

## BAB I PENDAHULUAN

### 1.1 Latar Belakang

Demam berdarah masih menjadi masalah kesehatan masyarakat yang serius di wilayah tropis dan subtropis, terutama di daerah perkotaan yang padat penduduk seperti di Indonesia. Ditularkan oleh nyamuk *Aedes aegypti*, penyakit ini dapat memicu wabah yang berdampak signifikan pada sistem kesehatan masyarakat dan perekonomian. Oleh karena itu, pemantauan rutin jumlah kasus demam berdarah sangat penting untuk upaya pencegahan dan pengendalian yang tepat waktu. Deteksi dini peningkatan jumlah kasus memungkinkan otoritas kesehatan untuk menerapkan tindakan pencegahan tepat waktu untuk meminimalkan risiko epidemi (WHO, 2023).

Salah satu pendekatan statistik yang banyak digunakan untuk pemantauan proses berkelanjutan adalah *Statistic Process Control* (SPC), yang mencakup bagan kendali seperti Shewhart, Exponentially Weighted Moving Average (EWMA), dan Cumulative Sum (CUSUM). Bagan Shewhart efektif untuk mendeteksi pergeseran besar dalam proses tetapi relatif tidak sensitif terhadap perubahan kecil. Untuk mengatasi keterbatasan ini, Page (1954) memperkenalkan konsep CUSUM, yang mengakumulasi deviasi dari target mean untuk meningkatkan sensitivitas terhadap pergeseran kecil. CUSUM menghitung jumlah kumulatif perbedaan antara pengamatan dan nilai target, sehingga lebih responsif terhadap perubahan bertahap dibandingkan dengan diagram Shewhart. Kemudian, Roberts (1959) mengembangkan diagram kendali EWMA, yang menetapkan bobot yang menurun secara eksponensial pada pengamatan sebelumnya, yang memungkinkan deteksi dini tren atau pergeseran proses kecil. Studi menunjukkan bahwa EWMA dan CUSUM mengungguli diagram Shewhart untuk mendeteksi pergeseran kecil, dengan CUSUM umumnya lebih cepat ketika parameter disetel dengan benar, meskipun lebih kompleks (Montgomery, 2009).

Namun, diagram kendali konvensional biasanya mengasumsikan bahwa data didistribusikan secara independen dan identik (i.i.d), asumsi yang sering dilanggar dalam data deret waktu epidemiologi, seperti kasus demam berdarah, yang menunjukkan autokorelasi karena ketergantungan temporal. Mengabaikan autokorelasi dapat mengakibatkan peningkatan tingkat alarm palsu atau kegagalan untuk mendeteksi perubahan yang berarti. Beberapa studi telah membahas masalah ini. Nguyen dkk. (2021) menekankan bahwa mengabaikan autokorelasi dapat menyebabkan tingkat alarm palsu yang lebih tinggi dalam aplikasi bagan kendali.



Temukan bahwa mengabaikan autokorelasi dapat mendistorsi bagan kendali dan batas kendali, sehingga meningkatkan alarm palsu. Modall (2024) menyoroti bagaimana kesalahan estimasi palsu, terutama ketika autokorelasi tidak diperhitungkan. Alwan mengilustrasikan efek merugikan autokorelasi pada tingkat alarm dalam pemodelan deret waktu untuk mengurangi masalah tersebut.

Sebagai bentuk validasi awal, data jumlah kasus demam berdarah dalam penelitian ini telah diuji autokorelasinya. Hasilnya menunjukkan pola autokorelasi yang signifikan, yang mengindikasikan adanya ketergantungan temporal. Oleh karena itu, pendekatan pemodelan deret waktu menjadi penting untuk diterapkan sebelum penggunaan bagan kendali agar hasil pemantauan lebih akurat dan tidak bias.

Untuk mengatasi hal ini, beberapa peneliti telah mengusulkan pengintegrasian pemodelan deret waktu dengan SPC. Montgomery (2009) menyarankan penggunaan model Autoregressive Integrated Moving Average (ARIMA) untuk menghilangkan autokorelasi sebelum menerapkan bagan kendali. Penelitian selanjutnya, seperti Zhang et al. (2010) dan Jiang et al. (2015), mengembangkan diagram kendali berbasis residual menggunakan residual dari model ARIMA sebagai input untuk diagram EWMA atau CUSUM, sehingga meningkatkan sensitivitas terhadap pergeseran kecil. Kontribusi tambahan datang dari Montgomery & Mastrangelo (1991), yang meninjau metode SPC untuk data autokorelasi, dan Apley & Shi (1999), yang memperkenalkan Generalized Likelihood Ratio Test (GLRT) untuk proses autokorelasi. Sebelumnya, Wardell dkk. (1992) mengevaluasi dampak autokorelasi pada kinerja diagram kendali, sementara Woodall (2000) membahas kontroversi SPC yang lebih luas, termasuk tantangan dengan data autokorelasi. Meskipun efektif dalam pengaturan industri, penerapan pendekatan terintegrasi tersebut dalam pengawasan kesehatan masyarakat masih terbatas.

