag ke-3 dan ke-4 juga berada di luar zona biru, sedangkan lag lainnya di dalam zona biru. Pola ini menunjukkan komponen *moving average* (MA) dengan nilai $q = 1$

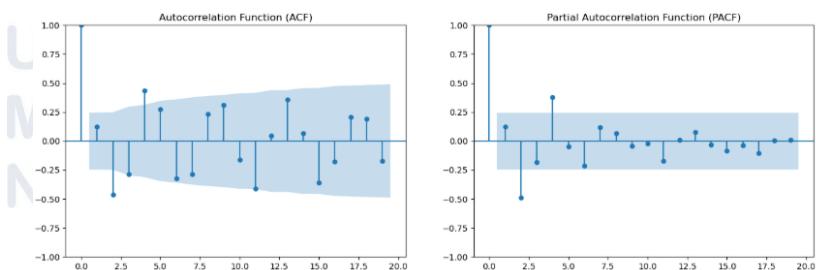
menjadi pilihan yang paling tepat. Maka, model ARIMA Manual untuk Kecamatan Karawaci adalah ARIMA (3,2,1). Visualisasi ACF dan PACF untuk Kecamatan Karawaci dapat dilihat pada Gambar 3.23.



Gambar 3.23 Visualisasi ACF dan PACF pada Kecamatan Karawaci

2) Kecamatan Pinang

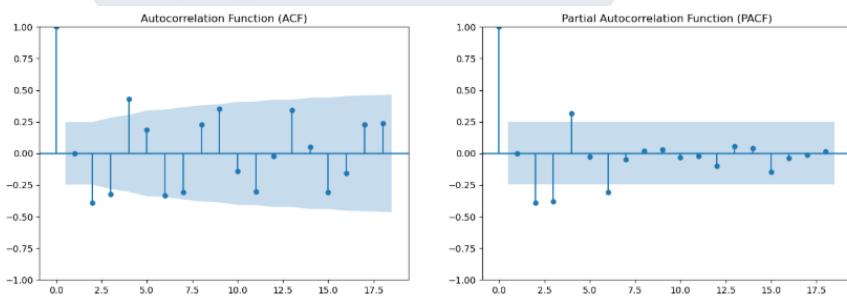
Grafik PACF pada Kecamatan Pinang menunjukkan lag 1 dan lag 3 berada di dalam batas signifikansi, sementara lag 2 dan lag 4 berada di luar batas signifikansi, dan lag-lag berikutnya kembali masuk ke dalam batas, sehingga komponen *autoregressive* (AR) yang paling sesuai adalah $p = 2$. Sementara itu, pada grafik ACF terlihat bahwa lag 1, dan lag 3 berada di dalam batas signifikansi, dan lag 2 serta lag 4 berada di luar batas, kemudian lag selanjutnya kembali masuk ke dalam batas. Pola ini menunjukkan komponen *moving average* (MA) dengan nilai $q = 2$ menjadi pilihan yang paling tepat. Oleh karena itu, model yang bisa digunakan oleh ARIMA Manual adalah ARIMA (2,1,2) untuk kecamatan Pinang. Visualisasi ACF dan PACF untuk Kecamatan Pinang dapat dilihat pada Gambar 3.24.



Gambar 3.24 Visualisasi ACF dan PACF pada Kecamatan Pinang

3) Kecamatan Ciledug

Grafik PACF pada Kecamatan Ciledug menunjukkan lag 1 berada di dalam zona biru, tetapi lag 2 hingga lag 4 terlihat keluar dari batas signifikansi. Setelah itu, lag 5 kembali masuk ke zona biru, lalu lag 6 muncul kembali sebagai lag yang signifikan, dan sisanya di dalam zona biru, sehingga komponen *autoregressive* (AR) yang paling sesuai adalah $p = 4$. Sementara pada grafik ACF, terlihat bahwa lag 1 masih berada dalam batas signifikansi, tetapi lag 2, lag 3, dan lag 4 keluar dari zona biru. Pola ini menunjukkan komponen *moving average* (MA) dengan nilai $q = 4$ menjadi pilihan yang paling tepat. Oleh karena itu, model ARIMA yang paling sesuai untuk Kecamatan Ciledug adalah ARIMA (4,1,4). Visualisasi ACF dan PACF untuk Kecamatan Pinang dapat dilihat pada Gambar 3.25.



Gambar 3.25 Visualisasi ACF dan PACF pada Kecamatan Ciledug

3.3.1.10 Pelatihan model ARIMA Manual dan Auto ARIMA

Pada tahap ini, proses pemodelan dilakukan dengan dua pendekatan, yaitu ARIMA manual (berdasarkan hasil analisis ACF dan PACF sebelumnya) dan Auto ARIMA yang secara otomatis mencari kombinasi parameter terbaik. Untuk memastikan bahwa model benar-benar mampu melakukan prediksi pada kondisi data nyata, digunakan metode validasi *walk-forward*, yaitu teknik evaluasi yang menguji model secara bertahap dari waktu ke waktu. Melalui metode ini, model belajar dari data minggu sebelumnya untuk memprediksi minggu berikutnya, kemudian diperbarui lagi dengan data terbaru sebelum memprediksi minggu setelahnya. Proses ini

berlangsung berulang-ulang sehingga performa model dapat dinilai secara lebih akurat dan mendekati penggunaan di kondisi sebenarnya. Tahap ini menggunakan deret waktu mingguan dari tiga kecamatan sebagai input, kemudian dilakukan proses pelatihan model ARIMA Manual dan Auto ARIMA menggunakan metode validasi *walk-forward*, di mana model belajar dari data historis dan diperbarui setiap minggu. Output dari proses ini berupa perbandingan hasil prediksi dengan data aktual. Berikut proses pelatihan pada tiga kecamatan:

1) Kecamatan Karawaci

Pada Kecamatan Karawaci, proses pelatihan model dilakukan menggunakan dua pendekatan berbeda, yaitu model ARIMA Manual dengan parameter (3,2,1) dan Auto ARIMA yang memilih parameter terbaik secara otomatis. Seluruh proses pelatihan dilakukan menggunakan metode *walk-forward validation*, di mana model selalu dilatih menggunakan data hingga minggu sebelumnya, lalu digunakan untuk memprediksi minggu berikutnya. Dengan pola ini, model benar-benar mensimulasikan kondisi prediksi dunia nyata, karena setiap minggu hanya belajar dari informasi historis yang sudah tersedia, tanpa melihat data masa depan. Proses pelatihan dapat dilihat pada Gambar 3.26.

```
# 2. Latih model
prediction_log = None

if model_name == "Auto ARIMA":
    model_auto = pm.auto_arima(
        train_data,
        d=d_value,
        seasonal=False,
        stepwise=True,
        suppress_warnings=True,
        trace=False
    )
    print(f" Iterasi {i+1}: Auto ARIMA Order (p,d,q) = {model_auto.order}")
    prediction_log = model_auto.predict(n_periods=1)[0]

else: # ARIMA Manual
    model_manual = ARIMA(train_data, order=model_config)
    model_fit_manual = model_manual.fit()
    prediction_log = model_fit_manual.forecast(steps=1).iloc[0]
```

Gambar 3.26 Pelatihan Model untuk Kecamatan Karawaci

Pada Kecamatan Karawaci, validasi *walk-forward* untuk model ARIMA Manual menunjukkan bagaimana model memprediksi jumlah kasus setiap minggu berdasarkan pola data historis. Dari tabel hasil validasi, terlihat bahwa pada beberapa minggu awal prediksi model cukup dekat dengan nilai aktual, misalnya pada tanggal 4 Mei 2025, model memberikan prediksi yang hampir sama dengan data sebenarnya. Namun, pada minggu-minggu tertentu seperti 25 Mei 2025, 15 Juni 2025, dan 22 Juni 2025, model cenderung menghasilkan prediksi yang lebih rendah atau lebih tinggi dari nilai aktual sehingga selisih antara keduanya menjadi cukup besar. Meskipun demikian, terdapat juga periode di mana pola prediksi kembali stabil, seperti pada tanggal 6 Juli 2025 dan 13 Juli 2025, ketika prediksi mendekati angka sebenarnya. Secara keseluruhan, hasil ini menggambarkan kemampuan ARIMA Manual dalam mengikuti perubahan tren mingguan, tetapi juga menunjukkan bahwa model masih mengalami kesulitan ketika terjadi kenaikan atau penurunan tajam pada data aktual. Proses pelatihan dan hasil validasi untuk ARIMA Manual di Kecamatan Karawaci dapat dilihat pada Gambar 3.27.



