

BAB II

TINJAUAN PUSTAKA

2.1 Landasan Teori

2.1.1 Kebencanaan

Kebencanaan merupakan peristiwa tragis yang berdampak besar bagi masyarakat, menghancurkan aset, dan mengancam keselamatan warga, dengan komunitas medis memiliki peran penting dalam meminimalkan kerugian jiwa dan materi (Desforjes & Waeckerle, 1991). Bencana alam sebagai objek dari kebencanaan, tidak hanya menyebabkan kerusakan fisik, tetapi juga mengganggu fungsi sosial, ekonomi, dan lingkungan dalam masyarakat (Abbas et al., 2019). Bentuk dari bencana alam sendiri dapat dilihat pada **Gambar 2.1**. Dampak dari bencana ini sering kali berkaitan erat dengan kerentanan wilayah terdampak dan kesiapan masyarakat dalam menghadapinya (Braitberg, 2022).



Gambar 2. 1. Bencana Alam

Sumber : diolah oleh peneliti

Kebencanaan sendiri dibagi menjadi 2 klasifikasi menurut sumbernya (Mohamed, 2007). Faktor alam yang telah disebutkan sebelumnya merupakan salah satunya, terdapat pula bencana non-alam yang disebabkan oleh aktivitas manusia, seperti kebakaran hutan, kecelakaan industri, dan peperangan (Anand & Nagol, 2016). Bentuk dari

bencana ini dapat dilihat pada **Gambar 2.2**. Sesuai dengan Undang-Undang Nomor 24 Tahun 2007 tentang Penanggulangan Bencana di Indonesia, bencana non-alam saat ini menjadi perhatian pemerintah dan masyarakat karena dampaknya bisa berskala besar, terutama terhadap kesehatan masyarakat dan stabilitas ekonomi (Akhmaddhian et al., 2022). Salah satu langkah untuk mengurangi risiko bencana non-alam adalah penanganan yang efektif dengan regulasi yang ketat, peningkatan kapasitas sumber daya manusia, dan implementasi teknologi pencegahan (Birnbaum et al., 2016).



Gambar 2. 2. Bencana Non-Alam


Sumber : diolah oleh peneliti

Potensi bencana yang akan dihadapi baik alam maupun non-alam, mitigasi menjadi salah satu langkah penting dalam mengurangi risiko yang muncul (Christoplos et al., 2001). Mitigasi bencana mencakup berbagai tindakan preventif untuk mengurangi kerugian dan kerusakan, termasuk penataan ruang yang tepat, edukasi masyarakat, serta penerapan teknologi pemantauan seperti satelit dan sistem peringatan dini (Press & Hamilton, 1999). Mitigasi bencana berfokus pada tindakan yang dilakukan sebelum bencana terjadi agar masyarakat lebih siap dalam menghadapi kemungkinan terburuk (Krimgold, 1986). Strategi mitigasi bencana dapat terinisiasi dengan pemantauan melalui data yang telah tervalidasi, diantaranya adalah pemantauan melalui jarak jauh. Warna daerah terdampak bencana tidak dapat diketahui secara pasti dan cenderung beragam pada data tersebut. Hal ini tergantung pada wilayah serta jenis bencana tersebut. Daerah dengan

dampak bencana cenderung memiliki perbedaan piksel dengan intensitas tertentu apabila dibandingkan dengan data sebelum terkena bencana.

2.1.2 Citra Digital

Citra digital merupakan representasi visual dari objek, pemandangan, atau permukaan tertentu yang dikonversi ke dalam format digital sehingga dapat disimpan, diolah, dan dianalisis secara komputasional. Informasi visual dikodekan dalam bentuk angka-angka diskrit yang merepresentasikan intensitas cahaya atau nilai warna di setiap titik (*pixel*) pada gambar. Proses pengubahan informasi visual menjadi data numerik inilah yang disebut dengan digitalisasi (Gonzalez et al., 2018). Citra ini terdiri dari elemen-elemen terkecil yang disebut *pixel* yang masing-masing menyimpan informasi mengenai tingkat intensitas cahaya atau nilai warna pada posisi tertentu dalam gambar. Hal ini direpresentasikan pada **Gambar 2.3** berikut.




Gambar 2. 3. Pixels pada Citra Digital

Sumber : diolah oleh peneliti

Setiap piksel dalam citra digital memiliki koordinat spasial (**Gambar 2.4a**) dan nilai intensitas yang merepresentasikan informasi visual dalam berbagai *channel*. *Channel* didefinisikan sebagai komponen warna penyusun citra digital yang masing-masing menangkap karakteristik tertentu dari cahaya. *Channel* umum yang digunakan adalah skala keabuan (*grayscale*) maupun dalam bentuk warna RGB (*Red, Green, Blue*). Hal ini dapat

diperhatikan visualnya pada **Gambar 2.4b**. *Channel* atau format dalam pengolahan citra menjadi sangat penting karena memungkinkan penerapan berbagai algoritma dan teknik analisis secara otomatis dan presisi melalui sistem komputasi.




