

Analisis Spasial-temporal Titik Panas dan PM2.5 di Riau, Jambi, dan Sumatera Selatan

Spatiotemporal Analysis of Fire Hotspots and PM2.5 in Riau, Jambi, and South Sumatra

YASMIN LUKMAN*, IMAS SUKAESIH SITANGGANG, MEDRIA KUSUMA DEWI
HARDHIENATA

Abstrak

Kebakaran hutan dan lahan (karhutla) di Indonesia berkontribusi signifikan terhadap penurunan kualitas udara melalui peningkatan konsentrasi PM2.5. Penelitian ini menganalisis pola spasial-temporal sebaran titik panas dan estimasi konsentrasi PM2.5 di Provinsi Riau, Jambi, dan Sumatera Selatan selama Agustus–Oktober 2023. Data titik panas MODIS dianalisis menggunakan algoritma ST-DBSCAN dengan pengaturan parameter jarak spasial, jarak temporal, dan jumlah minimum titik untuk mengidentifikasi kluster kebakaran. Estimasi PM2.5 diperoleh dari konversi *Aerosol Optical Depth* (AOD) MODIS menggunakan model empiris. Hasil menunjukkan bahwa ST-DBSCAN efektif dalam mengidentifikasi kluster titik panas, dengan kepadatan kluster tertinggi teramati di Provinsi Sumatera Selatan. Rata-rata estimasi PM2.5 tercatat sebesar 50,51 $\mu\text{g}/\text{m}^3$ di Provinsi Riau, 48,16 $\mu\text{g}/\text{m}^3$ di Provinsi Jambi, dan 41,59 $\mu\text{g}/\text{m}^3$ di Provinsi Sumatera Selatan. Konsentrasi PM2.5 tertinggi terjadi di Provinsi Riau pada bulan Oktober dan melampaui ambang batas pedoman kualitas udara WHO. Temuan ini menegaskan adanya keterkaitan kuat antara dinamika spasial-temporal karhutla dan peningkatan polusi udara, serta menunjukkan potensi pendekatan ini dalam mendukung analisis risiko lingkungan dan kesehatan.

Kata Kunci: karhutla, PM2.5, spasial-temporal, ST-DBSCAN, titik panas.

Abstract

Forest and land fires in Indonesia significantly degrade air quality by increasing PM2.5 concentrations. This study examines the spatiotemporal patterns of fire hotspot distribution and estimated PM2.5 concentrations in Riau, Jambi, and South Sumatra Provinces during August–October 2023. MODIS fire hotspot data were analyzed using the ST-DBSCAN algorithm with defined spatial distance, temporal distance, and minimum point parameters to identify fire clusters. PM2.5 concentrations were estimated by converting MODIS Aerosol Optical Depth (AOD) using an empirical model. The results demonstrate that ST-DBSCAN effectively identifies fire hotspot clusters, with the highest cluster density observed in South Sumatra Province. The average estimated PM2.5 concentrations were 50.51 $\mu\text{g}/\text{m}^3$ in Riau, 48.16 $\mu\text{g}/\text{m}^3$ in Jambi, and 41.59 $\mu\text{g}/\text{m}^3$ in South Sumatra. The highest PM2.5 levels occurred in Riau Province in October, exceeding the World Health Organization air quality guideline. These findings reveal a strong spatiotemporal association between fire activity and elevated particulate pollution and highlight the potential of this approach to support environmental and health risk assessments related to wildfire events.

Keywords: hotspot, forest and land fire, PM2.5, spatiotemporal, ST-DBSCAN.

PENDAHULUAN

Kebakaran hutan dan lahan (karhutla) merupakan salah satu bencana ekologis yang paling sering terjadi di kawasan tropis, khususnya Indonesia. Dalam beberapa dekade terakhir, intensitas dan frekuensi kejadian karhutla meningkat seiring dengan perubahan iklim global, tekanan terhadap ekosistem hutan, serta praktik pembukaan lahan dengan cara pembakaran (Field *et al.* 2009). Penelitian oleh Vásquez *et al.* (2021) menunjukkan bahwa kebakaran di lahan gambut Indonesia melepaskan emisi gas rumah kaca dalam jumlah besar. Karhutla tidak

hanya menimbulkan kerusakan pada lingkungan dan ekosistem, tetapi juga mengancam kesehatan masyarakat secara signifikan akibat tingginya paparan polusi udara, terutama partikel halus seperti PM_{2.5} (*particulate matter* dengan ukuran ≤ 2.5 mikrometer). Partikel ini mampu masuk hingga ke paru-paru bagian terdalam dan menyebabkan berbagai gangguan pernapasan, kardiovaskular, bahkan kematian dini (WHO 2021). Paparan PM_{2.5} dalam jangka pendek maupun panjang telah dikaitkan dengan peningkatan risiko penyakit jantung iskemik, stroke, hingga komplikasi kehamilan seperti kelahiran prematur dan keguguran (Chen *et al.* 2025; Wei *et al.* 2024; Liu *et al.* 2018).

Tiga provinsi di Pulau Sumatera, yaitu Riau, Jambi, dan Sumatera Selatan, dikenal sebagai wilayah dengan risiko karhutla tinggi di Indonesia. Hal ini disebabkan oleh kombinasi faktor seperti luasnya ekosistem lahan gambut yang mudah terbakar saat mengering, tekanan ekonomi terhadap konversi lahan menjadi perkebunan, serta minimnya pengawasan di wilayah terpencil (Miettinen *et al.* 2017). Menurut Kementerian Lingkungan Hidup dan Kehutanan (Kepmen LHK 2017), ketiga provinsi tersebut menyumbang sebagian besar luas area gambut di Sumatera, dengan Riau mencapai lebih dari 5 juta hektare. Kondisi ini menjadikan kawasan tersebut sangat rentan terhadap kebakaran skala besar, terutama pada musim kemarau. Sumatera Selatan sendiri mencatat lebih dari 33.000 titik panas pada tahun 2015, sekitar 72% di antaranya berada di lahan gambut (Nurhayati *et al.* 2021; Hawam dan Aulady 2024; Rahmat dan Sitanggang 2020).

Data dari *World Health Organization* (WHO) menunjukkan bahwa batas aman harian PM_{2.5} adalah 15 $\mu\text{g}/\text{m}^3$. Namun, di wilayah terdampak karhutla, nilai ini dapat meningkat drastis jauh di atas ambang tersebut. Karhutla di kawasan gambut menghasilkan asap yang lebih pekat dan persisten karena sifatnya yang membakar hingga ke dalam tanah. Kebanyakan kebakaran ini dipicu oleh aktivitas manusia, khususnya untuk pembukaan lahan pertanian dan perkebunan, terutama di area gambut yang mudah terbakar dan menghasilkan emisi PM_{2.5} dalam jumlah besar (Sze dan Lee 2019; Hawam dan Aulady 2024; Nurhayati *et al.* 2021).

Beberapa penelitian menunjukkan bahwa pengukuran langsung PM_{2.5} di wilayah ini masih sangat terbatas karena keterbatasan stasiun pemantauan kualitas udara (Rendana *et al.* 2022). Oleh karena itu, pendekatan berbasis penginderaan jauh menjadi alternatif penting dalam mengestimasi kualitas udara dan mendeteksi potensi kebakaran (Gupta *et al.* 2006). Data citra satelit seperti MODIS (*Moderate Resolution Imaging Spectroradiometer*) menyediakan informasi harian mengenai titik panas (*hotspot*) dan ketebalan aerosol di atmosfer (*Aerosol Optical Depth/AOD*). Titik panas merupakan indikator awal keberadaan api aktif, sedangkan AOD mencerminkan konsentrasi partikel aerosol di kolom atmosfer. Integrasi keduanya memberikan gambaran menyeluruh mengenai lokasi, waktu, dan potensi dampak karhutla terhadap kualitas udara.

Namun, sebagian besar studi sebelumnya cenderung menganalisis titik panas atau AOD secara terpisah tanpa integrasi spasial-temporal yang memadai, sehingga berpotensi kehilangan konteks penting dalam memahami proses propagasi asap dan hubungan dinamis antara sumber emisi dan konsentrasi partikulat di atmosfer (Sofyan *et al.* 2022; Levy *et al.* 2023). Pendekatan terpisah ini membuat interpretasi hubungan antara intensitas kebakaran, distribusi spasial asap, dan peningkatan konsentrasi PM_{2.5} menjadi kurang akurat, terutama pada wilayah dengan dinamika meteorologi yang kompleks seperti Sumatera. Oleh karena itu, diperlukan pendekatan analisis yang mampu mengintegrasikan dimensi spasial dan temporal secara simultan, sehingga pola kejadian karhutla dan dampaknya terhadap kualitas udara dapat diidentifikasi secara lebih komprehensif.

