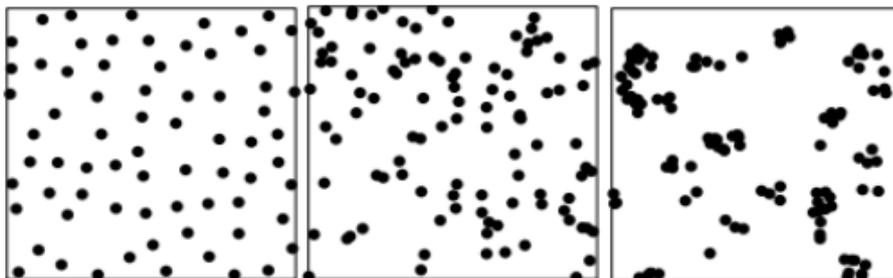


## BAB II TINJAUAN PUSTAKA

### 2.1 *Spatial Point Process*

*Spatial point process* digunakan sebagai model statistik untuk menganalisis pola persebaran titik, dimana titik tersebut mewakili lokasi dari suatu objek penelitian misalnya lokasi pohon, sarang burung, kasus penyakit dan lain-lain yang keberadaan dan persebarannya adalah *random* di suatu wilayah (Baddeley et al, 2015). *Spatial point process*  $\mathbf{X}$  adalah himpunan bagian acak yang berasal dari suatu batasan tertentu  $B \subset \mathbb{R}^2$ . Bentuk realisasi dari *spatial point process* adalah *spatial point pattern*  $\mathbf{x} = \{x_1, x_2, \dots, x_n\}$  dengan  $n(\mathbf{X} \cap B)$  adalah jumlah poin yang berada pada suatu *observation window*  $B$  (Moller dan Waagepetersen, 2007).  $x_i$  merupakan lokasi objek penelitian yang diwakili oleh koordinat *cartesian* berupa  $\mathbf{u} = (u_1, u_2)$  dengan  $\mathbf{u} \in B, B \subset \mathbb{R}^2$  dimana  $u_1$  adalah *longitude* dan  $u_2$  adalah *latitude*.

Berdasarkan korelasi spasial, terdapat 3 pola dasar dalam *point pattern* yaitu *regular*, independen (*random*) dan kelompok (*cluster*). Ketiga pola dasar tersebut dapat divisualisasikan pada Gambar 2.1 di bawah ini.



**Gambar 2.1** Pola Dasar dalam *Point Pattern Regular* (kiri), *Independen* (tengah) dan *Cluster* (kanan)

Gambar 2.1 menunjukkan pola dasar dalam *spatial point pattern*, diketahui bahwa pada pola *regular* titik-titik dalam wilayah pengamatan cenderung menjauh satu sama lain. Sedangkan pada pola independen (*random*), titik-titik cenderung menunjukkan pola yang acak (*complete spatial randomness*). Selain itu, pada pola kelompok (*cluster*) titik-titik cenderung berdekatan satu dan lainnya.

### 2.1.1 Poisson Process

*Poisson process* merupakan salah satu model untuk *spatial point pattern* yang memiliki pola acak (*complete spatial randomness*). Sebuah *poisson process*  $\mathbf{X}$  pada  $\mathbb{R}^2$  dengan fungsi intensitas  $\rho$  dan *observation window*  $B \subseteq \mathbb{R}^2$  dengan  $\mu(B) > 0$ , maka:

1.  $n(B)$  atau jumlah objek atau kejadian di  $B$  berdistribusi *poisson* dengan *mean*  $\mu(B)$ .
2. Poin di  $\mathbf{X}_B$  merupakan independent dengan fungsi intensitas  $\rho(\mathbf{u})$ , dimana  $\mathbf{u} \in B$

Terdapat dua tipe *poisson process*, tipe pertama yaitu jika  $\rho(\mathbf{u})$  merupakan sebuah konstanta untuk semua  $\mathbf{u} \in W$ , maka *poisson process homogen*. Sedangkan tipe kedua terdapat sebuah *point process* yang disebut *inhomogeneous poisson process* (Daley dan Vere-Jones, 2007). *Inhomogeneous poisson process* merupakan suatu *poisson process* dengan fungsi intensitas  $\rho(\mathbf{u})$  yang tidak konstan dan bervariasi sesuai dengan perubahan lokasi. Adapun karakteristik dari *inhomogeneous poisson process* adalah sebagai berikut:

