

Identifikasi *Hotspot* Kebakaran Hutan Kalimantan Timur Tahun 2023 Menggunakan Teknik Spasial-Temporal *Clustering* ST-DBSCAN *Identification of Forest Fire Hotspots in East Kalimantan in 2023 Using the Spatio-Temporal Clustering Technique ST-DBSCAN*

Mira Salsabila^{1*}, Asep Id Hadiana², Melina³

^{1,2,3} Jurusan Informatika, Fakultas Sains dan Informatika, Universitas Jenderal Achmad Yani

¹mira.salsabila@student.unjani.ac.id, ²asep.hadiana@lecture.unjani.ac.id, ³melina@lecture.unjani.ac.id

Abstract

Forest fires are a serious issue that impacts both the environment and public health. Forest fires can be detected through the number of hotspots. A higher number of hotspots indicates a greater potential for fire occurrence. Accurate and efficient identification of forest fire hotspots is essential for effective prevention efforts. This study aims to identify forest fire hotspots using the Spatio-Temporal clustering technique known as Spatio-Temporal Density-Based Spatial Clustering of Applications with Noise (ST-DBSCAN), which considers both spatial and temporal aspects in analyzing fire point data. The dataset used consists of 1,761 records with 12 attributes obtained from Moderate-Resolution Imaging Spectroradiometer MODIS satellite imagery. The ST-DBSCAN algorithm was applied to group fire points that are spatially and temporally close. The experiment, conducted with parameters $eps1 = 0.05$, $eps2 = 1.0$, and $MinPts = 4$, resulted in 85 clusters comprising 1,760 data points, with 162 points identified as outliers, and a silhouette score of 0.134.

Keywords: Cluster, Forest Fires, Hotspot, MODIS, ST-DBSCAN

Abstrak

Kebakaran hutan merupakan masalah serius yang berdampak pada lingkungan dan kesehatan masyarakat. Kebakaran hutan dapat dideteksi dari jumlah *hotspot*. Jika jumlah *hotspot* kebakaran hutan besar, maka semakin tinggi dan besar pula potensi kebakaran. Identifikasi *hotspot* kebakaran hutan yang akurat dan efisien sangat penting untuk pencegahan terjadinya kebakaran hutan. Penelitian ini bertujuan untuk mengidentifikasi *hotspot* kebakaran hutan menggunakan teknik spasial *clustering* Spatio Temporal – Density Based Spatial Clustering Application with Noise (ST-DBSCAN) yang mempertimbangkan aspek spasial dan temporal dalam menganalisis data titik api. Dataset yang digunakan sejumlah 1761 *records* dengan 12 atribut dari citra satelit Moderate-Resolution Imaging Spectroradiometer (MODIS) diproses menggunakan algoritma ST-DBSCAN untuk mengelompokkan titik-titik api yang berdekatan secara spasial dan temporal. Dari eksperimen yang dilakukan dengan $eps1 = 0.05$, $eps2 = 1.0$ dan $MinPts = 4$ menghasilkan 85 *cluster* dengan total titik data 1760, dan 162 titik merupakan *outlier* dengan *silhouette score* 0.134.

Kata kunci: Cluster, Hotspot, Kebakaran Hutan, MODIS, ST-DBSCAN

1. Pendahuluan

Indonesia merupakan negara yang mempunyai kekayaan alam yang sangat penting bagi keberlangsungan hidup manusia. Hutan adalah faktor utama dalam upaya menjaga ekosistem dunia, apabila hutan dirusak maka akan terjadi pemanasan global yang melahirkan tidak stabilnya iklim dunia [1]. Kebakaran hutan bisa dipengaruhi faktor alam dan faktor manusia. Dinas Kehutanan harus memiliki kapabilitas untuk menangani pencegahan kebakaran hutan[2]. Kebakaran hutan merupakan salah satu masalah serius yang berdampak luas terhadap ekologi, lingkungan, dan

sosial ekonomi negara-negara di dunia [3]. Untuk memitigasi dampak ini, prediksi akurat dan deteksi dini kebakaran hutan merupakan hal yang sangat penting [4].

Berdasarkan data dari Badan Penanggulangan Bencana Daerah (BPBD) Provinsi Kalimantan Timur, sepanjang tahun 2023 tercatat sejumlah besar kejadian kebakaran hutan dan lahan (Karhutla). Fenomena ini dipicu oleh kondisi iklim yang dipengaruhi oleh *El Nino*, yang menyebabkan musim kering. Meskipun intensitas *El Nino* pada tahun tersebut tergolong ringan hingga sedang, jumlah kasus Karhutla hampir mencapai 500 dalam kurun waktu delapan bulan.

