

# Pengelompokan Titik Panas Menggunakan Algoritma *DBSCAN* di Provinsi Sumatera Selatan

Nawa Fatimi Fauziah<sup>1</sup>, Febri Dwi Irawati<sup>2\*</sup>, Muhajir Hasibuan<sup>3</sup>

<sup>1,2</sup>Program Studi Sains Data, Institut Teknologi Sumatera, Indonesia

<sup>3</sup>Program Studi Rekayasa Kehutanan, Institut Teknologi Sumatera, Indonesia

<sup>1</sup>nawa.120450014@student.itera.ac.id, <sup>2\*</sup>febri.dwi@sd.itera.ac.id,

<sup>3</sup>mhd.hasibuan@rh.itera.ac.id

**Abstrak:** Kebakaran hutan dan lahan yang berulang setiap tahun di Provinsi Sumatera Selatan menimbulkan kerugian ekologis dan ekonomi yang signifikan, didukung oleh dominasi lahan gambut sebesar 21,88% dari total gambut Sumatera. Meskipun pemantauan titik panas dari citra satelit MODIS telah banyak digunakan sebagai indikator kebakaran, analisis pengelompokan spasial titik panas secara multi-tahun dengan evaluasi kualitas *clustering* di wilayah ini belum pernah dilakukan. Penelitian ini menerapkan algoritma *Density Based Clustering Application with Noise* dengan penentuan parameter adaptif menggunakan metode *k-distance* untuk mengelompokkan 17.353 titik panas tahun 2019–2023 dan mengidentifikasi pola spasial wilayah dengan kepadatan titik panas tertinggi. Parameter optimal ditentukan secara independen per tahun menggunakan *Silhouette Coefficient (SC)* sebagai kriteria seleksi, menghasilkan MinPts sebesar 11 sampai 13 dengan  $\epsilon$  sebesar 0,1 untuk data padat (2019 dan 2023), serta MinPts sebesar 2 dengan  $\epsilon$  sebesar 0,10 sampai 0,13 untuk data jarang (2020 sampai 2022), dengan kualitas *cluster SC* sebesar 0,296–0,670 dan *Davies-Bouldin Index* sebesar 0,273–0,595. Kabupaten Ogan Komering Ilir dan Kota Palembang teridentifikasi sebagai wilayah dengan kepadatan titik panas tertinggi secara konsisten selama lima tahun analisis, dengan *cluster* dominan mencakup 61,87% (2019) dan 73,92% (2023) dari seluruh titik panas yang terdeteksi.

**Kata Kunci:** Titik Panas; *DBSCAN*; Pengelompokan Spasial; *Silhouette Coefficient*; Sumatera Selatan

**Abstract:** Recurring forest and land fires in South Sumatra Province cause significant ecological and economic losses, driven by peatland dominance of 21.88% of Sumatra's total peatland area. Although hotspot monitoring using MODIS satellite imagery has been widely used as a fire indicator, multi-year spatial clustering analysis of hotspots with clustering quality evaluation in this region has never been conducted. This study applies the Density Based Clustering Application with Noise (*DBSCAN*) algorithm with adaptive parameter determination using the *k-distance* method to cluster 17,353 hotspots from 2019 to 2023 and identify spatial patterns of areas with the highest hotspot density. Optimal parameters were determined independently for each year using the *Silhouette Coefficient (SC)* as a selection criterion, yielding MinPts of 11–13 with  $\epsilon$  of 0.1 for dense data years (2019 and 2023) and MinPts of 2 with  $\epsilon$  of 0.10–0.13 for sparse data years (2020–2022), with clustering quality

confirmed based on SC of 0.296–0.670 and Davies-Bouldin Index of 0.273–0.595. Ogan Komering Ilir Regency and Palembang City were consistently identified as the areas with the highest hotspot density throughout the five-year analysis period, with dominant clusters covering 61.87% (2019) and 73.92% (2023) of all detected hotspots.

**Keywords:** Hotspot; DBSCAN; Spatial Clustering; Silhouette Coefficient; South Sumatra

## 1. PENDAHULUAN

Kebakaran hutan dan lahan (karhutla) merupakan bencana alam yang berulang setiap tahun di Indonesia dan menjadi isu lingkungan serius di kawasan Asia Tenggara, dengan dampak yang mencakup kerusakan ekosistem, gangguan kesehatan akibat kabut asap, kerugian ekonomi, hingga konflik diplomatik antarnegara [1], [2]. Provinsi Sumatera Selatan merupakan salah satu wilayah dengan intensitas karhutla tertinggi di Indonesia, dengan luas karhutla yang tercatat 336.798 ha (2019), 950 ha (2020), 5.245 ha (2021), dan 132.082 ha (2023) berdasarkan data Sipongi[3]. Tingginya kerentanan wilayah ini didukung oleh dominasi lahan gambut sebesar 21,88% dari total gambut Sumatera (9.604.529 ha), di mana gambut sangat mudah terbakar dan sulit dipadamkan karena api dapat menjalar di bawah permukaan tanah[4]. Fakta bahwa karhutla berulang pada lokasi yang hampir sama setiap tahunnya menunjukkan perlunya pendekatan berbasis data untuk mengidentifikasi pola spasial persebaran titik panas secara sistematis[1], [5], [6].

Pemantauan titik panas *hotspot* dari instrumen MODIS (*Moderate Resolution Imaging Spectroradiometer*) pada satelit Terra dan Aqua NASA telah banyak digunakan sebagai indikator awal karhutla dan tersedia secara *real-time* melalui platform FIRMS. Keberadaan titik panas tidak bersifat acak melainkan cenderung membentuk kelompok secara alami sesuai prinsip Hukum Geografi Pertama Tobler[7], sehingga metode *clustering* berbasis kepadatan tepat digunakan untuk menganalisis pola persebarannya. Beberapa penelitian terdahulu telah mengelompokkan titik panas menggunakan berbagai pendekatan antara lain *K-Means* yang tidak mampu menangani *noise* dan sensitif terhadap inialisasi *centroid*[8], *Agglomerative Hierarchical Clustering* yang tidak mempertimbangkan kepadatan spasial data[9], DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*) dengan evaluasi SSE yang belum menggunakan metrik evaluasi standar[10], ST-DBSCAN tanpa evaluasi kualitas *cluster*[11], serta perbandingan DBSCAN dan LSDBC yang hanya mencakup satu periode waktu[12]. Penelitian menggunakan Chronnet dan OPTICS menunjukkan efektivitas *clustering* berbasis kepadatan namun evaluasi kualitas *cluster* masih terbatas[5], [13], [14]. DBSCAN merupakan metode *clustering* yang mampu menemukan *cluster* berbentuk sembarang, tidak memerlukan spesifikasi jumlah *cluster* di awal, serta mampu mengidentifikasi *noise*[15], dengan evaluasi kualitas menggunakan *Silhouette Coefficient (SC)*[16] dan Davies-Bouldin Index (DBI)[17].

Berdasarkan studi literatur, tiga *gap* penelitian teridentifikasi belum ada penelitian yang mengevaluasi pengelompokkan titik panas di Sumatera Selatan menggunakan kombinasi SC dan DBI secara bersamaan, penelitian terdahulu tidak membahas pengaruh perbedaan volume data antar tahun terhadap pemilihan parameter optimal DBSCAN, dan belum ada analisis konsistensi pola spasial titik panas lintas tahun di Sumatera Selatan. Penelitian ini bertujuan untuk menentukan parameter optimal  $\epsilon$  dan MinPts menggunakan metode *k-distance* serta menganalisis pola spasial pengelompokkan titik panas di Provinsi Sumatera Selatan tahun 2019 sampai 2023 dengan hipotesis bahwa parameter optimal DBSCAN bervariasi sesuai volume data per tahun dan wilayah gambut dominan akan secara konsisten membentuk *cluster* dengan kepadatan tertinggi.