1. Jumlah dari titik berada dalam wilayah  $B$  atau  $n(\mathbf{X} \cap B)$  memiliki distribusi *poisson*.

2. Nilai ekspektasi dari *point* yang berada dalam wilayah  $B$  merupakan

$$E[n(\mathbf{X} \cap B)] = \int_B \rho(\mathbf{u}) d\mathbf{u} .$$

3. Jika  $B_1, B_2, \dots$  merupakan wilayah yang tidak beririsan dari suatu ruang, maka  $n(\mathbf{X} \cap B_1), n(\mathbf{X} \cap B_2), \dots$  merupakan variabel *random* yang saling independen.

4. Jika  $n(\mathbf{X} \cap B) = n$ , maka  $n$  *point* tersebut memiliki distribusi yang saling identik dan independen serta memiliki *probability density function* (pdf) seperti yang ditunjukkan pada persamaan 2.1 berikut ini.

$$f(\mathbf{u}) = \frac{\rho(\mathbf{u})}{I}, I = \int_B \rho(\mathbf{u}) d\mathbf{u} \quad (2.1)$$

### 2.1.2 Thomas Cluster Process

*Thomas Cluster Process* terbentuk dari dua tahapan yang pertama yaitu *mother process*. *Mother process* ( $C$ ) merupakan suatu *poisson process* dengan intensitas  $\kappa$ . Selanjutnya, akan muncul proses baru  $\mathbf{X}_c, c \in C$  yang dinamakan *offspring processes* yang tersebar disekitar *mother process* dengan fungsi intensitas seperti pada persamaan 2.2 di bawah ini.

$$\rho_c(\mathbf{u}; \boldsymbol{\beta}) = \exp(\zeta + \boldsymbol{\beta}^T z(\mathbf{u})) k(\mathbf{u} - \mathbf{c}; \omega) \quad (2.2)$$

$k(\mathbf{u})$  merupakan *probability density function* (pdf) dari distribusi jarak antara *offspring* dan *mother process* dengan parameter  $\omega$ , dimana  $\mathbf{X} = \cup_{c \in C} \mathbf{X}_c$  merupakan *Thomas Cluster Process* dengan induk  $C$  dan *offspring*  $\mathbf{X}_c, c \in C$ . *Mother points* dalam penelitian ini adalah lokasi terjadinya gempa bumi utama

(*mainshocks*) sedangkan lokasi terjadinya gempa bumi susulan (*aftershocks*) sebagai *offspring points*. Fungsi densitas  $k$  pada *Thomas Cluster Process* yang ditulis pada persamaan 2.3 (Møller dan Waagepetersen, 2007).

$$k(\mathbf{u}) = (2\pi\omega^2)^{-1} \exp(-\|\mathbf{u}\|^2 / (2\omega^2)) \quad (2.3)$$

Model *Thomas Cluster Process* memiliki fungsi kepadatan peluang jarak antara *mother* dan *offspring process* yang saling independen dan berdistribusi normal *bivariate*  $N(0, \omega^2 \mathbf{I})$ . Hal tersebut berlaku dengan kondisi ketika induk berada di  $c$ , maka anak biasanya juga didistribusikan di sekitar  $c$ . Jika nilai  $\omega$  semakin kecil maka *cluster* yang terbentuk semakin rapat dan jika nilai  $\kappa$  semakin kecil, maka *number of parent* juga akan lebih sedikit (Choiruddin, et al., 2018). Fungsi intensitas *Thomas Cluster Process* dapat ditulis seperti pada persamaan 2.4 di bawah ini.

$$\rho(\mathbf{u}; \beta) = \kappa \exp(\beta^T z(\mathbf{u})) \quad (2.4)$$

*K-function* pada *Thomas Process* dapat ditulis pada persamaan 2.5 di bawah ini.

$$K(r) = \pi r^2 + \frac{1}{\kappa} \left( 1 - \exp\left(-\frac{r^2}{4\omega^2}\right) \right) \quad (2.5)$$

Adapun *pair correlation function* *Thomas Cluster Process* dapat ditulis pada persamaan 2.6 berikut ini.

$$g(\mathbf{u}) = 1 + (4\pi\omega^2)^{-1} \exp(-\|\mathbf{u}\|^2 / (4\omega^2)) / \kappa \quad (2.6)$$

## 2.2 Analisis Eksplorasi Data

Analisis eksplorasi data pada *point process* digunakan untuk mengetahui stasioner/homogenitas data dan mengetahui pola persebaran data dengan menggunakan analisis korelasi spasial. Stasioneritas suatu data dapat diketahui dari *first order properties*. Sedangkan pola persebaran data dapat diketahui dari *second order properties*.