Penelitian ini menggunakan peta kendali Individuals-Moving Range (IMR) karena jenis data yang dianalisis adalah data deret waktu bulanan kasus DBD yang bersifat univariat dan tidak berkelompok. Diagram IMR cocok digunakan untuk memantau variasi individu dalam data observasi tunggal yang diperoleh secara berkala, seperti data epidemiologi. Selain itu, IMR relatif lebih mudah diterapkan dibandingkan CUSUM atau EWMA, namun tetap efektif untuk mendeteksi perubahan besar setelah autokorelasi diatasi melalui pemodelan deret waktu. Penggunaan IMR juga memungkinkan identifikasi titik luar kendali secara visual dan langsung, yang berguna dalam konteks pengambilan keputusan cepat dalam sistem peringatan dini.

Pemilihan Kota Makassar sebagai lokasi studi didasarkan pada beberapa pertimbangan strategis. Makassar merupakan salah satu kota besar di Indonesia bagian timur dengan kepadatan penduduk yang tinggi dan tingkat urbanisasi yang cepat, kondisi yang ideal bagi penyebaran penyakit berbasis vektor seperti demam berdarah. Selain itu, data historis menunjukkan bahwa Kota Makassar merupakan salah satu wilayah endemis DBD di Provinsi Sulawesi Selatan dengan fluktuasi jumlah kasus yang signifikan dari tahun ke tahun. Ketersediaan data bulanan dari



124 juga memungkinkan analisis deret waktu jangka menengah mengidentifikasi pola musiman dan tren jangka panjang secara

epidemiologi adalah bidang yang sedang berkembang untuk penyakit menular seperti demam berdarah, COVID-19, dan berkala atau secara real-time. Pertama, SPC memungkinkan yang memungkinkan petugas kesehatan untuk merespons

sebelum epidemi terjadi (Benneyan, 1998). Kedua, mendukung pemantauan tren secara real-time (Sellick, 1993). Ketiga, meningkatkan akurasi data dengan mengidentifikasi variasi dalam pengumpulan data dan proses pelaporan (Morton et al., 2001). Terakhir, adaptasi SPC dari manufaktur ke perawatan kesehatan telah meningkatkan kualitas dan efisiensi sistem pengawasan epidemiologi (Benneyan, 2001). Dengan demikian, SPC menawarkan pendekatan sistematis untuk peringatan dini, deteksi tren, dan peningkatan kualitas data dalam kesehatan masyarakat.

Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk mengembangkan kerangka pemantauan kasus DBD yang mengintegrasikan model deret waktu ARIMA dengan peta kendali Individual Moving Range (IMR) untuk mengatasi autokorelasi dalam data epidemiologi. Pendekatan ini diharapkan dapat menyediakan sistem peringatan dini yang kuat dan adaptif dalam mendeteksi potensi wabah DBD di daerah endemis seperti Makassar, Indonesia.

## 1.2 Rumusan Masalah

Rumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana pola distribusi dan tren kejadian DBD di Makassar?
2. Bagaimana membentuk grafik kendali yang efektif untuk deteksi dini dan pemantauan kasus DBD di Makassar menggunakan metode Individual Moving Range pada data berautokorelasi?

## 1.3 Batasan Masalah

Penelitian ini dibatasi pada:

1. Analisis data kasus DBD di Makassar dalam rentang waktu Januari 2013 hingga Desember 2024
2. Penggunaan pendekatan *Statistical Process Control* (SPC) terbatas pada penerapan peta kendali Individual Moving Range (IMR) terhadap data univariat yang mengandung autokorelasi.
3. Aspek non-statistik seperti faktor lingkungan, perilaku masyarakat, atau intervensi kesehatan tidak dianalisis secara mendalam.

## 1.4 Tujuan Penelitian

Berdasarkan rumusan masalah yang telah diuraikan, maka tujuan dari penelitian ini adalah sebagai berikut:

1. Menentukan pola distribusi dan tren kejadian DBD di Makassar.
2. Mengembangkan peta kendali yang tepat untuk deteksi dini dan pemantauan kasus DBD di Makassar dengan metode Individual Moving Range pada data berautokorelasi.



