

## BAB I PENDAHULUAN

### 1.1. Latar Belakang

Pemodelan matematika merupakan proses menyederhanakan fenomena atau sistem di dunia nyata ke dalam persamaan matematika. Model matematika tersebut dibuat untuk memahami, menganalisis, dan memprediksi perilaku sistem di dunia nyata dengan cara yang lebih mudah dan sistematis. Pemodelan matematika dapat membantu manusia untuk memahami dunia di sekitarnya dengan lebih baik. Pengembangan dan penyempurnaan teknik pemodelan membuat model menjadi lebih akurat, informatif, serta mampu menyelesaikan masalah nyata yang kompleks.

Penelitian ini membahas masalah jumlah kematian bayi menggunakan model matematika. Masalah jumlah kematian bayi merupakan salah satu fenomena alam yang penting untuk diselesaikan mengingat tingginya jumlah kematian bayi yang terjadi akhir-akhir ini. Pemodelan kematian bayi dibutuhkan sebagai upaya pencegahan atau pengurangan terhadap tingginya jumlah kematian bayi saat ini. Pemodelan terhadap jumlah kematian bayi merupakan suatu proses untuk memahami, menganalisis, ataupun memprediksi fenomena jumlah kematian bayi di kehidupan nyata dalam suatu model matematika.

Jumlah kematian adalah salah satu dari tiga komponen demografi yang fundamental dalam mempengaruhi jumlah dan struktur usia penduduk. Salah satu jenis mortalitas yang penting adalah kematian bayi (*infant mortality*), yang mengacu pada kematian anak yang terjadi sebelum mereka mencapai usia satu tahun. Di Negara Indonesia, akumulasi kejadian dari fenomena tersebut biasa disebut dengan sebutan Angka Kematian Bayi (AKB). Definisi AKB menurut *World Health Organization* (WHO) merupakan jumlah bayi yang meninggal sebelum mencapai usia satu tahun yang dihitung pada tiap seribu kelahiran bayi hidup di Negara Indonesia (Zalfani & Sudaryanto, 2023). Pada tahun 2017, AKB di Negara Indonesia berada di angka 27 kematian per 1000 kelahiran hidup, dimana angka tersebut mendekati angka kematian bayi secara global yang sebesar 29 kematian per 1000 kelahiran hidup (Parwodiwiyono & Witono, 2020). Jumlah AKB sebesar 27 tentunya memberikan gambaran bahwa fenomena kematian bayi masih sering terjadi di Indonesia.

Provinsi Sulawesi Barat sebagai salah satu provinsi di Negara Indonesia tentunya juga memiliki jumlah kematian bayi yang tinggi. Jumlah AKB di Provinsi Sulawesi Barat mencapai angka 29 kematian per 1000 kelahiran hidup (BPS, 2020). Provinsi Sulawesi Barat terdiri atas 6 Kabupaten dan 69 Kecamatan, di mana setiap wilayah tersebut tentunya berpotensi terjadi kasus kematian bayi. Jumlah AKB di suatu kecamatan dapat dipengaruhi atau berhubungan dengan jumlah AKB di Lokasi sekitarnya. Jumlah AKB juga dapat diakibatkan oleh beberapa faktor diantaranya ialah Berat Badan Lahir Rendah (BBLR), Asfiksia, Pneumonia, Tetanus Neonatorium,

Sepsis, dan Kelainan Kongenital (Brook, 2021; Ely & Driscoll, 2021). Pengamatan terhadap fenomena jumlah AKB di Provinsi Sulawesi Barat dapat dilakukan melalui pemodelan terhadap jumlah kematian bayi beserta faktor penyebabnya. Namun, hingga saat ini belum terdapat penelitian yang memodelkan data jumlah kematian bayi secara matematis yang mencakup seluruh kecamatan atau kabupaten di Provinsi Sulawesi Barat.

Pemodelan terhadap data jumlah kematian bayi dapat dilakukan dengan berbagai metode salah satunya ialah metode *Bayesian*. Beberapa penelitian yang menerapkan metode *Bayesian* untuk memodelkan data jumlah kematian bayi telah dilakukan oleh peneliti sebelumnya. Alexander & Alkema (2018) meneliti data kematian bayi di 195 negara pada tahun 1990-2015 menggunakan model *Bayesian Hierarchical Splines Regression*. Penelitian ini membuat suatu prediksi terhadap data jumlah kematian bayi dan ukuran penyimpangan dari prediksi data tersebut. Meskipun demikian, penelitian yang dilakukan oleh Alexander & Alkema (2018) hanya melakukan estimasi tanpa memperhatikan faktor ketetanggaan dari suatu wilayah dengan wilayah di sekitarnya. Penelitian lainnya yang menggunakan metode *Bayesian* untuk memodelkan data kematian bayi ialah penelitian yang dilakukan oleh Ranjan & Dwivedi (2022). Penelitian Ranjan & Dwivedi (2022) menilai pengelompokan dan variasi spasial kematian bayi antar distrik di negara bagian tertentu di India menggunakan model *Bayesian geoaddivitive discrete-time survival*. Penelitian tersebut menganalisis pengaruh dari faktor-faktor yang diduga berpengaruh terhadap kematian bayi di setiap wilayah, namun efek spasialnya tidak memperhitungkan pengaruh suatu wilayah terhadap wilayah lainnya.

Pada penelitian ini, analisis data jumlah kematian bayi dan faktor yang mempengaruhi terjadinya akan dimodelkan menggunakan metode *Bayesian Hierarchical* dengan memadukan analisis jumlah kematian bayi berdasarkan dimensi spasial dan temporal dengan mempertimbangkan faktor ketetanggaan setiap wilayah. Kemudian, akibat variasi spasial yang berbeda di tingkat Kabupaten dan Kecamatan metode *Bayesian Hierarchical* yang digunakan terdiri dari dua tingkatan analisis. Analisis *spatio-temporal* dengan metode *Bayesian Hierarchical* dua tingkat secara eksplisit memperhitungkan ketidakpastian dalam estimasi nilai parameter, yang mana menghasilkan distribusi probabilitas parameter dan bukan berupa konstanta. Selain itu, penggunaan metode *Bayesian Hierarchical* dua tingkat mempertimbangkan ketidakpastian dalam data dan informasi prior, yang mana hal tersebut dibutuhkan karena data *spatio-temporal* seringkali memiliki *noise* dan ketidakpastian yang tinggi. Adapun untuk menunjang model dalam penelitian ini, risiko relatif dan autokorelasi spasial juga dilibatkan untuk menganalisis pengaruh antar wilayah dari kasus kematian bayi dan faktor yang mempengaruhi kematian bayi tersebut. Selain itu, penelitian ini juga akan melibatkan Transformasi *Wavelet* untuk mengidentifikasi pola dalam data, serta mendekomposisi data berdasarkan frekuensi untuk mengelompokkan data berdasarkan amplitudonya.