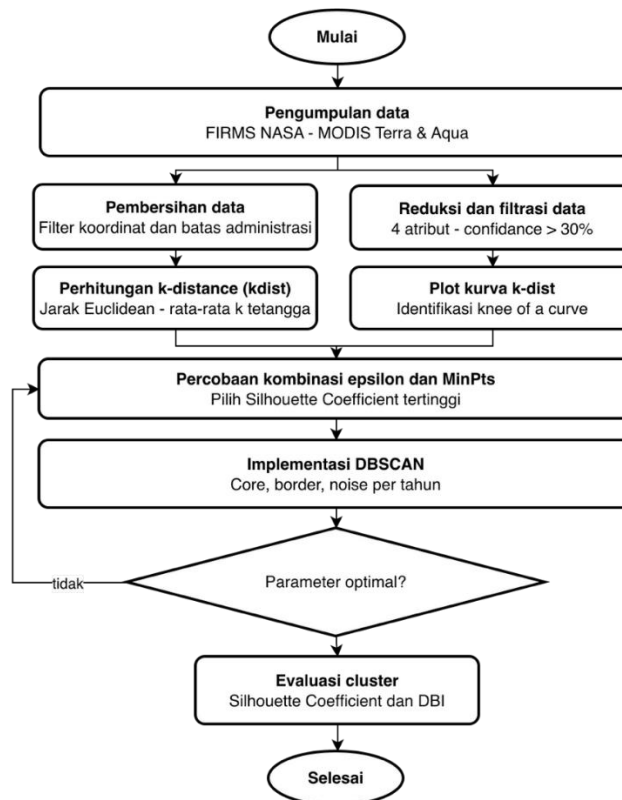
## 2. METODE PENELITIAN

### Data dan lokasi penelitian

Data titik panas (*hotspot*) periode 2019–2023 diperoleh dari platform *Fire Information for Resource Management System* (FIRMS) NASA (<https://firms.modaps.eosdis.nasa.gov/>) menggunakan instrumen MODIS (*Moderate Resolution Imaging Spectroradiometer*) dari satelit Terra dan Aqua dengan resolusi spasial 1 km<sup>2</sup> per piksel. Dataset awal terdiri dari 15 atribut, namun hanya 4 atribut yang digunakan dalam analisis, yaitu *latitude* dan *longitude* sebagai representasi spasial, *acq\_date* sebagai representasi temporal, dan *confidence* sebagai filter kualitas deteksi dengan ambang batas lebih dari 30% sesuai kategori nominal hingga tinggi [5]. Lokasi penelitian dibatasi pada wilayah administrasi Provinsi Sumatera Selatan yang terletak antara 1°–4° Lintang Selatan dan 102°–106° Bujur Timur dengan luas 87.017,41 km<sup>2</sup>, menggunakan *shapefile* batas administrasi resmi sebagai acuan pembersihan data spasial. Seluruh proses analisis dilakukan menggunakan Python dengan *library* *pandas*, *geopandas*, *shapely*, *scikit-learn*, dan *scipy*.

### Tahapan penelitian

Diagram alir ditunjukkan pada Gambar 1 yang terdiri dari preprocessing data, penentuan paramter optimal DBSCAN, implementasi algoritma DBSCAN, dan evaluasi cluster.



Gambar 1. Diagram alir penelitian

#### a. Preprocessing data

*Preprocessing* data dilakukan melalui tiga langkah berurutan. Pertama data awal yang mencakup seluruh wilayah Indonesia disesuaikan dengan batas administrasi resmi Provinsi Sumatera Selatan menggunakan operasi spasial *within* dari *library* *GeoPandas* untuk memastikan hanya titik panas yang benar-benar berada di dalam

wilayah administrasi yang dipertahankan. Kedua atribut direduksi dari 15 menjadi 4 atribut yang relevan (*latitude*, *longitude*, *acq\_date*, dan *confidence*), kemudian difilter pada nilai *confidence* lebih dari 30% sesuai kategori nominal hingga tinggi untuk meminimalkan deteksi *false positive*. Hasil *preprocessing* menghasilkan 17.353 data titik panas yang selanjutnya dipisahkan per tahun karena volume data yang sangat bervariasi antar tahun (340–10.303 titik panas per tahun) sehingga memengaruhi pemilihan parameter optimal secara independen untuk setiap tahun.

b. Penentuan parameter optimal DBSCAN

Parameter optimal  $\epsilon$  dan MinPts ditentukan menggunakan metode *k-distance* (*kdist*) yang diperkenalkan oleh Ester *et al.*[15] melalui empat tahap berikut. Pada tahap pertama, jarak antar setiap pasang titik panas dihitung berdasarkan koordinat *latitude* dan *longitude* menggunakan jarak Euclidean menggunakan (1)[15].

$$d(p, q) = \sqrt{(p_{lat} - q_{lat})^2 + (p_{lon} - q_{lon})^2} \quad (1)$$

Jarak Euclidean dipilih karena data titik panas dalam penelitian ini mencakup wilayah Provinsi Sumatera Selatan yang terbatas pada rentang koordinat 1°–4° Lintang Selatan dan 102°–106° Bujur Timur (cakupan  $\pm 4^\circ \times 4^\circ$ ). Pada skala geografis yang terbatas ini, deviasi antara jarak Euclidean dan jarak geodesik (Haversine distance) yang memperhitungkan kelengkungan bumi mencapai sekitar 0,3%, sehingga dianggap dapat diabaikan[18]. Penggunaan jarak Euclidean pada skala regional yang serupa juga diterapkan oleh Rahmah dan Sitanggang[6] serta Usman *et al.*[10] dalam analisis clustering titik panas gambut di Sumatera, yang mendukung kesesuaian pendekatan ini untuk data pada cakupan geografis serupa. Pendekatan Haversine distance lebih direkomendasikan apabila analisis mencakup wilayah yang lebih luas, seperti skala nasional atau benua, di mana deviasi terhadap jarak Euclidean menjadi signifikan.