Algoritma *Spatio-Temporal Density-Based Spatial Clustering of Applications with Noise* (ST-DBSCAN) digunakan dalam penelitian ini untuk mengidentifikasi kluster titik panas berdasarkan kedekatan spasial dan temporal (Birant dan Kut 2007). ST-DBSCAN telah diterapkan dalam berbagai studi sebelumnya untuk menganalisis distribusi titik panas di wilayah seperti Riau, Sulawesi, dan Sumatera Selatan. Hasil studi tersebut menunjukkan bahwa metode ini mampu mengelompokkan kejadian kebakaran ke dalam berbagai pola, termasuk

stasioner, *reappearing*, acak, sesekali, dan berpindah (*track clusters*), yang berkaitan dengan dinamika intensitas dan waktu kejadian kebakaran (Faraouk *et al.* 2023; Vatresia *et al.* 2020; Trisminingsih dan Shaztika 2016). Pendekatan klasterisasi dengan ST-DBSCAN di Pulau Sumatra telah terbukti efektif dalam mengidentifikasi pola kejadian kebakaran hutan. Sujiono (2023) melaporkan bahwa selama periode 2014–2019, sekitar 46,74% dari total titik panas di Sumatra membentuk klaster, yang menunjukkan potensi tinggi sebagai indikator kebakaran aktif.

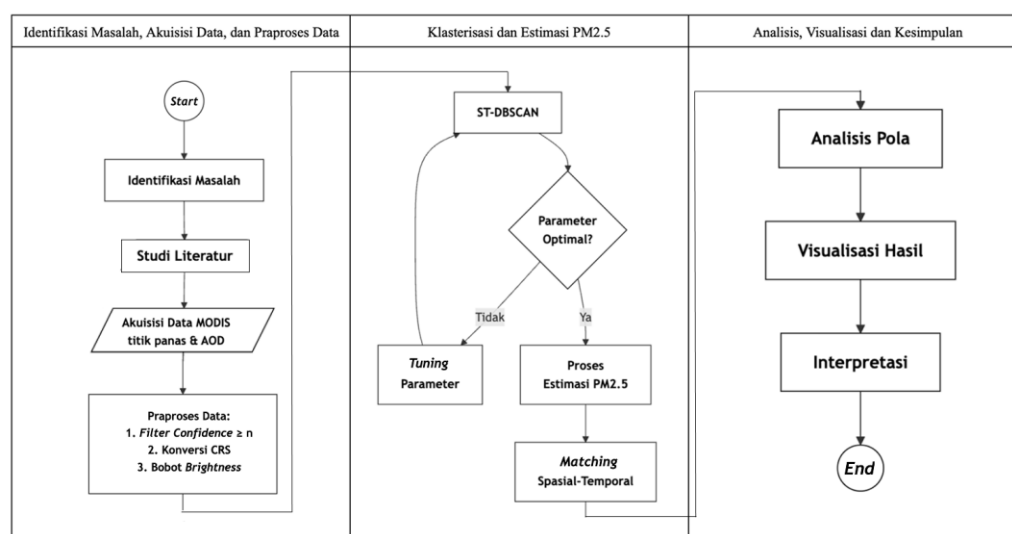
Meskipun demikian, studi-studi tersebut umumnya terbatas pada klasterisasi titik panas tanpa mengintegrasikan estimasi PM_{2.5} sebagai indikator dampak kualitas udara. Selain itu, penerapan algoritma ST-DBSCAN dan model empiris NASA ARSET memiliki tantangan tersendiri, seperti sensitivitas terhadap variasi parameter spasial dan temporal yang dapat memengaruhi hasil klasterisasi dan estimasi. Penelitian ini bertujuan untuk mengisi celah tersebut dengan menggabungkan analisis spasial-temporal titik panas menggunakan ST-DBSCAN dan estimasi konsentrasi PM_{2.5} dari data AOD MODIS berdasarkan model empiris NASA ARSET (2018). Karena studi serupa masih sangat terbatas pada konteks wilayah Sumatera, penelitian ini diharapkan dapat menjadi studi awal yang memberikan dasar bagi pengembangan metode integratif serupa di masa mendatang.

METODE

Penelitian ini dilakukan di Provinsi Riau, Jambi, dan Sumatera Selatan dengan cakupan waktu Agustus hingga Oktober 2023. Metode penelitian mencakup: (1) akuisisi dan pra-pemrosesan data titik panas dan data *Aerosol Optical Depth* (AOD) dari citra satelit MODIS; (2) analisis klaster titik panas menggunakan algoritma ST-DBSCAN (Birant dan Kut 2007); serta (3) estimasi konsentrasi PM_{2.5} berdasarkan nilai AOD melalui model konversi empiris dari NASA ARSET. Analisis spasial-temporal dilakukan untuk mengevaluasi hubungan antara klaster kebakaran dan peningkatan PM_{2.5} di wilayah terdampak menggunakan *hybrid matching* (pencocokan spasial-temporal) (Zhang *et al.* 2019).

Tahapan Penelitian

Penelitian ini terdiri dari beberapa tahapan, dimulai dari identifikasi masalah, pengumpulan dan praproses data, analisis spasial-temporal menggunakan algoritma ST-DBSCAN, hingga estimasi konsentrasi PM_{2.5} berdasarkan klaster kebakaran yang terbentuk sebagaimana dapat dilihat pada Gambar 1.



Gambar 1 Tahapan penelitian

Data dan Sumber Data

Data utama terdiri dari dua jenis: data titik panas dan data aerosol optik atau *Aerosol Optical Depth* (AOD). Data titik panas diperoleh dari produk MODIS (*Moderate Resolution Imaging Spectroradiometer*) *Collection 6.1 Active Fire* (MOD14/MYD14) yang diakses melalui FIRMS (*Fire Information For Resource Management System*) NASA (*National Aeronautics and Space Administration*) dalam format CSV. MODIS merupakan sensor pada satelit Terra dan Aqua yang secara luas digunakan untuk pemantauan titik panas. Sensor ini memiliki kemampuan mendeteksi anomali termal secara harian dengan resolusi spasial 1 km untuk kanal termal dan cakupan global. Data titik panas ini mencakup informasi lokasi (*latitude* dan *longitude*), waktu kejadian, tingkat kepercayaan (*confidence*), dan kecerahan (*brightness*) (NASA Earthdata 2023).

Tabel 1 Data titik panas MODIS

<i>Latitude</i>	<i>Longitude</i>	Kecerahan (Kelvin)	Tanggal	Nilai kepercayaan	Level kepercayaan
-0.9	101.7	310	2023-01-01	21	<i>Low</i>
-1.3	101.8	318.6	2023-01-01	66	<i>Nominal</i>
1.7	101.5	311.6	2023-01-05	35	<i>Nominal</i>
-0.5	101.7	313.4	2023-01-06	62	<i>Nominal</i>
-0.9	103.1	316.1	2023-01-06	40	<i>Nominal</i>

* *Brightness temperature* pada tabel ini dinyatakan dalam satuan Kelvin (K), sesuai dengan keluaran standar produk MODIS, dan digunakan langsung dalam analisis tanpa konversi ke derajat Celsius

Data AOD berasal dari produk MODIS Level 2 (MOD04_L2 dan MYD04_L2) dalam format HDF, yang mencakup nilai AOD per piksel dengan resolusi spasial 10 km dan resolusi temporal harian (NASA 2025). Total titik panas yang digunakan berjumlah sekitar 8000 titik data untuk ketiga provinsi dalam periode studi, sedangkan data AOD terdiri dari 527 *file* HDF granula harian yang mencakup wilayah studi. Sumber data ini kompatibel dengan penerapan algoritma ST-DBSCAN (Faraouk *et al.* 2023; Trisminingsih dan Shaztika 2016). Contoh data yang digunakan dalam analisis ditampilkan pada Tabel 1 dan Tabel 2, yang masing-masing menunjukkan atribut titik panas dan data AOD dari produk MODIS.