Gambar 2. 4. Koordinat Spasial (a) dan *Channel* (b) pada Citra

Sumber : diolah oleh peneliti

Mulanya, Citra digital dikembangkan untuk mengatasi keterbatasan pengolahan secara analog dan memberikan fleksibilitas tinggi dalam proses transformasi, segmentasi, klasifikasi, dan interpretasi data visual. Citra digital dapat direpresentasikan dalam berbagai dimensi spektral yang masing-masing memuat informasi dalam satu atau lebih *channel* spektrum elektromagnetik sebagai gambaran telah diperlihatkan pada **Gambar 2.4b** bagian kiri. Citra digital dapat diperoleh dari berbagai sumber, termasuk kamera digital, pemindai, dan perangkat penginderaan jauh seperti satelit.

2.1.3 Teknologi Penginderaan Jauh dan Citra Satelit

Penginderaan jauh didefinisikan sebagai metode untuk memperoleh informasi tentang objek atau fenomena di permukaan bumi tanpa melakukan kontak fisik langsung dengan objek tersebut (Hussain et al., 2013). Proses ini dilakukan dengan memanfaatkan sensor yang terpasang pada satelit atau pesawat terbang, yang mendeteksi radiasi elektromagnetik yang dipantulkan atau dipancarkan oleh permukaan bumi (Fu et al., 2020). Teknis dari Penginderaan jauh dapat dilihat pada **Gambar 2.5** (Sutomo et al., 2020). Teknologi ini telah berkembang pesat dan menjadi salah satu instrumen utama dalam berbagai bidang, termasuk pemantauan lingkungan, eksplorasi sumber daya alam, hingga mitigasi dan penanggulangan bencana (Alexander, 1991). Teknologi ini menyediakan informasi visual dan data numerik yang sangat dibutuhkan untuk memantau kondisi lingkungan dan perubahan yang terjadi akibat bencana alam, seperti banjir, gempa bumi, tanah longsor, serta kebakaran hutan (Joyce et al., 2009). Data citra satelit dapat ditangkap melalui teknologi penginderaan jauh, selanjutnya dapat diolah tanpa harus melakukan observasi langsung di lapangan. Hal ini sangat menguntungkan dalam situasi bencana di mana akses fisik ke wilayah terdampak sering kali sulit, berbahaya, atau tidak terjangkau (Liu & Hodgson, 2016).



Gambar 2. 5. Teknis Metode Penginderaan Jauh

Sumber : diolah oleh peneliti

Citra satelit didefinisikan sebagai gambar atau representasi visual dari permukaan bumi yang dihasilkan sebagai output dari teknologi penginderaan jauh (Bennett et al., 2022). Citra satelit termasuk dalam kategori citra digital karena berupa matriks dua dimensi yang merepresentasikan nilai intensitas cahaya atau pantulan permukaan bumi dalam bentuk numerik. Citra satelit yang digunakan untuk pemantauan dan analisis kebencanaan salah satunya dapat dibedakan berdasarkan resolusi spasialnya (Laneve et al., 2007). Resolusi spasial mengacu pada ukuran piksel atau detail terkecil yang dapat ditangkap oleh sensor satelit. Citra dengan resolusi spasial tinggi, seperti yang dihasilkan oleh satelit seperti WorldView atau GeoEye, mampu menangkap detail objek di permukaan bumi hingga skala meter. Hal ini sangat berguna untuk memantau kerusakan bangunan atau infrastruktur akibat gempa atau banjir. Citra dengan resolusi sedang hingga rendah, seperti yang dihasilkan oleh satelit Landsat atau MODIS, lebih efektif digunakan untuk pemantauan bencana dalam skala luas seperti kebakaran hutan atau perubahan penggunaan lahan.

Resolusi temporal juga merupakan faktor penting dalam pemilihan citra satelit untuk analisis kebencanaan selain resolusi spasial. Resolusi temporal mengacu pada seberapa sering satelit dapat mengamati area yang sama di permukaan bumi, untuk memantau peristiwa bencana yang berlangsung cepat, seperti banjir atau kebakaran, citra satelit dengan resolusi temporal tinggi sangat diperlukan agar perubahan yang terjadi dapat dipantau secara real-time atau dalam interval waktu yang pendek. Satelit seperti Sentinel-1, yang mampu menyediakan data radar dengan frekuensi kunjungan harian, sangat berguna dalam hal ini. Selain itu, citra satelit juga memiliki karakteristik resolusi spektral, yang merujuk pada kemampuan sensor satelit untuk menangkap data pada berbagai panjang gelombang cahaya. Sensor multispektral, seperti yang terdapat pada satelit Landsat dan Sentinel, mampu menangkap data dari berbagai pita spektral, termasuk pita inframerah dekat yang sangat berguna untuk memantau vegetasi dan kelembaban tanah. Sensor hiperspektral, yang menangkap data dari ratusan

pita spektral, menawarkan kemampuan yang lebih detail untuk menganalisis kondisi lingkungan dan perubahan yang terjadi akibat bencana. Data multispektral dan hiperspektral ini sangat penting dalam mendeteksi perubahan vegetasi akibat kebakaran hutan atau mengidentifikasi area banjir berdasarkan kelembaban tanah.