Pada tahap kedua, untuk setiap titik  $p_i$  dan setiap nilai  $k$  yang diuji ( $k \in \{2,4,7,9,11,13\}$ ), dihitung rata-rata jarak terhadap  $k$  tetangga terdekatnya menggunakan (2)[6], [18].

$$\bar{d}_k(p_i) = \frac{1}{k} \sum_{j=1}^k d(p_i, p_j^{(k)}) \quad (2)$$

di mana  $p_j^{(k)}$  adalah tetangga ke- $j$  terdekat dari titik  $p_i$  berdasarkan (1). Nilai  $k$  yang diuji sekaligus menjadi kandidat nilai MinPts karena titik-titik dalam *cluster* cenderung memiliki jarak yang kecil terhadap  $k$  tetangga terdekatnya, sedangkan titik *noise* memiliki jarak yang jauh lebih besar [5]. Pada tahap ketiga, seluruh nilai  $\bar{d}_k(p_i)$  dari (3) diurutkan secara menurun dan divisualisasikan sebagai kurva *k-dist*. Nilai  $\epsilon$  optimal ditentukan pada titik *nee* di mana laju perubahan kurva mencapai maksimum[18].

$$p^* = \arg \max_i |\bar{d}_k^{(i)} - \bar{d}_k^{(i+1)}| \quad (3)$$

Titik  $p^*$  pada (3) memisahkan segmen stabil di sebelah kiri (titik dalam *cluster* dengan nilai  $\bar{d}_k$  kecil) dari segmen yang meningkat tajam di sebelah kanan (titik *noise* dengan nilai  $\bar{d}_k$  besar), dan nilai  $\bar{d}_k$  pada posisi  $p^*$  digunakan sebagai nilai  $\epsilon$  optimal[6], [18]. Pada tahap keempat, dari rentang kandidat  $\epsilon$  dan MinPts yang diperoleh dari kurva *k-dist* pada (3), dilakukan percobaan sistematis pada setiap kombinasi parameter. Kombinasi optimal dipilih berdasarkan nilai SC tertinggi sebagaimana diformulasikan pada (4)[16].

$$(\epsilon^*, \text{MinPts}^*) = \arg \max_{\epsilon, \text{MinPts}} \left[ \frac{1}{n} \sum_{i=1}^n s(i) \right] \quad (4)$$

di mana  $n$  adalah jumlah titik yang bukan *noise* dan  $s(i)$  adalah nilai *silhouette* untuk titik ke- $i$ . Kombinasi dengan nilai SC pada (4) mendekati 1 menandakan *cluster* yang kompak dan terpisah dengan baik.

c. Implementasi algoritma DBSCAN

Algoritma DBSCAN diimplementasikan pada data titik panas per tahun menggunakan parameter optimal  $(\epsilon^*, \text{MinPts}^*)$  yang diperoleh dari (4). Proses implementasi mengacu

pada tiga definisi matematis berikut yang seluruhnya menggunakan jarak Euclidean dari (1)[15]. Definisi pertama adalah *epsilon-neighborhood*, yaitu himpunan semua titik yang berada dalam radius  $\epsilon$  dari titik  $p$ , sebagaimana didefinisikan pada (5)[19], [20].

$$N_\epsilon(p) = \{q \in D \mid d(p, q) \leq \epsilon\} \quad (5)$$

di mana  $D$  adalah keseluruhan dataset titik panas per tahun dan  $d(p, q)$  mengacu pada (1). Himpunan  $N_\epsilon(p)$  pada (5) digunakan sebagai dasar untuk menentukan jenis setiap titik pada (6). Definisi kedua adalah syarat *core point*, yaitu titik  $p$  diklasifikasikan sebagai *core point* apabila jumlah anggota  $N_\epsilon(p)$  dari (5) memenuhi ambang batas  $MinPts$  sebagaimana didefinisikan pada (6)[15], [20].

$$|N_\epsilon(p)| \geq MinPts \quad (6)$$

Berdasarkan (6), titik yang tidak memenuhi syarat  $MinPts$  namun berada dalam  $N_\epsilon$  dari suatu *core point* diklasifikasikan sebagai *border point*, sedangkan titik yang tidak masuk dalam  $N_\epsilon$  *core point* manapun diklasifikasikan sebagai *noise* dengan label  $-1$ [15], [20]. Definisi ketiga adalah *density reachability*, yaitu titik  $q$  dikatakan *density-reachable* dari titik  $p$  apabila memenuhi kondisi pada (7)[6], [15].

$$p \xrightarrow{\epsilon, MinPts} q \Leftrightarrow q \in N_\epsilon(p) \text{ dan } |N_\epsilon(p)| \geq MinPts. \quad (7)$$

Persamaan (7) menggabungkan kondisi (5) dan (6) secara bersamaan. Sebuah *cluster*  $C$  terbentuk apabila memenuhi dua syarat berdasarkan (7) yaitu setiap dua titik dalam  $C$  bersifat *density-connected* melalui rangkaian titik yang saling *density-reachable* dan setiap titik yang *density-reachable* dari anggota  $C$  juga merupakan anggota  $C$ [6], [15]. Titik yang tidak memenuhi kedua syarat tersebut diklasifikasikan sebagai *noise* berdasarkan (6).

d. Evaluasi cluster

Kualitas hasil *clustering* dievaluasi menggunakan *Davies-Bouldin Index* (DBI) yang mengukur rasio antara kohesi dalam *cluster* dan separasi antar *cluster*[17]. Semakin kecil nilai DBI dan mendekati nol, semakin baik kualitas *cluster* yang dihasilkan. Titik *noise* (label  $-1$ ) dari (6) dikecualikan dari seluruh perhitungan evaluasi karena bukan merupakan anggota *cluster* yang valid. DBI dihitung melalui empat tahap berikut yang seluruhnya menggunakan jarak *Euclidean* dari (1). Pada tahap pertama, dispersi rata-rata titik dalam *cluster* terhadap centroid dihitung menggunakan *Sum of Square Within* (SSW) sebagaimana didefinisikan pada (8)[17].

$$SSW_i = \frac{1}{m_i} \sum_{j=1}^{m_i} d(x_j, c_i) \quad (8)$$

di mana  $m_i$  adalah jumlah titik dalam *cluster*  $i$ ,  $x_j$  adalah titik ke- $j$  dalam *cluster*  $i$ ,  $c_i$  adalah centroid *cluster*  $i$ , dan  $d(x_j, c_i)$  mengacu pada (1). Nilai  $SSW_i$  yang kecil pada (8) menunjukkan *cluster* yang kompak. Pada tahap kedua, jarak antar centroid dua *cluster* dihitung menggunakan *Sum of Square Between* (SSB) sebagaimana didefinisikan pada (9)[17].

$$SSB_{ij} = d(c_i, c_j) \quad (9)$$

di mana  $c_i$  dan  $c_j$  adalah centroid *cluster*  $i$  dan  $j$  yang jaraknya dihitung menggunakan (1). Nilai  $SSB_{ij}$  yang besar pada (9) menunjukkan kedua *cluster* terpisah dengan baik. Pada tahap ketiga, rasio similaritas antar *cluster*  $i$  dan  $j$  dihitung berdasarkan nilai  $SSW_i$  dari (8) dan  $SSB_{ij}$  dari (9) sebagaimana didefinisikan pada (10)[17].

$$R_{ij} = \frac{SSW_i + SSW_j}{SSB_{ij}} \quad (10)$$

Nilai  $R_{ij}$  pada (10) yang kecil menunjukkan bahwa dua *cluster* tersebut kompak sekaligus terpisah jauh satu sama lain. Nilai  $R_{ij}$  inilah yang selanjutnya digunakan sebagai masukan pada (11). Pada tahap keempat, nilai DBI dihitung sebagai rata-rata dari nilai  $R_{ij}$  maksimum untuk setiap *cluster* berdasarkan (10), sebagaimana diformulasikan pada (11)[17].