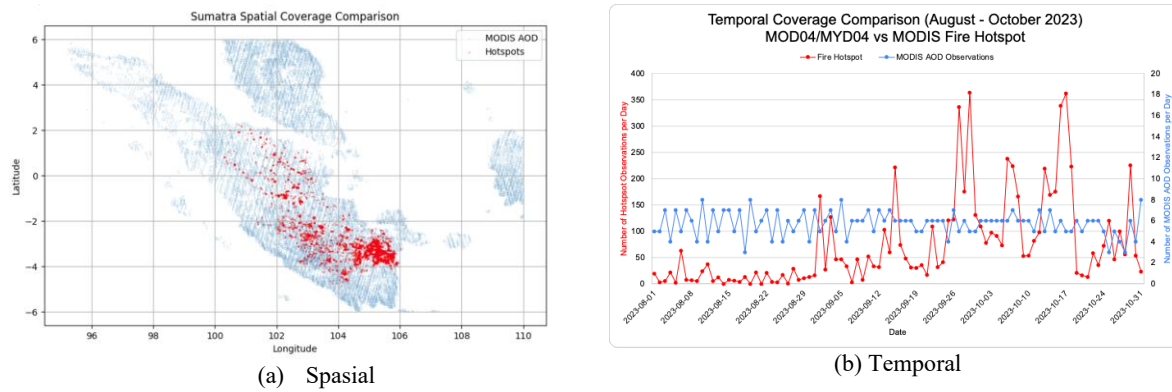
Tabel 2 Data AOD MODIS

<i>Latitude</i>	<i>Longitude</i>	Tanggal	AOD
-1.6	100.2	2023-08-25	-9999
-3.5	105.2	2023-08-25	-9999
-4.2	102.2	2023-08-25	-9999
-1.7	102.3	2023-08-25	699
-3.6	103.4	2023-08-25	391

*Nilai AOD didapat dari atribut *Deep_Blue_Aerosol_Optical_Depth_550_Land* pada *dataset*

Pra-Pemrosesan Data

Pra-pemrosesan mencakup beberapa tahap. Pertama, data titik panas disaring berdasarkan nilai kepercayaan $\geq 30\%$ untuk menghilangkan titik-titik yang kurang dapat diandalkan. Penyaringan berdasarkan nilai kepercayaan merupakan praktik umum dalam analisis spasial-temporal kebakaran hutan, karena nilai ini mencerminkan tingkat keyakinan algoritma MODIS dalam mendeteksi titik panas.



Gambar 2 Irisan data titik panas dan AOD MODIS. (a) AOD seluruh Sumatra, titik panas pada area studi (Riau, Jambi, Sumatera Selatan); (b) AOD dan titik panas yang difilter khusus untuk area studi

Beberapa penelitian sebelumnya juga menggunakan ambang batas kepercayaan $\geq 30\%$ untuk menjaga cakupan deteksi yang lebih luas dan tetap mempertahankan integritas analisis spasial, khususnya di wilayah tropis yang rentan terhadap kebakaran (Cahyani *et al.* 2024; Kirana *et al.* 2023; Unik *et al.* 2025). Selanjutnya, data AOD diubah dari format HDF menjadi *data frame* terstruktur menggunakan pustaka Python seperti Pyhdf dan Pandas. Data waktu dari kedua sumber diubah ke format temporal (tanggal dan waktu) standar untuk memungkinkan penggabungan spasial-temporal. Visualisasi irisan data secara spasial dan temporal dapat dilihat pada Gambar 2.

Perhitungan ST-DBSCAN

Setelah data dibersihkan dan dikonversi ke format yang seragam, dilakukan proses klusterisasi titik panas menggunakan algoritma ST-DBSCAN. Metode ini digunakan untuk mengelompokkan titik panas berdasarkan kedekatan spasial dan temporal (Birant dan Kut 2007). Pemilihan kombinasi parameter ST-DBSCAN pada penelitian ini didasarkan pada hasil uji awal dan rujukan dari beberapa studi terdahulu (Tabel 3). Kombinasi parameter yang diuji meliputi variasi nilai spasial $\varepsilon_1 = 0.01^\circ$, 0.15° , dan 0.18° , nilai temporal $\varepsilon_2 = 5$ hari, serta min_sampel (jumlah minimum sampel) = 3 dan 7. Kombinasi pertama mengacu pada Sujiono (2023) yang menggunakan $\varepsilon_1 = 0.01^\circ$ (~ 1 km) untuk analisis skala sangat halus, tetapi menghasilkan klaster yang sangat terfragmentasi dan tingkat *noise* tinggi. Merujuk pada Sitanggang *et al.* (2018) yang menggunakan $\varepsilon_1 = 0.1^\circ$ (~ 11 km) di Sumatra dan Syurifah dan Fahmi (2024) yang menggunakan $\varepsilon_1 = 0.3^\circ$ (~ 33 km) di Indonesia, penelitian ini menguji nilai ε_1 yang lebih besar untuk mengurangi fragmentasi klaster. Nilai $\varepsilon_1 = 0.15^\circ$ (~ 17 km) dipilih sebagai kompromi, tetapi masih menghasilkan *noise* cukup tinggi di Provinsi Riau dan Jambi (40–80%). Oleh karena itu, pada kombinasi ketiga digunakan $\varepsilon_1 = 0.18^\circ$ (~ 20 km) yang terbukti menghasilkan keseimbangan terbaik antara konsistensi spasial dan jumlah *noise* rendah.

Pemilihan $\text{min_sampel} = 7$ pada awalnya mengacu pada Sitanggang *et al.* (2018) dan Sujiono (2023), sedangkan penurunan menjadi tiga mengacu pada Faraouk (2023) yang menunjukkan bahwa ambang rendah dapat membantu mendeteksi klaster kecil di wilayah dengan sebaran titik panas jarang tanpa kehilangan pola utama. Kombinasi akhir $\varepsilon_1 = 0.18^\circ$, $\varepsilon_2 = 5$ hari, dan $\text{min_sampel} = 3$ digunakan sebagai konfigurasi optimal untuk penelitian ini.

Tabel 3 Referensi parameter ST-DBSCAN pada penelitian terdahulu

Studi	Lokasi Penelitian	ε_1 (derajat / km)	ε_2 (hari)	min_sampel
Sujiono (2023)	Kalimantan	0.01° (~ 1 km)	5	7
Sitanggang <i>et al.</i> (2018)	Sumatra	0.1° (~ 11 km)	5	7
Syurifah & Fahmi. 2024	Indonesia	0.3° (~ 33 km)	5	14
Faraouk (2023)	Riau	0.7° (~ 78 km)	2	2
Sujiono (2023)	Kalimantan	0.01° (~ 1 km)	5	7

Formulasi utama ST-DBSCAN melibatkan tiga komponen kunci. Pertama adalah fungsi jarak gabungan yang mengukur kedekatan spasial-temporal antara dua titik (Birant dan Kut 2007):

$$D(p_i, p_j) = \sqrt{\alpha \cdot d_{spatial}^2 + (1 - \alpha) \cdot d_{temporal}^2} \quad (1)$$

dengan:

- $d_{spatial}$ = dihitung menggunakan formula *Haversine* (Sinnott 1984) untuk jarak geodesik:

$$d_{spatial} = 2R \arcsin \left(\sqrt{\sin^2 \left(\frac{\Delta lat}{2} \right) + \cos(lat_i) \cos(lat_j) \sin^2 \left(\frac{\Delta lon}{2} \right)} \right) \quad (2)$$

- $d_{temporal} = |t_i - t_j|$ (selisih waktu dalam hari, Birant dan Kut (2007)).
- α = merupakan parameter pembobot (biasanya 0.5 untuk keseimbangan optimal antara komponen spasial dan temporal) (Kisilevich *et al.* 2010)

Komponen kedua adalah kriteria kepadatan, yaitu suatu titik p akan dimasukkan ke dalam sebuah kluster jika terdapat minimal titik tetangga (\min_sample) dalam radius ϵ_1 dan rentang waktu ϵ_2 . Hal ini memungkinkan identifikasi struktur kluster yang padat tetapi fleksibel terhadap *noise*, dirumuskan oleh Ester *et al.* (1996) sebagai berikut:

$$|\{q \in D \mid D(p, q) \leq \epsilon_1 \text{ (spasial)} \wedge |t_p - t_q| \leq \epsilon_2 \text{ (temporal)}\}| \geq \min_sample \quad (3)$$

dengan:

- ϵ_1 : *threshold* jarak spasial (pada penelitian ini, satuan yang digunakan: km)
- ϵ_2 : *threshold* jarak temporal (pada penelitian ini, satuan yang digunakan: hari)
- \min_sample : minimum titik tetangga (Ester *et al.* 1996)

Komponen ketiga adalah evaluasi kualitas kluster. Setelah proses klusterisasi, hasil dianalisis melalui statistik deskriptif seperti jumlah kluster, ukuran rata-rata kluster, dan persentase *noise*. Selanjutnya, kualitas kluster dinilai menggunakan *Silhouette Score* (Rousseeuw 1987):

$$s(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))} \quad (4)$$

dengan:

- $a(i)$: Jarak rata-rata titik i ke semua titik dalam kluster yang sama.
- $b(i)$: Jarak rata-rata terdekat ke titik di kluster lain.
- Skor akhir adalah rata-rata $s(i)$ untuk semua titik