2.1.4 Histogram Matching

Histogram *matching* adalah suatu teknik dalam pengolahan citra digital yang bertujuan untuk menyamakan bentuk distribusi intensitas dari suatu citra dengan distribusi histogram dari citra lain yang dijadikan acuan. Teknik ini sangat berguna dalam aplikasi di mana konsistensi visual antara dua citra penting, seperti pada pencocokan citra multisensor, kalibrasi pencahayaan, serta deteksi perubahan (*change detection*) pada citra satelit multitemporal. Histogram matching mempertahankan karakteristik histogram referensi. Teknik ini sering diterapkan pada tahap pra-pemrosesan dalam penelitian penginderaan jauh untuk menyamakan pencahayaan antara citra sebelum dan sesudah kejadian bencana. Hal ini dilakukan sehingga perubahan yang terdeteksi lebih mencerminkan kondisi nyata di lapangan dan bukan perbedaan sensor atau kondisi perekaman.

Histogram matching melibatkan pencocokan *cumulative distribution function* (CDF) antara citra sumber dan citra referensi. Bentuk hasil histogram matching dapat diperhatikan dalam **Gambar 2.6** berikut.



Gambar 2. 6. Histogram Matching B terhadap A

Sumber : diolah oleh peneliti

Proses ini dimulai dengan menghitung histogram dari citra masukan, kemudian membentuk fungsi distribusi kumulatifnya. Fungsi distribusi

kumulatif citra masukan dilambangkan dengan $T(r_k)$, yang merupakan hasil penjumlahan dari probabilitas kemunculan nilai intensitas piksel hingga indeks k , yaitu $p_r(r_i)$. Variabel r_k menyatakan nilai intensitas ke- k pada citra masukan, sedangkan $p_r(r_i)$ adalah probabilitas atau frekuensi relatif kemunculan intensitas r_i di citra tersebut.

Fungsi distribusi kumulatif $T(r_k)$ dihitung melalui **Persamaan 2.1** berikut.

$$T(r_k) = \sum_{i=0}^k p_r(r_i) \quad (2.1)$$

citra target yang memiliki histogram tujuan akan dihitung fungsi distribusi kumulatifnya dengan notasi $G(z_k)$, yang diperoleh dari jumlah kumulatif probabilitas target $p_z(z_i)$ hingga indeks k . Variabel z_k merepresentasikan nilai intensitas ke- k pada histogram target, dan $p_z(z_i)$ adalah probabilitas kemunculan intensitas z_i pada citra target. Persamaan untuk $G(z_k)$ dijabarkan dalam **Persamaan 2.2** berikut.

$$G(z_k) = \sum_{i=0}^k p_z(z_i) \quad (2.2)$$


Nilai intensitas baru pada citra output diperoleh dengan mencari intensitas z_l yang membuat nilai kumulatif $G(z_l)$ paling mendekati nilai $T(r_k)$ dari citra input. Variabel z_l di sini menunjukkan nilai intensitas pada citra target yang menjadi hasil pemetaan dari nilai input r_k . Proses ini dapat dituliskan sebagai **Persamaan 2.3** berikut.

$$T(r_k) \approx G(z_l) \quad (2.3)$$

Nilai $G(z_l)$ dihitung untuk semua kemungkinan nilai intensitas, kemudian dibulatkan ke bilangan bulat terdekat dan disimpan dalam sebuah *lookup table*. Setiap nilai r_k pada citra input kemudian dicocokkan dengan nilai z_l dari tabel tersebut yang paling mendekati nilai $T(r_k)$, sehingga setiap piksel di citra input dapat ditransformasikan ke nilai baru sesuai histogram yang ditentukan. Prosedur ini menghasilkan citra baru yang memiliki distribusi intensitas menyerupai histogram target. Algoritma ini diadaptasi dari metode Histogram Specification pada (Gonzalez et al., 2018).

2.1.5 Hue Saturation Value (HSV)

Model *multichannel* warna HSV (*Hue, Saturation, Value*) merupakan salah satu representasi warna yang dirancang agar lebih menyerupai persepsi visual manusia dibandingkan model warna RGB. Model HSV memisahkan informasi rona warna, kejenuhan, dan kecerahan ke dalam tiga komponen yang terpisah, yaitu *Hue* (H), *Saturation* (S), dan *Value* (V). *Hue* menyatakan rona atau jenis warna dalam satuan derajat dari 0° hingga 360° . *Saturation* menunjukkan tingkat kejenuhan warna, yaitu seberapa dominan warna dalam *channel* tersebut. *Value* menggambarkan tingkat kecerahan warna, nilai yang lebih tinggi menandakan warna yang lebih terang. Model HSV ini dapat diperhatikan pada **Gambar 2.7** berikut.