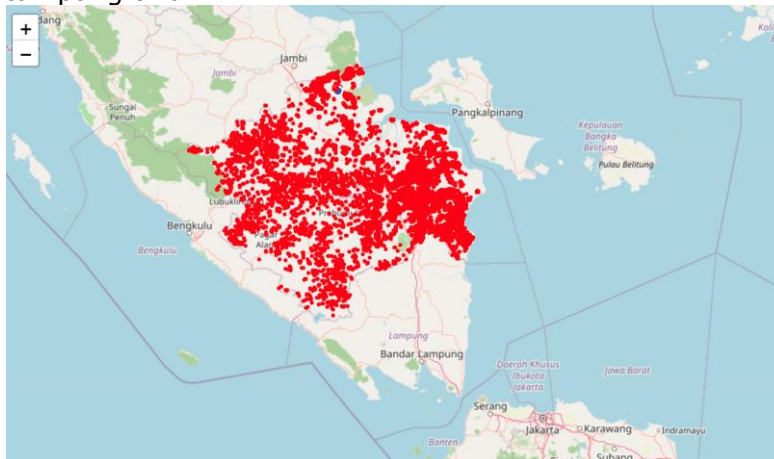
$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} (R_{ij}) \quad (11)$$

di mana  $k$  adalah jumlah *cluster* yang terbentuk dari implementasi DBSCAN pada tahap c. Nilai  $DBI$  mendekati 0 pada (11) menunjukkan bahwa *cluster* yang dihasilkan semakin kompak secara internal (nilai  $SSW$  dari (8) kecil) sekaligus semakin terpisah antar *cluster* (nilai  $SSB$  dari (9) besar)[17].

### 3. HASIL DAN PEMBAHASAN

#### Hasil Preprocessing data

*Preprocessing* menghasilkan 17.353 data titik panas yang valid dari total 18.780 data awal, atau berkurang 7.59% setelah pembersihan batas administrasi dan filtrasi *confidence* > 30%. Sebaran titik panas hasil preprocessing pada wilayah Provinsi Sumatera Selatan tahun 2019–2023 yang divisualisasikan menggunakan peta dasar OpenStreetMap ditunjukkan pada Gambar 2. Setiap titik merah merepresentasikan satu deteksi titik panas oleh instrumen MODIS pada satelit Terra dan Aqua NASA. Secara keseluruhan, sebaran titik panas tidak merata dan membentuk pola pengelompokan yang jelas di bagian tengah hingga timur provinsi. Konsentrasi titik panas tertinggi terlihat di wilayah yang mencakup Kabupaten Ogan Komering Ilir, Ogan Ilir, Kota Palembang, dan sebagian Kabupaten Banyuasin, yang terlihat dari tingginya kerapatan titik merah pada area tersebut hingga titik-titik saling tumpang tindih.



**Gambar 2.** Distribusi spasial titik panas di Provinsi Sumatera Selatan tahun 2019–2023

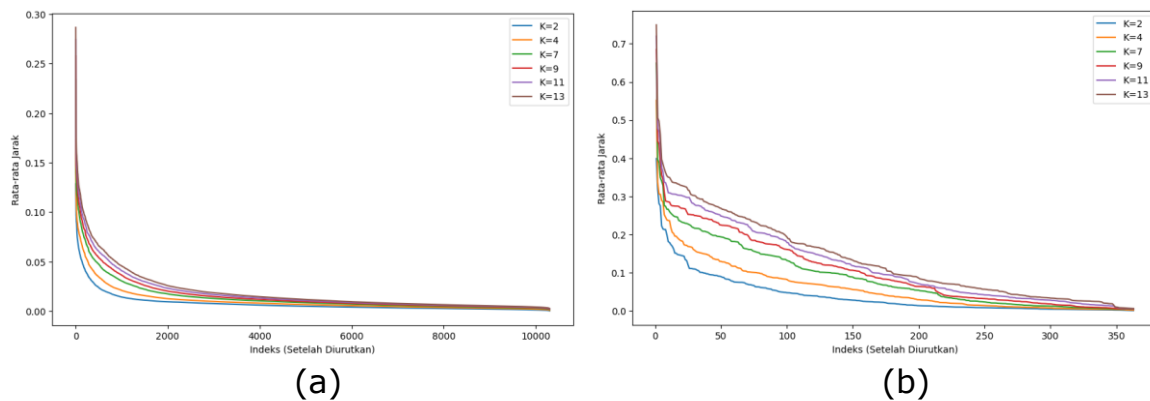
Jumlah titik panas per tahun di Provinsi Sumatera Selatan disajikan pada Tabel 1. Data menunjukkan pola yang sangat tidak merata antar tahun. Tahun 2019 mendominasi titik panas 59,37% dari total data, diikuti tahun 2023 dengan 33,50%. Sebaliknya, tahun 2020 hingga 2022 hanya menghasilkan kurang dari 4% dari total data. Kesenjangan volume data yang mencapai 30 kali lipat antara tahun 2019 dan tahun 2022 menjadi pertimbangan utama dalam pemilihan parameter DBSCAN yang berbeda untuk setiap tahun.