### litian

kan memberikan manfaat sebagai berikut:

i informasi berbasis data yang dapat digunakan oleh otoritas dalam pengambilan keputusan untuk pengendalian penyakit Makassar.

2. Menambah literatur ilmiah di bidang epidemiologi statistik, khususnya dalam penerapan peta kendali SPC pada data deret waktu yang mengandung autokorelasi.
3. Menghasilkan rancangan sistem peringatan dini (early warning system) berbasis grafik kendali untuk mendukung upaya mitigasi dan respons cepat terhadap potensi wabah DBD di wilayah endemis.

## 1.6 Teori

Sub-bab teori ini membahas mengenai beberapa teori yang digunakan untuk membahas pokok pembahasan terkait.

### 1.6.1 Demam Berdarah

Demam berdarah dengue atau biasa disingkat DBD adalah penyakit infeksi yang disebabkan oleh virus dengue. Dengue dengan serotipe 1-4 dibawa oleh nyamuk *Aedes Aegypti*. Seseorang yang tergigit nyamuk dengan virus tersebut akan menyebabkan terjadinya infeksi primer atau infeksi sekunder. Infeksi primer ini dalam bentuk demam akut sedangkan infeksi sekunder yang lebih berat menimbulkan demam berdarah dengue (Nugraheni, Rizqoh and Sundari, 2023).

Paling tidak ada 3 faktor yang memegang peranan dalam proses infeksi penyakit demam berdarah yakni vektor perantara, manusia, dan virus. Vektor perantaranya yakni nyamuk *Aedes Aegypti*. Sebenarnya ada juga nyamuk lain seperti *Aedes albopictus*, *Aedes polienensis* dan lainnya namun tidak terlalu berperan. Nyamuk yang membawa virus kemudian menggigit manusia. Virus kemudian berkembang dan mengalami masa inkubasi selama 8-10 hari (Sukohar, 2014).

DBD ditandai dengan panas tinggi mendadak yang berlangsung selama 2-7 hari. Hal ini disertai timbulnya gejala berupa tidak ada nafsu makan, mual, muntah, sakit kepala, nyeri ulu hati dan tanda-tanda perdarahan berupa bintik merah dikulit (petekia), mimisan, perdarahan pada mukosa, perdarahan gusi atau hematoma pada daerah suntikan, melena dan hati membengkak. Fase kritis terjadi pada hari 3-5 ketika terjadi penurunan suhu dan sindrom syok dengue (Kemenkes RI, 2017).

Penyakit ini diperparah lagi dengan tingkat kematian yang tinggi. Sekitar 30-50% penderita DBD mengalami syok dan berakhir pada kematian bila penanganan yang diberikan tidak adekuat. Angka kematian karena infeksi mencapai 5% pada anak. Penyakit akan lebih parah lagi jika disertai komplikasi seperti hiponatremia, hipokalsemia, dan overhidrasi (Tansil, Rampengan and Wilar, 2021).

Penyakit DBD memang merupakan salah satu masalah kesehatan serius di O menyebutkan bahwa 40% dari populasi dunia mempunyai virus dengue. Setiap tahunnya terdapat kematian karena DBD dengan jumlah kasus secara global 50-100 juta kasus (Ciptono at 129 negara yang memiliki risiko tinggi akan DBD dan 70% di Asia termasuk Indonesia (Alvin Faiz Bara Mentari and



Demam berdarah merupakan penyakit yang sangat umum ditemukan di Indonesia. Penyakit ini bersifat endemik namun sekali-kali dapat menyebabkan KLB bahkan epidemi. Indonesia sebagai negara tropis memungkinkan tumbuhnya penyakit tular nyamuk seperti DBD ini. Seluruh wilayah di Indonesia berpotensi terkena penyakit DBD karena nyamuk penular maupun virus penyebabnya telah tersebar luas di perumahan penduduk kecuali pada tempat di atas ketinggian 100 meter dpl. Dari tahun ke tahun, ada kecenderungan peningkatan. Bahkan pada rentang tahun 2019-2022, kabupaten yang terjangkit DBD sudah di atas 90% (Pusat Data dan Teknologi Informasi Kementerian Kesehatan RI, 2024).