Gambar 2. 7. Model Lingkaran Warna *Channel* HSV

Sumber : (Erdoğan & Yılmaz, 2014)

Konversi *channel* dari RGB ke HSV sering diaplikasikan dalam pengolahan citra digital karena HSV memungkinkan pemisahan komponen rona dari pencahayaan. Hal ini dianggap sangat berguna dalam proses segmentasi warna, pelacakan objek, maupun deteksi perubahan. Model HSV lebih stabil terhadap perubahan intensitas cahaya, berbeda dengan RGB yang sangat sensitif terhadap pencahayaan dan bayangan. Model HSV dapat digunakan secara luas dalam pengolahan citra berbasis warna, termasuk dalam penginderaan jauh dan pemetaan wilayah terdampak bencana. Secara matematis, konversi dari RGB ke HSV mengikuti **Persamaan 2.4** berikut.

$$\begin{aligned}
 V &= \max(R, G, B) \\
 S &= \begin{cases} \frac{V - \min(R, G, B)}{V} & , \text{jika } V \neq 0 \\ 0 & , \text{jika } V = 0 \end{cases} \\
 H &= \begin{cases} 60 \cdot \frac{G - B}{V - \min(R, G, B)} & , \text{jika } V = R \\ 120 + 60 \cdot \frac{B - R}{V - \min(R, G, B)} & , \text{jika } V = G \\ 240 + 60 \cdot \frac{R - G}{V - \min(R, G, B)} & , \text{jika } V = B \\ 0 & , \text{jika } R = G = B \end{cases} \quad (2.4)
 \end{aligned}$$

Berdasarkan **Persamaan 2.4** variabel R , G , dan B merupakan nilai-nilai komponen warna merah, hijau, dan biru dalam *channel* RGB. Komponen V merupakan nilai maksimum dari ketiga komponen RGB yang mencerminkan tingkat kecerahan warna, karena nilai tertinggi di antara R , G , dan B menunjukkan seberapa terang suatu warna tampak. Komponen S menyatakan tingkat kejenuhan warna, yaitu selisih antara nilai maksimum dan minimum yang dinormalisasi terhadap nilai maksimum tersebut. Apabila seluruh komponen RGB memiliki nilai yang sama atau nilai $V = 0$, maka tidak ada dominansi warna dan tidak terdapat perbedaan intensitas antar komponen, sehingga warna dianggap tidak jenuh ($S = 0$) dan tampil

sebagai hitam. Komponen H menentukan posisi rona dalam lingkaran warna pada **Gambar 2.7**. Hal ini didasarkan pada perbedaan nilai antar komponen RGB dengan penyesuaian berdasarkan komponen mana yang bernilai maksimum. Koreksi nilai H yaitu, *jika $H < 0$ maka $H = H + 360$* . Hal ini agar nilai tetap berada dalam rentang $[0^\circ, 360^\circ]$. Luaran dari HSV akan selalu berada dalam rentang berikut, $0 \leq V \leq 1, 0 \leq S \leq 1, 0 \leq H \leq 360$. HSV menjadi salah satu model warna yang sangat efektif dalam analisis citra berbasis warna. Hal ini karena HSV mampu menangani perubahan pencahayaan dan memberikan isolasi komponen rona secara eksplisit untuk keperluan segmentasi dan klasifikasi warna. Algoritma konversi *channel* sebelumnya merupakan adaptasi dari (OpenCV, 2025). Gambaran dari konversi ini ada pada **Gambar 2.8** berikut.



Gambar 2. 8. Konversi *Channel* RGB ke HSV

Sumber : diolah oleh peneliti

2.1.6 Dekomposisi Nilai Singular

Dekomposisi nilai singular (SVD) merupakan metode dekomposisi matriks yang banyak digunakan dalam bidang aljabar linear dan banyak diterapkan dalam berbagai bidang seperti pengolahan citra, kompresi data, dan pembelajaran mesin. SVD memfaktorkan sebuah matriks A berukuran $m \times n$ menjadi hasil perkalian dari tiga matriks: U , Σ , dan V^T , sebagaimana

dituliskan pada **Persamaan 2.5** berikut.

$$A = U\Sigma V^T \quad (2.5)$$

variabel $U \in R^{m \times m}$ dan $V \in R^{n \times n}$ adalah matriks ortogonal, sedangkan $\Sigma \in R^{m \times n}$ adalah matriks diagonal yang berisi nilai-nilai singular dari A pada diagonal utamanya. Nilai-nilai singular σ_i adalah akar dari nilai eigen dari $A^T A$, pada **Persamaan 2.6** berikut.

$$\sigma_i = \sqrt{\lambda_i} \quad (2.6)$$

dengan λ_i adalah nilai eigen dari $A^T A$. Elemen-elemen non-nol pada diagonal Σ disusun menurun, yakni $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$, dengan r adalah rank dari matriks A . Proses dekomposisi dimulai dengan menghitung nilai eigen dari AA^T untuk memperoleh vektor-vektor singular kiri yang menyusun kolom-kolom matriks U , dan kemudian menghitung nilai eigen dari $A^T A$ untuk memperoleh vektor-vektor singular kanan yang menjadi kolom-kolom matriks V . Langkah-langkah ini mengikuti struktur sistematis sebagai berikut.