**Tabel 1.** Jumlah data titik panas per tahun

Tahun	Jumlah Titik Panas
2019	10.303
2020	364
2021	538
2022	340
2023	5.813

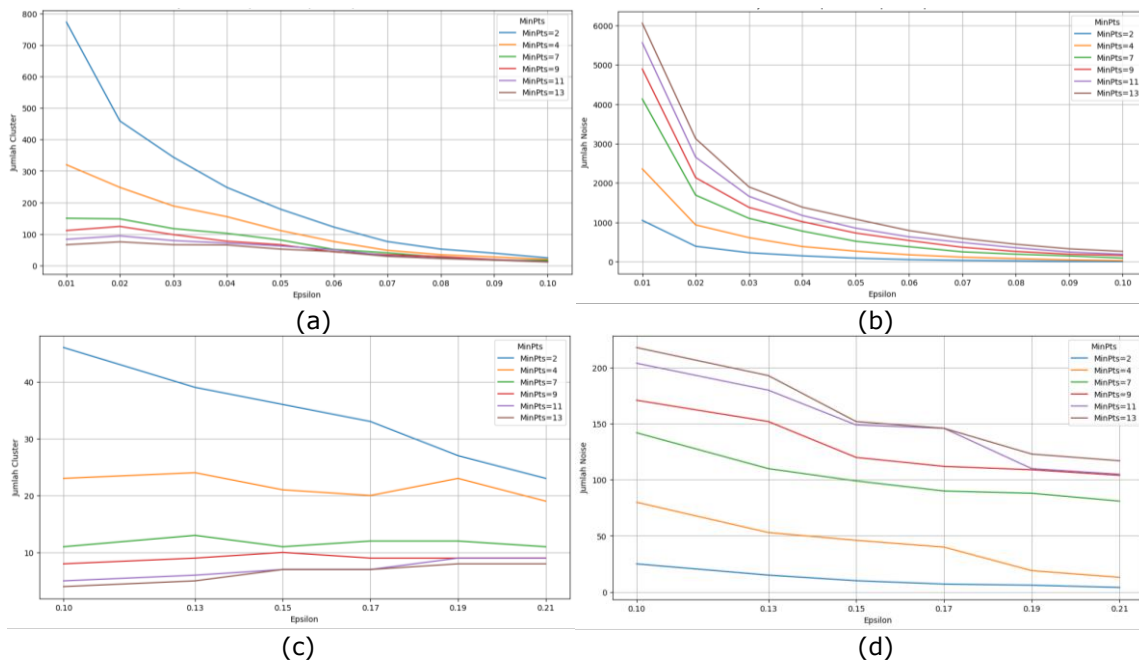
### Paremeter optimal DBSCAN

Grafik  $k$ -dist yang dihasilkan untuk seluruh nilai  $k$  yang diuji pada setiap tahun menunjukkan pola yang konsisten yaitu kurva menurun stabil pada segmen kiri kemudian meningkat tajam pada segmen kanan. Dua grafik representatif yang mewakili karakteristik berbeda ditunjukkan pada Gambar 3, yaitu tahun 2019 sebagai representasi data padat dan tahun 2020 sebagai representasi data jarang. Ketiga tahun lainnya yaitu 2021 sampai 2022 menunjukkan pola kurva yang serupa dengan tahun 2020 sehingga tidak ditampilkan secara terpisah. Dari grafik  $k$ -dist, titik perubahan tajam (*knee of a curve*) teridentifikasi pada rentang yang berbeda antar kelompok tahun. Tahun 2019 dan 2023 menunjukkan titik *knee* pada rentang  $\epsilon$  antara 0,01 sampai 0,1 sedangkan tahun 2020 sampai 2022 pada rentang  $\epsilon$  antara 0,1 sampai 0,2. Perbedaan rentang ini konsisten dengan perbedaan kepadatan data antar kelompok tahun 2019 dan 2023 memiliki titik panas yang lebih rapat sehingga nilai  $\epsilon$  optimal yang dibutuhkan lebih kecil dibandingkan tahun 2020 sampai 2022.



**Gambar 3.** Grafik rata-rata jarak  $k$  tetangga terdekat ( $k$ -distance) untuk penentuan nilai  $\epsilon$  optimal (a) tahun 2019 dan (b) tahun 2020

Berdasarkan rentang kandidat  $\epsilon$  yang diperoleh dari Gambar 3, percobaan sistematis dilakukan pada kombinasi  $\epsilon$  dan MinPts untuk setiap tahun. Grafik jumlah *cluster* dan *noise* yang dihasilkan pada setiap kombinasi untuk tahun 2019 dan 2020 sebagai representasi dua karakteristik data yang berbeda ditunjukkan pada Gambar 4. Pada seluruh tahun, kedua grafi menunjukkan pola yang konsisten yaitu semakin besar MinPts, jumlah *noise* semakin bertambah sementara jumlah *cluster* semakin berkurang. Pada tahun 2019 (Gambar 4a dan 4b), jumlah *cluster* paling sedikit dihasilkan pada MinPts sebesar 9, 11, dan 13 dengan  $\epsilon$  sebesar 0,1 (masing-masing 12, 12, dan 11 *cluster*), sedangkan *noise* paling sedikit pada MinPts sebesar 2 dengan  $\epsilon$  sebesar 0,09 (8 titik) dan  $\epsilon$  sebesar 0,1 (4 titik), sehingga parameter optimal ditetapkan pada MinPts sebesar 13 dengan  $\epsilon$  sebesar 0,1. Pada tahun 2020 (Gambar 4c dan 4d), jumlah *cluster* paling sedikit pada MinPts sebesar 11 dan 13 dengan  $\epsilon$  sebesar 0,1, sedangkan *noise* paling sedikit pada MinPts sebesar 2 dengan  $\epsilon$  sebesar 0,13 (15 titik), sehingga parameter optimal ditetapkan pada MinPts sebesar 2 dengan  $\epsilon$  sebesar 0,13. Tahun 2021 dan 2022 menunjukkan pola serupa dengan tahun 2020 dengan parameter optimal masing-masing MinPts sebesar 2 dengan  $\epsilon$  sebesar 0,1 dan MinPts sebesar 2 dengan  $\epsilon$  sebesar 0,11, sedangkan tahun 2023 menunjukkan pola serupa dengan tahun 2019 dengan parameter optimal MinPts sebesar 11 dan  $\epsilon$  sebesar 0,1.



**Gambar 4.** Grafik jumlah *cluster* dan *noise* terhadap variasi  $\epsilon$  dan MinPts (a)(b)tahun 2019 dan (c)(d) tahun 2020

Mekanisme pemilihan parameter optimal dilakukan dalam dua langkah berurutan. Langkah pertama adalah penyaringan kandidat dari rentang  $\epsilon$  yang diperoleh, seluruh kombinasi  $\epsilon$  dan MinPts yang menghasilkan *SC* bernilai negatif langsung dikesampingkan karena nilai negatif mengindikasikan bahwa lebih dari setengah titik lebih dekat ke *cluster* lain dibandingkan clusternya sendiri dimana kondisi yang menandakan parameter tidak layak digunakan[16]. Langkah kedua adalah pemilihan optimal dari kombinasi yang tersisa dengan *SC* positif, dipilih kombinasi dengan nilai *SC* tertinggi sebagaimana diformulasikan pada Persamaan 4. Grafik jumlah *cluster* dan *noise* dengan  $\epsilon$  berfungsi sebagai alat bantu visual untuk memahami *trade-off* antara kelengkapan *cluster* dan jumlah *noise*, namun keputusan akhir pemilihan parameter didasarkan sepenuhnya pada nilai *SC* tertinggi. Pendekatan dua langkah ini memastikan konsistensi antara visualisasi eksploratif dan kriteria evaluasi kuantitatif.

Rekapitulasi parameter optimal terpilih untuk setiap tahun disajikan pada Tabel 2. Seluruh parameter optimal menggunakan  $\epsilon$  yaitu 0,1 kecuali tahun 2020 yaitu 0,13 dan 2022 yaitu 0,11, yang keduanya merupakan tahun dengan volume data paling sedikit. Persentase *noise* pada seluruh tahun berada di bawah 6%, mengindikasikan bahwa sebagian besar titik panas berhasil dikelompokkan ke dalam *cluster* yang bermakna. Nilai *SC* pada tahun 2020 sampai 2022 berada pada rentang 0,546 sampai 0,673 lebih tinggi dibandingkan tahun 2019 yaitu 0,309 dan 2023 yaitu 0,296, yang menunjukkan bahwa *cluster* pada tahun dengan data lebih sedikit cenderung lebih terpisah satu sama lain. Perbedaan nilai *SC* ini tidak mengindikasikan kegagalan metode pada tahun 2019 dan 2023, melainkan mencerminkan karakteristik data spasial yang lebih padat dan saling berdekatan pada kedua tahun tersebut.

**Tabel 2.** Parameter optimal terpilih untuk setiap tahun

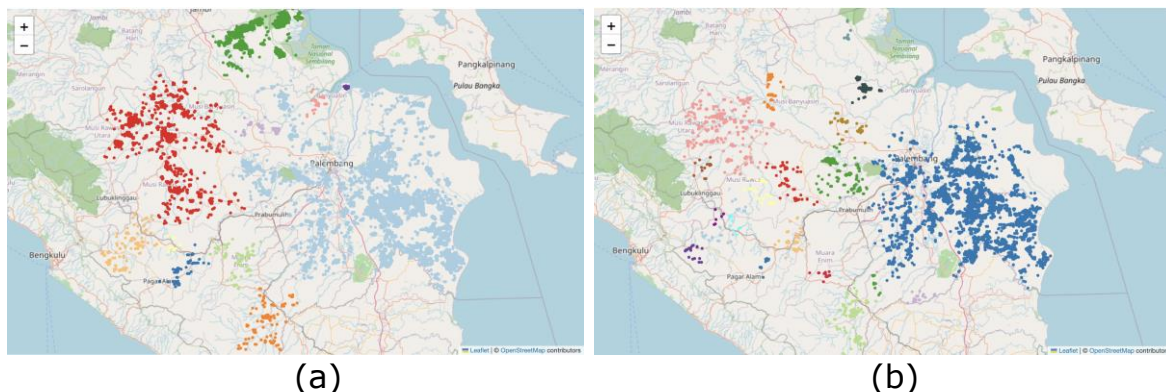
Tahun	$\epsilon_{\text{optimal}}$	MinPts <sub>optimal</sub>	Cluster	Noise	SC
2019	0,10	13	11	263	0,309
2020	0,13	2	38	15	0,620