Salah satu antisipasi yang dapat dilakukan dalam pencegahan kebakaran hutan yaitu dengan melakukan pengelompokan terhadap wilayah yang memiliki potensi kebakaran [5]. Meskipun *hotspot* merupakan indikator penting untuk potensi kebakaran hutan, tetapi tidak semua data titik panas menunjukkan kebakaran yang benar-benar terjadi ketika lapangan sehingga masih perlu memvalidasi dan investigasi langsung di lokasi yang membutuhkan waktu dan sumber daya yang signifikan, terutama untuk jumlah titik yang besar. Oleh karena itu, pendekatan berbasis *machine learning* dapat diterapkan analisis *hotspot* kebakaran hutan [6]. Pengelompokan *hotspot* untuk mengetahui daerah yang rawan terjadi kebakaran hutan dan lahan dapat menggunakan salah satu teknik clustering yang biasa digunakan yaitu *Spatial Temporal Density-Based Spatial Clustering Of Applications With Noise* (ST-DBSCAN) [7]. ST-DBSCAN adalah sebuah algoritma perkembangan dari algoritma DBSCAN yang mempunyai keunikan jika dibandingkan dengan algoritma *clustering* sejenisnya yang berbasis kerapatan data. ST-DBSCAN memiliki keunggulan dalam mencari *cluster* yang berhubungan dengan nilai spasial-temporal dari sebuah objek [8]. Keunggulan dari metode ST-DBSCAN adalah fleksibilitasnya dalam menangani data berukuran besar karena merupakan teknik yang berbasis kepadatan [9].


Beberapa penelitian terdahulu yang mengkaji tentang metode ST-DBSCAN dalam mengidentifikasi kebakaran hutan yaitu penelitian [10], yang menerapkan ST-DBSCAN pada dataset *hotspot* di Sumatera pada periode tersebut bulan September hingga Oktober 2017. Sebanyak 2.659 *hotspot* digunakan pada *clustering* awal dan 1.023 *hotspot* digunakan pada *cluster* awal. *Hotspot* baru digunakan untuk memperbarui *cluster* awal. *Clustering* awal di parameter *eps1* sebesar 0,1, *eps* sebesar 7, lalu *minPts* sebesar 5 yang mana menghasilkan 16 *cluster* juga 23 *outlier*. Tambahan pengelompokan pada parameter tersebut menghasilkan 7 *cluster* baru dan 6 *outlier* baru. Penelitian [11], yang mengkaji tentang analisis spasial temporal tentang implementasi algoritma ST-DBSCAN pada titik api kebakaran hutan di Provinsi Riau. Hasil penelitian ini membuktikan algoritma ST-DBSCAN dapat digunakan untuk *clustering* titik api di Provinsi Riau dalam jangka waktu 2015-2022. Berdasarkan hasil uji yang dilakukan menghasilkan 768 *cluster*. Penelitian [8], yang mengelompokkan kebakaran hutan di Indonesia menggunakan ST-DBSCAN. Hasil penelitiannya menghasilkan nilai *clustering* sebanyak 1.540 dalam jangka waktu 2015-2020 tolak ukur pada *Eps1*, *Eps2*, dan *MinPts* dengan tolak ukur terbaik yakni *eps1* = 0,55; *eps2* = 0,95; dan *minPts* = 2.

Berdasarkan latar belakang, telah ada penelitian yang mencakup aspek spasial atau temporal secara terpisah. Akan tetapi, belum banyak penelitian yang mengintegrasikan kedua aspek dalam kasus kebakaran

hutan. Oleh karena itu, penelitian ini bertujuan menganalisis *hotspot* kebakaran hutan dan lahan dengan menggunakan teknik spasial *clustering* ST-DBSCAN yang divisualisasikan dengan sebuah *website*.

2. Metode Penelitian

Penelitian ini menggunakan metode eksperimen dan pendekatan kuantitatif ini memiliki beberapa tahapan yang diuraikan pada Gambar 1.