Transformasi *Wavelet* menganalisis data yang memiliki bentuk seperti gelombang dan dapat diukur pada skala yang berbeda. Transformasi *Wavelet* mendekomposisi data menjadi komponen-komponen frekuensi yang berbeda,

kemudian menganalisis data tersebut dalam domain waktu dan frekuensi secara simultan. Komponen yang terdekomposisi dapat dibagi menjadi komponen frekuensi tinggi dan komponen frekuensi rendah. Pembagian komponen frekuensi pada Transformasi *Wavelet* membuat transformasi tersebut dapat digunakan untuk melakukan klusterisasi dan menganalisis data yang berhierarki atau data dengan multi-skala. Penerapan Transformasi *Wavelet* berhierarki terdapat pada penelitian yang dilakukan oleh Beninca et al. (2023), yang mana dalam penelitian tersebut mereka melakukan klusterisasi secara berhierarki berdasarkan tingkatan spektrum pada bakteri.

Berdasarkan pemaparan yang telah diberikan, penelitian ini melakukan analisis terhadap data jumlah kematian bayi dengan pendekatan *Bayesian Hierarchical* yang dipadukan dengan Transformasi *Wavelet*. Penelitian ini disusun dengan judul “Pemodelan Bayesian Hierarchical dan Klusterisasi Hierarkis Transformasi Wavelet Data Jumlah Kematian Bayi di Provinsi Sulawesi Barat”.

## 1.2. Rumusan Masalah

Rumusan masalah yang diteliti berdasarkan uraian latar belakang penelitian ialah bagaimanakah model matematika data jumlah kematian bayi di Provinsi Sulawesi Barat menggunakan metode *Bayesian Hierarchical*? Bagaimanakah analisis pengaruh ketetangaan antar wilayah dan faktor-faktor penyebab kematian bayi terhadap jumlah kematian bayi di Provinsi Sulawesi Barat? Bagaimanakah pola hierarki data jumlah kematian bayi di Provinsi Sulawesi Barat menggunakan Transformasi *Wavelet*?

## 1.3. Tujuan Penelitian

Tujuan dari penelitian ini berdasarkan rumusan masalah ialah membangun model matematika data jumlah kematian bayi di Provinsi Sulawesi Barat serta mengetahui pengaruh ketetangaan antar wilayah, pengaruh faktor-faktor penyebab kematian bayi dan pola hierarki data jumlah kematian bayi di Provinsi Sulawesi Barat.

## 1.4. Manfaat penelitian

Adapun manfaat yang diharapkan dari pelaksanaan penelitian ini adalah:

- Sebagai penyaji informasi tentang model *Bayesian Hierarchical* dan pola spasio-temporal data jumlah kematian bayi di Provinsi Sulawesi Barat.
- Sebagai bahan refleksi bagi pemerintah atau petugas kesehatan di Provinsi Sulawesi Barat untuk memilih strategi pencegahan kematian bayi berdasarkan analisis spasio-temporal jumlah kematian bayi.
- Sebagai bahan referensi bagi pembaca atau peneliti selanjutnya yang ingin mengetahui pola model *Bayesian Hierarchical* analisis spasio-temporal angka kematian bayi di Provinsi Sulawesi Barat.

## 1.5. Batasan Masalah

Adapun masalah dalam penelitian ini dibatasi oleh hal-hal berikut:

- Data yang akan digunakan dalam penelitian ini diperoleh dari Dinas Kesehatan dan Badan Pusat Statistik (BPS) di tiap Kecamatan di Provinsi Sulawesi Barat yang terdiri dari 6 Kabupaten dan 69 Kecamatan serta Rumah Sakit Umum Daerah (RSUD) yang ada di Provinsi Sulawesi Barat.
- Analisis statistik yang akan digunakan untuk menganalisis data dalam penelitian ialah analisis spasio-temporal dengan menggunakan metode *Bayesian Hierarchical*.
- Transformasi Wavelet yang digunakan dalam penelitian ini ialah Transformasi Wavelet *Mexician Hat*.
- *Software* yang akan digunakan untuk mengolah data dalam penelitian ini ialah aplikasi *OpenBUGS*, *Geoda*, dan *MATLAB*.

## 1.6. Landasan Teori

### 1.6.1. Angka Kematian Bayi (AKB)

Angka Kematian Bayi (AKB) merupakan jumlah bayi yang meninggal sebelum bayi tersebut berusia satu tahun pada waktu tertentu per 1000 kelahiran hidup yang dihitung pada periode waktu yang sama. Tingkat AKB disuatu wilayah digunakan untuk mengukur perbandingan antara jumlah kematian bayi lahir hidup dengan jumlah bayi lahir hidup pada setiap seribu kelahiran. Adapun cara untuk menghitung AKB berdasarkan Badan Perencanaan Pembangunan Nasional Republik Indonesia (BAPPENAS) dapat dilakukan dengan menggunakan rumus pada Persamaan (2.1) sebagai berikut (BAPPENAS, 2020):

$$AKB = \frac{(JK < 1th)}{JLH} \times 1.000 \quad (2.1)$$

Keterangan:

- AKB : Angka Kematian Bayi  
 JK < 1 th : Jumlah bayi lahir mati sebelum berusia 1 tahun  
 JLH : Jumlah kelahiran hidup bayi dalam periode waktu tertentu

Metode penghitungan AKB pada Persamaan 2.1 menunjukkan bahwa nilai AKB dapat diperoleh melalui perbandingan antara jumlah bayi lahir yang meninggal sebelum usia 1 tahun dan jumlah kelahiran bayi yang lahir hidup pada waktu tertentu.

### 1.6.2. Faktor-Faktor Penyebab Kematian Bayi

Faktor-faktor penyebab terjadinya kematian bayi cukup beragam. Temuan dari beberapa penelitian yang telah dilakukan menunjukkan bahwa terdapat

beberapa hal yang dapat mempengaruhi terjadinya kematian bayi diantaranya ialah sebagai berikut:

- Berat badan lahir rendah yang dialami oleh bayi  
 Berdasarkan penelitian yang dilakukan oleh Ely & Driscoll (2021), bayi yang terlahir dengan berat badan rendah lebih rentan terhadap gangguan kesehatan seperti: gangguan atau kegagalan tumbuh-kembang di awal masa kelahiran. Berat bayi tergolong rendah ketika bayi memiliki berat badan dibawah 2,5 kg atau 2.500 gram saat ia lahir
- Tetanus Neonatorum (TN)  
 Berdasarkan Kementerian Kesehatan Republik Indonesia (Kemenkes RI) dan penelitian yang dilakukan oleh Brook (2021), Tetanus Neonatorum merupakan tetanus pada bayi saat usia hari ke-3 hingga ke-28 setelah kelahiran serta menjadi salah satu penyebab utama kematian neonatal dan masih menjadi masalah kesehatan di negara berkembang termasuk Indonesia. Tetanus merupakan penyakit infeksi yang diakibatkan oleh bakteri *Clostridium tetani* yang mana bakteri tersebut dapat mengeluarkan toksin (racun) dan menyerang sistem saraf pusat dalam tubuh. Pada kasus TN, spora bakteri *Clostridium tetani* masuk ke dalam tubuh bayi melalui tali pusat, hal tersebut terjadi dikarenakan pemotongan atau perawatan tali pusat dilakukan menggunakan alat dan/atau bahan yang tidak steril.
- Asfiksia  
 Asfiksia pada bayi baru lahir biasa disebut dengan asfiksia perinatal atau asfiksia neonatorum, kondisi tersebut terjadi ketika bayi mengalami kekurangan oksigen sebelum, selama, ataupun setelah proses persalinan. Berdasarkan penelitian yang dilakukan oleh Cavallin et al. (2020), bayi yang mengalami asfiksia atau tidak mendapatkan asupan oksigen yang cukup akan membuat bayi mengalami kerusakan jaringan dan organ tubuh. Jika tidak ditangani dengan tepat dan cepat, asfiksia bisa merusak otak bayi atau bahkan merenggut nyawanya.
- Sepsis  
 Sepsis merupakan infeksi darah yang terjadi pada bayi lahir dalam 28 hari pertama setelah kelahiran yang disebabkan oleh serangan bakteri, virus, atau jamur pada berbagai organ tubuh bayi. Berdasarkan penelitian yang dilakukan Ershad et al. (2019), sepsis pada bayi dapat menyebabkan sindrom klinis yang mungkin berupa tanda-tanda infeksi sistemik, syok sirkulasi, dan kegagalan organ multisystem.
- Pneumonia  
 Pneumonia atau radang paru-paru merupakan infeksi serius pada paru-paru yang sering menyerang bayi dan anak balita. Infeksi ini disebabkan oleh bakteri, virus, atau jamur yang masuk ke paru-paru dan menyebabkan peradangan. Infeksi ini menyebabkan alveolus terisi dengan nanah dan cairan, sehingga membuat pernapasan menjadi sulit. Penelitian

yang dilakukan oleh Lalangui et al. (2022) menunjukkan bahwa salah satu faktor yang menjadi penyebab kematian bayi ialah pneumonia.

- **Kelainan Kongenital**

Kelainan kongenital merupakan kelainan anatomis atau fungsional yang terjadi pada bayi sejak bayi tersebut lahir atau bahkan sejak bayi tersebut masih berada dalam kandungan. Berdasarkan Kemenkes (2023), kelainan kongenital dapat mencakup beragam permasalahan dan mempengaruhi perkembangan normal tubuh atau organ pada bayi yang mengakibatkan gangguan perkembangan mental atau gangguan fungsi organ. Kondisi tersebut dapat diakibatkan oleh beberapa faktor seperti: genetik, infeksi, dan kekurangan asam folat.

### 1.6.3. Metode Bayes

Metode *Bayes* dikembangkan berdasarkan teorema *Bayes*, yaitu mengalikan distribusi *prior* dan informasi data atau fungsi *likelihood* untuk membentuk distribusi *posterior*. Pada Metode *Bayes* terdapat suatu parameter yang dinyatakan kedalam suatu distribusi yang disebut dengan distribusi prior, di mana parameter tersebut menggambarkan pengetahuan awal dari suatu pengamatan (Diana, 2016). Distribusi prior yang dipadukan dengan fungsi *likelihood* kemudian akan menghasilkan suatu distribusi posterior. Jika  $Y$  merupakan suatu variabel acak yang mengikuti pola distribusi tertentu dengan fungsi densitas  $f(y|p)$ , dimana  $p$  merupakan vector parameter berukuran  $n$  sehingga  $p = (p_1, p_2, \dots, p_n)^T$  dan  $y = (y_1, y_2, \dots, y_k)^T$  merupakan vektor sampel yang berukuran  $k$  dengan distribusi identik dan independent, maka dsitribusi *joint* dari  $p$  dan  $y$  dapat dituliskan sebagai berikut:

$$f(y, p) = f(y|p)f(p) = f(p|y)f(y) \quad (2.2)$$

Persamaan (2.2) dapat diturunkan menggunakan teorema *Bayes* sehingga menjadi:

$$f(p|y) = \frac{f(y|p)f(p)}{f(y)}, \text{ dimana } f(y|p) = \prod_{i=1}^n f(y_i|p) \quad (2.3)$$

Pada Persamaan (2.3),  $(y|p)$  merupakan fungsi *likelihood*. Sedangkan,  $(p)$  merupakan fungsi distribusi *prior* dari parameter  $f(y)$  dan  $p$  sehingga diperoleh distribusi *posterior* dari  $p$  sebagai berikut:

$$f(p|y) \propto f(y|p)f(p) \text{ atau } \text{Posterior} \propto \text{Likelihood} \times \text{Prior} \quad (2.4)$$

### 1.6.4. Bayesian Hierarchical

Model *Bayesian Hierarchical* merupakan suatu model yang dibentuk berdasarkan struktur atau tingkatan, dimana setiap tingkatan memiliki variabel parameternya masing-masing. Model tersebut menggambarkan hubungan antar variabel yang berada pada tingkatan yang sama serta hubungan antar variabel di

tingkatan yang berbeda. Misal,  $y_1, y_2, \dots, y_i$  adalah variabel dependen, kemudian  $x_1, x_{2i}, \dots, x_{ki}$  merupakan variabel independent atau prediktor. Penjabaran untuk model regresi *Bayesian* ialah sebagai berikut:

$$y_i = \alpha_0 + \beta x_i + \varepsilon_i$$

dimana  $i = 1, 2, \dots, m$ . Adapun  $\alpha$  dan  $\beta$  merupakan parameter, sedangkan  $\varepsilon_i$  menyatakan error model yang diasumsikan bebas dan terdistribusi secara identik sebagai variabel acak normal dengan rata-rata nol dan variabel konstan  $\sigma^2$ :

$$\varepsilon_i \sim_{iid} Normal(0, \sigma^2)$$

#### 1. Model Tingkat 1

Bentuk persamaan untuk model yang berada pada tingkat pertama dapat dinyatakan kedalam bentuk berikut (Liu et al., 2017):

$$Y_i \sim Poisson \{y_i\} \quad (2.5)$$

$$\ln(y_i) = \ln(n_i p_i)$$

$$\ln(y_i) = \ln(n_i) + \ln(p_i)$$

dimana  $i = 1, 2, \dots, m$ . Pada persamaan (2.5)  $y_i$  diasumsikan berdistribusi Poisson dengan rata-rata  $n_i p_i$ , dimana  $n_i$  menyatakan jumlah pengujian dan  $p_i$  menyatakan prevalensi atau proporsi individu dalam populasi yang memiliki karakteristik tertentu dalam jangka waktu tertentu.

#### 2. Model tingkat 2

Bentuk persamaan untuk model yang berada pada tingkat kedua dapat dinyatakan kedalam bentuk berikut (Liu et al., 2017):

$$\ln(p_i) = \alpha_0 + \sum_{k=1}^n a_k x_{ki} + \varepsilon_i \quad (2.6)$$

dimana  $i = 1, 2, \dots, m$ ;

Persamaan gabungan dari (2.5) dan (2.6) membentuk suatu model hierarki dikarenakan model pada tingkat pertama dipengaruhi oleh model tingkat pada tingkat kedua sehingga membentuk suatu model *Bayesian Hierarchical*.