2021	0,10	2	68	32	0,546
2022	0,11	2	41	15	0,673
2023	0,10	11	22	209	0,296

### Hasil Pembentukan Cluster

Pembentukan *cluster* menggunakan parameter optimal dari Tabel 2 menghasilkan distribusi spasial yang ditunjukkan pada Gambar 5. Gambar 5(a) menunjukkan hasil pengelompokan 10.303 titik panas tahun 2019 yang menghasilkan 11 *cluster* dengan 263 titik *noise* (2,55%). *Cluster* 0 (biru muda) mendominasi dengan 6.374 titik panas (61,87%) yang tersebar luas di bagian timur provinsi meliputi Kabupaten Ogan Komering Ilir, Ogan Ilir, sebagian Banyuasin, dan sebagian Muara Enim, mengindikasikan bahwa wilayah timur Provinsi Sumatera Selatan merupakan zona dengan konsentrasi titik panas tertinggi selama tahun 2019. *Cluster* 3 (hijau) dengan 1.853 anggota (17,99%) teridentifikasi di bagian utara provinsi di wilayah Kabupaten Musi Banyuasin yang berbatasan dengan Provinsi Jambi, dan *cluster* 5 (merah) dengan 1.295 anggota (12,57%) terkonsentrasi di bagian tengah-barat provinsi di sekitar wilayah Lubuklinggau. Ketiga *cluster* tersebut secara bersama-sama mencakup 92,43% dari seluruh titik panas yang terdeteksi, sementara delapan *cluster* lainnya (*cluster* 1, 2, 4, 6, 7, 8, 9, dan 10) tersebar di bagian selatan dan tengah provinsi dengan kontribusi masing-masing di bawah 1,14%.

Gambar 5(b) menunjukkan hasil pengelompokan 5.813 titik panas tahun 2023 yang menghasilkan 22 *cluster* dengan 209 titik *noise* (3,60%). *Cluster* 1 (biru) mendominasi dengan 4.296 titik panas (73,92%) yang terkonsentrasi di bagian timur provinsi meliputi Kabupaten Ogan Komering Ilir dan Kota Palembang, menunjukkan pola spasial yang sangat serupa dengan *cluster* 0 pada tahun 2019 meskipun dengan cakupan wilayah yang sedikit lebih sempit di bagian barat. *Cluster* 4 (biru tua) dengan 332 anggota (5,71%) teridentifikasi di Kabupaten Musi Banyuasin bagian utara yang berbatasan dengan Provinsi Jambi, *cluster* 3 (oranye) dengan 223 anggota (3,84%) di Kabupaten Penukal Abab Lematang Ilir, dan *cluster* 17 (oranye tua) dengan 197 anggota (3,39%) di wilayah Tungkal Ilir, Banyuasin. Delapan belas *cluster* lainnya tersebar di bagian barat dan selatan provinsi meliputi wilayah sekitar Lubuklinggau, Pagar Alam, dan perbatasan Provinsi Lampung, dengan kontribusi masing-masing di bawah 1,79% dari total titik panas. Dibandingkan dengan hasil tahun 2019, perbedaan yang teridentifikasi adalah wilayah Banyuasin bagian utara yang berbatasan dengan Musi Banyuasin tidak masuk ke dalam *cluster* dominan pada tahun 2023, serta jumlah *cluster* yang lebih banyak (22 *cluster*) dengan sebaran yang lebih merata di bagian barat provinsi.



**Gambar 5.** Hasil pengelompokan titik panas menggunakan DBSCAN (a) tahun 2019 dan (b) tahun 2023

### Hasil evaluasi cluster

Kualitas *cluster* yang dihasilkan dievaluasi menggunakan *Davies-Bouldin Index* (DBI) yang mengukur rasio kohesi dalam *cluster* terhadap separasi antar *cluster*. Nilai DBI yang semakin mendekati nol menunjukkan *cluster* yang semakin kompak dan terpisah dengan baik. Hasil evaluasi DBI untuk seluruh tahun analisis disajikan pada Tabel 3.

**Tabel 3.** Hasil evaluasi kualitas *cluster* tiap tahun

Tahun	Jumlah Cluster	SSW	SSB	DBI
2019	11	0,521	1,024	0,557
2020	38	0,038	0,170	0,356
2021	68	0,050	0,277	0,404
2022	41	0,004	0,275	0,273
2023	22	0,083	0,161	0,595

Nilai DBI pada seluruh tahun berkisar antara 0,273 hingga 0,595, dengan nilai terkecil pada tahun 2022 sebesar 0,273 dan nilai terbesar pada tahun 2023 sebesar 0,595. Pada seluruh tahun, nilai SSW lebih kecil dibandingkan SSB, mengindikasikan bahwa jarak rata-rata titik terhadap centroid *cluster*-nya sendiri lebih kecil dibandingkan jarak antar centroid *cluster*, sehingga *cluster* yang terbentuk lebih kompak secara internal dibandingkan jarak pemisahannya. Nilai DBI tahun 2020 sampai 2022 yang lebih rendah dibandingkan tahun 2019 dan 2023 konsisten dengan karakteristik data tahun 2020 sampai 2022 yang memiliki volume lebih sedikit sehingga *cluster* yang terbentuk lebih kecil dan lebih terpisah satu sama lain. Secara keseluruhan, seluruh nilai DBI yang dihasilkan mendekati nol dan tidak ada yang bernilai negatif, mengindikasikan bahwa *cluster* yang terbentuk pada semua tahun analisis memiliki kualitas yang memadai. Nilai  $\bar{SC}$  yang digunakan sebagai kriteria seleksi parameter berkisar antara 0,296 hingga 0,670 dan seluruhnya bernilai positif, yang secara konsisten mendukung hasil evaluasi DBI.

Nilai  $SC$  yang lebih rendah pada tahun 2019 (0,309) dan 2023 (0,296) dibandingkan tahun 2020–2022 (0,546–0,670) tidak mengindikasikan kualitas *clustering* yang buruk, melainkan mencerminkan dua karakteristik intrinsik data yang perlu dipahami secara terpisah. Pertama, kepadatan data spasial yang tinggi pada tahun 2019 (10.303 titik) dan 2023 (5.813 titik) menyebabkan titik-titik panas dari *cluster* yang berbeda secara geografis berdekatan, sehingga nilai  $b(i)$  dari Persamaan 9 mendekati nilai  $a(i)$  dari Persamaan 8, menghasilkan nilai  $s(i)$  yang lebih kecil secara matematis meskipun *cluster* terbentuk dengan benar[16]. Kedua, titik *noise* (263 titik pada 2019 dan 209 titik pada 2023) diperlakukan sebagai satu *cluster* tersendiri dalam kalkulasi  $SC$ , dan karena titik *noise* secara definisi tidak memiliki *cluster* yang sesuai, nilai  $s(i)$  cenderung negatif atau mendekati nol, sehingga menurunkan nilai  $SC$  rata-rata secara sistematis [16], [21]. Hal ini dikonfirmasi oleh nilai DBI yang tetap baik pada tahun 2019 (0,557) dan 2023 (0,595), yang mengevaluasi kualitas *cluster* dari perspektif rasio kohesi-separasi tanpa pengaruh titik *noise*, sehingga kedua metrik bersama-sama memberikan penilaian yang lebih komprehensif dan tidak bias[17].