1. Hitung nilai-nilai eigen λ_i dari $A^T A$ dan AA^T ,
2. Normalisasi vektor-vektor eigen menjadi ortonormal untuk menyusun U dan V ,
3. Susun matriks Σ sebagai **Persamaan 2.7** berikut.

$$\Sigma = \begin{bmatrix} \sigma_1 & 0 & \dots & 0 \\ 0 & \sigma_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_r \end{bmatrix}_{m \times n} \quad (2.7)$$


Salah satu kekuatan utama dari SVD adalah kemampuannya untuk menghasilkan aproksimasi peringkat rendah dari suatu matriks, yang sangat

berguna dalam pengolahan data citra satelit berdimensi besar. Matriks citra satelit yang semula kompleks dapat direduksi dengan hanya mempertahankan beberapa nilai singular terbesar yang menyimpan informasi paling penting dalam struktur citra. Aproksimasi dapat ditulis sebagai **Persamaan 2.8** berikut.

$$A_k = \sum_{i=1}^k \sigma_i u_i v_i^T \quad (2.8)$$

A_k disusun dari komponen-komponen singular, dengan $k < r$ dan u_i, v_i masing-masing adalah vektor singular kiri dan kanan. SVD memungkinkan pengurangan dimensi data secara efisien tanpa kehilangan informasi penting, serta mempercepat proses komputasi lanjutan seperti segmentasi citra, klasifikasi, dan pemetaan wilayah terdampak bencana.

Permasalahan timbul pada pemilihan nilai singular **Persamaan 2.7** yang optimal untuk digunakan dalam proses segmentasi. Pemilihan σ_r sebagai dasar klasifikasi atau ekstraksi fitur dapat didukung oleh analisis perilaku nilai singular terhadap distribusi nilai matriks A . Perhatikan **Gambar 2.9** berikut.



Gambar 2. 9. Plot Nilai Singular terhadap Nilai Matriks A


Sumber : diolah oleh peneliti

Berdasarkan **Gambar 2.9**, sebaran nilai singular terhadap variasi nilai piksel dalam matriks lokal menunjukkan perbedaan karakteristik yang signifikan antar komponen. Komponen singular pertama (d_{11}) memperlihatkan tren

pertumbuhan linier dan konsisten, yang mengindikasikan dominasi informasi global yang stabil di seluruh citra. Sebaliknya, nilai singular terakhir (d_{nn}) dalam hal ini d_{55} terdistribusi secara sempit dengan nilai relatif rendah serta fluktuasi minimal. Pola tersebut mencerminkan sensitivitas tinggi terhadap perubahan halus di sekitar titik pusat kernel. Nilai singular terakhir memiliki potensi sebagai indikator kuat dalam segmentasi berbasis lokal karena kemampuannya menyoroti dinamika kecil yang tidak terdeteksi oleh komponen utama. Pendekatan ini memungkinkan pemodelan yang lebih adaptif terhadap variasi tekstur dan struktur lokal pada citra. Strategi pemanfaatan d_{nn} memberikan peluang bagi algoritma segmentasi untuk fokus pada fitur yang relevan, tanpa bergantung semata pada informasi dominan dari komponen singular pertama. Hal ini sejalan dengan penelitian (Abdurrazzaq et al., 2021).

2.1.7 Nilai Singular Terkecil dalam Segmentasi Citra

Nilai singular terkecil (σ_r) dalam dekomposisi nilai singular (SVD) memiliki peran yang sangat penting dalam segmentasi citra, khususnya dalam mendeteksi perubahan halus yang tidak dapat diungkapkan oleh komponen singular yang lebih dominan. Matriks berukuran kecil seperti matriks lokal 2×2 dapat mendeteksi perbedaan antara elemen-elemen matriks yang tampaknya kecil serta dapat mempengaruhi nilai singular terkecil secara signifikan. Hal ini dapat direpresentasikan pada **Gambar 2.10** berikut.