Iterasi 1/16: Melatih data s/d 2025-04-13 untuk memprediksi 2025-04-20...
 Iterasi 2/16: Melatih data s/d 2025-04-20 untuk memprediksi 2025-04-27...
 Iterasi 3/16: Melatih data s/d 2025-04-27 untuk memprediksi 2025-05-04...
 Iterasi 4/16: Melatih data s/d 2025-05-04 untuk memprediksi 2025-05-11...
 Iterasi 5/16: Melatih data s/d 2025-05-11 untuk memprediksi 2025-05-18...
 Iterasi 6/16: Melatih data s/d 2025-05-18 untuk memprediksi 2025-05-25...
 Iterasi 7/16: Melatih data s/d 2025-05-25 untuk memprediksi 2025-06-01...
 Iterasi 8/16: Melatih data s/d 2025-06-01 untuk memprediksi 2025-06-08...
 Iterasi 9/16: Melatih data s/d 2025-06-08 untuk memprediksi 2025-06-15...
 Iterasi 10/16: Melatih data s/d 2025-06-15 untuk memprediksi 2025-06-22...
 Iterasi 11/16: Melatih data s/d 2025-06-22 untuk memprediksi 2025-06-29...
 Iterasi 12/16: Melatih data s/d 2025-06-29 untuk memprediksi 2025-07-06...
 Iterasi 13/16: Melatih data s/d 2025-07-06 untuk memprediksi 2025-07-13...
 Iterasi 14/16: Melatih data s/d 2025-07-13 untuk memprediksi 2025-07-20...
 Iterasi 15/16: Melatih data s/d 2025-07-20 untuk memprediksi 2025-07-27...
 Iterasi 16/16: Melatih data s/d 2025-07-27 untuk memprediksi 2025-08-03...

Tanggal	Aktual	Prediksi
2025-04-20	106.00	79.52
2025-04-27	65.67	41.69
2025-05-04	70.33	68.70
2025-05-11	81.67	111.91
2025-05-18	145.67	121.38
2025-05-25	205.33	129.12
2025-06-01	257.00	194.60
2025-06-08	283.33	258.06
2025-06-15	237.33	398.07
2025-06-22	212.67	322.54
2025-06-29	184.67	291.88
2025-07-06	198.33	213.56
2025-07-13	208.33	191.72
2025-07-20	152.67	197.34
2025-07-27	84.00	125.76
2025-08-03	84.00	72.59

Gambar 3.27 Proses Pelatihan dan Hasil Validasi ARIMA Manual

Selanjutnya adalah Auto ARIMA. Dari hasil validasi, terlihat bahwa Auto ARIMA menunjukkan performa yang cukup bervariasi. Pada beberapa minggu awal seperti 20 April 2025 dan 27 April 2025, prediksi masih berada cukup jauh dari nilai aktual. Namun pada minggu 4 Mei 2025, model mulai memberikan prediksi yang lebih mendekati nilai aktual. Meski demikian, Auto ARIMA tampak kesulitan mengikuti lonjakan tajam, terutama pada periode 11 Mei – 25 Mei 2025, ketika data aktual meningkat signifikan tetapi prediksi tertinggal jauh. Kondisi serupa terjadi pada 1 Juni – 15 Juni 2025, ketika model beberapa kali menghasilkan prediksi yang lebih rendah atau jauh lebih tinggi dari nilai sebenarnya. Namun, pada periode pertengahan Juli, tepatnya 6 Juli 2025 dan 13 Juli 2025, model kembali stabil dan memberikan prediksi yang cukup mendekati nilai aktual, menunjukkan

bahwa Auto ARIMA mampu mengenali pola ketika tren mingguan lebih konsisten. Pada minggu terakhir validasi, yaitu 3 Agustus 2025, model memberikan hasil prediksi yang sangat dekat dengan data aktual, menandakan bahwa Auto ARIMA dapat bekerja lebih baik ketika perubahan data tidak terlalu ekstrem. Secara keseluruhan, validasi ini menunjukkan bahwa Auto ARIMA mampu mengikuti pola umum, tetapi sensitif terhadap perubahan mendadak atau fluktuasi besar pada jumlah kasus di Kecamatan Karawaci. Proses pelatihan dan hasil validasi untuk Auto ARIMA di Kecamatan Karawaci dapat dilihat pada Gambar 3.28.

```
--- Menguji Model: Auto ARIMA ---
Iterasi 1/16: Melatih data s/d 2025-04-13 untuk memprediksi 2025-04-20...
  Iterasi 1: Auto ARIMA Order (p,d,q) = (4, 2, 0)
Iterasi 2/16: Melatih data s/d 2025-04-20 untuk memprediksi 2025-04-27...
  Iterasi 2: Auto ARIMA Order (p,d,q) = (5, 2, 3)
Iterasi 3/16: Melatih data s/d 2025-04-27 untuk memprediksi 2025-05-04...
  Iterasi 3: Auto ARIMA Order (p,d,q) = (5, 2, 3)
Iterasi 4/16: Melatih data s/d 2025-05-04 untuk memprediksi 2025-05-11...
  Iterasi 4: Auto ARIMA Order (p,d,q) = (5, 2, 0)
Iterasi 5/16: Melatih data s/d 2025-05-11 untuk memprediksi 2025-05-18...
  Iterasi 5: Auto ARIMA Order (p,d,q) = (3, 2, 4)
Iterasi 6/16: Melatih data s/d 2025-05-18 untuk memprediksi 2025-05-25...
  Iterasi 6: Auto ARIMA Order (p,d,q) = (4, 2, 1)
Iterasi 7/16: Melatih data s/d 2025-05-25 untuk memprediksi 2025-06-01...
  Iterasi 7: Auto ARIMA Order (p,d,q) = (5, 2, 2)
Iterasi 8/16: Melatih data s/d 2025-06-01 untuk memprediksi 2025-06-08...
  Iterasi 8: Auto ARIMA Order (p,d,q) = (4, 2, 1)
Iterasi 9/16: Melatih data s/d 2025-06-08 untuk memprediksi 2025-06-15...
  Iterasi 9: Auto ARIMA Order (p,d,q) = (4, 2, 1)
Iterasi 10/16: Melatih data s/d 2025-06-15 untuk memprediksi 2025-06-22...
  Iterasi 10: Auto ARIMA Order (p,d,q) = (4, 2, 1)
Iterasi 11/16: Melatih data s/d 2025-06-22 untuk memprediksi 2025-06-29...
  Iterasi 11: Auto ARIMA Order (p,d,q) = (3, 2, 3)
Iterasi 12/16: Melatih data s/d 2025-06-29 untuk memprediksi 2025-07-06...
  Iterasi 12: Auto ARIMA Order (p,d,q) = (4, 2, 3)
Iterasi 13/16: Melatih data s/d 2025-07-06 untuk memprediksi 2025-07-13...
  Iterasi 13: Auto ARIMA Order (p,d,q) = (5, 2, 3)
Iterasi 14/16: Melatih data s/d 2025-07-13 untuk memprediksi 2025-07-20...
  Iterasi 14: Auto ARIMA Order (p,d,q) = (4, 2, 1)
Iterasi 15/16: Melatih data s/d 2025-07-20 untuk memprediksi 2025-07-27...
  Iterasi 15: Auto ARIMA Order (p,d,q) = (4, 2, 1)
Iterasi 16/16: Melatih data s/d 2025-07-27 untuk memprediksi 2025-08-03...
  Iterasi 16: Auto ARIMA Order (p,d,q) = (5, 2, 2)
```

	Aktual	Prediksi
Tanggal		
2025-04-20	106.00	81.96
2025-04-27	65.67	31.62
2025-05-04	70.33	61.63
2025-05-11	81.67	145.76
2025-05-18	145.67	106.30
2025-05-25	205.33	112.10
2025-06-01	257.00	178.53
2025-06-08	283.33	224.79
2025-06-15	237.33	351.16 ¹
2025-06-22	212.67	261.80
2025-06-29	184.67	233.36
2025-07-06	198.33	210.78
2025-07-13	208.33	195.46
2025-07-20	152.67	212.18
2025-07-27	84.00	135.59
2025-08-03	84.00	81.37

Gambar 3.28 Proses Pelatihan dan Hasil Validasi Auto ARIMA

2) Kecamatan Pinang

Pada Kecamatan Pinang, proses pelatihan dilakukan menggunakan metode *walk-forward validation*, yaitu model selalu belajar dari minggu-minggu sebelumnya untuk memprediksi minggu berikutnya. Cara ini meniru kondisi nyata, di mana data baru terus masuk dari waktu ke waktu dan model harus terus menyesuaikan pola yang dipelajarinya. Pada setiap iterasi, rentang data pelatihan bertambah satu minggu, lalu model dilatih ulang sebelum menghasilkan satu prediksi. Dengan demikian, performa yang diukur benar-benar menggambarkan kemampuan model dalam memprediksi data yang belum pernah dilihat sebelumnya. Proses ini dilakukan sebanyak 16 iterasi, sesuai jumlah minggu yang dialokasikan sebagai data validasi. Proses pelatihan dapat dilihat pada Gambar 3.29.

```
# 2. Latih model
prediction_log = None

if model_name == "Auto ARIMA":
    model_auto = pm.auto_arima(
        train_data,
        d=d_value,
        seasonal=False,
        stepwise=True,
        suppress_warnings=True,
        trace=False
    )
    print(f" Iterasi {i+1}: Auto ARIMA Order (p,d,q) = {model_auto.order}")
    prediction_log = model_auto.predict(n_periods=1)[0]

else: # ARIMA Manual
    model_manual = ARIMA(train_data, order=model_config)
    model_fit_manual = model_manual.fit()
    prediction_log = model_fit_manual.forecast(steps=1).iloc[0]
```