Perhitungan Estimasi PM2.5

Estimasi konsentrasi PM2.5 dilakukan setelah proses identifikasi kluster titik panas menggunakan algoritma ST-DBSCAN. Setiap kluster yang terbentuk direpresentasikan dalam bentuk *convex hull* (Barber *et al.* 1996), kemudian diperluas dengan *buffer* (zona penyangga) sebesar 0.2° (~ 22 km) ke segala arah untuk mencakup wilayah penyebaran polutan yang lebih luas. Zona penyangga 0.2° (~ 22 km) dipilih berdasarkan studi sebelumnya mengenai estimasi jarak sebaran asap akibat kecepatan angin. Misalnya, Pandapotan *et al.* (2021) menemukan bahwa angin di Kalimantan dengan kecepatan 10–37 km/h menyebabkan asap tersebar signifikan ke daerah sekitar titik panas. Selain itu, Storey and Price (2022) menunjukkan bahwa di New South Wales, Australia, zona penyangga hingga 150 km digunakan untuk menghubungkan titik. Dengan demikian, zona penyangga sekitar 22 km dianggap sebagai kompromi yang mencerminkan kecepatan angin rata-rata di wilayah studi serta cakupan spasial yang realistis. Pendekatan pencocokan spasial-temporal (Zhang *et al.* 2019) kemudian diterapkan untuk menghubungkan kluster titik panas dengan data AOD dari citra MODIS. Pencocokan dilakukan dalam dua aspek: spasial (berdasarkan area zona penyangga dari *convex*

hull) dan temporal (dengan memilih data AOD yang memiliki tanggal yang sama dengan kejadian titik panas).

Sebelum pencocokan dilakukan, data titik panas (resolusi 1 km) dan AOD (resolusi 10 km) dikalibrasi terlebih dahulu untuk menyelaraskan skala spasial antar data. Kalibrasi ini dilakukan bukan dengan mengubah resolusi asli masing-masing data, tetapi dengan menyamakan satuan ruang analisis menggunakan grid spasial berukuran 10 km × 10 km, sesuai dengan resolusi data AOD. Data titik panas yang memiliki resolusi lebih tinggi diagregasi ke dalam grid tersebut berdasarkan lokasi geografisnya, sehingga setiap grid dapat direpresentasikan oleh satu nilai AOD dan jumlah titik panas yang terkandung di dalamnya. Keluaran yang dihasilkan berupa data tabular berbasis grid 10 km. Setelah penyelarasan selesai, konversi nilai AOD menjadi estimasi konsentrasi PM_{2.5} dilakukan menggunakan model regresi linear yang dikembangkan oleh NASA ARSET (2018), yaitu:

$$PM_{2.5} = 46.7 \times AOD + 7.13 \quad (5)$$

dengan:


- PM_{2.5}: konsentrasi partikulat halus dalam $\mu\text{g}/\text{m}^3$
- AOD: nilai kedalaman optik aerosol dari data satelit
- a : koefisien kemiringan, menunjukkan besarnya peningkatan PM_{2.5} untuk setiap kenaikan satu satuan AOD.
- b : koefisien *intercept*, menunjukkan nilai PM_{2.5} saat AOD = 0, yaitu kontribusi dari sumber lokal yang tidak tertangkap oleh data AOD. Koefisien a dan b adalah koefisien hasil regresi berdasarkan data lokal atau regional

Model ini berasal dari hasil regresi antara AOD MODIS dan data pengukuran permukaan PM_{2.5} dari berbagai stasiun pemantauan kualitas udara, dengan nilai koefisien determinasi sekitar $R^2 \approx 0.56$. Nilai ini menunjukkan hubungan yang cukup kuat tetapi tidak sempurna antara variabel AOD dan konsentrasi PM_{2.5} di permukaan. Artinya, sekitar 56% variasi konsentrasi PM_{2.5} dapat dijelaskan oleh perubahan nilai AOD, sementara sisanya dipengaruhi oleh faktor yang tidak dimasukkan ke dalam model. Meskipun model ini dikembangkan dalam konteks global, pendekatan ini tetap digunakan dalam studi ini karena keterbatasan data pengukuran lapangan di wilayah studi. Selain itu, model ini dinilai relevan karena wilayah studi dipengaruhi oleh sumber emisi utama yang serupa, yaitu transportasi serta kebakaran hutan dan lahan (Rahman dan Thurston 2022).

Hasil konversi AOD ke PM_{2.5} dihitung sebagai rata-rata untuk setiap kluster kebakaran, dengan mempertimbangkan nilai-nilai AOD yang berada dalam area zona penyangga dan pada waktu yang sesuai. Pendekatan ini memungkinkan evaluasi sebaran spasial dan temporal konsentrasi PM_{2.5} secara lebih komprehensif. Studi-studi sebelumnya juga menunjukkan bahwa model regresi linear berbasis AOD seperti ini mampu mencapai korelasi sedang hingga tinggi ($R^2 = 0.53\text{--}0.81$) terhadap pengukuran PM_{2.5} di permukaan, tergantung wilayah dan musim (Li *et al.* 2018; Handschuh *et al.* 2022; Zhao *et al.* 2018; Lv *et al.* 2016). Dengan demikian, meskipun nilai R^2 sebesar 0.56 mengindikasikan masih adanya ketidakpastian, pendekatan ini tetap digunakan untuk menggambarkan pola distribusi spasial-temporal PM_{2.5} di wilayah dengan keterbatasan data pengamatan langsung seperti Sumatera.

HASIL DAN PEMBAHASAN

Algoritma ST-DBSCAN mengelompokkan titik panas berdasarkan tiga parameter utama: *threshold* spasial (ϵ_1), *threshold* temporal (ϵ_2), dan *min_sampel*. Eksperimen dilakukan untuk *dataset* di Provinsi Riau, Jambi dan Sumatera Selatan selama Agustus hingga Oktober 2023 dengan tiga kombinasi parameter. Perbandingan hasil jumlah titik yang dikategorikan sebagai *noise* dari masing-masing kombinasi dapat dilihat pada Gambar 3. Penyesuaian parameter ini memengaruhi sensitivitas algoritma dalam membedakan kluster dari titik *noise*.



Gambar 3 Perbandingan jumlah titik noise pada hasil ST-DBSCAN untuk tiga kombinasi parameter ϵ_1 , ϵ_2 , dan min_sampel

Tabel 4 mengevaluasi performa algoritma ST-DBSCAN dengan tiga kombinasi parameter utama. Kombinasi pertama ($\epsilon_1 = 0.01^\circ$, $\epsilon_2 = 5$ hari, $min_sampel = 7$), yang mengacu pada studi Sujiono (2023), belum menunjukkan performa yang baik. Jumlah kluster sangat sedikit atau tidak ada, *noise* ekstrem (hingga 100%), dan terjadi fragmentasi tinggi. Meski *Silhouette Score* terlihat tinggi, nilai tersebut bias karena hampir semua titik dianggap *noise*. Ini menunjukkan bahwa parameter terlalu ketat untuk menangkap dinamika spasial-temporal kebakaran hutan di wilayah studi.

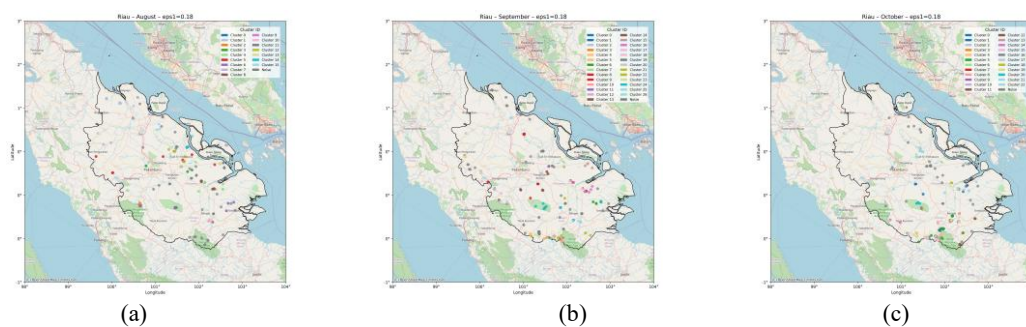
Kombinasi kedua ($\epsilon_1 = 0.15^\circ$, $min_sampel = 7$) memperbaiki performa secara signifikan. Kluster lebih banyak terbentuk, *noise* menurun drastis, terutama di Sumatera Selatan. Namun, ukuran kluster cenderung terlalu besar, menandakan bahwa nilai ϵ_1 terlalu longgar jika tidak diimbangi dengan penyesuaian min_sampel . Hal ini menyebabkan tidak dapat terdeteksinya kluster-kluster berukuran kecil.