### 2.2.1 Intesitas

Intensitas merupakan karakteristik deskriptif dasar dari suatu proses titik yang merupakan ekspektasi atau *first order properties* yang analog dengan rata-rata jumlah poin, dimana setiap *point process*  $X$ , karakteristik intensitas dijelaskan sepenuhnya jika diketahui ekspektasi jumlah titik yang dapat dituliskan seperti pada persamaan 2.7 berikut ini.

$$\mu(B) = E[n(X \cap B)] \quad (2.7)$$

Fungsi intensitas  $\rho(\mathbf{u}; \boldsymbol{\beta})$  merupakan fungsi *non* negatif yang dapat memodelkan *first order*, sehingga jika ditulis seperti pada persamaan 2.8.

$$\mu(B) = \int_B \rho(\mathbf{u}; \boldsymbol{\beta}) du \quad (2.8)$$

$\mathbf{u}$  merupakan lokasi wilayah spasial, nilai intensitas dilambangkan dengan  $\rho(\mathbf{u}; \boldsymbol{\beta})$ , dimana  $\rho(\mathbf{u}; \boldsymbol{\beta})$  merupakan sebuah fungsi yang menyatakan peluang mengobservasi sebuah *point* di suatu wilayah yang sangat kecil dengan luas  $du$  dan pusat  $\mathbf{u}$ .

Sebelum melakukan pengujian homogenitas dari data, maka *observation window* yang ada dibagi menjadi *quadrat*, dimana  $n_1, n_2, \dots, n_m$  merupakan jumlah

point disetiap kotak bagian. Adapun uji yang digunakan adalah uji *chi-squared* dengan hipotesis pengujian sebagai berikut:

$H_0: \rho(\mathbf{u}) = \rho(\mathbf{v}); \mathbf{u}, \mathbf{v} \in B$  (intesitas homogen)

$H_1: \rho(\mathbf{u}) \neq \rho(\mathbf{v}); \mathbf{u}, \mathbf{v} \in B$  (intesitas tidak homogen)

Adapun statistik uji yang digunakan dapat ditulis pada persamaan 2.9 berikut ini.

$$\chi_{hit}^2 = \sum_{j=1}^m \frac{n_j - e_j}{e_j} = \sum_{j=1}^m \frac{n_j - \frac{n}{m}}{\frac{n}{m}} \quad (2.9)$$

Keterangan:

$n_j$  : banyaknya *point* di *quadrat count* ke- $j$

$e_j$  : ekspektasi banyaknya *point* di *quadrat count* ke- $j$

$m$  : jumlah kotak bagian/*quadrature*

Hasil pengujian akan menolak hipotesis nol jika  $\chi_{hit}^2 > \chi_{\alpha;df}^2$  dengan  $df = m - 1$  atau  $P\text{-value} < \alpha$  (Baddeley et al, 2015).

### 2.2.2 K-Function

Salah satu metode yang digunakan untuk mengukur ketergantungan suatu variabel adalah korelasi. Korelasi dalam teori statistik, diklasifikasikan sebagai *second moment* dan rata-rata sebagai *first moment*. Sedangkan pada analisis *spatial point process* teknik yang paling populer untuk menganalisis korelasi spasial adalah *K-Function* yang diusulkan oleh Ripley (Ripley, 1977).

Konsep *K-Function* adalah menghitung jarak  $d_{ij} = \|\mathbf{u}_i - \mathbf{u}_j\|$  antar semua pasangan titik berbeda  $\mathbf{u}_i$  dan  $\mathbf{u}_j$  dalam suatu *point pattern*. Menggunakan jarak ini akan diketahui mengenai pola spasial yang terbentuk. Jika pola mengelompok