Gambar 3.29 Pelatihan Model untuk Kecamatan Pinang

Selanjutnya adalah proses pelatihan dan hasil validasi dari ARIMA Manual. Hasil validasi ARIMA Manual pada Kecamatan Pinang menunjukkan bahwa performa model cukup bervariasi di setiap minggu. Pada beberapa titik awal, seperti 6 April 2025 dan 13 April 2025, model masih menghasilkan prediksi yang cukup jauh dari nilai aktual. Namun, pada tanggal 20 April 2025, model memberikan prediksi yang hampir sama dengan data sebenarnya, menunjukkan bahwa model dapat bekerja baik ketika pola datanya stabil. Meski demikian, tantangan muncul ketika terjadi kenaikan tajam pada nilai

aktual, seperti pada 25 Mei 2025, 1 Juni 2025, dan 15 Juni 2025, di mana prediksi ARIMA Manual tertinggal jauh dari nilai aktual. Hal ini menunjukkan bahwa model kesulitan menangkap lonjakan mendadak dalam data. Proses pelatihan dan hasil validasi untuk ARIMA Manual di Kecamatan Pinang dapat dilihat pada Gambar 3.30.

Iterasi 1/16: Melatih data s/d 2025-03-30 untuk memprediksi 2025-04-06...
Iterasi 2/16: Melatih data s/d 2025-04-06 untuk memprediksi 2025-04-13...
Iterasi 3/16: Melatih data s/d 2025-04-13 untuk memprediksi 2025-04-20...
Iterasi 4/16: Melatih data s/d 2025-04-20 untuk memprediksi 2025-04-27...
Iterasi 5/16: Melatih data s/d 2025-04-27 untuk memprediksi 2025-05-04...
Iterasi 6/16: Melatih data s/d 2025-05-04 untuk memprediksi 2025-05-11...
Iterasi 7/16: Melatih data s/d 2025-05-11 untuk memprediksi 2025-05-18...
Iterasi 8/16: Melatih data s/d 2025-05-18 untuk memprediksi 2025-05-25...
Iterasi 9/16: Melatih data s/d 2025-05-25 untuk memprediksi 2025-06-01...
Iterasi 10/16: Melatih data s/d 2025-06-01 untuk memprediksi 2025-06-08...
Iterasi 11/16: Melatih data s/d 2025-06-08 untuk memprediksi 2025-06-15...
Iterasi 12/16: Melatih data s/d 2025-06-15 untuk memprediksi 2025-06-22...
Iterasi 13/16: Melatih data s/d 2025-06-22 untuk memprediksi 2025-06-29...
Iterasi 14/16: Melatih data s/d 2025-06-29 untuk memprediksi 2025-07-06...
Iterasi 15/16: Melatih data s/d 2025-07-06 untuk memprediksi 2025-07-13...
Iterasi 16/16: Melatih data s/d 2025-07-13 untuk memprediksi 2025-07-20...

	Aktual	Prediksi
Tanggal		
2025-04-06	30.00	21.14
2025-04-13	87.00	55.18
2025-04-20	92.67	92.50
2025-04-27	69.67	45.49
2025-05-04	48.33	57.73
2025-05-11	83.33	81.93
2025-05-18	144.00	119.50
2025-05-25	170.67	95.90
2025-06-01	207.00	108.92
2025-06-08	244.67	272.87
2025-06-15	242.33	331.59
2025-06-22	222.33	195.63
2025-06-29	175.00	186.14
2025-07-06	216.00	196.34
2025-07-13	174.33	272.97
2025-07-20	174.33	145.82

Gambar 3.30 Proses Pelatihan dan Hasil Validasi ARIMA Manual

Selanjutnya adalah untuk Auto ARIMA. Untuk Kecamatan Pinang, hasil validasi Auto ARIMA menghasilkan prediksi yang identik dengan ARIMA Manual pada setiap minggu. Hal ini menunjukkan bahwa Auto ARIMA secara otomatis memilih parameter model yang sama dengan model manual. Dengan demikian, performa kedua model sama persis. Ciri yang sama terlihat pada Auto ARIMA yang mampu memberikan prediksi yang baik pada minggu-minggu stabil seperti 20 April 2025, namun tetap kesulitan mengikuti lonjakan tajam di minggu-minggu seperti 25 Mei, 1 Juni, dan 15 Juni 2025.

Proses pelatihan dan hasil validasi untuk Auto ARIMA di Kecamatan Pinang dapat dilihat pada Gambar 3.31.

--- Menguji Model: Auto ARIMA ---		
Iterasi 1/16: Melatih data s/d 2025-03-30 untuk memprediksi 2025-04-06...		
Iterasi 1: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 2/16: Melatih data s/d 2025-04-06 untuk memprediksi 2025-04-13...		
Iterasi 2: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 3/16: Melatih data s/d 2025-04-13 untuk memprediksi 2025-04-20...		
Iterasi 3: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 4/16: Melatih data s/d 2025-04-20 untuk memprediksi 2025-04-27...		
Iterasi 4: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 5/16: Melatih data s/d 2025-04-27 untuk memprediksi 2025-05-04...		
Iterasi 5: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 6/16: Melatih data s/d 2025-05-04 untuk memprediksi 2025-05-11...		
Iterasi 6: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 7/16: Melatih data s/d 2025-05-11 untuk memprediksi 2025-05-18...		
Iterasi 7: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 8/16: Melatih data s/d 2025-05-18 untuk memprediksi 2025-05-25...		
Iterasi 8: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 9/16: Melatih data s/d 2025-05-25 untuk memprediksi 2025-06-01...		
Iterasi 9: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 10/16: Melatih data s/d 2025-06-01 untuk memprediksi 2025-06-08...		
Iterasi 10: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 11/16: Melatih data s/d 2025-06-08 untuk memprediksi 2025-06-15...		
Iterasi 11: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 12/16: Melatih data s/d 2025-06-15 untuk memprediksi 2025-06-22...		
Iterasi 12: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 13/16: Melatih data s/d 2025-06-22 untuk memprediksi 2025-06-29...		
Iterasi 13: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 14/16: Melatih data s/d 2025-06-29 untuk memprediksi 2025-07-06...		
Iterasi 14: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 15/16: Melatih data s/d 2025-07-06 untuk memprediksi 2025-07-13...		
Iterasi 15: Auto ARIMA Order (p,d,q) = (2, 1, 2)		
Iterasi 16/16: Melatih data s/d 2025-07-13 untuk memprediksi 2025-07-20...		
Iterasi 16: Auto ARIMA Order (p,d,q) = (2, 1, 2)		

	Aktual	Prediksi
Tanggal		
2025-04-06	30.00	21.14
2025-04-13	87.00	55.18
2025-04-20	92.67	92.50
2025-04-27	69.67	45.49
2025-05-04	48.33	57.73
2025-05-11	83.33	81.93
2025-05-18	144.00	119.50
2025-05-25	170.67	95.90
2025-06-01	207.00	108.92
2025-06-08	244.67	272.87
2025-06-15	242.33	331.59
2025-06-22	222.33	195.63
2025-06-29	175.00	186.14
2025-07-06	216.00	196.34
2025-07-13	174.33	272.97
2025-07-20	174.33	145.82

Gambar 3.31 Proses Pelatihan dan Hasil Validasi Auto ARIMA

3) Kecamatan Ciledug

Pada Kecamatan Ciledug, proses pelatihan model dilakukan menggunakan metode *walk-forward validation*. Pada pendekatan ini, model selalu dilatih menggunakan seluruh data hingga minggu tertentu, kemudian digunakan untuk memprediksi minggu berikutnya. Setelah prediksi dilakukan, satu minggu berikutnya ditambahkan ke data pelatihan, lalu model dilatih ulang dari awal. Dengan cara ini, model selalu belajar dari minggu sebelumnya untuk menghasilkan prediksi

minggu mendatang. Proses ini dilakukan sebanyak 16 iterasi, sesuai jumlah minggu data validasi. Metode ini sangat penting karena memvalidasi kemampuan model dalam memprediksi data yang benar-benar belum pernah dilihat sebelumnya. Proses pelatihan dapat dilihat pada Gambar 3.32.

```
# 2. Latih model
prediction_log = None

if model_name == "Auto ARIMA":
    model_auto = pm.auto_arima(
        train_data,
        d=d_value,
        seasonal=False,
        stepwise=True,
        suppress_warnings=True,
        trace=False
    )
    print(f" Iterasi {i+1}: Auto ARIMA Order (p,d,q) = {model_auto.order}")
    prediction_log = model_auto.predict(n_periods=1)[0]

else: # ARIMA Manual
    model_manual = ARIMA(train_data, order=model_config)
    model_fit_manual = model_manual.fit()
    prediction_log = model_fit_manual.forecast(steps=1).iloc[0]
```

Gambar 3.32 Pelatihan Model untuk Kecamatan Ciledug

Selanjutnya adalah pelatihan dan hasil validasi dari ARIMA Manual. Hasil validasi ARIMA Manual pada Kecamatan Ciledug menunjukkan bahwa performa model cenderung fluktuatif pada beberapa minggu awal. Pada minggu pertama yaitu 30 Maret 2025, prediksi model jauh lebih tinggi dibandingkan nilai aktual. Pada minggu seperti 27 April 2025, 4 Mei 2025, dan 8 Juni 2025, model tampak kesulitan mengikuti perubahan mendadak pada jumlah kasus. Meskipun begitu, ada beberapa minggu ketika ARIMA Manual mampu memberikan hasil yang cukup dekat dengan aktual, seperti 13 April 2025, 22 Juni 2025, dan 29 Juni 2025. Namun terdapat minggu-minggu dengan lonjakan prediksi yang jauh dari aktual, seperti 6 Juli 2025, ketika model memprediksi 134, padahal nilai aktual hanya 63. Proses pelatihan dan hasil validasi untuk ARIMA Manual di Kecamatan Ciledug dapat dilihat pada Gambar 3.33.