Upaya pengendalian terhadap penyakit DBD oleh pemerintah telah dilakukan dalam berbagai bentuk. Diantara program yang dilaksanakan yakni kegiatan Sarang Pemberantasan Nyamuk (PSN) melalui konsep 3M, memelihara ikan pemakan jentik, dan penggunaan kelambu di rumah-rumah warga. Walaupun demikian, penanggulangan yang masih bersifat reaktif mengakibatkan jumlah penderita DBD belum dapat ditekan secara nasional. Kesulitan tersebut disebabkan karena belum baiknya proyeksi terhadap kasus DBD baik dari sisi waktu, tempat maupun angka kejadiannya (Pusat Data dan Teknologi Informasi Kementerian Kesehatan RI, 2024).

### 1.6.2 Kejadian Luar Biasa (KLB)

Menurut UU No. 17 Tahun 2023 tentang Kesehatan, Kejadian Luar Biasa atau selanjutnya disingkat KLB adalah meningkatnya kejadian, kesakitan, kematian, dan/atau kedisabilitas akibat penyakit dan masalah Kesehatan yang bermakna secara epidemiologis di suatu daerah pada kurun waktu tertentu. KLB menjadi sebuah persoalan kesehatan masyarakat. Hal ini dikarenakan KLB dapat menyebabkan jatuhnya korban sakit bahkan kematian dalam jumlah yang banyak. Selain itu, kejadian KLB dapat menyerap anggaran besar dalam penanggulangannya serta berpotensi menyebar luas lintas kabupaten, provinsi bahkan negara (Kemenkes RI, 2004).

Suatu daerah baru dapat dikatakan KLB jika memenuhi beberapa syarat berikut (Kemenkes RI, 2010).

- Timbulnya suatu penyakit menular tertentu yang sebelumnya tidak ada atau tidak dikenal pada suatu daerah.
- Peningkatan kejadian kesakitan terus menerus selama tiga kurun waktu (jam, hari, atau minggu) berturut-turut.
- Peningkatan kejadian kesakitan dua kali atau lebih dibandingkan dengan periode sebelumnya.
- Jumlah penderita baru dalam satu bulan meningkat dua kali atau lebih dibandingkan tahun sebelumnya.



adalah kejadian kesakitan per bulan selama satu tahun  
kenaikan dua kali atau lebih dibandingkan tahun sebelumnya.  
kematian dalam satu periode naik 50 persen atau lebih  
periode sebelumnya dalam kurun waktu yang sama.  
i penyakit penderita baru pada satu periode naik dua kali atau  
ng satu periode sebelumnya dalam kurun waktu yang sama.

Pada kasus DBD, status KLB baru bisa dinyatakan jika bila jumlah kasus DBD yang terjadi di wilayah tersebut dua kali lipat lebih banyak dari kasus DBD yang terjadi di bulan yang sama pada tahun sebelumnya (Pusat Komunikasi Publik Sekretariat Jenderal Kementerian Kesehatan RI, 2015). Pasal 4 Permenkes No 1501/2010 memuat lebih detail tentang penetapan KLB DBD. Penetapan yang dimaksud terjadi bila terjadi satu atau lebih dari kondisi berikut (Kemenkes RI, 2017):

- Timbulnya suatu penyakit menular tertentu (DBD) yang sebelumnya tidak ada atau tidak dikenal pada suatu daerah.
- Peningkatan kejadian kesakitan dua kali atau lebih dibandingkan dengan periode sebelumnya dalam kurun waktu jam, hari atau minggu menurut jenis penyakitnya.
- Angka kematian kasus suatu penyakit (Case Fatality Rate) dalam 1 (satu) kurun waktu tertentu menunjukkan kenaikan 50% (lima puluh persen) atau lebih dibandingkan dengan angka kematian kasus suatu penyakit periode sebelumnya dalam kurun waktu yang sama.

Dalam memastikan kejadian KLB, harus dilakukan tahapan-tahapan tertentu. Langkah pertama adalah menegaskan diagnosis. Setelah itu, harus diketahui bahwa insiden penyakit berdasarkan waktu memiliki variasi yang berbeda-beda. Olehnya itu, untuk mengetahui kenaikan frekuensi penyakit maka harus dibandingkan dengan bulan yang sama pada tahun berbeda atau bulan yang berbeda pada tahun yang sama. Hal ini untuk memastikan bahwa peningkatan kasus yang terjadi memang benar-benar berbeda dibandingkan biasanya. Langkah selanjutnya, adalah menghitung jumlah kasus/insidens yang sementara berjalan. Terakhir, KLB yang terjadi digambarkan sesuai karakteristiknya. Biasanya dengan menggunakan variabel tempat, waktu, dan orang (Kemenkes RI, 2017).