### Diskusi

Penelitian ini mengonfirmasi bahwa algoritma DBSCAN dengan penentuan parameter adaptif menggunakan metode *kdist* mampu mengidentifikasi pola pengelompokan spasial titik panas di Provinsi Sumatera Selatan secara konsisten selama 2019 sampai 2023, dengan nilai DBI di rentang 0,273 sampai 0,595 yang mendekati nol pada seluruh tahun analisis. Temuan pertama menunjukkan bahwa parameter optimal DBSCAN bergantung secara langsung pada volume data per tahun. Data dengan lebih dari 5.000 titik (2019 dan 2023) membutuhkan *MinPts* sebesar 11 sampai 13, sedangkan data

dengan kurang dari 538 titik (2020 sampai 2022) optimal pada MinPts sebesar 2. Perbedaan parameter optimal yang signifikan antar kelompok tahun mengindikasikan bahwa penggunaan parameter seragam untuk seluruh periode berpotensi menghasilkan *cluster* yang tidak bermakna pada tahun dengan volume data rendah, sehingga penentuan parameter adaptif per periode lebih tepat untuk dataset dengan variasi volume tinggi sebagaimana direkomendasikan Rahmah *et al.*[6] serta Yin *et al.*[18]. Hal ini juga sejalan dengan perkembangan terkini dalam penentuan parameter adaptif DBSCAN, di mana Li *et al.*[22] menunjukkan bahwa optimasi parameter  $\epsilon$  dan MinPts secara iteratif menghasilkan *cluster* yang lebih akurat dibandingkan parameter yang ditentukan secara manual.

Temuan kedua menunjukkan konsistensi pola spasial di bagian timur dan tengah provinsi, di mana Kabupaten Ogan Komering Ilir menjadi wilayah dengan *cluster* dominan pada seluruh lima tahun analisis dengan kontribusi 61,87% (2019) dan 73,92% (2023). Konsistensi ini selaras dengan dominasi lahan gambut di wilayah tersebut sebesar 21,88% dari total gambut Sumatera[3], di mana gambut yang pernah terbakar memiliki kerentanan lebih tinggi untuk terbakar kembali akibat perubahan struktur fisik dan hidrologi pasca-kebakaran [23], [24]. Khakim *et al.*[23] secara spesifik mengkonfirmasi bahwa kebakaran El Niño 2019 yang menghasilkan 7.893 titik panas di Ogan Komering Ilir terjadi pada lokasi yang sebelumnya terbakar pada El Niño 2015, menunjukkan pola berulang yang konsisten dengan temuan penelitian ini. Muslikah *et al.*[24] juga menegaskan bahwa sekitar 796.000 hektare lahan gambut di Kabupaten Ogan Komering Ilir hampir setiap tahun mengalami kebakaran akibat kombinasi karakteristik gambut yang mudah terbakar dan rendahnya muka air tanah selama musim kemarau, sehingga menjelaskan mengapa pola spasial yang sama berulang meskipun volume data berfluktuasi dari 10.303 titik (2019) hingga 340 titik (2022).

Dibandingkan penelitian sejenis, DBSCAN dalam penelitian ini menunjukkan tiga keunggulan. Pertama, dibandingkan K-Means yang digunakan Khairani *et al.*[8], DBSCAN mampu mengidentifikasi 2,55% sampai 5,96% titik panas sebagai *noise* sehingga memisahkan titik panas terisolasi dari wilayah berkepadatan tinggi, kemampuan yang tidak dimiliki K-Means karena mengharuskan seluruh titik masuk ke dalam *cluster*. Kedua, dibandingkan Usman *et al.*[10] yang hanya menggunakan SSE sebagai kriteria evaluasi, penelitian ini menggunakan DBI yang mempertimbangkan rasio kohesi dan separasi secara bersamaan, dengan nilai DBI sebesar 0,273 sampai 0,595 yang konsisten dengan temuan Ulandari *et al.*[12] bahwa DBSCAN menghasilkan kualitas *clustering* lebih baik dibandingkan metode berbasis kepadatan lainnya. Ketiga, dibandingkan pendekatan Chronnet yang digunakan Ismanto *et al.*[5], pendekatan per tahun dalam penelitian ini lebih fleksibel mengakomodasi perubahan karakteristik data yang drastis antar tahun.

Secara praktis, hasil penelitian ini memiliki dua implikasi langsung bagi sistem mitigasi karhutla di Provinsi Sumatera Selatan. Pertama, terkait penentuan prioritas wilayah pemantauan konsistensi Kabupaten Ogan Komering Ilir sebagai *cluster* dominan dengan kontribusi 61,87% (2019) dan 73,92% (2023) dari seluruh titik panas memberikan dasar empiris yang kuat untuk mengalokasikan sumber daya pemantauan secara proporsional. Hasil *clustering* ini dapat diintegrasikan langsung dengan sistem peringatan dini berbasis satelit seperti FIRMS NASA [NASA FIRMS] untuk menghasilkan peta prioritas wilayah rawan yang diperbarui secara *real-time*, sehingga respons pencegahan dapat difokuskan pada wilayah yang terbukti berulang kali menjadi pusat kebakaran. Kedua, terkait perencanaan intervensi berbasis data yaitu perbedaan parameter optimal yang bergantung pada volume data antar tahun mengindikasikan bahwa sistem pemantauan otomatis perlu mengadaptasi parameter *clustering* secara dinamis sesuai kondisi titik panas aktual, bukan menggunakan parameter tetap. Pendekatan adaptif ini memungkinkan deteksi pola *clustering* yang bermakna bahkan pada tahun dengan intensitas kebakaran rendah (seperti 2020–2022), sehingga wilayah yang mulai

menunjukkan pengelompokan dapat diidentifikasi lebih awal sebelum berkembang menjadi kebakaran besar[6], [23], [24].

#### 4. KESIMPULAN

Penelitian ini mengimplementasikan algoritma DBSCAN dengan penentuan parameter adaptif menggunakan metode kdist untuk mengidentifikasi pola pengelompokan spasial titik panas di Provinsi Sumatera Selatan tahun 2019 sampai 2023. Parameter optimal DBSCAN bersifat adaptif terhadap volume data per tahun. Data dengan lebih dari 5.000 titik panas (2019 dan 2023) menghasilkan parameter optimal MinPts sebesar 11 sampai 13 dengan  $\epsilon$  sebesar 0,1 sedangkan data dengan kurang dari 538 titik panas (2020 sampai 2022) menghasilkan parameter optimal MinPts sebesar 2 dengan  $\epsilon$  antara 0,10 sampai 0,13. Pola spasial titik panas yang konsisten teridentifikasi selama lima tahun analisis, di mana Kabupaten Ogan Komering Ilir dan Kota Palembang secara konsisten membentuk *cluster* dominan dengan kontribusi 61,87% pada 2019 dan 73,92% pada 2023 dari seluruh titik panas yang terdeteksi, diikuti Kabupaten Musi Banyuasin dan Banyuasin sebagai wilayah rawan berikutnya. Kualitas *cluster* yang dihasilkan terkonfirmasi memadai berdasarkan dua metrik evaluasi yaitu nilai *SC* berkisar antara 0,296 hingga 0,670 dengan seluruh nilai bernilai positif yang mengindikasikan setiap titik lebih sesuai dengan *clusternya* sendiri dibandingkan *cluster* lain, serta nilai DBI berkisar antara 0,273 hingga 0,595 yang mendekati nol pada seluruh tahun analisis yang mengindikasikan *cluster* yang kompak dan terpisah dengan baik.