### 1.6.5. Risiko Relatif

Risiko Relatif (RR) adalah rasio atau ukuran statistik yang digunakan dalam epidemiologi untuk mengukur seberapa besar risiko kelompok orang yang terpapar suatu faktor tertentu untuk mengalami suatu kondisi atau kejadian tertentu, dibandingkan dengan risiko kelompok orang yang tidak terpapar faktor tersebut. Risiko Relatif dalam model *Bayesian Hierarchical* dapat dihitung dengan bantuan

metode *Intrinsic Conditional Autoregressive* (ICAR). Metode ICAR mengurangi kekeliruan taksiran nilai resiko relatif dengan memasukkan informasi spasial dalam pemodelan. Pengukuran nilai RR menggunakan model *Bayesian Hierarchical* dengan ICAR dan Persamaan (2.6) dapat dituliskan sebagai berikut:

$$\ln(r_i) = a_0 + \sum_{k=1}^n a_{ki}x_{ki} + s_i$$

sehingga diperoleh:

$$r_i = \exp(a_0 + \sum_{k=1}^n a_{ki}x_{ki} + s_i) \quad (2.7)$$

Pada Persamaan (2.7)  $a_0$  menyatakan prior atau *intercept* dari suatu kejadian dan  $s_i$  menyatakan efek spasial terstruktur pada lokasi  $i$ . Secara umum, bentuk efek spasial ICAR  $s_i$  berdasarkan Besag (1974) ialah sebagai berikut:

$$s_i | s_j, j \in ne(i), \sim N\left(\bar{s}_i, \frac{\sigma_s^2}{m_i}\right) \quad (2.8)$$

Pada Persamaan (2.8),  $s_j$  menyatakan pengaruh spasial dari seluruh wilayah di sekitar lokasi  $i$ ,  $ne(i)$  menyatakan himpunan tetangga di sekitar lokasi  $i$ , sedangkan parameter  $\sigma_s^2$  menyatakan variansi kondisional untuk variasi spasial. Adapun  $\bar{s}_i$  menyatakan rata-rata efek acak spasial dari tetangga-tetangga tersebut.

$$\bar{s}_i = \frac{1}{m_i} \sum_{j \in ne(i)} s_j$$

Pada Persamaan (2.8),  $m_i$  menyatakan jumlah tetangga dari lokasi  $i$ .

Adapun Interpretasi dari nilai Risiko Relatif (RR) suatu wilayah terhadap suatu kejadian ialah sebagai berikut (Feng et al., 2016):

- RR ( $r_i$ ) = 1, artinya risiko pada kelompok yang terpapar dan tidak terpapar sama.
- RR ( $r_i$ ) < 1, artinya kelompok yang terpapar memiliki risiko lebih rendah untuk mengalami peristiwa atau kondisi tertentu dibandingkan dengan orang yang tidak terpapar.
- RR ( $r_i$ ) > 1, artinya kelompok yang terpapar memiliki risiko lebih tinggi untuk mengalami peristiwa atau kondisi tertentu dibandingkan dengan kelompok yang tidak terpapar.

#### 1.6.6. Nilai Ekspektasi

Nilai ekspektasi suatu kasus pada lokasi  $i$  dapat dinyatakan menggunakan metode *Bayesian Hierarchical* sebagai berikut:

$$E_i = P \times \theta_i$$

$E_i$  menyatakan nilai ekspektasi dari suatu kejadian yang diperoleh dari perkalian populasi kasus yang diamati ( $P$ ) dengan laju terjadinya suatu kasus di lokasi

$i(\theta_i)$  Laju terjadinya suatu kasus dapat dimodelkan menggunakan metode *Bayesian Hierarchical*. Parameter  $\theta_i$  berdistribusi gamma dan dipengaruhi oleh parameter  $\alpha$  dan  $\beta$  atau hyperprior:

$$\theta_i \sim \text{gamma} \{\alpha, \beta\}$$

Penjabaran model *Bayesian* di atas menunjukkan bahwa parameter  $E_i$  dipengaruhi oleh parameter  $\theta_i$ , sedangkan parameter  $\theta_i$  dipengaruhi parameter  $\alpha$  dan  $\beta$ . Model *Bayesian* tersebut menunjukkan bahwa terdapat hierarki dua tingkat pada model *Bayesian* tersebut yaitu parameter  $\alpha$  dan  $\beta$  terhadap parameter  $\theta_i$  di tingkat pertama dan parameter  $\theta_i$  terhadap parameter  $E_i$  di tingkatan kedua. Model tersebut menunjukkan terbentuknya model *Bayesian Hierarchical* dua tingkat.

Parameter  $\theta_i$  diketahui berdistribusi gamma dan dipengaruhi oleh parameter  $\alpha$  dan  $\beta$ , dimana fungsi kepadatan peluang (fkp) dari distribusi gamma dengan dua parameter ialah:

$$f(x; \sigma, p) = \frac{x^{p-1} e^{-\frac{x}{\sigma}}}{\Gamma(p)\sigma^p}$$

dimana:

- $\Gamma(p) = (p-1)!$  merupakan fungsi gamma
- $x \geq 0$  dan  $\sigma, p > 0$

Adapun parameter  $\theta_i$  memiliki fkp sebagai berikut:

$$\theta_i(t; \alpha, \beta) = \frac{t^{\beta-1} e^{-\frac{t}{\alpha}}}{\Gamma(\beta)\alpha^\beta}$$

dimana:

- $\Gamma(\beta)$  merupakan fungsi gamma
- $t \geq 0$  dan  $\alpha, \beta > 0$

Fungsi kepadatan peluang untuk  $Y_i \sim \text{Poisson}(\lambda_i)$  dapat dilihat pada persamaan sebagai berikut:

$$f(Y_i|\lambda_i) = \frac{(\lambda_i)^{Y_i} e^{-\lambda_i}}{Y_i!} \quad (2.9)$$

Berdasarkan Persamaan (2.9) diperoleh fungsi *likelihood* untuk  $Y_i$  ialah sebagai berikut:

$$\begin{aligned} L(Y_{ij}|\lambda_i) &= \prod_{j=1}^n f(Y_{ij}|\lambda_i) \\ &= \frac{(\prod_{ij} [\exp(Y_{ij}(\theta_i p_i)) - \exp(\theta_i p_i)])}{Y_{ij}!} \end{aligned}$$

### 1.6.7. Spasial Model

Spasial model dibuat untuk mengetahui model spasio-temporal dari kejadian di suatu wilayah yang akan diamati berdasarkan pola spasial dan temporal dari kejadian tersebut. Adapun bentuk umum persamaan spasial model berdasarkan Besag (1974) ialah sebagai berikut:

$$Y_i = a_0 + \delta_i + \varepsilon_i$$

dimana:

- $Y_i$  = posterior dari jumlah kasus pada area  $i$
- $\delta_i$  = standar deviasi pada area  $i = 1, 2, \dots, m$
- $a_0$  = Prior/rata-rata keseluruhan dari suatu kasus
- $\varepsilon_i$  = Error pada area  $i = 1, 2, \dots, m$

### 1.6.8. Autokorelasi Spasial

Autokorelasi spasial merupakan analisis korelasi dari suatu kejadian atau kondisi berdasarkan jarak, waktu, ataupun wilayah yang menyebabkan keterkaitan tertentu antar wilayah yang berdekatan atau bertetangga (Fat et al., 2020). Hubungan ketetanggaan menunjukkan informasi antar lokasi dalam ruang tertentu, di mana umumnya disajikan berdasarkan interpretasi pada peta. Selain itu, penggunaan matriks pembobot spasial juga dilakukan untuk menentukan bobot antar lokasi yang diamati berdasarkan hubungan ketetanggaan antar lokasi.