### 1.6.3 Peta Kendali

Peta Kendali adalah sebuah teknik yang digunakan untuk mengevaluasi apakah suatu proses beroperasi dalam kendali kualitas yang baik secara statistik, atau jika tidak, untuk mengidentifikasi masalah yang ada dan memperbaikinya. Teknik ini pertama kali diperkenalkan oleh DR. Walter Andrew Shewhart pada tahun 1924 dengan tujuan untuk membedakan antara variasi yang disebabkan oleh faktor-faktor khusus dan variasi yang disebabkan oleh faktor umum dalam suatu proses (Gaspersz, 1998).

Tujuan peta kendali adalah untuk memastikan bahwa proses yang berjalan tetap stabil dan dapat diprediksi dalam jangka waktu yang panjang. Dalam peta kendali, data dikumpulkan secara periodik dan dianalisis menggunakan berbagai teknik untuk mendeteksi adanya variasi atau penyimpangan yang dapat mengganggu proses tersebut.

Peta kendali digunakan untuk memantau fluktuasi jumlah kasus secara real-time. Jika terjadi lonjakan atau penurunan yang tidak normal, yang dapat



memberikan informasi penting mengenai adanya Kejadian Luar Biasa (KLB) atau wabah.

Gasperz (2009) menjelaskan bahwa terdapat beberapa jenis peta kendali yang berdasarkan pada jenis data yang digunakan (data variabel atau atribut). Data variabel mencakup karakteristik kualitas yang bersifat kontinu dan dapat bervariasi tanpa batas, seperti panjang, kecepatan, bobot, dan volume. Sebaliknya, data atribut hanya memiliki dua hasil yang relevan, seperti ya atau tidak, atau sesuai atau tidak sesuai, seperti yang biasa digunakan dalam pengendalian kualitas. Biasanya, peta kendali digambarkan dengan tiga garis utama, yaitu garis tengah (center line), garis batas atas (UCL – Upper Control Limit), dan garis batas bawah (LCL – Lower Control Limit).

#### 1.6.4 Autoregressive Integrated Moving Average (ARIMA)

Metode ARIMA (Autoregressive Integrated Moving Average) merupakan teknik peramalan deret waktu (time series) yang digunakan ketika data memiliki pola yang kompleks dan kondisi peramalan yang menantang. Metode ini, dikenal juga sebagai pendekatan Box-Jenkins, bertujuan untuk memilih model terbaik dari sejumlah model deret waktu linier yang cocok untuk data yang sudah bersifat stasioner (Chatfield, 1975).

Model ARIMA dirancang untuk menganalisis data univariat, baik yang menunjukkan pola musiman maupun tren. Namun, karena model ini hanya berlaku untuk data yang stasioner, maka data yang belum stasioner perlu ditransformasikan atau dilakukan diferensiasi terlebih dahulu agar memenuhi syarat tersebut.

Dalam penerapannya, ARIMA menuntut identifikasi berbagai karakteristik deret waktu seperti kestasioneran dan pola musiman. Proses identifikasi ini dilakukan secara sistematis untuk membantu membangun pemahaman yang lebih jelas mengenai model dasar yang akan digunakan. Selain itu, ARIMA juga mampu menangani berbagai karakteristik data deret waktu, seperti unsur acak, tren, musiman, dan siklus (Chatfield, 1975).

Metode ARIMA dibagi menjadi tiga klasifikasi model time series, yaitu model Autoregressive (AR), model Moving Average (MA), dan model campuran yang memiliki karakteristik kedua model (Makridakis dkk, 2008).

- Model Autoregressive (AR) Bentuk umum dari model AR ordo  $p$  adalah  $(AR(p))$  atau  $ARIMA(p,0,0)$ .
- Model Moving Average (MA) Bentuk umum dari model MA ordo  $q$  adalah  $(MA(q))$  atau  $ARIMA(0,0,q)$ .
- Model Autoregressive Moving Average (ARMA) Bentuk umum model  $AR(p)$  dan  $MA(q)$  atau sering kali disebut dengan model ARMA  $ARMA(p,0,q)$ .



Autoregressive Integrated Moving Average (ARIMA). Bentuk umum  $ARIMA(p, d, q)$  dengan  $ARIMA(p, d, q)$ . Dimana nilai  $p$  adalah ordo  $AR$ , nilai  $d$  adalah tingkat proses diferensiasi (differencing)  $ARIMA$  adalah ordo Moving Average (MA).