Gambar 1. Metode Penelitian


Pada tahap pertama dilakukan studi pustaka ini mencakup riset pada berbagai contoh kasus dan pengumpulan studi pustaka yang relevan dengan teknik *clustering*, spesifiknya pada ST-DBSCAN, data *hotspot* dan parameter-parameter penting pada ST-DBSCAN seperti *eps 1*, *eps 2*, dan *MinPts*. Lalu, dilanjut dengan data *collection*, data yang digunakan pada penelitian untuk mengidentifikasi *hotspot* kebakaran hutan diperoleh dari situs <https://firms.modaps.eosdis.nasa.gov>. Data dari situs tersebut memiliki informasi mengenai kebakaran hutan yang terjadi di Indonesia pada tahun 2023 seperti *longitude*, *latitude*, tanggal, waktu kejadian, dan intensitas kepanasan yang terjadi. Setelah data *collection* dilanjut dengan data *preprocessing*.

Tahapan *preprocessing* merupakan tahap krusial untuk memastikan bahwa data berada dalam kondisi yang layak dan sesuai guna menghasilkan analisis yang valid [12]. Pada tahap ini, dilakukan serangkaian proses seperti pembersihan data *cleaning*, data *selection*, dan data *transformation*. Tahapan ini penting untuk memastikan bahwa data yang digunakan berada dalam format yang konsisten dan sesuai dengan kebutuhan algoritma yang digunakan.

Data cleaning merupakan proses untuk menghapus atau memperbaiki data yang tidak lengkap, tidak relevan, duplikat, atau mengandung kesalahan. Tujuan dari tahapan ini adalah untuk meningkatkan kualitas data sehingga dapat digunakan secara optimal dalam proses analisis atau pemodelan [13]. Pada tahapan data *selection* dilakukan pemilihan data yang awalnya jumlah data yang tertera pada situs tersebut terdapat 52157 records, lalu dipilah berdasarkan *field longitude* dan *latitude* yang menunjukkan titik-titik pada Provinsi

Kalimantan Timur sehingga data yang dihasilkan sebanyak 1734.

Pada tahap *data transformation*, dilakukan penyesuaian data dengan mengubah tipe data ke tipe data yang lain. Data yang diubah meliputi menyatukan *field* *acq_date* dan *acq_time* menjadi *field* baru yaitu *datetime*, dan mengubah tipe data yang awalnya *acq_date* dan *acq_time* bertipe data *string*, diubah menjadi tipe data *datetime*. Setelah melewati tahap data *preprocessing*, kemudian masuk ke tahap penentuan parameter. Parameter yang diperlukan dalam penerapan metode *clustering* DBSCAN maupun ST-DBSCAN sangat berperan penting, karena pemilihan parameter tersebut akan memengaruhi kualitas dan hasil akhir dari proses pengelompokan data [14]. ST-DBSCAN menggabungkan aspek spasial (ruang) dan temporal (waktu), yang memungkinkan untuk mendeteksi *cluster* yang memiliki kedekatan dalam kedua dimensi tersebut, yaitu lokasi geografis dan waktu kejadian [11]. Adapun perhitungan menggunakan algoritma ST-DBSCAN menggunakan *python*. Tahapan ST-DBSCAN dapat dilihat pada Gambar 2.



Gambar 2. Alur ST-DBSCAN

Tahap selanjutnya adalah evaluasi, salah satu metode evaluasi untuk mengetahui kualitas dari suatu *cluster* adalah *silhouette coefficient* yang merupakan gabungan dari *cohesion* dan *separation*. *Cohesion* adalah untuk mengukur seberapa dekat antara objek dan *cluster*. Sementara, *separation* untuk mengukur seberapa jauh sebuah *cluster* dengan *cluster* yang lainnya. Untuk setiap objek data x_i , dihitung rata-rata jaraknya dengan semua objek lain dalam *cluster* yang sama (disebut $a(x_i)$). Kemudian, dihitung pula jarak rata-rata dari objek tersebut ke semua objek dalam *cluster* lain yang terdekat (disebut $b(x_i)$). *Silhouette Coefficient* dari objek x_i didefinisikan pada Persamaan (1) [15].

$$s(x_i) = \frac{b(x_i) - a(x_i)}{\max\{a(x_i) - b(x_i)\}} \quad (1)$$

dengan

$s(x_i)$: nilai *Silhouette Coefficient* dari 0,

$a(x_i)$: rata-rata objek i ke semua objek yang lain dalam *cluster* A,

$b(x_i)$: rata-rata jarak minimum dari objek i ke semua *cluster* lain (yang bukan *cluster* dari objek i).