Iterasi 1/16: Melatih data s/d 2025-03-23 untuk memprediksi 2025-03-30...
 Iterasi 2/16: Melatih data s/d 2025-03-30 untuk memprediksi 2025-04-06...
 Iterasi 3/16: Melatih data s/d 2025-04-06 untuk memprediksi 2025-04-13...
 Iterasi 4/16: Melatih data s/d 2025-04-13 untuk memprediksi 2025-04-20...
 Iterasi 5/16: Melatih data s/d 2025-04-20 untuk memprediksi 2025-04-27...
 Iterasi 6/16: Melatih data s/d 2025-04-27 untuk memprediksi 2025-05-04...
 Iterasi 7/16: Melatih data s/d 2025-05-04 untuk memprediksi 2025-05-11...
 Iterasi 8/16: Melatih data s/d 2025-05-11 untuk memprediksi 2025-05-18...
 Iterasi 9/16: Melatih data s/d 2025-05-18 untuk memprediksi 2025-05-25...
 Iterasi 10/16: Melatih data s/d 2025-05-25 untuk memprediksi 2025-06-01...
 Iterasi 11/16: Melatih data s/d 2025-06-01 untuk memprediksi 2025-06-08...
 Iterasi 12/16: Melatih data s/d 2025-06-08 untuk memprediksi 2025-06-15...
 Iterasi 13/16: Melatih data s/d 2025-06-15 untuk memprediksi 2025-06-22...
 Iterasi 14/16: Melatih data s/d 2025-06-22 untuk memprediksi 2025-06-29...
 Iterasi 15/16: Melatih data s/d 2025-06-29 untuk memprediksi 2025-07-06...
 Iterasi 16/16: Melatih data s/d 2025-07-06 untuk memprediksi 2025-07-13...

	Aktual	Prediksi
Tanggal		
2025-03-30	14.00	37.13
2025-04-06	35.67	18.40
2025-04-13	73.33	64.67
2025-04-20	92.00	73.01
2025-04-27	86.67	49.86
2025-05-04	134.67	79.19
2025-05-11	178.00	206.77
2025-05-18	217.67	197.26
2025-05-25	178.67	136.52
2025-06-01	158.67	134.79
2025-06-08	144.33	212.71
2025-06-15	148.33	187.42
2025-06-22	141.33	111.61
2025-06-29	111.33	102.28
2025-07-06	63.67	134.28
2025-07-13	63.67	97.69

Gambar 3.33 Proses Pelatihan dan Hasil Validasi ARIMA Manual

Berbeda dengan ARIMA Manual, model Auto ARIMA memberikan hasil prediksi yang lebih konsisten dan lebih mendekati nilai aktual di sebagian besar minggu. Pada beberapa minggu, seperti 13 April 2025, 20 April 2025, 15 Juni 2025, dan 22 Juni 2025, Auto ARIMA menghasilkan prediksi yang sangat dekat dengan nilai aktual. Bahkan pada 13 Juli 2025, prediksi model sama persis dengan data aktual yaitu 63.67. Walaupun masih ada beberapa minggu misalnya 30 Maret 2025 dan 6 Juli 2025 secara umum performanya lebih baik dibandingkan ARIMA Manual. Proses pelatihan dan hasil validasi untuk Auto ARIMA di Kecamatan Ciledug dapat dilihat pada Gambar 3.34.

```

--- Menguji Model: Auto ARIMA ---
Iterasi 1/16: Melatih data s/d 2025-03-23 untuk memprediksi 2025-03-30...
  Iterasi 1: Auto ARIMA Order (p,d,q) = (0, 1, 3)
Iterasi 2/16: Melatih data s/d 2025-03-30 untuk memprediksi 2025-04-06...
  Iterasi 2: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 3/16: Melatih data s/d 2025-04-06 untuk memprediksi 2025-04-13...
  Iterasi 3: Auto ARIMA Order (p,d,q) = (4, 1, 0)
Iterasi 4/16: Melatih data s/d 2025-04-13 untuk memprediksi 2025-04-20...
  Iterasi 4: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 5/16: Melatih data s/d 2025-04-20 untuk memprediksi 2025-04-27...
  Iterasi 5: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 6/16: Melatih data s/d 2025-04-27 untuk memprediksi 2025-05-04...
  Iterasi 6: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 7/16: Melatih data s/d 2025-05-04 untuk memprediksi 2025-05-11...
  Iterasi 7: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 8/16: Melatih data s/d 2025-05-11 untuk memprediksi 2025-05-18...
  Iterasi 8: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 9/16: Melatih data s/d 2025-05-18 untuk memprediksi 2025-05-25...
  Iterasi 9: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 10/16: Melatih data s/d 2025-05-25 untuk memprediksi 2025-06-01...
  Iterasi 10: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 11/16: Melatih data s/d 2025-06-01 untuk memprediksi 2025-06-08...
  Iterasi 11: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 12/16: Melatih data s/d 2025-06-08 untuk memprediksi 2025-06-15...
  Iterasi 12: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 13/16: Melatih data s/d 2025-06-15 untuk memprediksi 2025-06-22...
  Iterasi 13: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 14/16: Melatih data s/d 2025-06-22 untuk memprediksi 2025-06-29...
  Iterasi 14: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 15/16: Melatih data s/d 2025-06-29 untuk memprediksi 2025-07-06...
  Iterasi 15: Auto ARIMA Order (p,d,q) = (0, 1, 0)
Iterasi 16/16: Melatih data s/d 2025-07-06 untuk memprediksi 2025-07-13...
  Iterasi 16: Auto ARIMA Order (p,d,q) = (0, 1, 0)

```

Tanggal	Aktual	Prediksi
2025-03-30	14.00	39.32
2025-04-06	35.67	14.00
2025-04-13	73.33	65.13
2025-04-20	92.00	73.33
2025-04-27	86.67	92.00
2025-05-04	134.67	86.67
2025-05-11	178.00	134.67
2025-05-18	217.67	178.00
2025-05-25	178.67	217.67
2025-06-01	158.67	178.67
2025-06-08	144.33	158.67
2025-06-15	148.33	144.33
2025-06-22	141.33	148.33
2025-06-29	111.33	141.33
2025-07-06	63.67	111.33
2025-07-13	63.67	63.67

Gambar 3.34 Proses Pelatihan dan Hasil Validasi Auto ARIMA

3.3.1.11 Evaluasi kinerja model

Setelah proses pelatihan model selesai, langkah selanjutnya adalah mengevaluasi seberapa baik model tersebut bekerja dalam memprediksi data. Penilaian ini dilakukan menggunakan empat metrik, yaitu MAE, RMSE, MAPE, dan *R-Squared*. Keempat metrik ini digunakan karena masing-masing memberikan gambaran yang berbeda tentang kualitas prediksi. MAE dan RMSE membantu

menunjukkan seberapa besar rata-rata kesalahan model dibandingkan nilai asli. RMSE lebih sensitif terhadap kesalahan yang besar karena nilai *error* dikuadratkan sebelum dihitung rata-ratanya. MAPE menunjukkan kesalahan dalam bentuk persentase sehingga memudahkan dalam melihat seberapa besar model meleset dibandingkan nilai sebenarnya. Sementara itu, *R-Squared* mengukur seberapa baik model mampu mengikuti pola data secara keseluruhan. Pada tahap ini, input yang digunakan adalah hasil prediksi model. Proses evaluasi dilakukan menggunakan empat metrik performa, yaitu MAE, RMSE, MAPE, dan *R-Squared* untuk mengukur performa model. Output dari tahap ini berupa nilai evaluasi dalam bentuk tabel model pada tiga kecamatan.