Gambar 2. 10. Visualisasi Nilai Singular Terkecil

Sumber : diolah oleh peneliti

Berdasarkan **Gambar 2.10**, kedua grafik menunjukkan pola distribusi nilai singular terkecil terhadap variasi nilai piksel A , sementara nilai B tetap. Nilai-nilai A dipetakan dari rentang 1 hingga 255, membentuk 3 nilai dari matriks 2×2 , sedangkan nilai B sebagai suatu nilai yang bersifat konstan. Terlihat bahwa titik minimum dari kurva terjadi saat A mendekati B , yang menunjukkan bahwa nilai singular terkecil (σ_2) mencapai nilai terendah ketika baris-baris dalam matriks memiliki nilai yang seragam atau sangat mirip. Hal ini menandakan bahwa (σ_2) sangat peka terhadap kemiripan lokal, dan fluktuasinya dapat digunakan untuk mendeteksi variasi kecil antar piksel. Ketika nilai A semakin berbeda dari B , nilai (σ_2) meningkat, mencerminkan perbedaan fitur yang semakin besar antara dua bagian citra. Pola ini memperkuat posisi nilai singular terkecil sebagai indikator segmentasi yang tanggap terhadap perubahan lokal, dan sangat berguna dalam membedakan area terdampak dalam citra satelit resolusi tinggi. Segmentasi citra berdasarkan fenomena nilai singular terkecil ini telah berhasil diterapkan dalam penelitian oleh (Abdurrazzaq et al., 2021).

2.1.8 Log Ratio Comparison

Log-ratio merupakan salah satu metode perbandingan citra dalam deteksi perubahan berbasis citra *Synthetic Aperture Radar* (SAR). Metode ini digunakan untuk mengekstraksi informasi perubahan antara dua citra dengan intensitas yang telah saling diregistrasi, yaitu citra sebelum dan sesudah kejadian. Log-ratio bertujuan untuk mereduksi pengaruh noise speckle (**Gambar 2.11a**) yang bersifat multiplikatif pada citra SAR serta memperjelas perbedaan spektral antar piksel. Noise speckle adalah jenis gangguan khas pada citra SAR yang muncul akibat interferensi koheren gelombang radar dan bersifat memperbanyak intensitas secara acak. Log-ratio bekerja dengan mengubah domain data ke dalam skala logaritmik. Hal ini membuat sinyal perubahan dapat lebih mudah dikenali karena noise speckle menjadi lebih menyerupai noise aditif (**Gambar 2.11b**) yang distribusinya lebih teratur. Noise aditif bersifat menjumlahkan gangguan pada sinyal lebih terkendali dan distribusinya biasanya lebih simetris.



Gambar 2. 11. Noise Speckle (a) dan Aditif (b) dalam Data SAR

Sumber : diolah oleh peneliti

Metode ini diawali dengan membentuk citra rasio untuk setiap piksel antara dua citra SAR X_1 dan X_2 , yang kemudian dikonversi ke dalam bentuk logaritma natural untuk membentuk log-ratio image. Proses ini memungkinkan perbedaan kecil pada intensitas rendah menjadi lebih nyata dalam *outputnya*, serta memperbaiki keseimbangan antar kelas piksel yang berubah (ω_c) dan tidak berubah (ω_u). Secara matematis, untuk menghasilkan citra log-ratio X_{LR} adalah menggunakan **Persamaan 2.9** berikut (Bovolo & Bruzzone, 2005).

$$X_{LR} = \log X_2 - \log X_1 = \log \left(\frac{X_2}{X_1} \right) \quad (2.9)$$

Berdasarkan **Persamaan 2.9**, fungsi *log* menyatakan logaritma natural. Persamaan ini mengimplikasikan bahwa perbedaan logaritmik antara dua citra dapat memberikan representasi yang lebih stabil dan bersih dari perubahan yang terjadi. Hasil dari persamaan yang berupa citra log-ratio ini dapat digunakan dalam proses dekomposisi multiresolusi untuk mengidentifikasi perubahan pada berbagai skala spasial, dengan mempertimbangkan kompromi antara pelestarian detail geometris dan reduksi speckle.

2.1.9 Visual Quality Assessment

Visual Quality Assessment (VQA) adalah metode untuk menilai kualitas visual dari gambar, yang mencakup aspek subjektif dan objektif dalam mengukur seberapa baik kualitas visual suatu media. *Area Under Curve* (AUC) adalah salah satu metode dalam konteks ini yang digunakan untuk memberikan metrik yang dapat mengukur performa model atau algoritma dalam mengidentifikasi kualitas visual. AUC dihitung dari kurva *Receiver Operating Characteristic* (ROC) yang menggambarkan hubungan antara *true positive rate* dan *false positive rate* dalam skenario klasifikasi biner. Nilai AUC yang tinggi menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan antara area dengan kualitas visual tinggi dan rendah, yang dalam konteks ini mengacu pada perbedaan citra sebelum dan sesudah bencana (Carrington et al., 2023).