Menurut Pankratz (1983), proses dalam membangun model ARIMA terdiri dari tiga langkah utama: identifikasi model, estimasi parameter, dan evaluasi diagnostik. Berikut penjabaran dari setiap tahapannya:

- **Identifikasi Model.**  
Langkah pertama adalah mengidentifikasi model yang paling tepat untuk data yang dianalisis. Ini dilakukan dengan mengamati grafik deret waktu, serta pola Autocorrelation Function (ACF) dan Partial Autocorrelation Function (PACF) dari data historis (korelogram). Tahapan ini bertujuan untuk menentukan apakah data sudah bersifat stasioner dan untuk membuat dugaan awal mengenai struktur model yang mungkin sesuai.
- **Estimasi Parameter**  
Setelah model awal teridentifikasi, tahap berikutnya adalah memperkirakan nilai koefisien dari model tersebut. Estimasi ini penting untuk menentukan apakah parameter yang diperoleh signifikan secara statistik. Hanya model dengan parameter signifikan yang akan diterima; jika tidak, model tersebut harus ditolak atau disesuaikan.
- **Uji Diagnostik**  
Tahap ini bertujuan untuk menilai apakah model yang telah dibentuk benar-benar sesuai. Uji diagnostik dilakukan terhadap sisa (residual) dari model untuk memastikan bahwa kesalahan prediksi tidak menunjukkan pola tertentu dan bersifat acak, yang menandakan bahwa model sudah cukup baik dan layak digunakan.
- **Peramalan (Forecasting)**  
Setelah model dinyatakan layak melalui uji diagnostik, langkah terakhir adalah melakukan peramalan. Model yang telah tervalidasi digunakan untuk memprediksi nilai-nilai di masa mendatang berdasarkan data historis yang tersedia.

Rumus ARIMA(p,d,q):

$$Y_t = c + \sum_{i=1}^p \phi_i Y_{t-i} + \epsilon_t + \sum_{j=1}^q \theta_j \epsilon_{t-j} \quad (1)$$

- $Y_t$  : jumlah kasus DBD pada bulan  $t$   
 $p$  : ordo komponen autoregresif (AR)  
 $d$  : jumlah differencing untuk stasioneritas  
 $q$  : ordo komponen moving average (MA)



\AR dan MA  
 acak pada  $t$   
 tetapan mean  
 iakan untuk membuat data stasioner.

### 1.6.5 Seasonal Autoregressive Integrated Moving Average (SARIMA)

Model SARIMA merupakan model ARIMA yang digunakan untuk menyelesaikan deret waktu musiman yang terdiri dari bagian tidak musiman dan bagian musiman. Bagian tidak musiman dari metode ini adalah model ARIMA. Model SARIMA dinotasikan sebagai berikut (Makridakis,dkk, 1999):

$$ARIMA(p,d,q)(P,D,Q)S \quad (2)$$

dengan,

$(p, d, q)$  : bagian tidak 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 per musim

Bentuk umum model SARIMA adalah sebagai berikut:

$$\phi_p(B^s)\phi_p(1 - B)^d(1 - B^s)^D Y_t = \theta_q(B^s)\theta_q(B) \epsilon_t \quad (3)$$

dengan,

$s = 12$  : Siklus tahunan

$\phi_p(B^s) = 1 - \phi_1 B^s - \dots - \phi_p B^{ps}$  (AR musiman)

$\theta_q(B^s)$  : MA musiman

$D$  : differencing musiman

$B$  : operator lag

### 1.6.6 Individual Moving Range (IMR)

Peta kendali Individual Moving Range (I-MR) merupakan salah satu alat dalam SPC yang digunakan untuk menganalisis data kontinu atau data yang diukur dalam satuan tertentu, seperti jumlah kasus penyakit. Peta kendali I-MR terdiri dari dua jenis peta kendali: Individual (X-bar) dan Moving Range (MR).

- Peta Kendali Individual (X-bar chart): Digunakan untuk memantau nilai individu dari data yang diambil satu per satu dalam suatu periode tertentu. Setiap titik pada grafik ini mewakili satu pengukuran atau observasi, seperti jumlah kasus DBD pada suatu tahun atau minggu (Montgomery, 2009).
- Peta Kendali Moving Range (MR chart): Digunakan untuk memantau perbedaan antar dua pengukuran berturut-turut dalam periode waktu. Moving Range dihitung sebagai selisih antara dua titik pengamatan, yang kemudian diubah menjadi peta kendali untuk mendeteksi signifikansi dalam variabilitas atau fluktuasi data (Kubiak & 9).