Adapun hal yang dibutuhkan dalam analisis spasial adalah adanya pembobot atau sering disebut sebagai matriks pembobot spasial. Matriks pembobot spasial digunakan untuk menentukan bobot antar lokasi yang akan diamati berdasarkan hubungan ketetanggaan antar lokasi. Menurut Liu (2006) grid umum ketetanggaan dapat didefinisikan dalam beberapa cara yakni *rook contiguity*, *bishop contiguity* dan *queen contiguity* (Fallo et al., 2020).

Pengukuran autokorelasi spasial dapat dihitung menggunakan metode *Moran's Index* (Indeks Moran). Metode ini dapat digunakan untuk mendeteksi permulaan dari keacakan spasial. Keacakan spasial ini dapat mengindikasikan adanya pola-pola yang mengelompok. Pengukuran autokorelasi spasial dengan metode Indeks Moran dapat dilakukan sebagai berikut (Heyne & Fhoteringham, 2020):

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{S_0 \sum_{i=1}^n (x_i - \bar{x})^2} \quad (2.11)$$

dimana  $I$  menyatakan indeks moran,  $n$  menyatakan banyaknya lokasi kejadian,  $x_i$  menyatakan nilai pada lokasi  $i$ ,  $x_j$  menyatakan nilai pada lokasi  $j$ ,  $\bar{x}$  menyatakan rata-rata dari jumlah nilai,  $w_{ij}$  menyatakan elemen matriks pembobot terstandarisasi

antara lokasi  $i$  dan  $j$ ,  $S_0$  menyatakan agregat seluruh bobot spasial dengan persamaan sebagai berikut:

$$S_0 = \sum_{i=1}^n \sum_{j=1}^n w_{ij}$$

Nilai indeks Moran yang positif menunjukkan terjadinya autokorelasi spasial positif yang berarti bahwa nilai-nilai di lokasi yang berdekatan cenderung serupa atau lokasi yang berdekatan memiliki karakteristik yang mirip. Sedangkan nilai yang negatif menunjukkan terjadinya autokorelasi spasial negatif yang berarti bahwa nilai-nilai di lokasi yang berdekatan cenderung berbeda atau lokasi yang berdekatan memiliki karakteristik yang berlawanan. Adapun nilai Indeks Moran yang bernilai nol mengindikasikan bahwa tidak terbentuknya pola autokorelasi spasial yang kuat pada data secara global. Identifikasi terhadap adanya autokorelasi spasial atau tidak, dilakukan uji signifikansi Indeks Moran.

Uji hipotesis untuk Indeks Moran ialah sebagai berikut:

i.  $H_0 : I = 0$  Tidak terdapat autokorelasi spasial

$H_1 : I \neq 0$  Terdapat autokorelasi spasial

ii. Tingkat signifikansi:  $\alpha = 0,05\%$

iii. Nilai uji:  $Z(I) = \frac{I - E(I)}{\sqrt{Var(I)}}$

dengan

$$E(I) = -\frac{1}{n-1}$$

$$Var(I) = \frac{n^2 S_1 - n S_2 + 3 S_0^2}{(n^2 - 1) S_0^2} - [E(I)]^2$$

$$S_1 = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n (w_{ij} + w_{ji})^2$$

$$S_2 = \sum_{i=1}^n \left( \sum_{j=1}^n w_{ij} + \sum_{j=1}^n w_{ji} \right)^2$$

iv. Kriteria uji:  $H_0$  ditolak atau terdapat autokorelasi antar lokasi jika  $|Z(I)| > Z_{\alpha/2}$  dengan nilai  $\alpha = 0,05\%$ .

Interpretasi nilai indeks Moran digunakan untuk mengukur tingkat autokorelasi spasial data wilayah secara global atau menyeluruh, sedangkan pengukuran autokorelasi spasial secara lokal di masing-masing wilayah dapat dilakukan menggunakan *Local Indicators of Spatial Association* (LISA). Pengukuran autokorelasi spasial menggunakan nilai LISA untuk mengukur tingkat autokorelasi spasial data di masing-masing wilayah dapat dilakukan dengan metode berikut (Anselin, 1995):

$$I_i = \frac{n \sum_{j=1}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

dimana parameter  $I_i$  menyatakan nilai LISA di Lokasi  $i$  dengan keterangan untuk parameter lainnya serupa dengan keterangan pada Persamaan (2.10). Parameter  $I_i$  digunakan untuk mengukur tingkat kemiripan atau perbedaan karakteristik nilai suatu lokasi dengan nilai-nilai di sekitar lokasi tersebut. Kemiripan karakteristik nilai pada lokasi yang berdekatan dapat berupa sekumpulan lokasi yang sama-sama memiliki nilai yang tinggi (*High-High*) atau sama-sama memiliki nilai yang rendah (*Low-Low*). Perbedaan karakteristik pada setiap lokasi dapat diakibatkan oleh suatu lokasi dengan nilai yang tinggi dikelilingi oleh lokasi-lokasi dengan nilai yang rendah (*High-Low*) ataupun sebaliknya (*Low-High*).

### 1.6.9. Markov Chain Monte Carlo (MCMC)

*Markov Chain Monte Carlo* (MCMC) merupakan suatu metode yang digunakan untuk membangkitkan peubah peubah acak yang berdasar pada rantai *Markov*. Barisan sampel acak yang saling berkorelasi akan diperoleh saat menggunakan MCMC atau dengan kata lain nilai ke- $i$  dari barisan  $\{\theta_i\}$  diperoleh dari menyamplingkan sebuah dsitribusi peluang yang bergantung pada nilai  $\{\theta_{i-1}\}$ . Pada metode MCMC data sampel dari distribusi sampel dibangkitkan menggunakan proses *Markov Chain* dan simulasi *Monte Carlo*. Metode MCMC sering dipadukan dengan algoritma *Gibbs Sampling* sebagai algoritma pembangkit variabel respon dari suatu fungsi dsitribusi tertentu (Gelman et al. 2014).

Adapun algoritma *Gibbs sampling* ialah sebagai berikut:

1. Penetapan nilai awal parameter  $\pi^t$  pada  $t = 0$ , sehingga  $\pi^{(0)} = (\pi_1^0, \pi_2^0, \dots, \pi_i^0)^T$ .
2. Adapun untuk  $t = 1, 2, \dots, N$ , ulangi langkah berikut:
  - i. Tentukan  $\pi = \pi^{(t-1)}$
  - ii. Kembangkan  $\pi_s \sim f(\pi_s | \pi_s, y)$ , untuk  $s = 1, 2, \dots, i$ .
  - iii. Tentukan  $\pi^t = \pi$ , kemudian gunakan hal tersebut sebagai pembangkit iterasi ke  $t+1$ .