AUC merupakan nilai yang diperoleh dari perhitungan luas di bawah kurva ROC, yang menunjukkan kemampuan model untuk membedakan antara dua kelas atau kategori. Secara matematis, AUC dapat dirumuskan berdasarkan integral dari kurva ROC pada **Persamaan 2.10** berikut.

$$AUC = \int_0^1 TPR(FPR)d(FPR) \quad (2.10)$$

Variabel *TPR* (*True Positive Rate*) didefinisikan sebagai rasio antara jumlah prediksi positif yang benar terhadap total data positif yang sebenarnya. Bentuk matematis *TPR* dituliskan pada **Persamaan 2.11** berikut.

$$TPR = \frac{TP}{TP + FN} \quad (2.11)$$

Variabel *TP* (*True Positive*) adalah jumlah data positif yang berhasil diklasifikasikan secara benar sebagai positif, dan *FN* (*False Negative*) adalah jumlah data positif yang salah diklasifikasikan sebagai negatif. *TPR* sering

disebut juga sebagai sensitivitas atau *recall*, yang merepresentasikan kemampuan model dalam mengenali data positif secara akurat. *FPR* (*False Positive Rate*) merupakan rasio antara jumlah prediksi positif yang salah terhadap total data negatif yang sebenarnya. Bentuk matematis *FPR* dituliskan pada **Persamaan 2.12** berikut.

$$FPR = \frac{FP}{FP + TN} \quad (2.12)$$

variabel *FP* (*False Positive*) adalah jumlah data negatif yang salah diklasifikasikan sebagai positif, dan *TN* (*True Negative*) adalah jumlah data negatif yang berhasil diklasifikasikan secara benar sebagai negatif. *FPR* menggambarkan sejauh mana model melakukan kesalahan dalam mengidentifikasi data negatif sebagai positif. Kedua metrik ini digunakan dalam pembentukan kurva ROC, yang menjadi dasar perhitungan AUC dalam evaluasi performa model klasifikasi.

2.2 Hasil Penelitian Terdahulu

Berbagai pendekatan telah dikembangkan untuk memisahkan area terdampak dari latar belakang citra, baik melalui teknik berbasis transformasi citra, pengelompokan piksel, analisis spasial, maupun pemrosesan tepi. Setiap pendekatan memiliki karakteristik tersendiri dalam menyesuaikan segmentasi terhadap jenis bencana dan kondisi citra. Beberapa penelitian yang menjadi acuan dalam studi ini disajikan pada **Tabel 2.1** berikut.

Tabel 2. 1. Hasil Penelitian Terdahulu

No.	Judul	Metode	Hasil	Ref.
1.	New white blood cell detection technique by	Segmentasi berbasis analisis SVD	Penelitian ini memperkenalkan metode deteksi sel darah putih tanpa segmentasi eksplisit, dengan membandingkan kesamaan fitur antara	(Abdur razzaq et al., 2021)

	using singular value decomposition concept	menggunakan elemen d_{22}	citra input dan citra indikator melalui nilai singular dari matriks 2×2 . Elemen d_{22} digunakan sebagai penentu kedekatan fitur, sedangkan aljabar tropis dipakai untuk mendeteksi tepi objek yang tidak terdeteksi oleh SVD. Hasil eksperimen menunjukkan metode ini memiliki akurasi rata-rata 63.55%, lebih tinggi dibanding lima metode lain yang dibandingkan, dan mampu mendeteksi berbagai jenis sel darah putih secara lebih konsisten.	
2.	Research on Threshold Segmentation Method of Two-Dimensional Otsu Image Based on Improved Sparrow Search Algorithm	Segmentasi berbasis fungsi objektif Otsu, optimasi nilai trace dengan SSA	Penelitian ini mengoptimasi fungsi objektif 2D Otsu dengan meningkatkan nilai trace matriks dispersi antar kelas menggunakan algoritma SSA yang dimodifikasi. Penggabungan tent chaos mapping dan elite reverse learning meningkatkan kualitas solusi awal dan kemampuan lepas dari local optimum. Metode ini menghasilkan segmentasi dengan MSE yang lebih rendah hingga 40.84% dan PSNR yang lebih tinggi hingga 24.48% dibanding metode lain, serta memberikan hasil segmentasi yang lebih detail dan presisi.	(Du et al., 2023)
3.	Application and comparison of K-means and PCA based segmentation models for Alzheimer disease detection using MRI	Segmentasi berbasis K-means clustering	Penelitian ini menggunakan K-means clustering untuk segmentasi citra MRI otak dalam mendeteksi penyakit Alzheimer. Segmentasi dilakukan dengan membagi piksel menjadi tiga klaster (cairan serebrospinal, materi abu-abu, dan materi putih) berdasarkan kemiripan intensitas. Nilai K ditentukan melalui metode Elbow, dengan $k = 3$ sebagai jumlah klaster optimal. Model	(Olle et al., 2024)

		ini dikombinasikan dengan CNN untuk klasifikasi dan menghasilkan akurasi sebesar 82% serta AUC sebesar 88.7% pada data uji. Segmentasi dengan K-means terbukti efektif mengisolasi bagian penting otak sebagai penanda diagnosis Alzheimer.	
4.	Segmentation of the Melanoma Lesion and Its Border	Segmentasi berbasis region growing dengan fungsi kesamaan dan histogram	Penelitian ini menerapkan region growing untuk segmentasi lesi dan latar belakang secara terpisah, lalu mengekstrak batas lesi dari selisih dua mask. Ambang ditentukan secara adaptif dari histogram, dan perluasan area dilakukan jika perbedaan intensitas lokal di bawah ambang. Hasil menunjukkan sensitivitas 0.92 dan presisi 0.98 (data A), serta sensitivitas 0.85 dan presisi 0.91 (data B), dengan akurasi tinggi pada lesi berdetail kabur. (Suró wka & Ogorz alek, 2022)