Nilai *Silhouette Coefficient* berkisar antara -1 sampai 1. Nilai positif tinggi menunjukkan objek sudah terkelompok dengan baik, nilai negatif menunjukkan objek salah terkelompok, sedangkan nilai sekitar nol berarti objek tersebut berada di antara dua *cluster* atau tidak jelas kelompoknya [16].

3. Hasil dan Pembahasan

3.1 Hasil Data *Preprocessing*

Data yang tersedia pada situs <https://firms.modaps.eosdis.nasa.gov> berjumlah 52157 data kebakaran hutan Indonesia pada tahun 2023, lalu data melalui tahap data *cleaning* dan data *selection* menghasilkan data sejumlah 1760 berdasarkan titik *longitude*, dan *latitude* yang menunjukkan daerah Provinsi Kalimantan Timur. Kemudian, pada data *transformation* dilakukan penyesuaian data dengan mengubah tipe data ke tipe data yang lain. Data yang diubah meliputi menyatukan *field* *acq_date* dan *acq_time* menjadi *field* baru yaitu *datetime*, dan mengubah tipe data yang awalnya *acq_date* dan *acq_time* bertipe data *string*, diubah menjadi tipe data *datetime*. Dataset sebelum dilakukan *preprocessing* dapat dilihat pada Tabel 1.

Tabel 1. Dataset sebelum *Preprocessing*

No	Latitude	Longitude	Acq_date	Acq_time
1	-9296	1017016	01/01/2023	640
2	-13048	1018272	01/01/2023	640
3	-25064	1203362	02/01/2023	543
.	.	.	.	.
52157	-25734	1213901	31/12/2023	1814

Dataset yang telah melalui tahap *preprocessing*, dapat dilihat pada Tabel 2.

Tabel 2. Dataset setelah *Preprocessing*


No	Latitude	Longitude	Datetime
1	22.738	1.179.747	02/01/2023 05:44
2	-0.2156	1.155.835	11/01/2023 15:00
3	0.8571	1.169.681	16/01/2023 05:50
.	.	.	.
1760	11.518	1.176.893	30/12/2023 02:30

Pada Tabel 2, kolom *datetime* merupakan hasil dari disatukannya antara kolom *acq_date* dan *acq_time*,

yang awalnya `acq_date` dan `acq_time` bertipe data *string* pada kolom *datetime* diubah tipe datanya menjadi *datetime*.


3.2 Menentukan Parameter

Menghitung K-Dist ini berfungsi untuk menentukan nilai `MinPts` dan `eps`. K-Dist juga dapat memvisualisasikan k-dist plot untuk mencari *elbow point* atau titik optimal untuk parameter `eps`.



Gambar 3. K-Dist Spasial

Pada penelitian ini nilai $k = 4$, dapat dilihat pada Gambar 3. Dari Gambar 3. dapat ditinjau bahwa terjadi *elbow point* sekitar jarak 0.05 – 0.1, artinya ini berkisar sekitar 5–10 km, tergantung lokasi (karena 1 derajat $\approx$ 111 km di khatulistiwa), sehingga 0.05 – 0.1 merupakan *range* nilai optimal untuk `eps1`. Pada Gambar 4 juga dapat ditinjau bahwa terjadi *elbow point* terlihat secara visual berada di sekitar 86.400 detik (1 hari) sehingga menjadikan 1.0 merupakan nilai yang optimal untuk `eps2`.



Gambar 4 K-Dist Temporal

3.3 Menghitung Jarak Spasial-Temporal

Setelah menentukan parameter untuk ST-DBSCAN, langkah selanjutnya adalah menghitung jarak spasial temporal. Dalam pembentukan *cluster* diperlukan pengukuran terhadap setiap objek. Jarak setiap objek dapat dihitung menggunakan *Euclidean Distance* pada koordinat spasial (*longitude* dan *latitude*) dan unsur temporal (*datetime*) pada dataset yang digunakan. Jarak *Euclidean Distance* sedangkan untuk menghitung jarak temporal menggunakan rumus *Manhattan*. Pada Tabel 3, ditampilkan 5 data teratas dataset kebakaran hutan di Provinsi Kalimantan Timur.

Pada Tabel 3 ditampilkan 5 data teratas dataset kebakaran hutan di Provinsi Kalimantan Timur. Nilai yang tertera pada kolom *latitude* dan *longitude* akan

dihitung menggunakan rumus *Euclidean Distance* seperti pada Persamaan (2).