Tabel 4 Performa ST-DBSCAN dengan variasi parameter di wilayah studi


Atribut	$\epsilon_1=0.01^\circ$, $\epsilon_2=5$, $min_samples=7$			$\epsilon_1=0.15^\circ$, $\epsilon_2=5$, $min_sampel=7$			$\epsilon_1=0.18^\circ$, $\epsilon_2=5$, $min_sampel=3$		
	Agu	Sept	Okt	Agu	Sept	Okt	Agu	Sept	Okt
Provinsi Riau									
Total titik panas	156	216	280	156	216	280	156	216	280
Jumlah kluster	2	0	7	5	7	12	16	27	23
Jumlah <i>noise</i>	133	216	212	110	158	114	65	64	65
<i>Noise (%)</i>	85.26	100	75.71	70.51	73.15	40.71	41.67	29.63	23.21
Ukuran kluster (mean)	11.50	0.00	9.71	9.20	8.28	13.83	5.69	5.63	9.38
<i>Silhouette score</i>	0.98	NaN	0.86	0.72	0.62	0.69	0.63	0.45	0.73
Provinsi Jambi									
Total titik panas	46	210	210	46	210	210	46	210	210
Jumlah kluster	0	0	1	1	9	8	6	22	26
Jumlah <i>noise</i>	46	210	201	39	100	114	19	27	32
<i>Noise (%)</i>	100	100	95.71	84.78	47.62	54.28	41.30	12.86	15.24
Ukuran kluster (mean)	0	0	9	7	12.22	12	4.50	8.32	6.85
<i>Silhouette score</i>	NaN	NaN	NaN	NaN	0.46	0.58	0.74	0.48	0.56
Provinsi Sumatera Selatan									
Total titik panas	186	2247	3200	186	2247	3200	186	2247	3200
Jumlah kluster	1	63	103	4	39	38	23	47	54
Jumlah <i>noise</i>	179	1239	1647	148	169	196	55	68	59
<i>Noise (%)</i>	96.24	55.14	51.47	79.57	7.52	6.12	29.57	3.03	1.84
Ukuran kluster (mean)	7	16	15.07	9.5	53.28	79.05	5.69	46.36	58.16
<i>Silhouette score</i>	NaN	0.29	0.23	0.88	0.42	0.35	0.47	0.40	0.33

Kombinasi ketiga ($\epsilon_1 = 0.18^\circ$, $\min_sampel = 3$) menunjukkan kinerja paling optimal. Di seluruh provinsi, terbentuk banyak kluster dengan *noise* rendah dan ukuran kluster yang proporsional. *Silhouette Score* tetap kompetitif dan konsisten menunjukkan pemisahan spasial-temporal yang baik. Konfigurasi ini berhasil menyeimbangkan sensitivitas terhadap kejadian lokal tanpa mengorbankan kualitas segmentasi. Dengan demikian, kombinasi ketiga paling sesuai digunakan dalam konteks analisis spasial-temporal titik panas, karena mampu menangkap struktur data secara realistis dan operasional tanpa mengabaikan kualitas klusterisasi.

Hasil visualisasi provinsi Riau (Gambar 4) menunjukkan pada bulan Agustus, sebanyak 15 kluster berhasil teridentifikasi. Kluster-kluster ini umumnya berukuran kecil. Di bulan September, terjadi peningkatan jumlah kluster menjadi 26, yang menandakan peningkatan kejadian kebakaran maupun deteksi spasial-temporal yang lebih aktif. Di bulan Oktober, jumlah kluster sedikit menurun menjadi 22, tetapi tetap menunjukkan konsistensi spasial, terutama pada area yang sebelumnya juga mengalami kebakaran.



Gambar 4 Visualisasi 2D hasil *klusterisasi* menggunakan parameter $\epsilon_1=0.18^\circ$, $\epsilon_2=5$, $\min_sampel=3$ di Provinsi Riau. (a)Agustus 2023; (b) September 2023; (c) Oktober 2023



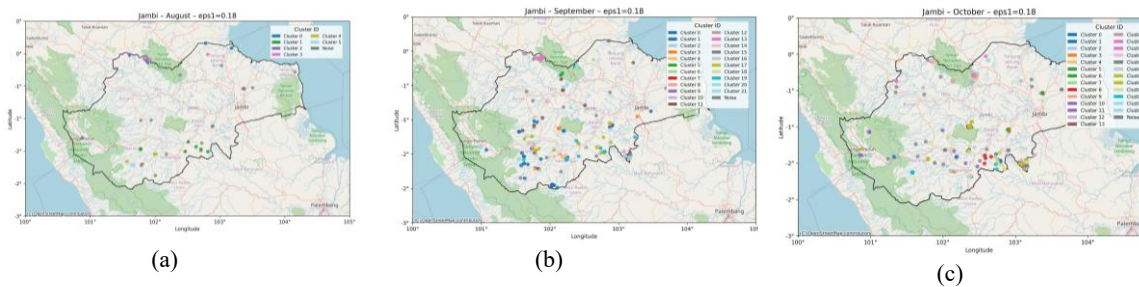
Gambar 5 Visualisasi evolusi kluster 17 (Riau, 27 Sep–17 Okt 2023)

Gambar 5 menunjukkan evolusi kluster 17 di Riau. Titik-titik panas muncul secara konsisten dalam beberapa interval waktu dengan pola penyebaran yang tersebar. Berdasarkan karakteristik ini, kluster 17 dikategorikan sebagai kluster bertipe *stasioner*, yakni terbatas secara spasial tetapi muncul terus-menerus sepanjang periode pengamatan (Andrienko *et al.* 2010). Secara umum, sebagian besar kluster lain di Provinsi Riau juga menunjukkan pola kemunculan berulang yang serupa, meskipun beberapa kluster lainnya bersifat *reappearing*, yaitu kluster yang muncul berulang di lokasi serupa, tetapi tanpa keteraturan waktu yang spesifik (Andrienko *et al.* 2010).

Hasil klusterisasi titik panas menggunakan ST-DBSCAN di Provinsi Jambi dapat dilihat pada Gambar 6, visualisasi menunjukkan pola spasial-temporal yang terstruktur dan konsisten. Pada bulan Agustus, algoritma berhasil mengidentifikasi 9 kluster, kemudian meningkat menjadi 13 kluster pada September, dan mencapai puncaknya dengan 26 kluster pada Oktober. Distribusi spasial menunjukkan bahwa kluster-kluster dominan muncul di tengah ke selatan Provinsi Jambi, berbatasan dengan Provinsi Sumatera Selatan.


Sebaran spasial pada kluster di Provinsi Jambi memperlihatkan pemisahan yang cukup baik antar kluster, tanpa tumpang tindih yang berarti. Banyak kluster memiliki bentuk kompak menunjukkan bahwa ST-DBSCAN mampu menangkap segmentasi spasial yang sesuai dengan kondisi geografis wilayah tersebut. Secara khusus, pada bulan Oktober terlihat lonjakan

klasterisasi dengan klaster-klaster berukuran kecil hingga menengah yang muncul secara serentak tetapi tersebar merata, mengindikasikan adanya gelombang kebakaran luas tetapi terlokalisasi secara spasial.



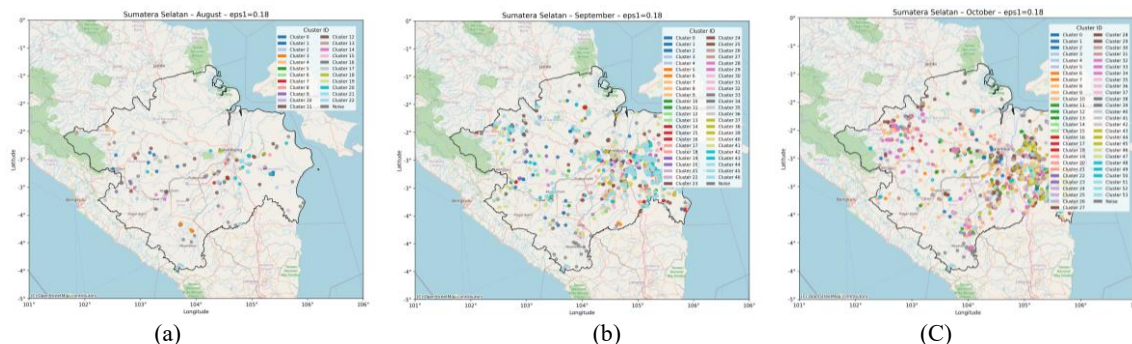
Gambar 6 Visualisasi 2D hasil *klasterisasi* menggunakan parameter $\epsilon_1=0.18^\circ$, $\epsilon_2=5$, $min_sampel=3$ di Provinsi Jambi.
(a)Agustus 2023; (b) September 2023; (c) Oktober 2023

Gambar 7 memvisualisasikan evolusi spasial-temporal klaster 20 di Provinsi Jambi, menunjukkan pola kemunculan yang persisten secara temporal dan berulang di area geografis yang relatif sama, sehingga dapat dikategorikan sebagai klaster bertopologi *stasioner*. Titik panas muncul secara konsisten selama empat interval waktu dan tersebar di wilayah barat daya dan tenggara provinsi. Dari total delapan klaster besar (≥ 20 titik panas) yang dianalisis tren temporalnya di Provinsi Jambi, sebanyak empat klaster menunjukkan pola *stasioner*, sementara empat lainnya memiliki karakteristik *reappearing*, yaitu muncul kembali pada lokasi serupa setelah jeda waktu tertentu.