Sumber : diolah oleh peneliti

Berdasarkan **Tabel 2.1**, Metode segmentasi Otsu (2), *K-Means clustering* (3), dan *region growing* (4) telah banyak diterapkan dalam pemrosesan citra digital karena kemudahan implementasi dan efisiensi komputasi. Ketiga metode ini mengandalkan pendekatan global atau berbasis kluster tanpa mempertimbangkan variasi lokal secara mendalam. Pendekatan tersebut sering menyebabkan *oversegmentation*, terutama pada citra dengan tekstur kompleks seperti citra satelit, karena segmentasi dilakukan berdasarkan nilai intensitas piksel secara keseluruhan. Pada citra satelit yang secara alami mengandung noise seperti *speckle*, ketiga metode tersebut cenderung menganggap noise sebagai bagian dari objek, sehingga menghasilkan hasil segmentasi yang tidak akurat dan kurang mewakili struktur sebenarnya. Penelitian ini mengusulkan pendekatan

segmentasi berbasis nilai singular terkecil secara lokal sebagai alternatif untuk mendeteksi perubahan intensitas piksel secara lebih presisi. Proses dekomposisi nilai singular pada pasangan citra sebelum dan sesudah bencana digunakan untuk mengukur degradasi struktural secara matematis. Strategi ini dirancang untuk mendeteksi perubahan halus yang sering kali tidak teridentifikasi oleh metode segmentasi konvensional. Integrasi log-rasio sebagai informasi tambahan bertujuan meningkatkan sensitivitas terhadap perbedaan intensitas antar waktu. Pendekatan ini secara metodologis relevan untuk mendeteksi perubahan terlokalisasi dalam citra satelit, khususnya dalam konteks pemantauan dan analisis dampak kebencanaan yang membutuhkan tingkat akurasi tinggi dalam proses penanganannya.

2.3 Kerangka Pemikiran

Penelitian ini dimulai dengan permasalahan mengenai pentingnya pemantauan dan analisis dampak bencana di Indonesia secara efektif dan efisien. Penulis menyusun kerangka pemikiran dalam **Gambar 2.12** berikut.



Gambar 2. 12. Kerangka Pemikiran

Sumber : diolah oleh peneliti

Berdasarkan **Gambar 2.12**, Kerangka pemikiran mencerminkan keterkaitan antara berbagai elemen dalam proses analisis data citra satelit untuk

mencapai tujuan penelitian. Pemilihan indikator dalam analisis citra satelit, seperti kriteria *pixels* menjadi penting karena kriteria ini mempengaruhi kualitas dan kedalaman informasi yang dapat diperoleh dari data (Bolón et al., 2013; Khaire & Dhanalakshmi, 2022; Liefoghe & Derbel, 2016). Resolusi citra, baik spasial maupun spektral maupun temporal akan mempengaruhi kemampuan model untuk mendeteksi detail objek dalam citra. Penggunaan dekomposisi nilai singular dalam metode usulan bertujuan untuk mereduksi data secara optimal untuk mendapatkan informasi penting dari data (Gómez et al., 2022; Hasan et al., 2015; Zipunnikov et al., 2011). SVD digunakan untuk memisahkan komponen signifikan dalam struktur data yang kompleks, termasuk dalam blok kernel citra, yang memungkinkan identifikasi nilai batas secara adaptif melalui nilai singular terkecil. Proses ini bertujuan untuk meningkatkan akurasi model dan efisiensi komputasi sebagai objektif penelitian. Log ratiio digunakan dalam pengurangan *noise speckle* dimana akan memperhalus hasil visual. Akurasi model mengacu pada kemampuan metode dalam menghasilkan hasil yang akurat dan sesuai dengan kondisi sebenarnya, sedangkan efisiensi komputasi berkaitan dengan penggunaan sumber daya komputasi yang optimal. Tahap pengukuran, nilai singular digunakan untuk menilai kekuatan informasi lokal, selisih piksel digunakan untuk mendeteksi perubahan, dan komparasi VQA digunakan untuk menilai akurasi dan kualitas hasil segmentasi. Hubungan antara indikator, metode, objektif, dan pengukuran dalam kerangka ini menggambarkan pendekatan sistematis untuk mencapai hasil yang optimal dalam analisis citra satelit.