(*cluster*), maka banyak jarak antar pasang titik yang bernilai kecil. Sedangkan jika polanya *regular*, maka akan ada beberapa jarak antar pasang titik yang bernilai kecil. Apabila intensitas *inhomogen*, maka ditambahkan bobot untuk  $\mathbf{u}_i$  sebesar  $b_i = 1/\rho(\mathbf{u}_i)$ , dimana  $b_i$  merupakan intensitas proporsional pada poin  $\mathbf{u}_i$ . Sedangkan pasangan  $\mathbf{u}_i$  dan  $\mathbf{u}_j$  akan ditambahkan bobot sebesar  $b_{ij} = b_i b_j = \frac{1}{\rho(\mathbf{u}_i)\rho(\mathbf{u}_j)}$ , sehingga untuk rumus *K-Function* dengan intensitas *inhomogen* dapat ditulis seperti pada persamaan 2.10 berikut ini.

$$\hat{K}_{inhom} = \frac{1}{D^p |B|} \sum_{i=1}^n \sum_{\substack{j=1 \\ j \neq i}}^n \mathbf{I} \left\{ \frac{\|\mathbf{u}_i - \mathbf{u}_j\|}{\hat{\rho}(\mathbf{u}_i)\hat{\rho}(\mathbf{u}_j)} \right\} e(\mathbf{u}_i; \mathbf{u}_j; r) \quad (2.10)$$

dimana nilai  $D = \frac{1}{|B|} \sum_{i=1}^n \frac{1}{\hat{\rho}(\mathbf{u}_i)}$

Keterangan:

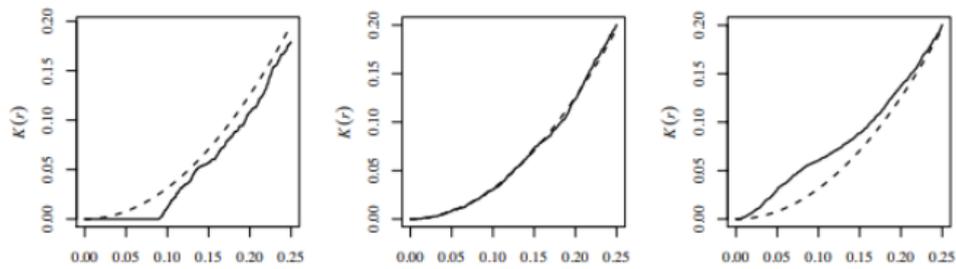
$h_{ij}(\mathbf{u}_i; \mathbf{u}_j; r)$  : bobot *edge correction*

$|B|$  : luas area *observation window*

$\hat{\rho}(\mathbf{u}_i)$  : nilai estimasi dari  $\rho(\mathbf{u}_i)$

$\hat{\rho}(\mathbf{u}_j)$  : nilai estimasi dari  $\rho(\mathbf{u}_j)$

Berdasarkan hasil *K-Function*  $\hat{K}(r)$  yang telah dihitung dengan menggunakan rumus 2.9, sehingga dapat dilakukan visualisasi terhadap *K-Function* empiris  $\hat{K}(r)$  bersama dengan *K-Function* teoritis dari *poisson process*  $K_{pois}(r) = \pi r^2$ , sehingga didapatkan plot seperti pada Gambar 2.2 di bawah ini.



**Gambar 2.2** *K-Function Plot Regular* (kiri), *Independen* (tengah) dan *Cluster* (kanan)

Function empiris  $\hat{K}(r)$  bersama dengan *K-Function* teoritis dari *Poisson process*. Kurva dengan garis putus-putus merupakan plot dari *K-Function* teoritis dari *Poisson process*. Sedangkan *K-Function* empiris dilambangkan dengan *solid line*. Ada tiga tipe plot yang terbentuk, dimana pada kondisi pertama garis *K-Function* empiris berada dibawah garis *K-Function* teoritis  $\hat{K}(r) < K_{pois}(r)$ . Kondisi tersebut menunjukan bahwa jenis titik dalam pola ini memiliki tetangga (*neighbour*) lebih sedikit daripada yang diharapkan apabila pola tersebut benar-benar acak. Pola ini konsisten membentuk pola *regular*. Kondisi kedua dimana *K-Function* empiris bertumpukan dengan garis *K-Function* teoritis  $\hat{K}(r) = K_{pois}(r)$ , artinya jenis titik dalam pola ini memiliki tetangga (*neighbour*) sesuai dengan yang diharapkan. Kondisi ketiga, dimana *K-Function* empiris berada diatas garis *K-Function* teoritis  $\hat{K}(r) > K_{pois}(r)$  yang artinya jenis titik dalam pola ini memiliki tetangga (*neighbour*) lebih banyak daripada yang diharapkan. Kondisi ini konsisten membentuk pola *cluster* (Baddeley et al, 2015).