MR sangat berguna dalam situasi di mana data yang digunakan mungkin akan ke dalam subgrup. Sebagai contoh, dalam kasus kumpulan data dilakukan setiap tahun (atau bahkan setiap

minggu) tanpa subgrup tertentu, sehingga data setiap titik harus dianalisis secara individual untuk mendeteksi lonjakan yang tidak normal.

Peta kendali I-MR memungkinkan untuk mendeteksi lonjakan atau penurunan dalam data secara cepat, yang sangat berguna untuk mengidentifikasi masalah atau perubahan yang tidak terduga, seperti lonjakan jumlah kasus DBD (Wheeler, 2000).

- Individual (I) Chart

Menampilkan rata-rata dan batas kontrol rata-rata:

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad (4)$$

$$UCL_X = \bar{X} + 3\sigma, \quad LCL_X = \bar{X} - 3\sigma$$

- Moving Range (MR) Chart

Mengukur variasi antar pengamatan:

$$MR_i = |X_i - X_{i-1}|, \overline{MR} = \frac{1}{n-1} \sum_{i=2}^n MR_i \quad (5)$$

Batas control MR:

$$UCL_{MR} = D_4 \overline{MR}, \quad LCL_{MR} = D_3 \overline{MR} \quad (6)$$

- Peta Kendali IMR Residual

Setelah model SARIMA dibuat, residual digunakan untuk memantau apakah proses sudah stabil tanpa pola musiman/tren.

Menghitung residual:

$$\hat{\epsilon}_t = Y_t - \hat{Y}_t \quad (7)$$

Keterangan:

$\hat{\epsilon}_t$  : Residual ARIMA

$Y_t$  : Data aktual pada waktu ke-t

$\hat{Y}_t$  : Prediksi model SARIMA pada waktu ke-t

### 1.6.7 Data Berautokorelasi



lisis deret waktu, salah satu karakteristik penting yang perlu autokorelasi, yaitu adanya hubungan atau ketergantungan dengan nilai sebelumnya dalam rentang waktu tertentu. Pada seperti jumlah kasus DBD bulanan, autokorelasi sangat lazim penyebaran penyakit sering kali menunjukkan ketergantungan musiman yang konsisten dari tahun ke tahun (Alwan & Roberts,

Autokorelasi mengindikasikan bahwa observasi pada waktu tertentu dipengaruhi oleh nilai-nilai masa lalu. Hal ini dapat diukur menggunakan fungsi autokorelasi (Autocorrelation Function / ACF) dengan rumus sebagai berikut:

$$\rho_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (8)$$

di mana:

- $\rho_k$  : koefisien autokorelasi pada lag ke-k,
- $Y_t$  : nilai observasi pada waktu ke-t,
- $\bar{Y}$  : rata-rata dari seluruh observasi,
- n : jumlah total observasi.

Apabila data memiliki autokorelasi signifikan, penerapan metode statistik konvensional seperti peta kendali (control chart) dapat menjadi tidak valid. Hal ini karena metode seperti Shewhart atau IMR chart mengasumsikan bahwa data bersifat independen dan identik terdistribusi (i.i.d). Jika asumsi ini dilanggar, maka hasil pemantauan cenderung menghasilkan batas kendali yang terlalu sempit dan memunculkan false alarms (Montgomery & Mastrangelo, 1991).

Untuk mengatasi masalah tersebut, data perlu dimodelkan terlebih dahulu menggunakan pendekatan ARIMA (Autoregressive Integrated Moving Average) atau SARIMA (Seasonal ARIMA) agar autokorelasi dan pola musiman dapat dihilangkan.

Setelah model deret waktu dibentuk, residual (sisa) dari model tersebut digunakan untuk keperluan pemantauan proses. Residual yang dihasilkan diharapkan telah bebas dari autokorelasi dan dapat dianggap sebagai data acak. Untuk memastikan hal ini, digunakan uji Ljung-Box untuk menguji keberadaan autokorelasi dalam residual:

$$Q = n(n+2) \sum_{k=1}^h \frac{\hat{\rho}_k^2}{n-k} \quad (9)$$

Dimana:



Ljung-Box,  
si lag ke-k dari residual,  
servasi.

ri uji Ljung-Box lebih besar dari 0,05, maka residual dapat  
okorelasi dan siap untuk dimasukkan ke dalam peta kendali

residual, seperti IMR residual chart. Pendekatan ini telah terbukti lebih akurat dalam mendeteksi anomali proses, khususnya pada data epidemiologi yang bersifat berautokorelasi (Benneyan, 1998; Jiang et al., 2015).