Gambar 7 Visualisasi evolusi klaster 20 (Jambi, 29 Sep–17 Okt 2023)

Dapat dilihat pada Gambar 8 Sumatera Selatan menunjukkan hasil klasterisasi paling mencolok dari ketiga provinsi, baik dari segi jumlah klaster maupun kedalaman spasial-temporalnya. Hasil ST-DBSCAN mengidentifikasi 50 klaster pada bulan Agustus, meningkat menjadi 62 klaster pada September, dan mencapai angka tertinggi sebesar 68 klaster pada Oktober. Peta persebaran spasial memperlihatkan klaster-klaster tersebar sangat luas, terutama di bagian pantai timur dan tenggara provinsi. Banyaknya klaster yang terbentuk memperlihatkan kemampuan algoritma dalam menangkap unit-unit kebakaran kecil yang tersebar secara luas. Ukuran klaster umumnya berada pada kategori sedang, terdiri dari 20 hingga 60 titik per klaster. Sebaran yang luas dan jumlah klaster yang tinggi mencerminkan karakteristik kebakaran di Sumatera Selatan yang masif tetapi singkat, dengan banyak kejadian terjadi secara berdekatan tetapi tidak saling terhubung secara temporal.



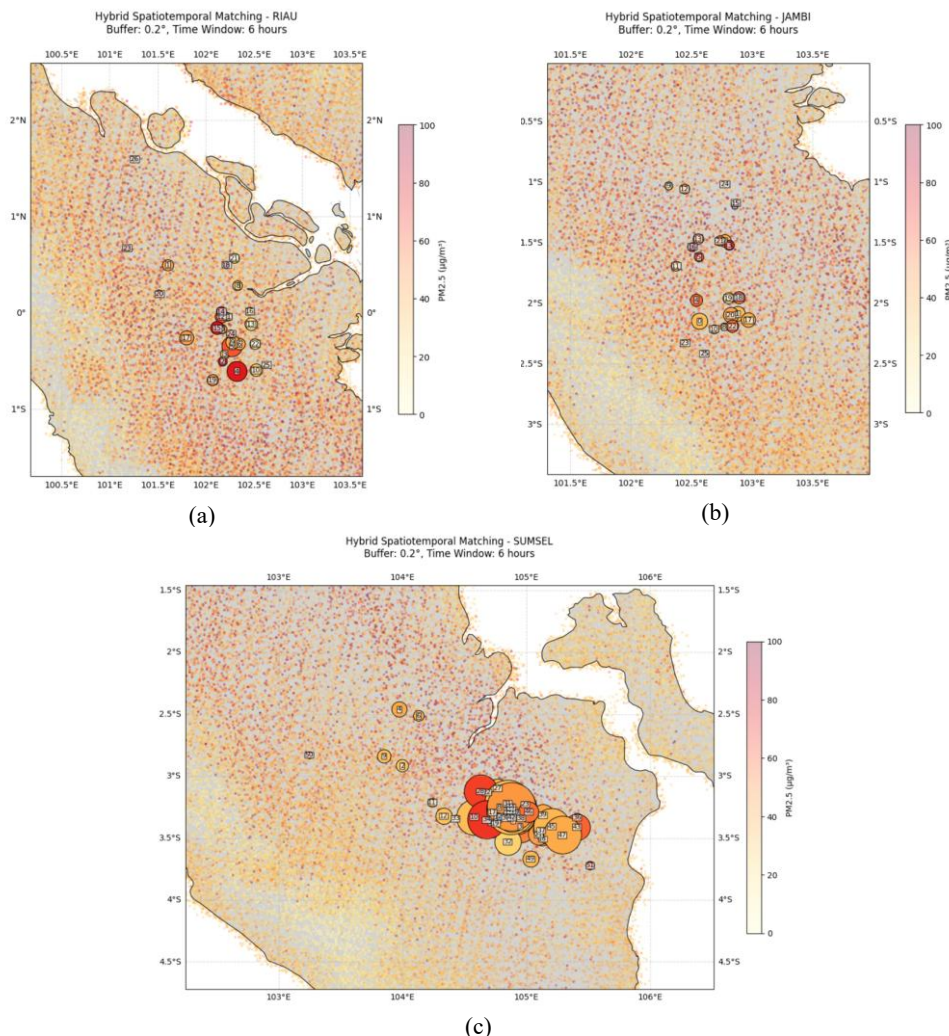
Gambar 8 Visualisasi hasil *klasterisasi* menggunakan parameter $\epsilon_1=0.18^\circ$, $\epsilon_2=5$, $min_sampel=3$ di Provinsi Sumatera Selatan.
(a)Agustus 2023; (b) September 2023; (c) Oktober 2023



Gambar 9 Visualisasi evolusi klaster 20 (Sumatera Selatan, 29 Sep–17 Okt 2023)

Pada Provinsi Sumatera Selatan, topologi klaster hasil analisis ST-DBSCAN menunjukkan variasi pola spasial temporal, beberapa klaster seperti klaster 20 (Gambar 9), menunjukkan pola *stasioner*, sementara klaster lainnya memiliki karakteristik *reappearing*. Selain itu, ditemukan pula klaster dengan topologi *tracks*, yaitu pergeseran lokasi titik panas secara bertahap mengikuti arah tertentu dari satu interval waktu ke interval berikutnya (Andrienko *et al.* 2010).

Untuk melengkapi analisis spasial-temporal titik panas dan klasterisasi kebakaran hutan dan lahan, dilakukan konversi estimasi konsentrasi PM_{2.5} berdasarkan data MODIS AOD. Gambar 10 menampilkan hasil pencocokan spasial-temporal antara klaster titik panas dan estimasi PM_{2.5} di Provinsi Riau, Jambi, dan Sumatera Selatan selama Agustus–Oktober 2023. Lingkaran menunjukkan lokasi *centroid* dari klaster titik api, warna lingkaran merepresentasikan rata-rata nilai PM_{2.5} hasil konversi AOD (semakin gelap menunjukkan konsentrasi yang lebih tinggi), sedangkan diameter lingkaran menggambarkan jumlah titik api dalam klaster.

Gambar 10 Visualisasi rata-rata perhitungan PM_{2.5} selama Agustus hingga Oktober per klaster. (a) Provinsi Riau; (b) Provinsi Jambi; (c) Provinsi Sumatera Selatan.

Secara umum, hasil menunjukkan adanya hubungan spasial-temporal yang konsisten antara distribusi titik panas dan peningkatan konsentrasi PM_{2.5} di seluruh provinsi. Di Provinsi Riau, konsentrasi PM_{2.5} meningkat signifikan dari Agustus (rata-rata 36.3 $\mu\text{g}/\text{m}^3$) ke Oktober (62.2 $\mu\text{g}/\text{m}^3$), dengan nilai maksimum mencapai 96.7 $\mu\text{g}/\text{m}^3$. Klaster dengan PM_{2.5} tertinggi terkonsentrasi di wilayah timur dan tenggara, berdekatan dengan area lahan gambut dan perkebunan, yang merupakan lokasi utama kejadian kebakaran berulang.

Di Provinsi Jambi, peningkatan serupa terjadi dari 42.1 $\mu\text{g}/\text{m}^3$ pada September menjadi 54.8 $\mu\text{g}/\text{m}^3$ pada Oktober, meskipun jumlah klaster sedikit menurun. Klaster dengan nilai PM_{2.5} tertinggi berada di bagian tengah provinsi yang juga menjadi area dengan konsentrasi titik panas tinggi, menunjukkan kesesuaian spasial antara kejadian kebakaran dan peningkatan polusi udara.

Sementara itu, Sumatera Selatan mencatat jumlah titik panas dan klaster terbanyak, dengan rata-rata PM_{2.5} meningkat dari 26.4 $\mu\text{g}/\text{m}^3$ di Agustus menjadi 46.0 $\mu\text{g}/\text{m}^3$ pada Oktober. Klaster terbesar dengan nilai PM_{2.5} tinggi umumnya berada di bagian timur dan tenggara provinsi, yang didominasi oleh kawasan rawa dan gambut. Hal ini menegaskan bahwa area dengan kepadatan klaster tinggi cenderung berasosiasi dengan peningkatan signifikan konsentrasi PM_{2.5} di atmosfer.