## 2.3 Estimasi Parameter

Penaksiran parameter dilakukan pada penelitian ini untuk menaksir nilai parameter  $\beta$  dan parameter model *cluster*, yaitu  $\omega$  dan  $\kappa$ . Pada penelitian ini, penaksiran parameter  $\beta$  di *first order* menggunakan metode *maximum composite likelihood orde 1*. Sedangkan penaksiran parameter model *cluster* digunakan metode *maximum composite likelihood orde 2*.

### 2.3.1 Maximum Composite Likelihood Orde 1

Model *inhomogeneous poisson process* dengan intensitas  $\rho(\mathbf{u}; \beta)$  terdapat parameter yang dinotasikan dengan  $\beta$ . Fungsi *likelihood* yang digunakan untuk mengestimasi  $\beta$  dapat dituliskan seperti pada persamaan 2.11.

$$L(\beta; \mathbf{u}) = \rho(\beta; \mathbf{u}_1) \dots \rho(\beta; \mathbf{u}_n) \exp \left( \int_B (1 - \rho(\beta; \mathbf{u})) d\mathbf{u} \right) \quad (2.11)$$

Berdasarkan persamaan 2.11 di atas, maka dapat terbentuk fungsi *log-likelihood* seperti dituliskan pada persamaan 2.12.

$$\log L(\beta; \mathbf{u}) = \sum_{i=1}^n \rho(\beta; \mathbf{u}_i) - \int_B \rho(\beta; \mathbf{u}) d\mathbf{u} \quad (2.12)$$

Berdasarkan persamaan 2.12 dapat diketahui bahwa fungsi *log-likelihood* dari *inhomogeneous poisson process* melibatkan integral dari *observation window*  $B$ . Oleh karena itu, penaksiran parameter dengan fungsi *likelihood* tersebut tidak dapat dihitung dengan tepat, sehingga dibutuhkan perhitungan secara numerik. Metode *numerical quadrature* dikembangkan untuk *inhomogeneous poisson point process* agar fungsi *likelihood* nya mendekati fungsi *likelihood* dari *generalized linear poisson model*. Menggunakan pendekatan *numerical quadrature*, maka

$\int_B \rho(\boldsymbol{\beta}; \mathbf{u}) d\mathbf{u}$  dapat didekati oleh  $\sum_{i=1}^{n+q} \rho(\boldsymbol{\beta}; \mathbf{u}_i) w_i$ , dimana  $w_i$  merupakan bobot *quadrature* dan  $q$  merupakan banyaknya *dummy point*, sehingga persamaan 2.12 dapat ditulis menjadi persamaan 2.13 seperti berikut ini.

$$\log L(\boldsymbol{\beta}; \mathbf{u}) = \sum_{i=1}^n \rho(\boldsymbol{\beta}; \mathbf{u}_i) - \sum_{i=1}^{n+q} \rho(\boldsymbol{\beta}; \mathbf{u}_i) w_i \quad (2.13)$$

Bentuk sederhana dari persamaan 2.13 dapat ditulis seperti pada persamaan 2.14.

$$\log L(\boldsymbol{\beta}; \mathbf{u}) = \sum_{i=1}^{n+q} (I_i \log \rho(\boldsymbol{\beta}; \mathbf{u}_i) - \rho(\boldsymbol{\beta}; \mathbf{u}_i) w_i) \quad (2.14)$$

Nilai  $I_i$  bernilai 1 jika  $\mathbf{u}_i$  merupakan sebuah data poin. Sedangkan untuk  $\mathbf{u}_i$  yang merupakan *dummy point*  $I_i$  bernilai 0. Persamaan 2.14 juga dapat ditulis seperti pada persamaan 2.15 (Berman dan Turner, 1992).

$$\log L(\boldsymbol{\beta}; \mathbf{u}) = \sum_{i=1}^{n+q} (y_i \log \rho(\boldsymbol{\beta}; \mathbf{u}_i) - \rho(\boldsymbol{\beta}; \mathbf{u}_i) w_i) \quad (2.15)$$

Dimana  $y_i = I_i/w_i$ , persamaan 2.15 ekuivalen dengan fungsi *likelihood weighted poisson* yang diberi bobot  $w_i$ .