### 1.6.10. Deviance Information Criterion (DIC)

DIC atau kriteria informasi penyimpangan merupakan suatu metode statistik yang digunakan dalam pemilihan model *Bayesian*. Metode DIC dilakukan untuk menentukan model yang terbaik, di mana metode ini membandingkan kecocokan data dan kompleksitas model. Adapun persamaan untuk DIC ialah sebagai berikut:

$$DIC(M) = \overline{D(M)} + pD$$

Keterangan:

DIC = Kriteria informasi penyimpangan

$\overline{D(M)}$  = Penyimpangan

$pD$  = Penalti berdasarkan jumlah parameter efektif

Model dengan interpretasi nilai DIC yang lebih rendah menunjukkan bahwa model yang tersebut merupakan model yang terbaik (Ranjan & Dwivedi, 2022).

### 1.6.11. Transformasi Wavelet

Transformasi Wavelet menggunakan skala waktu yang berbeda untuk menganalisis komponen frekuensi yang berbeda dalam suatu gelombang serta memberikan informasi tiga dimensi tentang sinyal tersebut, yaitu frekuensi pada interval waktu tertentu, komponen frekuensi yang ada dalam sinyal tersebut, dan amplitudo dari gelombang tersebut. Transformasi Wavelet memiliki kemampuan multi-resolusi, dikarenakan transformasi tersebut menggunakan skala waktu yang berbeda untuk menganalisis komponen frekuensi yang berbeda, di mana skala waktu yang digunakan berbanding terbalik dengan komponen frekuensi yang akan dianalisis. Skala waktu yang tinggi digunakan untuk menganalisis komponen frekuensi rendah, sedangkan skala rendah digunakan untuk menganalisis komponen frekuensi tinggi. Selain memiliki kemampuan multi-resolusi, Transformasi Wavelet juga memiliki kemampuan lokalitas spektral, yaitu mampu memberikan informasi mengenai kemunculan komponen frekuensi dalam suatu gelombang pada interval waktu tertentu.

Persamaan matematis untuk Transformasi Wavelet ialah sebagai berikut:

$$W_f(u, s) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{s}} \bar{\psi} \left( \frac{t-u}{s} \right) dt$$

Persamaan tersebut mewakili Transformasi Wavelet Kontinu (CWT) dari suatu gelombang atau suatu fungsi dari  $\psi \in L^2(\mathbb{R})$  yang digunakan untuk melokalisasi sebuah fungsi  $f$  yang terdapat pada skala  $s > 0$  yang ditranslasikan oleh  $u \in \mathbb{R}$ . Adapun  $\bar{\psi}(t)$  merupakan kompleks konjugat dari Wavelet induk  $\psi(t)$  pada ruang *Lebesgue*  $L^2(\mathbb{R})$  (Mallat, 1999):

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi \left( \frac{t-u}{s} \right)$$

Adapun bentuk wavelet induk  $\psi(t)$  untuk wavelet *Mexican Hat* ialah sebagai berikut (Mallat, 2008):

$$\psi(t) = (1 - t^2) e^{-\frac{t^2}{2}}$$

Wavelet *Mexican Hat* adalah turunan kedua dari fungsi Gaussian yang dinormalisasi secara tepat. Wavelet *Mexican Hat* memiliki beberapa keuntungan diantaranya yaitu:

- Sangat sensitif terhadap perubahan cepat dalam sinyal dan sangat cocok untuk sinyal non-stasioner yang mengandung perubahan frekuensi dan amplitudo yang tiba-tiba.
- Memiliki lokalisasi yang baik dalam waktu dan frekuensi, sehingga memungkinkan analisis secara detail terutama terhadap sinyal yang karakteristik statistiknya, seperti rata-rata, varian, atau spektrum frekuensi, yang berubah seiring waktu.

- Memiliki interpretasi fisik yang intuitif sehingga memudahkan interpretasi hasil analisis. Jika sinyal mengandung banyak detail halus, wavelet Mexican Hat dapat secara efektif mengungkapkannya.

Adapun untuk data diskrit, wavelet  $\psi$  ditranslasikan dan diskalakan dengan langkah-langkah sebagai berikut:

- Untuk setiap skala  $s$ :

Buat array  $t$  yang diskalakan

$$t \rightarrow \frac{t-u}{s}$$

Hitung nilai wavelet sesuai dengan fungsi wavelet Mexican Hat untuk Setiap  $t$ :

$$\begin{aligned}\psi_{u,s}(t) &= \psi\left(\frac{t-u}{s}\right) \\ &= \left(1 - \left(\frac{t-u}{s}\right)^2\right) e^{-\frac{\left(\frac{t-u}{s}\right)^2}{2}} \\ &= \left(1 - \left(\frac{t-u}{s}\right)^2\right) e^{-\left(\frac{t-u}{2s}\right)^2}\end{aligned}$$

Kemudian lakukan normalisasi wavelet:

$$\psi_{u,s}(t) = \frac{\psi\left(\frac{t-u}{s}\right)}{\sqrt{s}} = \frac{\left(1 - \left(\frac{t-u}{s}\right)^2\right) e^{-\left(\frac{t-u}{2s}\right)^2}}{\sqrt{s}}$$

- Untuk setiap translasi  $u$ :  
Lakukan konvolusi diskrit antara data dan diskrit yang telah diskalakan:

$$W_d(u, s) = \sum_{t=1}^n f(t) \psi_{u,s}(t)$$

Langkah-langkah untuk melakukan analisis Wavelet ialah sebagai berikut:

1. Pilih jenis Wavelet induk, seperti: Mexican Hat, Haar, dan Morlet Wavelet
2. Bandingkan dengan bagian awal gelombang pada waktu,  $t = 1$ ; hitung  $W_1$
3. Geser gelombang ke bagian berikutnya dari gelombang pada waktu,  $t = 1 + 1$ ; hitung  $W_2$
4. Hitung semua  $W_i$  pada semua selang waktu
5. Gunakan gelombang-gelombang dengan skala yang berbeda (diregangkan atau ditekan) dan ulangi langkah 1–4.
6. Gambarkan plot skala terhadap waktu.

Wavelet memiliki beberapa sifat-sifat penting diantaranya yaitu sifat penerimaan (*admissibility*) dan sifat keteraturan (*regularity*), dimana  $\psi(t)$  dikatakan sebagai sebuah wavelet jika memenuhi kedua sifat tersebut (Valens, 1999).

Frekuensi untuk masing-masing langkah waktu dapat direpresentasikan dalam bidang waktu/frekuensi yang membentuk spektrum Wavelet

$$F_x(u, s) = |W_{dx}(u, s)|^2$$

dimana  $F$  adalah spektrum wavelet dan  $x$  menyatakan lokasi. Spektrum Wavelet  $F_x(u, s)$  diplot sebagai fungsi waktu dan periode dalam grafik 2 dimensi. Transformasi wavelet bertindak sebagai filter lokal yang secara langsung menghubungkan besarnya gelombang ke waktu untuk melacak komponen frekuensi yang berubah seiring waktu. Analisis wavelet secara khusus diadaptasi untuk penyelidikan gelombang non-stasioner dan transien.