Secara keseluruhan, hasil ini menunjukkan bahwa pola peningkatan PM_{2.5} di wilayah studi tidak hanya dipengaruhi oleh jumlah klaster yang terbentuk, tetapi juga oleh distribusi spasialnya yang berdekatan dengan area lahan gambut dan perkebunan. Integrasi antara klaster titik panas dan estimasi PM_{2.5} berbasis AOD terbukti efektif untuk menggambarkan dinamika spasial dan temporal polusi udara akibat karhutla di Sumatera.

Tabel 5 merangkum lima klaster dengan estimasi konsentrasi PM_{2.5} tertinggi dari masing-masing provinsi. Pemilihan klaster ini didasarkan pada rerata konsentrasi PM_{2.5} hasil konversi dari nilai AOD yang berada dalam area spasial zona penyangga tiap klaster. Klaster-klaster di Provinsi Riau mendominasi posisi teratas dengan nilai rata-rata PM_{2.5} di atas 74 $\mu\text{g}/\text{m}^3$ dan cakupan area yang luas. Salah satu klaster bahkan memiliki durasi hingga 63 hari. Hal ini menunjukkan adanya kejadian kebakaran yang persisten dan berulang secara spasial.

Tabel 5 Lima Klaster dengan Estimasi Konsentrasi PM_{2.5} Tertinggi di Setiap Provinsi

<i>Cluster id</i>	Provinsi	Jumlah titik panas	Jumlah AOD	Mean PM _{2.5}	Area (km ²)	Interval titik panas dalam klaster (hari)	<i>Tanggal mulai</i>
18	Riau	6	49	96.71	24480	21	2023-09-27
14	Riau	14	108	83.91	27811	51	2023-08-27
15	Riau	23	115	76.98	39091	51	2023-08-27
4	Riau	54	179	75.21	35351	63	2023-08-06
2	Riau	11	16	74.03	13909	63	2023-08-04
16	Jambi	11	157	92.34	30995	20	2023-09-26
6	Jambi	7	1	88.76	9459	36	2023-09-04
3	Jambi	14	33	71.52	22197	58	2023-08-11
5	Jambi	12	56	62.31	22873	48	2023-08-22
18	Jambi	20	123	57.87	19213	20	2023-09-27
1	Sumatera Selatan	77	241	72.26	47978	60	2023-08-04
5	Sumatera Selatan	84	197	71.80	70525	55	2023-08-11
34	Sumatera Selatan	221	137	68.39	55973	26	2023-09-23
51	Sumatera Selatan	11	7	67.05	5388	1	2023-10-31
28	Sumatera Selatan	168	213	65.96	61797	28	2023-09-18

Di Provinsi Riau, klaster dengan konsentrasi PM_{2.5} tertinggi mencapai nilai rata-rata 96.71 $\mu\text{g}/\text{m}^3$, yang terjadi pada akhir September. Klaster ini memiliki area sebaran sekitar 31000 km² dan durasi 20 hari. Sedangkan di Sumatera Selatan, lima klaster utama menunjukkan

karakteristik PM2.5 tinggi (lebih dari $65 \mu\text{g}/\text{m}^3$) dengan cakupan area sangat luas, termasuk satu klaster yang menjangkau lebih dari 70000 km^2 .

Analisis korelasi antara interval hari antar kemunculan titik panas dalam satu klaster dan estimasi konsentrasi PM2.5 menunjukkan variasi hubungan antarprovinsi. Di Provinsi Riau, korelasi negatif yang sangat kuat ($r = -0.96$) menunjukkan bahwa semakin besar jarak waktu antar kemunculan titik panas dalam suatu klaster, konsentrasi rata-rata PM2.5 justru cenderung menurun. Hal ini mengindikasikan bahwa akumulasi polutan lebih dipengaruhi oleh kemunculan titik panas yang terjadi dalam waktu berdekatan. Sebaliknya, di Sumatera Selatan ditemukan korelasi positif yang kuat ($r = 0.85$), menandakan bahwa klaster dengan jarak antar kemunculan titik panas yang lebih panjang justru berkaitan dengan peningkatan rata-rata PM2.5, kemungkinan akibat area penyebaran klaster yang lebih luas. Adapun di Provinsi Jambi, korelasi lemah ($r = -0.22$) menunjukkan hubungan yang tidak signifikan antara interval hari dan konsentrasi PM2.5. Secara keseluruhan, hasil ini mengindikasikan bahwa frekuensi kemunculan titik panas dalam suatu periode lebih berpengaruh terhadap konsentrasi PM2.5 dibandingkan jarak temporal antar kejadian, dan bahwa karakteristik spasial-temporal kebakaran di tiap provinsi memiliki dinamika yang berbeda.

SIMPULAN

Penelitian ini berhasil menerapkan pendekatan spasial-temporal untuk menganalisis sebaran titik panas dan estimasi konsentrasi PM2.5 di Provinsi Riau, Jambi, dan Sumatera Selatan selama periode Agustus hingga Oktober 2023. Algoritma ST-DBSCAN terbukti efektif dalam mengidentifikasi klaster kebakaran dengan tingkat *noise* yang rendah serta mampu menangkap dinamika spasial-temporal kebakaran di wilayah studi. Provinsi Sumatera Selatan menunjukkan jumlah klaster tertinggi dan distribusi spasial yang paling luas, sedangkan Provinsi Riau mencatat konsentrasi PM2.5 tertinggi mencapai $96.7 \mu\text{g}/\text{m}^3$.

Hasil estimasi PM2.5 dari data MODIS AOD menunjukkan bahwa sebagian besar wilayah terdampak memiliki konsentrasi partikulat halus yang melebihi ambang batas harian WHO (2021) sebesar $15 \mu\text{g}/\text{m}^3$, menandakan tingkat risiko kesehatan yang signifikan selama periode puncak kebakaran. Integrasi antara klaster titik panas dan estimasi PM2.5 menghasilkan gambaran komprehensif mengenai lokasi, waktu, dan intensitas kejadian kebakaran, sehingga dapat digunakan untuk mengidentifikasi wilayah prioritas pemantauan serta mendukung sistem peringatan dini berbasis data satelit. Selain itu, hasil estimasi PM2.5 juga berpotensi menjadi indikator risiko kesehatan masyarakat dan dasar dalam perumusan kebijakan mitigasi polusi udara akibat karhutla.

Namun, penelitian ini memiliki beberapa keterbatasan yang perlu diakui. Model estimasi PM2.5 berbasis AOD yang digunakan memiliki koefisien determinasi ($R^2 \approx 0.56$), sehingga masih terdapat ketidakpastian dalam akurasi estimasi, terutama tanpa validasi langsung menggunakan data pengukuran lapangan. Selain itu, variabilitas meteorologis dan faktor emisi lokal tidak sepenuhnya terwakili dalam analisis ini. Oleh karena itu, hasil estimasi PM2.5 dalam penelitian ini perlu ditafsirkan dengan hati-hati, dan tidak dapat menggantikan pengukuran langsung. Validasi berbasis data in-situ dari BMKG atau sensor kualitas udara lokal disarankan sebagai pekerjaan lanjutan, sekaligus mengintegrasikan faktor meteorologi untuk meningkatkan akurasi dan reliabilitas model.

DAFTAR PUSTAKA

- Andrienko G, Andrienko N, Hurter C, Rinzivillo S, Wrobel S. 2010. From movement tracks through events to places: Extracting and characterizing significant places from mobility data. *Proceedings of the IEEE Symposium on Visual Analytics Science and Technology (VAST)*. p.161–170.
- Barber CB, Dobkin DP, Huhdanpaa H. 1996. The Quickhull algorithm for convex hulls. *ACM Transactions on Mathematical Software*. 22(4):469–483.