Tabel 3.2 Metrik Evaluasi untuk ARIMA Manual

	MAE	RMSE	MAPE	<i>R-Squared</i>
Karawaci	48.63	48.63	29.60 %	0.1381
Pinang	35.95	35.95	23.69 %	0.4951
Ciledug	32.90	32.90	41.32 %	0.5327

Tabel 3.2 merupakan metrik evaluasi untuk ARIMA Manual. Performa ARIMA Manual menunjukkan hasil yang berbeda-beda di setiap kecamatan. Pada Kecamatan Karawaci, nilai MAE dan RMSE yang berada di angka 48.63 menunjukkan bahwa rata-rata kesalahan prediksi masih cukup besar. Nilai MAPE sebesar 29.60% juga menunjukkan bahwa prediksi masih sering meleset dari nilai sebenarnya. Hal ini dilihat dari nilai *R-Squared* yang sangat rendah, yaitu 0.1381, yang berarti model belum mampu menjelaskan pola data dengan baik. Untuk Kecamatan Pinang, hasilnya sedikit lebih baik dibandingkan Karawaci. Nilai MAE dan RMSE sebesar 35.95 menunjukkan kesalahan prediksi yang lebih kecil, dan MAPE 23.69% menandakan tingkat kesalahan persentase yang masih cukup wajar. Nilai *R-Squared* sebesar 0.4951 menunjukkan bahwa hampir setengah

variasi data dapat dijelaskan oleh model, sehingga performanya lebih stabil. Sedangkan untuk Kecamatan Ciledug, nilai MAE dan RMSE 32.90 merupakan yang paling rendah di antara ketiga kecamatan, menunjukkan kesalahan prediksi yang paling kecil secara rata-rata. Namun, nilai MAPE yang cukup tinggi yaitu 41.32% menandakan bahwa model kadang meleset jauh pada beberapa titik data. Meski begitu, nilai *R-Squared* sebesar 0.5327 adalah yang tertinggi, menunjukkan bahwa model ARIMA Manual cukup mampu menangkap pola data di wilayah ini.

Tabel 3.3 Metrik Evaluasi untuk Auto ARIMA

	MAE	RMSE	MAPE	<i>R-Squared</i>
Karawaci	46.95	46.95	31.40 %	0.3556
Pinang	35.95	35.95	23.69 %	0.4951
Ciledug	23.26	23.26	31.95 %	0.7380

Tabel 3.3 merupakan metrik evaluasi untuk Auto ARIMA. Performa Auto ARIMA terlihat memberikan hasil yang lebih baik dibandingkan ARIMA Manual di beberapa kecamatan. Pada Kecamatan Karawaci, model menghasilkan MAE dan RMSE sebesar 46.95, sedikit lebih kecil daripada ARIMA Manual. Hal ini menunjukkan bahwa kesalahan prediksinya sedikit lebih rendah. Namun, nilai MAPE mencapai 31.40%, yang berarti prediksi masih sering meleset secara persentase. Meskipun begitu, nilai *R-Squared* 0.3556 menunjukkan peningkatan yang cukup jelas, karena model sudah mulai lebih mampu mengikuti pola data dibandingkan versi manual. Pada Kecamatan Pinang, hasil Auto ARIMA sama persis dengan ARIMA Manual. MAE dan RMSE berada di angka 35.95, dengan MAPE sebesar 23.69%. Nilai *R-Squared* 0.4951 juga tidak berubah. Kondisi ini terjadi karena Auto ARIMA memilih konfigurasi model yang sama atau sangat mirip dengan model manual. Dengan kata lain, baik model manual maupun otomatis memberikan kualitas

prediksi yang sama untuk wilayah Pinang. Untuk Kecamatan Ciledug, Auto ARIMA memberikan hasil terbaik dibandingkan semua kecamatan lainnya. Nilai MAE dan RMSE yang hanya 23.26 menunjukkan kesalahan prediksi yang rendah. MAPE sebesar 31.95% masih menunjukkan beberapa kesalahan persentase, tetapi tidak setinggi di kecamatan lain. Yang paling menonjol adalah nilai R-Squared 0.7380, yang merupakan yang tertinggi dan menunjukkan bahwa Auto ARIMA mampu menangkap sebagian besar pola data mingguan secara akurat. Secara keseluruhan, Auto ARIMA memberikan peningkatan performa terutama di Karawaci dan Ciledug, sementara di Pinang performanya sama dengan model manual.

3.3.1.12 Hasil peramalan untuk delapan minggu ke depan

Setelah model selesai dilatih dan dievaluasi pada data historis, langkah selanjutnya membuat prediksi ke depan. Pada tahap ini, model digunakan untuk meramalkan jumlah kasus *stunting* selama 8 minggu berikutnya. Proses ini dilakukan dengan memanfaatkan pola yang telah dipelajari model dari data mingguan sebelumnya. Hasil ramalan ini sangat penting karena dapat memberikan gambaran awal mengenai potensi peningkatan atau penurunan kasus *stunting*, sehingga pihak terkait dapat merencanakan langkah pencegahan lebih awal. Pada tahap ini, input yang digunakan adalah model dari hasil pelatihan sebelumnya. Proses yang dilakukan berupa ramalan untuk memprediksi jumlah kasus selama 8 minggu ke depan menggunakan model ARIMA Manual dan Auto ARIMA. Output dari tahap ini berupa hasil ramalan dalam bentuk numerik dan visualisasi grafik di setiap kecamatan. Berikut merupakan ramalan untuk tiga kecamatan:

1) Kecamatan Karawaci

Pada model ARIMA Manual, model menghasilkan ramalan dengan kecenderungan menurun secara bertahap. Prediksi menunjukkan bahwa jumlah kasus *stunting*

diperkirakan turun dari sekitar 90 kasus pada minggu pertama ramalan pada 10 Agustus 2025 menjadi sekitar 22 kasus pada minggu terakhir ramalan 28 September 2025. Hasil ini menggambarkan di mana model cenderung memperkirakan jumlah kasus akan menurun dan tetap stabil. Proses dan hasil ramalan ARIMA Manual di Kecamatan Karawaci dapat dilihat pada Gambar 3.35.

```
final_manual = ARIMA(data_series_log, order=MANUAL_ORDER)
model_fit_manual = final_manual.fit()
forecast_manual_log = model_fit_manual.forecast(steps=forecast_horizon)
forecast_manual = np.exp(forecast_manual_log) - 1
forecast_manual[forecast_manual < 0] = 0

last_date = data_series_log.index.max()
forecast_index = [last_date + pd.DateOffset(weeks=i+1) for i in range(forecast_horizon)]

df_forecast_manual = pd.DataFrame({
    'Tanggal': forecast_index,
    'Ramalan': forecast_manual
}).set_index('Tanggal')

--- Ramalan 8 Minggu Manual ARIMA ---
   Tanggal      Ramalan
2025-08-10    90.65
2025-08-17    83.86
2025-08-24    53.39
2025-08-31    41.40
2025-09-07    39.57
2025-09-14    39.89
2025-09-21    30.72
2025-09-28    22.51
```

Gambar 3.35 Ramalan ARIMA Manual di Kecamatan Karawaci

Berbeda dengan model manual, Auto ARIMA menghasilkan ramalan dengan pola yang lebih fluktuatif dan cenderung berada pada angka yang lebih tinggi. Model ini secara otomatis memilih parameter terbaik yaitu ARIMA(3,2,3) berdasarkan pemilihan nilai AIC terendah. Prediksi dimulai pada sekitar 110 kasus di minggu pertama pada 10 Agustus 2025 dan bergerak naik hingga mencapai 133 kasus di minggu berikutnya, kemudian mengalami naik-turun di kisaran 86-114 kasus hingga akhir periode ramalan. Pola ini menunjukkan bahwa Auto ARIMA menangkap dinamika data yang lebih variatif dan tidak memperkirakan penurunan tajam seperti pada model manual. Proses dan hasil ramalan Auto ARIMA di Kecamatan Karawaci dapat dilihat pada Gambar 3.36.

```

# 2. Auto ARIMA Forecast
final_auto = pm.auto_arima(
    data_series_log,
    d=d_value,
    seasonal=False,
    stepwise=True,
    suppress_warnings=True,
    trace=False
)
print(f"Order Terbaik Auto ARIMA Final: {final_auto.order}")
forecast_auto_log = final_auto.predict(n_periods=forecast_horizon)
forecast_auto = np.exp(forecast_auto_log) - 1
forecast_auto[forecast_auto < 0] = 0

df_forecast_auto = pd.DataFrame({
    'Tanggal': forecast_index,
    'Ramalan': forecast_auto
}).set_index('Tanggal')

--- Ramalan 8 Minggu Auto ARIMA ---
   Ramalan
Tanggal
2025-08-10  110.02
2025-08-17  133.32
2025-08-24  100.55
2025-08-31  86.67
2025-09-07  96.79
2025-09-14  114.29
2025-09-21  104.26
2025-09-28  90.57