Transformasi Wavelet  $W_{dx}$  digunakan untuk menghitung matriks kovarians  $R_{i,j}$  antara setiap pasangan wavelet spektrum  $W_{di}$  dan  $W_{dj}$ , hal tersebut dilakukan untuk mencari '*singular value decomposition*' atau nilai singular dekomposisi dari wavelet spektrum  $W_{di}$  dan  $W_{dj}$ .

$$R_{i,j} = W_i W_j^t$$

$W_{dj}^t$  menunjukkan transposisi  $W_{dj}$  serta dekomposisi nilai singular pada  $R_{i,j}$  juga dapat dituliskan sebagai berikut:

$$R_{i,j} = \mathbf{U} \mathbf{\Gamma} \mathbf{V}^t$$

dimana kolom-kolom matriks  $\mathbf{U}$  bersifat ortogonal dan berisi vektor tunggal untuk  $W_i$ . Matriks  $\mathbf{V}^t$  juga merupakan matriks ortogonal dan mengandung vektor tunggal untuk  $W_j$ . Adapun  $\mathbf{\Gamma}$  adalah matriks diagonal yang elemen diagonalnya bernilai tunggal dengan urutan besarnya yang menurun dan sebanding dengan kovarians kuadrat yang diperhitungkan untuk setiap sumbu.

Pola utama masing-masing frekuensi spektrum Wavelet berkembang seiring waktu, serta diperoleh dengan memproyeksikan setiap spektrum wavelet ke spektrum vektor tunggalnya masing-masing.  $L_i(t)$  dan  $L_j(t)$  masing-masing adalah pola utama untuk  $W_{di}$  dan  $W_{dj}$ :

$$L_i(t) = \sum_{f=1}^{f=F} W_{di}(f, t) \quad \text{dan} \quad L_j(t) = \sum_{f=1}^{f=F} W_{dj}(f, t) \quad (2.12)$$

dengan  $F$  merupakan frekuensi maksimum yang sama untuk kedua spektrum.

Jarak antara 2 spektrum wavelet diukur dengan membandingkan pola utama dan vektor tunggal yang diperoleh. Hubungan antar 2 vektor tunggal dan antar 2 pola utama tidak linier, sehingga tidak dapat dibandingkan dengan menggunakan korelasi sederhana. Hubungan tersebut diukur menggunakan ukuran jarak (D) berikut yang diadaptasi dari Rouyer et al. (2008):

$$D(L_i, L_j) = \sum_{t=1}^{n-1} \text{acos} \left[ \left| \left( L_i^k(t) - L_j^k(t) \right) - \left( L_i^k(t+1) - L_j^k(t+1) \right) \right| \right]$$

dimana  $n$  adalah panjang vektor, serta  $L_i(t)$  dan  $L_j(t)$  merupakan pola utama untuk spektrum Wavelet  $W_{di}$  dan  $W_{dj}$ . Ukuran jarak tersebut membandingkan 2 vektor dengan mengukur sudut antara setiap pasangan segmen yang bersesuaian dan ditentukan oleh titik-titik berurutan dari 2 vektor, dimana 2 vektor paralel akan menghasilkan jarak nol. Ukuran jarak tersebut kemudian dihitung sebagai rata-rata tertimbang untuk jarak masing-masing vektor tunggal dan pola utama, dimana perbandingan spektrum wavelet  $i$  dan  $j$  dihitung menurut  $DT(i, j)$  berikut:

$$DT(i, j) = \frac{\sum_{k=1}^{k=K} w_k \times (D(L_i, L_j) + D(U_i, V_j))}{\sum_{k=1}^{k=K} w_k}$$

dengan  $w_k$  sebagai bobot yang ditetapkan sama dengan jumlah kovarians pada setiap sumbu. Jarak  $DT(i, j)$  kemudian digunakan untuk mengisi matriks jarak yang sesuai untuk analisis cluster serta membuat hierarki Wavelet berdasarkan matriks tersebut. Semakin besar jumlahnya kovarians, semakin besar jumlah sumbu yang dipertahankan. Semakin panjang jumlah sumbu memungkinkan untuk memperhitungkan fitur waktu-frekuensi umum yang lebih rinci antara 2 spektrum.

## 1.7. Penelitian yang Relevan

Adapun beberapa penelitian yang relevan dengan topik atau masalah yang akan dibahas dalam penelitian ini ialah sebagai berikut:

1. Penelitian yang dilakukan oleh Ranjan & Dwivedi (2022) yang berjudul kematian dan pengelompokan kematian bayi di tingkat kabupaten di India: pendekatan *Bayesian*. Penelitian ini mengelompokkan dan menilai variasi spasial kematian bayi antar kabupaten diberbagai tempat tertentu di India menggunakan model geodatif *Bayesian*. Tujuan utama dalam penelitian tersebut ialah memodelkan kematian bayi beserta korelasinya setelah memperhitungkan dampak nonlinier dari usia ibu saat melahirkan dan dampak spasial residual dari tiap kabupaten. Temuan dalam penelitian menunjukkan bahwa Usia ibu saat melahirkan mempunyai pengaruh nonlinier terhadap kematian bayi di semua bagian negara. Hal tersebut terlihat dari grafik sebagian besar kabupaten yang menunjukkan bahwa pada usia awal masa reproduksi, risiko kematian bayi sangat tinggi dan secara bertahap menurun seiring bertambahnya usia dan tetap konstan setelahnya.
2. Penelitian yang dilakukan oleh Soehardjoepri et al. (2018) yang berjudul Model *Bayesian Hierarki* curah hujan untuk menentukan *return level* pendekatan *Peaks Over Threshold*. Penelitian tersebut mengidentifikasi curah hujan ekstrim di Daerah Aliran Sungai (DAS) menggunakan pendekatan *Peaks Over Threshold* (POT). Pendekatan tersebut diterapkan pada pola distribusi *Generalized Pareto Distribution* (GPD) data curah hujan. Estimasi parameter GDP selanjutnya dianalisis menggunakan Model Bayesian Hierarki dua tingkat dengan menggunakan *conjugat prior* sebagai distribusi prior. Hasil penelitian tersebut menunjukkan bahwa hujan ekstrim


tidak terjadi dalam satu tahun kedepan di lima pos hujan, namun terjadi hujan ekstrim di tiga dan lima tahun kedepan.

3. Penelitian yang dilakukan oleh Chen et al. (2022), yang berjudul Model *Bayesian Hierarchical spatio-temporal* proses interaksi antar wilayah. Penelitian tersebut mencoba untuk membuat suatu model *spatio-temporal* yang fleksibel dan dapat mendeskripsikan interaksi spasial dan temporal antar titik. Model yang telah ditemukan disimulasikan menggunakan data kebakaran hutan akibat alam yang terjadi di Negara Amerika Serikat. Penelitian tersebut menerapkan *Metropolis-Hastings* ganda dengan algoritma penyampelan Gibbs untuk menghasilkan 10.000 sampel posterior dari parameter model. Berdasarkan Hasil estimasi dan *credible interval* menunjukkan bahwa rata-rata posterior lebih besar dari 0 sehingga menyatakan bahwa lokasi kebakaran hutan mengelompok secara signifikan setiap tahunnya.