- Birant D, Kut A. 2007. ST-DBSCAN: An algorithm for clustering spatial–temporal data. *Data & Knowledge Engineering*. 60(1):208–221.
- Cahyani C, Kusnandar D, Debataraja N & Martha S. 2024. Cluster mapping of hotspots using kernel density estimation in West Kalimantan. *BAREKENG: Jurnal Ilmu Matematika dan Terapan* 18(4): 2353–2362.
- Chen M, Chen Q, Liao G, Sun C, Liu C, Meng X, Li W, Qiu A, Bukulmez O, Kan H, Wang F, Tse L, Teng X. 2025. Associations of maternal PM_{2.5} exposure with preterm birth and miscarriage in women undergoing in vitro fertilization: a retrospective cohort study. *Front Endocrinol*. 16:1312.
- Ester M, Kriegel HP, Sander J, Xu X. 1996. A density-based algorithm for discovering clusters in large spatial databases. *Proceedings of the Second International Conference on Knowledge Discovery and Data Mining (KDD)*. p. 226–231.
- Faraouk K, Witriyono H, Deslianti D, Veronika N. 2023. ST-DBSCAN algorithm implementation at Riau Province forest fire points (2015–2022). *J Komput Inform Teknol (JKOMITEK)*. 3(1).
- Field RD, van der Werf GR, Shen SS. 2009. Human amplification of drought-induced biomass burning in Indonesia since 1960. *Nature Geoscience*. 2:185–188.
- Gupta P, Christopher SA, Wang J, Gehrig R, Lee YC, Kumar N. 2006. Satellite remote sensing of particulate matter and air quality assessment over global cities. *Atmos Environ*. 40(30):5880–5892.
- Handschuh J, Erbertseder T, Schaap M, Baier F. 2022. Estimating PM_{2.5} surface concentrations from AOD: A combination of SLSTR and MODIS. *Remote Sens Appl Soc Environ*. 27:100804.
- Hawam M, Aulady MA. 2024. Potential forest fire during the long dry season Province Riau & Jambi. *Calamity: A J Disaster Technol Eng*. 2(1).
- [Kepmen LHK] Keputusan Menteri Lingkungan Hidup dan Kehutanan Republik Indonesia dengan Nomor SK.130/MENLHK/SETJEN/PKL.0/2/2017 tentang Penetapan Peta Fungsi Ekosistem Gambut Nasional. 2017. [internet]. [diacu 2025 Juli 3]. Tersedia dari: <http://pkgppkl.menlhk.go.id/v0/fungsi-ekosistem-gambut-nasional-skala-1250-000/>.
- Kirana A, Astiningrum M, Vista C, Bhawiyuga A & Amrozi A. 2023. Spatio-temporal pattern analysis of forest fire in Malang based on remote sensing using K-Means clustering. *International Journal of Multidisciplinary: Applied Business and Education Research* 4(8): 3173–3180.
- Kisilevich S, Mansmann F, Keim D. 2010. P-DBSCAN: A density based clustering algorithm for exploration and analysis of attractive areas using collections of geo-tagged photos. *Proceedings of the 1st International Conference and Exhibition on Computing for Geospatial Research and Application*. p. 1–4.
- Levy RC, Mattoo S, Munchak LA, Remer LA, Sayer AM, Patadia F. 2013. The Collection 6 MODIS aerosol products over land and ocean. *Atmos Meas Tech*. 6(1):159–259.
- Li R, T Xu, Q Xu, X Song. 2018. Using MAIAC AOD to verify the PM_{2.5} spatial patterns of a land use regression model. *Environ Pollut*. 243(Pt A):501–509.
- Lv B, Hu Y, Chang H, Russell A, Bai Y. 2016. Improving the accuracy of daily PM_{2.5} distributions derived from the fusion of ground-level measurements with aerosol optical depth observations: A case study in North China. *Environ Sci Technol*. 50(9):4752–4759.
- Miettinen J, Shi C, Liew SC. 2017. Fire distribution in Peninsular Malaysia, Sumatra and Borneo in 2015 with special emphasis on peatland fires. *Environ Manage*. 60(4):747–757.
- NASA Applied Remote Sensing Training Program (ARSET). 2018. Converting AOD to PM_{2.5}: A Statistical Approach. NASA [internet]. [diunduh 2025 Mei 25] https://appliedsciences.nasa.gov/sites/default/files/D2P3_AODPMEx.pdf

- NASA Atmosphere Discipline Team Imager Products. 2025. MODIS Atmosphere L2 Aerosol Product (MOD04_L2). [internet]. [diacu 2025 Agustus 4]. NASA LP DAAC. Tersedia di: <https://modis-atmos.gsfc.nasa.gov/products/aerosol>.
- NASA Earthdata. 2023. Active Fire Data Attributes for MODIS and VIIRS. [internet]. [diacu 2025 Juli 8]. <https://www.earthdata.nasa.gov/data/tools/firms/active-fire-data-attributes-modis-viirs>
- Nurhayati A, Saharjo BH, Sundawati L, Syartinilia S, Cochrane MA. 2021. Forest and peatland fire dynamics in South Sumatra Province. *Forest Soc.* 5(2):359–375.
- Pandapotan A, Khairina R, Hidayat MF. 2021. Smoke distribution patterns analysis on meteorological conditions on Kalimantan Island related to forest and land fires: A case study forest fires in September 2019. *Journal of Physics: Conference Series.* 2111(1):012020.
- Rahman M dan Thurston G. 2022. A hybrid satellite and land use regression model of source-specific PM_{2.5} and PM_{2.5} constituents. *Environ Int.* 163:107233.
- Rahmat H, Sitanggang IS. 2020. Clustering pollutants concentration from Sumatra peat fire using fuzzy C-means algorithm. *IOP Conf Ser Earth Environ Sci.* 528:012054.
- Rendana M, Idris W dan Rahim A. 2022. Clustering analysis of PM_{2.5} concentrations in the South Sumatra Province, Indonesia, using the Merra-2 Satellite Application and Hierarchical Cluster Method. *AIMS Environmental Science.* 9(6):754-770.
- Rousseeuw PJ. 1987. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis. *J Comput Appl Math.* 20:53–65.
- Sinnott RW. 1984. Virtues of the Haversine. *Sky and Telescope.* 68(2):159.
- Sitanggang I, Risal A, Syaufina L. 2018. Incremental clustering on hotspot data as forest and land fires indicator in Sumatra. *IOP Conference Series: Earth and Environmental Science.* 187:012043.
- Sofyan A, Hidayat R, Ruminta L, Widyastuti W. 2022. The estimation of PM_{2.5} concentration from MODIS AOD data in Indonesia using multiple linear regression. *Int J Remote Sens Earth Sci (IJReSES).* 19(1):13–22.
- Storey MA, Price OF. 2022. Statistical modelling of air quality impacts from individual forest fires in New South Wales, Australia. *Natural Hazards and Earth System Sciences.* 22:4039–4062.
- Sujiono DNR. 2023. Verifikasi titik panas kebakaran hutan dan lahan berdasarkan pola sekuens dan spatiotemporal cluster titik panas [thesis]. Bogor (ID): Institut Pertanian Bogor.
- Syurifah G, Fahmi H. 2024. Implementasi metode ST-DBSCAN untuk pengelompokan pola persebaran titik api pada data kebakaran hutan di Indonesia. *J Riset Mhs Matematika.* 3(5).
- Sze J, Lee J. 2019. Evaluating the social and environmental factors behind the 2015 extreme fire event in Sumatra, Indonesia. *Environ Res Lett.* 14(4):045003.
- Trisminingsih R, Shaztika SS. 2016. ST-DBSCAN clustering module in SpagoBI for hotspots distribution in Indonesia. In: *Proceedings of the 3rd International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE).* p. 327–330.
- Unik M, Sitanggang I, Syaufina L & Surati N. 2025. Application of Random Forest Algorithm to Analyze the Confidence Level of Forest Fire Hotspots in Riau Peatland. *Jurnal Pengelolaan Sumberdaya Alam dan Lingkungan* 15(2): 255–266.
- Vásquez M, Benoist A, Roda J, Fortin M. 2021. Estimating greenhouse gas emissions from peat combustion in wildfires on Indonesian peatlands, and their uncertainty. *Glob Biogeochem Cycles.* 35:e2019GB006218.
- Vatresia A, Rais R, Miliana R. 2020. Spatio-Temporal Clustering for Fire Hot Spots Occurrence Over Sulawesi Island. In: 2020 FORTEI-International Conference on Electrical Engineering (FORTEI-ICEE), pp.156–161.

- Wei Y, Feng Y, Yazdi M, Yin K, Castro E, Shtein A, Qiu X, Peralta A, Coull B, Dominici F, Schwartz J. 2024. Exposure-response associations between chronic exposure to fine particulate matter and risks of hospital admission for major cardiovascular diseases: population based cohort study. *BMJ*. 384.
- World Health Organization (WHO). 2021. WHO global air quality guidelines: particulate matter (PM_{2.5} and PM₁₀), ozone, nitrogen dioxide, sulfur dioxide and carbon monoxide [Internet]. Geneva (CH): World Health Organization. [diunduh 2024 Jan 12]. <https://www.who.int/publications/i/item/9789240034228>
- Zhang Y, Lim S, Sharples J. 2016. Modelling spatial patterns of wildfire occurrence in South-Eastern Australia. *Geomatics, Natural Hazards and Risk*. 7(6):1800–1815.
- Zhao R, Gu X, Xue B, Zhang J, Ren W. 2018. Short period PM_{2.5} prediction based on multivariate linear regression model. *PLoS ONE*. 13(7):e0201011.