```

Gambar 3.36 Ramalan Auto ARIMA di Kecamatan Karawaci

2) Kecamatan Pinang

Kecamatan Pinang menunjukkan pola yang cenderung meningkat di awal, lalu bergerak naik-turun pada minggu-minggu berikutnya. Prediksi dimulai pada sekitar 158 kasus dan terus meningkat hingga mencapai puncak di sekitar 194 kasus pada minggu ketiga ramalan pada 10 Agustus 2025. Setelah itu, model memperkirakan penurunan sekitar 161 kasus, sebelum kembali naik hingga mendekati 189 kasus menjelang minggu terakhir ramalan. Pola ini menunjukkan bahwa ARIMA Manual membaca dinamika data Pinang sebagai data yang memiliki variasi namun masih berada dalam kisaran angka tinggi, dengan kecenderungan fluktuatif namun stabil di rentang 160–190 kasus. Proses dan hasil ramalan untuk ARIMA Manual di Kecamatan Pinang dapat dilihat pada Gambar 3.37.

```

final_manual = ARIMA(data_series_log, order=MANUAL_ORDER)
model_fit_manual = final_manual.fit()
forecast_manual_log = model_fit_manual.forecast(steps=forecast_horizon)
forecast_manual = np.exp(forecast_manual_log) - 1
forecast_manual[forecast_manual < 0] = 0

last_date = data_series_log.index.max()
forecast_index = [last_date + pd.DateOffset(weeks=i+1) for i in range(forecast_horizon)]

df_forecast_manual = pd.DataFrame({
    'Tanggal': forecast_index,
    'Ramalan': forecast_manual
}).set_index('Tanggal')

```

```

--- Ramalan 8 Minggu Manual ARIMA ---
    Ramalan
Tanggal
2025-07-27 158.12
2025-08-03 174.23
2025-08-10 194.78
2025-08-17 182.27
2025-08-24 161.98
2025-08-31 168.02
2025-09-07 188.99
2025-09-14 187.32

```

Gambar 3.37 Ramalan ARIMA Manual di Kecamatan Pinang

Berbeda dari kasus Karawaci sebelumnya, hasil Auto ARIMA untuk Kecamatan Pinang ternyata sama persis dengan hasil ARIMA Manual di seluruh minggu ramalan. Model otomatis memilih parameter terbaik yaitu ARIMA(2,1,2), yang ternyata sama dengan konfigurasi model manual sehingga menghasilkan prediksi yang identik pada setiap minggu ramalan. Proses dan hasil ramalan untuk Auto ARIMA di Kecamatan Karawaci dapat dilihat pada Gambar 3.38.

```

# 2. Auto ARIMA Forecast
final_auto = pm.auto_arima(
    data_series_log,
    d=d_value,
    seasonal=False,
    stepwise=True,
    suppress_warnings=True,
    trace=False
)
print(f"Order Terbaik Auto ARIMA Final: {final_auto.order}")
forecast_auto_log = final_auto.predict(n_periods=forecast_horizon)
forecast_auto = np.exp(forecast_auto_log) - 1
forecast_auto[forecast_auto < 0] = 0

df_forecast_auto = pd.DataFrame({
    'Tanggal': forecast_index,
    'Ramalan': forecast_auto
}).set_index('Tanggal')
--- Ramalan 8 Minggu Auto ARIMA ---
    Ramalan
Tanggal
2025-07-27 158.12
2025-08-03 174.23
2025-08-10 194.78
2025-08-17 182.27
2025-08-24 161.98
2025-08-31 168.02
2025-09-07 188.99
2025-09-14 187.32

```

Gambar 3.38 Ramalan Auto ARIMA di Kecamatan Pinang

3) Kecamatan Ciledug

Pada model ARIMA Manual, hasil ramalan menunjukkan pola yang naik-turun. Prediksi dimulai dari sekitar 61.99 kasus pada minggu pertama ramalan di tanggal 20 Juli 2025, kemudian

turun ke 49.50 kasus, dan kembali meningkat hingga mencapai puncak sekitar 93.64 kasus pada pertengahan periode ramalan di 17 Agustus 2025. Setelah itu, nilai kembali bergerak turun dan naik. Dengan demikian, model manual memberikan gambaran bahwa kondisi kasus *stunting* di Ciledug berpotensi mengalami naik-turun dalam beberapa minggu ke depan, bukan bergerak stabil. Proses dan hasil ramalan ARIMA Manual di Kecamatan Ciledug dapat dilihat pada Gambar 3.39.

```
final_manual = ARIMA(data_series_log, order=MANUAL_ORDER)
model_fit_manual = final_manual.fit()
forecast_manual_log = model_fit_manual.forecast(steps=forecast_horizon)
forecast_manual = np.exp(forecast_manual_log) - 1
forecast_manual[forecast_manual < 0] = 0

last_date = data_series_log.index.max()
forecast_index = [last_date + pd.DateOffset(weeks=i+1) for i in range(forecast_horizon)]

df_forecast_manual = pd.DataFrame({
    'Tanggal': forecast_index,
    'Ramalan': forecast_manual
}).set_index('Tanggal')

--- Ramalan 8 Minggu Manual ARIMA ---

Ramalan
Tanggal
2025-07-20    61.99
2025-07-27    49.50
2025-08-03    56.28
2025-08-10    85.23
2025-08-17    93.64
2025-08-24    71.50
2025-08-31    66.23
2025-09-07    93.03
```

Gambar 3.39 Ramalan ARIMA Manual di Kecamatan Ciledug

Berbeda dengan pendekatan manual, model Auto ARIMA menghasilkan ramalan yang jauh lebih stabil. Seluruh prediksi selama 8 minggu berada di sekitar angka 63.67 kasus dan tidak menunjukkan perubahan berarti dari minggu ke minggu. Model otomatis memilih parameter terbaik yaitu ARIMA(0,1,0), yang menghasilkan pola prediksi konstan karena model menilai data historis tidak menunjukkan fluktuasi signifikan. Pola ramalan yang datar ini mengindikasikan bahwa Auto ARIMA menilai data historis Ciledug sebagai pola yang cenderung stabil dalam jangka pendek, sehingga model memilih parameter yang menghasilkan prediksi konstan. Dengan hasil tersebut, Auto

ARIMA memberikan pandangan bahwa jumlah kasus *stunting* di Kecamatan Ciledug tidak menunjukkan perubahan tajam pada beberapa minggu mendatang. Proses dan hasil ramalan Auto ARIMA di Kecamatan Ciledug dapat dilihat pada Gambar 3.40.

```
# 2. Auto ARIMA Forecast
final_auto = pm.auto_arima(
    data_series_log,
    d=1,value,
    seasonal=False,
    stepwise=True,
    suppress_warnings=True,
    trace=False
)
print(f"Order Terbaik Auto ARIMA Final: {final_auto.order}")
forecast_auto_log = final_auto.predict(n_periods=forecast_horizon)
forecast_auto = np.exp(forecast_auto_log) - 1
forecast_auto[forecast_auto < 0] = 0

df_forecast_auto = pd.DataFrame({
    'Tanggal': forecast_index,
    'Ramalan': forecast_auto
}).set_index('Tanggal')

--- Ramalan 8 Minggu Auto ARIMA ---
Ramalan
Tanggal
2025-07-20    63.67
2025-07-27    63.67
2025-08-03    63.67
2025-08-10    63.67
2025-08-17    63.67
2025-08-24    63.67
2025-08-31    63.67
2025-09-07    63.67
```

Gambar 3.40 Ramalan Auto ARIMA di Kecamatan Ciledug

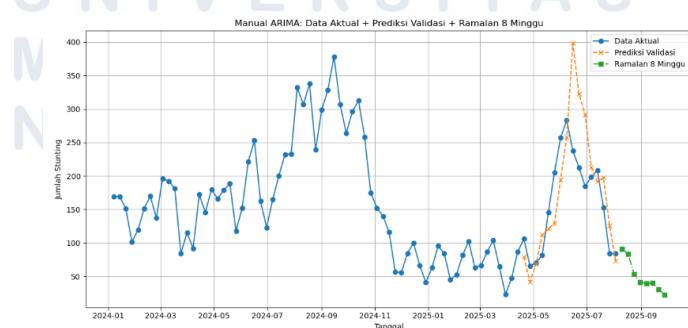
3.3.1.13 Visualisasi akhir hasil analisis dan peramalan

Setelah seluruh proses pemodelan selesai dilakukan, langkah berikutnya adalah menyajikan visualisasi akhir. Visualisasi ini dibuat untuk memberikan gambaran lengkap mengenai bagaimana model bekerja dalam mengikuti pola data historis, bagaimana hasil prediksi pada tahap validasi, serta bagaimana model memperkirakan kondisi di masa mendatang. Dalam satu grafik, ditampilkan tiga komponen utama, yaitu data aktual, prediksi validasi, dan ramalan untuk 8 minggu ke depan. Pada tahap ini, input yang digunakan berupa data aktual mingguan, hasil prediksi validasi model, dan hasil ramalan untuk 8 minggu ke depan. Proses yang dilakukan adalah membuat grafik komparatif untuk menampilkan ketiga komponen tersebut dalam satu visual agar perbandingan pola dapat terlihat jelas. Output dari tahap ini berupa visualisasi akhir yang menunjukkan data historis,

performa model pada validasi, serta prediksi masa depan untuk setiap kecamatan. Berikut visualisasi akhir untuk tiga kecamatan:

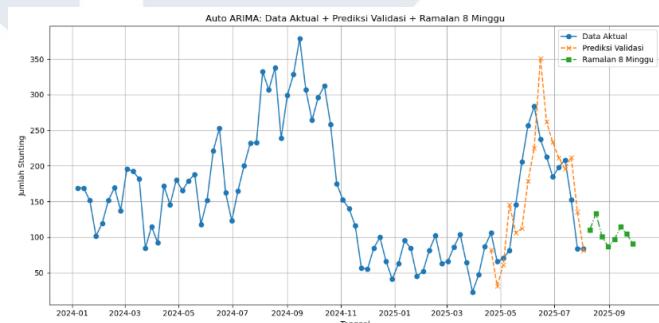
1) Kecamatan Karawaci

Pada grafik ARIMA Manual, garis biru menunjukkan data aktual jumlah kasus *stunting* di Karawaci. Polanya terlihat sangat tidak stabil, dengan kenaikan dan penurunan yang tajam. Misalnya, kasus sempat melonjak sangat tinggi di sekitar September 2024 dan pertengahan 2025, mencapai angka di atas 300 kasus. Namun setelah itu, kasus turun sangat drastis hingga kembali ke angka di bawah 100. Pola yang naik-turun ekstrem ini menggambarkan bahwa kondisi *stunting* di Karawaci cukup dinamis dan mudah berubah. Garis oranye putus-putus adalah hasil prediksi validasi dari model ARIMA Manual. Garis ini digunakan untuk melihat apakah model mampu mengikuti pola data sebenarnya. Pada fase-fase akhir, terutama saat terjadi lonjakan besar dan penurunan tajam, garis oranye terlihat cukup dekat dengan garis biru yang menandakan bahwa model manual berhasil memahami tren terbaru dengan cukup baik, sehingga prediksinya tidak jauh berbeda dari data asli. Sementara itu, garis hijau menunjukkan ramalan untuk 8 minggu ke depan. Pada bagian ini terlihat bahwa model memprediksi tren penurunan akan terus berlanjut. Nilai ramalan semakin mendatar dan bergerak menuju angka yang lebih rendah, berkisar pada 20-50 kasus. Visualisasi akhir untuk ARIMA Manual di Kecamatan Karawaci dapat dilihat pada Gambar 3.41.



Gambar 3.41 Visualisasi Akhir ARIMA Manual di Kecamatan Karawaci

Pada grafik Auto ARIMA, garis biru tetap menunjukkan data asli jumlah kasus *stunting*. Polanya sama seperti sebelumnya sangat fluktuatif, dengan lonjakan dan penurunan ekstrem. Garis oranye putus-putus pada visualisasi Auto ARIMA adalah hasil dari model otomatis. Berbeda dari model manual, garis prediksi Auto ARIMA cenderung memberikan nilai yang sedikit lebih tinggi daripada data sebenarnya pada beberapa bagian, terutama saat terjadi lonjakan besar mendekati pertengahan 2025. Meskipun bentuk polanya berhasil mengikuti arah naik-turunnya data, angka yang dihasilkan kadang lebih tinggi dari kondisi asli. Untuk ramalan 8 minggu ke depan (garis hijau), Auto ARIMA menunjukkan pola yang lebih fluktuatif dibanding model manual. Ramalannya tidak langsung turun ke angka rendah, melainkan berada di kisaran 90–130 kasus. Visualisasi akhir Auto ARIMA di Kecamatan Karawaci dapat dilihat pada Gambar 3.42.

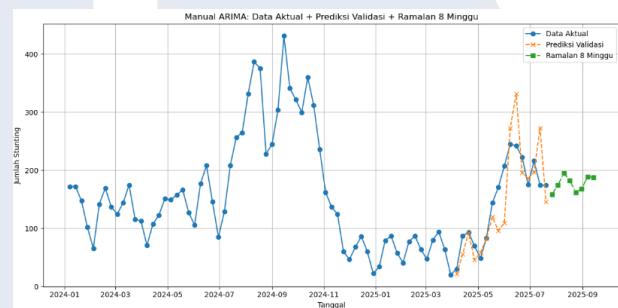


Gambar 3.42 Visualisasi Akhir Auto ARIMA di Kecamatan Karawaci

2) Kecamatan Pinang

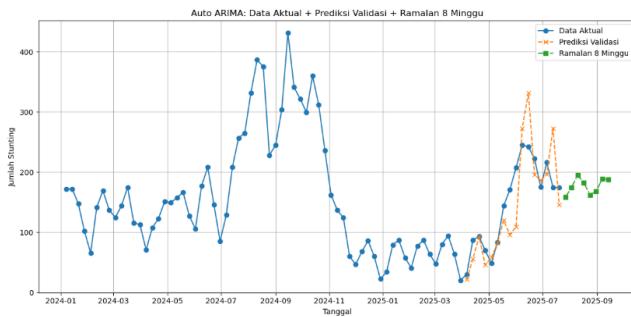
Pada grafik ARIMA Manual, garis biru menggambarkan data aktual jumlah kasus *stunting* di Kecamatan Pinang. Di akhir tahun 2024, terjadi lonjakan besar yang membuat jumlah kasus lebih dari 400 kasus. Namun setelah puncak tersebut, angka *stunting* turun pada awal 2025. Meskipun begitu, tren kemudian kembali bergerak naik dan mencapai kisaran 200 an kasus di pertengahan 2025. Pola naik-turun yang berulang ini menunjukkan bahwa kondisi *stunting* di Pinang belum stabil dan mudah berubah dalam waktu singkat. Garis oranye

putus-putus menunjukkan hasil prediksi validasi. Model memprediksi nilai yang lebih tinggi dari data sebenarnya. Misalnya, saat data aktual berada di kisaran 200–250 kasus, model justru mengestimasi angka hingga lebih dari 300 kasus. Untuk ramalan 8 minggu mendatang, kasus tetap berfluktuasi di kisaran 150–200 kasus. Tidak ada prediksi lonjakan besar seperti di tahun sebelumnya, tetapi juga tidak ada tanda penurunan drastis dalam waktu dekat. Visualisasi akhir ARIMA Manual di Kecamatan Pinang dapat dilihat pada Gambar 3.43.



Gambar 3.43 Visualisasi Akhir ARIMA Manual di Kecamatan Pinang

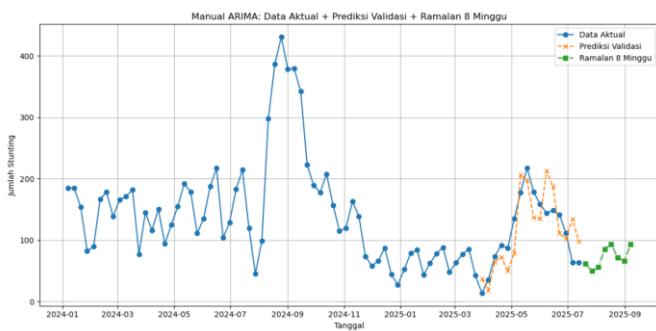
Sama seperti pada model manual, terdapat lonjakan besar di akhir 2024, penurunan tajam di awal 2025, lalu kenaikan kembali di pertengahan 2025. Fluktuasi ekstrem ini memperlihatkan bahwa kasus *stunting* di Pinang sangat sensitif dan dapat berubah drastis dalam waktu singkat. Garis oranye putus-putus pada grafik Auto ARIMA menunjukkan bagaimana model otomatis membaca pola tersebut. Ketika data aktual mulai naik pada Mei–Juni 2025, model langsung memprediksi kenaikan daripada kenyataan, dengan ramalan yang mencapai angka 300-an. Meskipun begitu, pola naik-turunnya masih mengikuti arah data sebenarnya. Untuk prediksi 8 minggu ke depan, garis hijau memperlihatkan bahwa model otomatis memproyeksikan pergerakan yang fluktuatif namun stabil di kisaran 160–190 kasus. Visualisasi akhir Auto ARIMA di Kecamatan Pinang dapat dilihat pada Gambar 3.44.