Tabel 3. Dataset Kebakaran Hutan Kalimantan Timur

No	Latitude	Longitude	Datetime
1	22.738	117.9747	02/01/2023 05:44
2	-0.2156	115.5835	11/01/2023 15:00
3	0.8571	116.9681	16/01/2023 05:50
4	0.8557	116.9588	16/01/2023 05:50
5	0.4239	117.2334	16/01/2023 05:51

$$d_s(1,2) = \sqrt{(x_{long_2} - x_{long_1})^2 + (x_{lat_2} - x_{lat_1})^2} \quad (2)$$

dengan,

$d_s(1,2)$: Jarak data spasial ke-1 dan data spasial ke-2

$long_1$: Longitude data ke-1

$long_2$: Longitude data ke-2

lat_1 : Latitude data ke-1

lat_2 : Latitude data ke-1

Selanjutnya, pada kolom *datetime* dihitung menggunakan rumus *Manhattan* seperti pada Persamaan 3.

$$d_t(1,2) = |x_{waktu_1} - x_{waktu_2}| \quad (3)$$

dengan

$d_t(1,2)$: Jarak data temporal ke-1, data temporal ke-2

x_{waktu_1} : x waktu pada data ke-1

x_{waktu_2} : x waktu pada data ke-2

Setelah perhitungan jarak spasial-temporal dilakukan, berikut hasil yang dapat dilihat pada Tabel 4.

Tabel 4. Jarak Spasial-Temporal

(i,j)	d(i,j)spasial	d(i,j)temporal
(1,1)	0	0
(1,2)	34518	9
(1,3)	17379	14
(1,4)	174444	14
(1,5)	19929	14

3.4 Hasil Cluster

Dari $k = 4$ dan nilai `eps 1`, `eps 2`, dan `MinPts` menghasilkan *cluster* sebanyak 85 *cluster* dengan total titik data 1760, dan 1179 merupakan *outlier*. Hasil *cluster* relatif banyak namun itu merupakan gabungan *cluster* dari setiap bulan pada tahun 2023. Hasil *cluster* perbulan dapat dilihat pada Tabel 5.

Pada awal tahun (Januari-Maret) tidak ada *cluster* yang terbentuk pada bulan Januari dan Februari, pada bulan maret mulai terjadi 1 *cluster* dengan distribusi 23 data dan memiliki *outlier* sebanyak 19. Pertengahan tahun (April-Agustus) terjadi peningkatan jumlah *cluster* secara bertahap. Bulan April 0 *cluster* dengan 39 *outlier*, bulan Mei memiliki 1 *cluster* dengan distribusi data sebanyak 45 dan memiliki 41 *outlier*, bulan Juni memiliki 0 *cluster* dengan 39 *outlier*, bulan Juli memiliki 2 *cluster* dengan distribusi data sebanyak 106 dan 88 *outlier*, dan bulan Agustus memiliki 20 *cluster* dengan distribusi data 355 dan 237 *outlier*. Pada akhir

tahun (September-Desember) merupakan bulan dengan jumlah *cluster* tertinggi, pada bulan Oktober memiliki 20 *cluster* dengan distribusi data sebanyak 394 dan 295 *outlier*, bulan November memiliki 2 *cluster* dengan distribusi data sebanyak 74 dan 61 *outlier*, dan pada bulan Desember memiliki 1 *cluster* dengan distribusi data sebanyak 64 dan 60 *outlier*.

Tabel 5. Jumlah Cluster Perbulan 2023

	Jumlah <i>cluster</i>	Titik Data	<i>Outlier</i>
Januari	0	0	5
Februari	0	0	5
Maret	1	23	19
April	0	0	39
Mei	1	45	41
Juni	0	0	39
Juli	2	106	88
Agustus	20	355	237
September	38	615	290
Oktober	20	394	295
November	2	74	61
Desember	1	64	60

3.5 Evaluasi *Cluster*

Cluster yang telah dihasilkan lalu dievaluasi dengan *silhouette coefficient* untuk mengoptimasi hasil *cluster* dengan ST-DBSCAN. Secara keseluruhan *silhouette coefficient score* yang dihasilkan adalah 0.134, untuk *silhouette coefficient score* perbulan dapat dilihat pada Tabel 6.