#### 5. REFERENCES

- [1] Arisman, "Analisis Tren Kebakaran Hutan dan Lahan di Indonesia Periode Tahun 2015-2019 Trend Analysis of Forest and Land Fires in Indonesia periods 2015-2019," *Jurnal Sains Teknologi & Lingkungan*, vol. 6, no. 1, 2020.
- [2] N. Bilqis, "Analisis Dampak Kasus Kebakaran Hutan di Indonesia terhadap Hubungan Diplomatik Indonesia dengan Malaysia dan Singapura," *Gorontalo Journal of Government and Political Studies*, vol. 3, no. 2, 2020, doi: 10.32662/gjgops.v3i2.1123.
- [3] Sipongi, "Grafik Rekapitulasi Luas Kebakaran Hutan dan Lahan (Ha) per Provinsi di Indonesia," Direktorat Pengendalian Kebakaran Hutan - Kementerian Kehutanan. Accessed: May 17, 2026. [Online]. Available: <https://sipongi.gakkum.kehutan.go.id/indikasi-luas-kebakaran>
- [4] K. M. Khalwani, B. Bahrani, and L. Syaufina, "Nilai Kerugian Dan Efektivitas Pencegahan Kebakaran Hutan Gambut (Studi Kasus Di Taman Nasional Sebangau Provinsi Kalimantan Tengah)," 2017. doi: 10.20957/jkebijakan.v2i3.12575.
- [5] R. D. Ismanto, A. Vatesia, I. N. Wahyuni, and ..., "Spatio-Temporal Clustering of Forest Fire Hotspots in the Wallacea Region in 2012-2022 Using Chronnet," ... , *Informatics and its ...*, 2024, [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/10732171/>
- [6] N. Rahmah and I. S. Sitanggang, "Determination of Optimal Epsilon (Eps) Value on DBSCAN Algorithm to Clustering Data on Peatland Hotspots in Sumatra," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 31, no. 1, 2016, doi: 10.1088/1755-1315/31/1/012012.
- [7] H. J. Miller, "Tobler's first law and spatial analysis," 2004. doi: 10.1111/j.1467-8306.2004.09402005.x.
- [8] N. A. Khairani and E. Sutoyo, "Application of K-Means Clustering Algorithm for Determination of Fire-Prone Areas Utilizing Hotspots in West Kalimantan Province,"

- International Journal of Advances in Data and Information Systems*, vol. 1, no. 1, 2020, doi: 10.25008/ijadis.v1i1.13.
- [9] K. P. Simanjuntak and U. Khaira, "Pengelompokan Titik Api di Provinsi Jambi dengan Algoritma Agglomerative Hierarchical Clustering," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 1, no. 1, 2021, doi: 10.57152/malcom.v1i1.6.
- [10] M. Usman, I. S. Sitanggang, and L. Syaufina, "Hotspot Distribution Analyses Based on Peat Characteristics Using Density-based Spatial Clustering," *Procedia Environ. Sci.*, vol. 24, pp. 132–140, 2015, doi: 10.1016/j.proenv.2015.03.018.
- [11] R. Trisminingsih and S. S. Shaztika, "ST-DBSCAN clustering module in SpagoBI for hotspots distribution in Indonesia," *2016 3rd International ...*, 2016, [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/7892465/>
- [12] Fella Ulandari and Robert Kurniawan, "PERBANDINGAN ALGORITMA LSDBC DAN DBSCAN PADA PEMETAAN DAERAH RAWAN KEBAKARAN HUTAN," *Jurnal Aplikasi Statistika & Komputasi Statistik*, vol. 12, no. 2, 2020.
- [13] N. L. Febriana and I. S. Sitanggang, "Outlier Detection on Hotspot Data in Riau Province using OPTICS Algorithm," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 58, no. 1, 2017, doi: 10.1088/1755-1315/58/1/012004.
- [14] R. M. Taufiq, R. Firdaus, F. Handayani, H. Mukhtar, and ..., "Clustering Hotspots Using OPTICS Algorithm to Create a Fire Hazard Map of Riau Province as a Disaster Mitigation Effort," *... for Sustainable Decision ...*, 2026, doi: 10.1007/978-3-032-04174-6\_16.
- [15] M. Ester, H. P. Kriegel, J. Sander, and X. Xu, "A Density-Based Algorithm for Discovering Clusters A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise," in *Proceedings - 2nd International Conference on Knowledge Discovery and Data Mining, KDD 1996*, 1996.
- [16] P. J. Rousseeuw, "Silhouettes: A graphical aid to the interpretation and validation of cluster analysis," *J. Comput. Appl. Math.*, vol. 20, no. C, 1987, doi: 10.1016/0377-0427(87)90125-7.
- [17] D. L. Davies and D. W. Bouldin, "A Cluster Separation Measure," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. PAMI-1, no. 2, 1979, doi: 10.1109/TPAMI.1979.4766909.
- [18] L. Yin, H. Hu, K. Li, G. Zheng, Y. Qu, and H. Chen, "Improvement of DBSCAN Algorithm Based on K-Dist Graph for Adaptive Determining Parameters," *Electronics (Switzerland)*, vol. 12, no. 15, 2023, doi: 10.3390/electronics12153213.
- [19] R. Hermawati and I. S. Sitanggang, "Web-Based Clustering Application Using Shiny Framework and DBSCAN Algorithm for Hotspots Data in Peatland in Sumatra," *Procedia Environ. Sci.*, vol. 33, pp. 317–323, 2016, doi: 10.1016/j.proenv.2016.03.082.
- [20] P. Sukmasetya and I. S. Sitanggang, "Outlier Detection on Hotspots Data in Riau Province using DBSCAN Algorithm," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 31, no. 1, 2016, doi: 10.1088/1755-1315/31/1/012035.
- [21] R. Hidayati, A. Zubair, A. Hidayat Pratama, and L. Indana, "Silhouette Coefficient Analysis in 6 Measuring Distances of K-Means Clustering," *Techno.Com*, vol. 20, no. 2, 2021.
- [22] Z. Huang, Z. Liang, S. Zhou, and S. Zhang, "An Improved Density-Based Spatial Clustering of Applications with Noise Algorithm with an Adaptive Parameter Based on the Sparrow Search Algorithm," *Algorithms*, vol. 18, no. 5, 2025, doi: 10.3390/a18050273.
- [23] M. Y. N. Khakim *et al.*, "LAND COVER AND BURN SEVERITY DYNAMICS OF THE OGAN KOMERING ILIR PEATLANDS FROM 2015 TO 2023 USING SAR AND OPTICAL DATASETS," *Geography, Environment, Sustainability*, vol. 17, no. 3, 2024, doi: 10.24057/2071-9388-2024-3217.

- [24] S. Muslikah and Y. Yuliani, "Potential Analysis Of Peatland Fire In Ogan Komering Ilir District," *International Journal of Progressive Sciences and Technologies*, vol. 41, no. 1, 2023, doi: 10.52155/ijpsat.v41.1.5691.