### 2.3.2 Maximum Composite Likelihood Orde 2

*Maximum composite likelihood* orde 2 merupakan salah satu metode penaksiran parameter model *clustered point process*  $\boldsymbol{\theta} = (\kappa, \omega)^T$  pada persamaan 2.16 dituliskan fungsi *composite likelihood orde 2* yang dibangun dari semua titik data  $u_i u_j$  (Baddeley et al, 2015).

$$\log CL(\boldsymbol{\theta}) = \sum_i \sum_{j \neq i} w(\mathbf{u}_i, \mathbf{u}_j) \left[ \log \rho^{(2)}(\mathbf{u}_i, \mathbf{u}_j; \boldsymbol{\theta}) - \log \int_B \int_B w(\mathbf{u}_i, \mathbf{u}_j) \rho^{(2)}(\mathbf{u}_i, \mathbf{u}_j; \boldsymbol{\theta}) d\mathbf{u}_i d\mathbf{u}_j \right] \quad (2.16)$$

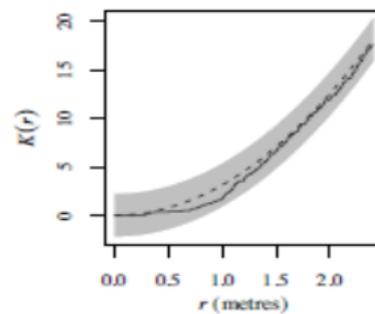
Nilai  $w$  pada persamaan 2.16 merupakan fungsi pembobot, untuk memudahkan perhitungan maka nilai  $w(\mathbf{u}_i, \mathbf{u}_j) = 1\{\|\mathbf{u}_i - \mathbf{u}_j\| \leq R\}$  dengan  $R > 0$  merupakan batas atas korelasi dari model. Fungsi *composite score* yang merupakan turunan pertama *fungsi likelihood* terhadap  $\theta$ , dapat dituliskan seperti pada persamaan 2.17.

$$\frac{\partial}{\partial \theta} \log CL(\theta) = \sum_i \sum_{j \neq i} w(\mathbf{u}_i, \mathbf{u}_j) \frac{\kappa_2(\mathbf{u}_i, \mathbf{u}_j; \theta)}{\rho^{(2)}(\mathbf{u}_i, \mathbf{u}_j; \theta)} - \sum_i \sum_{j \neq i} w(\mathbf{u}_i, \mathbf{u}_j) \frac{\kappa_2, w}{\rho^{(2), w}} \quad (2.17)$$

Dimana  $\kappa_2(\mathbf{u}_i, \mathbf{u}_j; \theta) = \frac{\partial}{(\partial \theta) \rho^{(2)}(\mathbf{u}_i, \mathbf{u}_j; \theta)}$  dan  $(l, w) = \iint_{B, B} w(\mathbf{u}_i, \mathbf{u}_j) \rho^{(2)}(\mathbf{u}_i, \mathbf{u}_j; \theta) du_i du_j$

#### 2.4 Kebaikan Model

Kebaikan model yang dihasilkan dapat dicek dengan menggunakan plot *envelope K-Function*. Selain itu, plot *K-Function* dari data *point* asli akan dibandingkan dengan hasil dari simulasi model *inhomogeneous thomas cluster process*. Suatu model dikatakan baik untuk memodelkan data tertentu jika plot *K-Function* data *point* asli berada pada data interval *envelope K-Function*. Ilustrasi dari plot *envelope K-Function* data *Swedishpines*, dimana area abu-abu merupakan area interval *envelope* seperti ditunjukkan pada Gambar 2.3 (Baddeley et al, 2015).



Gambar 2.3 *Plot Envelope K-Function* Data *Swedishpines*

Selain menggunakan plot *envelope K-Function*, model terbaik dapat dipilih berdasarkan nilai BIC terkecil. Kriteria BIC dapat didefinisikan seperti pada persamaan 2.18 berikut ini.

$$-2\ell_n(\hat{\beta}) + p \log\{\mu(W)\} \quad (2.18)$$

$p$  merupakan banyaknya parameter yang ditaksir ( $\hat{\beta}$ ), pada prakteknya, nilai  $\mu(W)$  tidak diketahui, sehingga dapat didekati dengan  $n(W)$ , maka kriteria BIC juga dapat didefinisikan seperti pada persamaan 2.19 (Choiruddin et al, 2020).

$$BIC = -2\ell_n(\hat{\beta}) + p \log\{n(W)\} \quad (2.19)$$

$\ell_n(\hat{\beta})$  merupakan *maximum composite likelihood* orde 1 seperti pada persamaan 2.14.  $n(W)$  merupakan jumlah titik yang ada dalam sebuah *observation window*  $W$  dan  $p$  merupakan jumlah parameter yang ada dalam model.