## BAB II METODE PENELITIAN

### 2.1. Jenis Penelitian

Penelitian ini akan menggunakan metode *Bayesian Hierarchical* untuk memodelkan serta melakukan analisis spasio-temporal terhadap data jumlah kematian bayi lahir hidup beserta faktor penyebab kematian bayi dan jumlah bayi lahir hidup di Provinsi Sulawesi Barat. Adapun tingkatan wilayah pada penelitian ini ialah sebagai berikut:



**Gambar 2.1** Tingkatan wilayah lokasi penelitian

### 2.2. Jenis dan Sumber Data Penelitian

Data yang akan digunakan dalam penelitian ini merupakan data sekunder yang bersumber dari Dinas Kesehatan Daerah dan Badan Pusat Statistik (BPS) serta Rumah Sakit Umum Daerah (RSUD) di tiap kabupaten di Provinsi Sulawesi Barat. Selain itu, data dalam penelitian ini juga menggunakan data geografis Provinsi Sulawesi Barat untuk masing-masing kabupaten dan kecamatan yang dapat diakses menggunakan aplikasi *google maps*. Adapun daftar nama kabupaten dan kecamatan di Provinsi Sulawesi Barat dapat dilihat pada Tabel 2.1 berikut:

**Tabel 1.1** Nama kabupaten dan kecamatan di Provinsi Sulawesi Barat

| No | Kabupaten       | Kecamatan                                                                                                                                                                    |
|----|-----------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 1  | Majene          | Banggae, Banggae Timur, Pamboang, Sendana, Tammerodo Sendana, Tubo Sendana, Malunda, Ulumanda.                                                                               |
| 2  | Mamasa          | Aralle, Balla, Bambang, Buntu Malangka, Mamasa, Mambi, Mehalaan, Messawa, Nosu, Rantebulahan Timur, Pana, Sesena Pada, Sumarorong, Tabang, Tabulahan, Tanduk Kalua, Tawalian |
| 3  | Polewali Mandar | Tinambung, Balanipa, Limboro, Tubbi Taramanu, Alu, Campalagian, Luyo, Wonomulyo, Mapilli, Tapango, Matakali, Bulo, Polewali, Binuang, Anreapi, Matangnga                     |
| 4  | Mamuju          | Bonehau, Kalukku, Kalumpang, Kepulauan Balabalakang, Mamuju, Papalang, Sampaga, Simboro dan Kepulauan, Tapalang, Tapalang Barat, Tommo                                       |
| 5  | Mamuju Tengah   | Pangale, Budong-Budong, Tobadak, Topoyo, Karossa                                                                                                                             |
| 6  | Pasangkayu      | Sarudu, Dapurang, Duripoku, Baras, Bulu Taba, Lariang, Pasangkayu, Tikke Raya, Pedongga, Bambalamotu, Bambaira, Sarjo                                                        |

### 2.3. Teknik Analisis Data

Teknik analisis data yang akan digunakan dalam penelitian ini ialah analisis deskriptif dan analisis inferensial.

#### 2.3.1. Analisis Deskriptif

Analisis statistika deskriptif dalam penelitian ini bertujuan untuk mendeskripsikan data jumlah kematian bayi di tiap kecamatan dan kabupaten di Provinsi Sulawesi Barat, penyebab atau faktor yang mempengaruhi kematian bayi, daftar wilayah kecamatan yang saling bertetangga, serta deskripsi dari interpretasi data spasial maupun temporal.

#### 2.3.2. Analisis Inferensial

Analisis statistika inferensial dalam penelitian ini dimaksudkan untuk mengolah data penelitian secara *spatio-temporal* menggunakan bantuan aplikasi *OpenBUGS*, *Geodat* dan *MATLAB*. Langkah analisisnya ialah sebagai berikut:

- Memodelkan fenomena kematian bayi lahir hidup menggunakan Model *Bayesian Hierarchical*.

Pemodelan diawali dengan penentuan distribusi prior dari parameter yang akan diestimasi, kemudian melakukan estimasi terhadap parameter

model *Bayesian Hierarchical* menggunakan algoritma *Gibbs Sampling* dalam metode *Markov Chain Monte Carlo* (MCMC).


- Melakukan analisis resiko relatif dan autokorelasi terhadap data jumlah kematian bayi lahir hidup berdasarkan data faktor-faktor penyebab kematian bayi, jumlah bayi lahir hidup serta faktor ketetanggaan daerah-daerah yang berdekatan antara yang satu dengan yang lainnya di Provinsi Sulawesi Barat. Adapun faktor penyebab kematian bayi akan dijadikan sebagai kovariat dan faktor ketetanggaan antar wilayah akan dijadikan sebagai efek spasial.
- Melakukan klusterisasi terhadap data kematian bayi lahir hidup berdasarkan frekuensi dan skala waktu kejadian di tiap wilayah di Provinsi Sulawesi Barat menggunakan Transformasi *Wavelet*.
- Menghitung nilai DIC dari model matematika yang telah terbentuk untuk melihat besar penyimpangan dari model.

### 2.3.3. Kerangka Pikir

Ketika ibu atau anak mengalami atau melakukan suatu hal yang menjadi faktor terjadinya kematian bayi sama halnya dengan menambah peluang terjadinya kematian bayi (Irawaty et al., 2021). Fenomena perkembangan nilai jumlah kematian bayi yang terjadi di suatu wilayah pada waktu tertentu tersebut dapat membentuk suatu pola berdimensi ruang dan waktu yang biasa disebut dengan pola *spatio-temporal*. Pola tersebut dapat diamati dengan menggunakan suatu model perhitungan matematis yang biasa disebut dengan Model *Bayesian Hierarchical*. Model tersebut merupakan pengembangan dari salah satu metode statistik yang disebut dengan Metode *Bayes*. Kelebihan dari Model *Bayesian Hierarchical* tersebut dapat digunakan untuk memodelkan pola *spatio-temporal* data jumlah kematian bayi dan faktor-faktor penyebabnya dalam dua tingkatan analisis.

Penelitian ini akan menggunakan model *Bayesian Hierarchical* pada analisis statistiknya. Pada tahap analisis yang pertama, model akan dianalisis berdasarkan karakteristik data di tingkat kecamatan yang meliputi jumlah bayi yang lahir hidup, jumlah kematian bayi yang lahir hidup, dan faktor-faktor kematian bayi di tingkat kecamatan. Hasil analisis data pada tahap pertama akan digunakan sebagai referensi untuk menganalisis karakteristik data di tingkat kabupaten. Pada tingkat yang kedua, data kemudian akan dianalisis berdasarkan data di tingkat kecamatan dan karakteristik data di tingkat kabupaten. Hasil analisis data menggunakan model *Bayesian Hierarchical* di tingkat kecamatan dan tingkat kabupaten kemudian akan dianalisis untuk melihat resiko relatif dan autokorelasi spasial. Kemudian melakukan klusterisasi menggunakan Transformasi *Wavelet* untuk menggambarkan pola *spatio-temporal* data jumlah kematian bayi di Provinsi Sulawesi Barat.

Adapun kerangka pikir penelitian dapat dilihat pada Gambar 2.2 berikut:



**Gambar 2.2** Kerangka pikir penelitian