### 1.6.8 Kota Makassar sebagai Objek Penelitian

Kota Makassar merupakan ibu kota Provinsi Sulawesi Selatan dan merupakan salah satu kota metropolitan terbesar di wilayah Indonesia bagian timur. Dengan luas wilayah sekitar 175,77 km<sup>2</sup> dan jumlah penduduk lebih dari 1,4 juta jiwa (BPS Kota Makassar, 2023), kota ini memiliki kepadatan penduduk yang tinggi serta pertumbuhan urbanisasi yang pesat.


Kondisi geografis dan iklim tropis Kota Makassar, yang ditandai dengan musim hujan dan kemarau yang cukup jelas, sangat mendukung perkembangan populasi nyamuk *Aedes aegypti*, vektor utama penyebaran virus Dengue. Musim hujan biasanya terjadi antara November hingga April, sementara musim kemarau berlangsung dari Mei hingga Oktober. Pola iklim ini memberikan dampak langsung terhadap siklus penyebaran penyakit Demam Berdarah Dengue (DBD).

Menurut data dari Dinas Kesehatan Kota Makassar, DBD masih menjadi salah satu penyakit menular yang prevalensinya tinggi dari tahun ke tahun. Lonjakan kasus DBD umumnya terjadi pada periode awal hingga pertengahan tahun, terutama setelah musim penghujan, saat populasi nyamuk meningkat secara signifikan akibat genangan air yang menjadi tempat perkembangbiakan.

Selain itu, padatnya permukiman dan tingginya mobilitas penduduk turut mempercepat transmisi virus Dengue antarwilayah. Oleh karena itu, Kota Makassar menjadi wilayah yang sangat relevan untuk dijadikan objek kajian dalam upaya pengembangan sistem pemantauan kasus DBD yang efektif dan berbasis data.

Dengan mempertimbangkan pola musiman, tren jangka panjang, dan kemungkinan autokorelasi pada data jumlah kasus DBD bulanan di Kota Makassar, pendekatan pemodelan deret waktu dan peta kendali residual dinilai sesuai untuk mendeteksi potensi Kejadian Luar Biasa (KLB) secara lebih akurat dan tepat waktu.

### 1.6.9 Kerangka Konseptual



Gambar 1. Kerangka Konseptual

## BAB II METODE PENELITIAN

### 2.1 Sumber Data

Penelitian ini menggunakan data sekunder berupa data penderita DBD bulanan di Kota Makassar pada tahun 2013-2024. Data diperoleh dari Dinas Kesehatan Kota Makassar. Data bersifat deret waktu (time series) sehingga dimungkinkan adanya pola autokorelasi, musiman, atau tren tahunan yang perlu dianalisis sebelum diterapkan peta kendali.

### 3.2 Variabel Penelitian

Penelitian ini menggunakan satu variabel utama, yaitu jumlah kasus Demam Berdarah Dengue (DBD) bulanan di Kota Makassar dari Januari 2013 hingga Desember 2024, yang disimbolkan sebagai  $Y_t$ . Variabel ini bersifat deret waktu, kuantitatif, dan menunjukkan pola musiman serta autokorelasi. Dari proses pemodelan SARIMA terhadap data tersebut, dihasilkan variabel turunan berupa residual  $\hat{\epsilon}_t$  yaitu selisih antara nilai aktual dan nilai prediksi model. Residual ini kemudian digunakan sebagai input dalam peta kendali residual karena dianggap telah bebas dari autokorelasi dan pola musiman, sehingga sesuai untuk pemantauan statistik yang lebih akurat.

### 2.3 Metode Analisis Data

Analisis data dilakukan melalui beberapa tahap berikut:

1. Eksplorasi Data  
Visualisasi pola musiman dan tren data bulanan DBD.
2. Uji Stasioneritas dan Identifikasi Model  
Menggunakan uji ADF dan analisis ACF/PACF untuk menentukan ordo ARIMA/SARIMA.
3. Pemodelan SARIMA  
Menentukan model terbaik yang menangkap pola musiman, kemudian menguji validitas model melalui residual dan uji Ljung-Box.
4. Perhitungan Residual dan Peta Kendali IMR
  - Menghitung residual dari model SARIMA.
  - Menerapkan peta kendali IMR pada residual dan pada data asli.
  - Menentukan batas kendali (UCL dan LCL) dan mengidentifikasi titik out-of-control.
5. Interpretasi dan Evaluasi