## 2.5 Gempa Bumi

Gempabumi adalah getaran yang terjadi di permukaan bumi akibat pelepasan energi dari dalam secara tiba-tiba yang menciptakan gelombang seismik. Gempabumi akan terjadi apabila penumpukan energi pada batas lempeng yang bersifat *konvergen* (bertumbukan), *divergen* (saling menjauh) dan *transform* (berpapasan) atau pada sesar dan blok batuan tersebut tidak mampu lagi menahan batas elastisitasnya. Gempabumi dapat dikelompokkan menjadi beberapa macam berdasarkan penyebabnya yaitu tektonik, vulkanik, runtuhan, jatuhnya meteor dan gempabumi buatan manusia. Gempabumi tektonik adalah gempabumi yang disebabkan oleh pelepasan energi elastis yang tersimpan dalam lempeng tektonik. Gempabumi vulkanik adalah gempabumi yang disebabkan oleh kegiatan gunung

berapi. Magma yang berada pada kantong di bawah gunung tersebut mendapat tekanan dan melepaskan energinya secara tiba-tiba sehingga menimbulkan getaran tanah. (Sunarjo et al., 2012). Tidak sama seperti bencana alam yang lain, gempa bumi terjadi secara mendadak tanpa ada tanda-tanda sebelumnya dan belum dapat diprediksi kapan dan dimana akan terjadi gempabumi (Sunarjo et al., 2012). Akibat utama yang ditimbulkan gempabumi adalah hancurnya bangunan dan jatuhnya korban jiwa karena tertimpa reruntuhan bangunan, bahkan gempabumi juga bisa memicu terjadinya bencana alam lain yaitu tanah longsor dan tsunami, jika sumbernya berada di dasar lautan (ESDM, 2013).

## 2.6 Faktor Geologis

Subduksi merupakan pertemuan (tumbukan) dua lempeng akibat adanya pergerakan lempeng yang saling mendekat (lempeng benua dan lempeng samudera). Kedua lempeng yang bergerak saling menekan, sehingga terjadi pembengkokan pada lempeng samudera (sudut subduksi) yang kemudian menyusup ke bawah lempeng benua. Besar sudut subduksi dipengaruhi oleh besarnya tekanan yang diberikan lempeng atasnya (Akmam, 2016).

Sesar adalah struktur rekahan yang telah mengalami pergeseran. Umumnya disertai oleh struktur yang lain seperti lipatan, rekahan, dsb. Sesar dapat dibagi kedalam beberapa jenis tergantung pada arah relatif pergeserannya. Selama sesar dianggap suatu bidang datar, maka konsep jurus dan kemiringan juga dapat dipakai, dengan demikian jurus dan kemiringan dari suatu bidang sesar dapat diukur dan ditentukan. Jenis sesar dapat digolongkan menjadi *dip slip faults*, *normal faults*,

*horsts and grabens, half-grabens, reverse faults, thrust fault, strike slip faults dan transform-faults* (Noor, 2009).

Gunung berapi muncul akibat magma dari dalam bumi bergerak naik ke atas permukaan. Naiknya magma ke permukaan disebabkan oleh dua hal yaitu aktifitas tektonik dan konduksi panas. Naiknya magma ke permukaan disebabkan oleh adanya aktifitas tektonik yang bermula dari ketidakseimbangan litostatik di dalam bumi. Sedangkan naiknya magma karena konduksi panas terjadi karena aliran panas dari kantung magma ke lapisan batuan terdekat. Aliran panas ini berisi gas, air tanah atau fluida yang disebut sebagai kantung fluida. Konduksi panas yang terjadi secara terus menerus menyebabkan terjadinya peningkatan suhu dan tekanan pada kantung fluida. Sehingga suatu saat tidak dapat menahan tekanan gas. Akibatnya magma mengalir dan terjadilah erupsi (Setiawan, 2014; Hermon, 2015).