Gambar 3.44 Visualisasi Akhir Auto ARIMA di Kecamatan Pinang

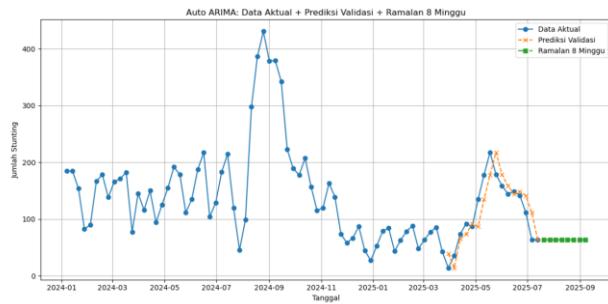
3) Kecamatan Ciledug

Pada grafik ARIMA Manual, garis biru menggambarkan data aktual kasus *stunting* di Kecamatan Ciledug yang mengalami fluktuasi cukup ekstrem. Pada periode September–Oktober 2024, sempat mencapai puncak yang sangat tinggi hingga melewati angka 400 kasus. Setelah itu, grafik menunjukkan penurunan yang cukup dalam. Di pertengahan 2025, pola naik-turun kembali dengan jumlah kasus sempat naik hingga kisaran 200-an, kemudian turun tajam kembali ke angka di bawah 100 kasus. Garis oranye putus-putus menunjukkan hasil prediksi validasi dari model ARIMA Manual. Pada bagian ini, model terlihat mengikuti pola data terbaru. Ketika data aktual ada kenaikan kecil di pertengahan 2025, garis oranye ikut naik. Ketika turun tajam ke angka rendah, garis oranye juga mengikuti penurunan tersebut. Kedekatan antara garis oranye dan biru menunjukkan bahwa model manual yang digunakan sudah cukup baik dalam menangkap tren terkini dan mampu membaca perubahan yang terjadi pada data. Untuk prediksi 8 minggu mendatang, garis hijau menunjukkan bahwa model memperkirakan adanya sedikit kenaikan kembali setelah penurunan tajam. Ramalan tidak menunjukkan penurunan lanjutan, melainkan fluktuasi ringan di kisaran angka 50 hingga 100 kasus. Prediksi ini memberikan kesimpulan bahwa meskipun kondisi saat ini sedang membaik, terdapat kemungkinan bahwa angka *stunting* akan naik kembali dalam dua bulan ke depan. Visualisasi akhir ARIMA Manual di Kecamatan Ciledug dapat dilihat pada Gambar 3.45.



Gambar 3.45 Visualisasi Akhir ARIMA Manual di Kecamatan Ciledug

Pada grafik Auto ARIMA, garis biru menunjukkan data aktual kasus *stunting* yang sangat fluktuatif. Pola data di Ciledug memperlihatkan lonjakan besar di akhir 2024, kemudian penurunan, dan disusul kenaikan kecil di pertengahan 2025 sebelum akhirnya turun tajam ke angka yang cukup rendah pada periode terbaru. Penurunan tajam di bagian akhir ini terlihat sebagai tren yang cukup kuat menuju kondisi yang lebih baik. Garis oranye putus-putus menggambarkan hasil pembelajaran dari model Auto ARIMA. Pada bagian prediksi validasi, model terlihat sangat mampu meniru pola penurunan yang terjadi di data aktual. Garis oranye hampir menempel pada garis biru, terutama pada fase penurunan terbaru. Untuk prediksi 8 minggu ke depan, garis hijau memperlihatkan hasil yang berbeda dari model manual. Model otomatis memprediksi bahwa angka *stunting* akan stabil di angka rendah, yaitu sekitar 60-an kasus, tanpa adanya kenaikan maupun penurunan berarti. Bentuk garis yang mendatar menunjukkan bahwa Auto ARIMA membaca kondisi saat ini sebagai titik stabil baru dan memperkirakan bahwa keadaan akan tetap berada di angka tersebut selama dua bulan mendatang. Visualisasi akhir Auto ARIMA di Kecamatan Ciledug dapat dilihat pada Gambar 3.46.



Gambar 3.46 Visualisasi Akhir Auto ARIMA di Kecamatan Ciledug

3.3.1.14 Penyusunan dokumentasi kode

Pada tahap ini, input yang digunakan berupa seluruh proses analisis yang dilakukan di *Jupyter Notebook* dengan bahasa pemrograman *python*. Seluruh hasil analisis yang sudah dikerjakan, dievaluasi secara langsung oleh Kepala Bidang *e-Government*, Kepala Tim Kerja sebagai *supervisor 1*, dan *supervisor 2*. Hasil yang telah selesai dikerjakan dinyatakan diterima oleh pihak terkait dan disimpan oleh *supervisor 2* sebagai arsip. Seluruh proses analisis disusun dalam bentuk dokumentasi yang rapi dan mudah dipahami. Dokumentasi ini bertujuan agar setiap langkah mulai dari persiapan data, pembuatan model ARIMA, evaluasi hasil, hingga penyusunan ramalan dapat dipelajari dan digunakan kembali oleh tim pengembang lain tanpa kebingungan. Setiap bagian kode diberi penjelasan menggunakan *markdown*, sehingga tim pengembang lain dapat memahami apa tujuan dari kode tersebut, data apa yang sedang diproses. Output dari tahap ini berupa dokumentasi kode yang rapi, sistematis, dan dapat digunakan kembali oleh tim pengembang lain tanpa hambatan. Dengan dokumentasi yang jelas dan terstruktur, *Notebook* tidak hanya sekadar kumpulan kode, tetapi juga panduan kerja yang dapat mempermudah proses analisis.

3.3.1.15 Pelaksanaan kegiatan magang sesuai jadwal kerja

Pada tahap ini, input yang digunakan adalah jadwal kerja yang telah ditetapkan sebagai pedoman dalam melaksanakan tugas harian.

Proses yang dilakukan adalah mematuhi jadwal kerja yang telah disepakati dan menjalankan setiap tugas sesuai dengan waktu yang sudah ditentukan sejak awal. Hal ini penting untuk memastikan seluruh proses penggerjaan proyek berjalan lancar. Jadwal kerja yang diterapkan adalah *hybrid* yaitu *Work from Office* dari hari Senin hingga Kamis. Jam kerja dimulai pukul 07.30 WIB hingga 17.30 WIB, dengan waktu istirahat pukul 12.00 WIB – 13.00 WIB dan *Work from Home* di hari Jumat. Output dari tahap ini adalah pelaksanaan pekerjaan yang lebih teratur, penyelesaian tugas yang tepat waktu, serta koordinasi yang lebih efektif bersama tim. Dengan mengikuti jadwal, setiap tugas dapat selesai tepat waktu. Selain itu, disiplin terhadap jadwal membantu menghindari penumpukan pekerjaan serta memastikan bahwa proyek dapat diselesaikan sesuai target yang telah direncanakan bersama.

3.3.2 Kendala yang Ditemukan

Pada proses kegiatan magang, terdapat beberapa kendala yang muncul baik dari sisi teknis maupun proses kerja. Kendala-kendala ini menjadi bagian dari tantangan yang harus dihadapi dalam menyelesaikan tugas analisis dan pemodelan data. Berikut merupakan kendala yang ditemukan selama proses pelaksanaan magang:

1) Rentang Data

Data yang diberikan pada tahap awal hanya mencakup periode satu tahun yaitu dari Januari – Desember 2024. Rentang waktu yang terbatas ini membuat analisis tren jangka panjang sulit dilakukan dan berdampak pada hasil pemodelan.

2) Kurangnya Pengalaman dalam Menggunakan Algoritma *Time Series*

Proses pemodelan menggunakan ARIMA memerlukan pemahaman teknis tertentu. Pada tahap awal, model ini belum sepenuhnya dikuasai sehingga membutuhkan waktu tambahan untuk mempelajari cara kerja dan penerapannya.

3) Masuknya Data Kecamatan di Luar Kota Tangerang

Dalam proses pengolahan data ditemukan beberapa baris data yang berasal dari kecamatan di luar Kota Tangerang. Data ini tidak relevan dengan ruang lingkup analisis yang hanya mencakup kecamatan di Kota Tangerang, khususnya di tiga kecamatan yaitu Karawaci, Pinang, dan Ciledug. Keberadaan data yang tidak sesuai wilayah ini berpotensi mengganggu hasil pemodelan, karena dapat menambah *noise* atau pola yang tidak seharusnya dianalisis.

3.3.3 Solusi atas Kendala yang Ditemukan

Berbagai langkah dilakukan untuk mengatasi kendala yang muncul selama proses magang. Solusi-solusi ini membantu dalam memastikan pekerjaan tetap berjalan dengan baik meskipun terdapat beberapa kendala. Berikut merupakan solusi dari kendala yang ditemukan:

1) Penambahan Rentang Data untuk Mendukung Analisis Tren

Setelah melakukan koordinasi, data tambahan berhasil diperoleh hingga Agustus 2025. Dengan rentang data yang lebih panjang, proses analisis tren menjadi lebih akurat dan mendukung hasil prediksi yang lebih stabil.

2) Meningkatkan Pemahaman Algoritma melalui Pembelajaran Mandiri

Untuk mengatasi keterbatasan pemahaman awal, dilakukan pembelajaran mandiri melalui *platform* seperti *YouTube*. Cara ini membantu dalam memahami proses pemodelan secara lebih mendalam.

3) Melakukan Penyaringan Wilayah

Untuk mengatasi data kecamatan di luar wilayah Kota Tangerang, dilakukan penyaringan wilayah saat proses *preprocessing* untuk memastikan hanya data dari kecamatan yang masuk cakupan analisis yang ikut diolah. Data dari luar Kota Tangerang dihapus agar hasil pemodelan ARIMA yang dilakukan lebih akurat dan sesuai dengan tujuan proyek.