Tabel 6. Silhouette Coefficient Score perbulan 2023

Bulan	<i>Silhouette Score</i>
Januari	-
Februari	-
Maret	-
April	-
Mei	-
Juni	-
Juli	0.9593
Agustus	0.3787
September	0.1268
Oktober	0.5177
November	0.6608
Desember	-

Dapat dilihat pada Tabel 6, bahwa pada bulan Januari, Februari, Maret, April, Mei, Juni, dan Desember tidak memiliki *silhouette score* karena pada bulan-bulan tersebut tidak memiliki >1 *cluster*, apabila hanya memiliki 1 *cluster* maka *silhouette coefficient* tidak bisa dihitung karena tidak memiliki tetangga. Dengan parameter dan *cluster* yang dihasilkan terlihat bahwa pada bulan Juli memiliki nilai *silhouette coefficient* 0.9593 atau mendekati 1.

4. Kesimpulan

Penelitian ini berhasil mengidentifikasi titik-titik hotspot kebakaran hutan di Provinsi Kalimantan Timur selama tahun 2023 menggunakan algoritma ST-DBSCAN yang mempertimbangkan dimensi spasial dan temporal. Dari 1760 data hasil preprocessing,

diperoleh 85 klaster dengan 1179 data termasuk kategori outlier. Nilai *silhouette coefficient* keseluruhan sebesar 0.134 menunjukkan bahwa kualitas klaster masih perlu ditingkatkan, meskipun beberapa bulan seperti Juli menunjukkan hasil yang sangat baik dengan nilai mendekati 1 (0.9593). Hasil ini menunjukkan bahwa pendekatan ST-DBSCAN mampu memberikan pemetaan awal wilayah rawan kebakaran berdasarkan kedekatan waktu dan lokasi. Metode ini dapat diaplikasikan sebagai alat bantu sistem peringatan dini dalam mitigasi kebakaran hutan. Penelitian selanjutnya disarankan untuk mengeksplorasi parameter lain dan integrasi dengan visualisasi geografis berbasis web guna meningkatkan akurasi dan kegunaan informasi klaster yang dihasilkan.

Daftar Rujukan

- [1] N. Ahada and A. F. Zuhri, "Menjaga Kelestarian Hutan Dan Sikap Cinta Lingkungan Bagi Peserta Didik MI / SD," vol. 03, no. April, pp. 35–46, 2020.
- [2] A. J. Kurniawan, H. Emawati, and Ismail, "(Integrated Patrol For Forest And Land Fire Prevention In Paser District , East Kalimantan Province) Patroli Terpadu Pencegahan Kebakaran Hutan dan Lahan . penting yang dilaksanakan pada tahun 2016 , 2017 dan 2018 dengan melibatkan peran serta," *J. Agroteknologi dan Kehutan. Trop.*, vol. 2, no. 1, pp. 85–100, 2024.
- [3] C. P. Kala, "Environmental and socioeconomic impacts of forest fires: A call for multilateral cooperation and management interventions," *Nat. Hazards Res.*, vol. 3, no. 2, pp. 286–294, 2023, doi: 10.1016/j.nhres.2023.04.003.
- [4] S. Giannakidou *et al.*, "Leveraging the power of internet of things and artificial intelligence in forest fire prevention, detection, and restoration: A comprehensive survey," *Internet of Things (Netherlands)*, vol. 26, no. July 2023, p. 101171, 2024, doi: 10.1016/j.iot.2024.101171.
- [5] R. Kusumastuti, E. Bayunanda, A. M. Rifa'i, M. R. G. Asgar, F. I. Ilmawati, and K. Kusriani, "Clustering Titik Panas Menggunakan Algoritma Agglomerative Hierarchical Clustering (AHC)," *CogITo Smart J.*, vol. 8, no. 2, pp. 501–513, 2022, doi: 10.31154/cogito.v8i2.438.501-513.
- [6] K. Pratama Simanjuntak and U. Khaira, "Hotspot Clustering in Jambi Province Using Agglomerative Hierarchical Clustering Algorithm Pengelompokan Titik Api di Provinsi Jambi dengan Algoritma Agglomerative Hierarchical Clustering," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 1, no. 1, pp. 7–16, 2021.
- [7] N. A. Putri, T. W. Utami, and R. Wasono, "Spatial Temporal Density-Based Spatial Clustering Applications With Noise (ST-DBSCAN) Untuk Pengelompokan Titik Kebakaran Hutan dan Lahan di Provinsi Riau Pada Tahun 2021," pp. 436–445, 2021.
- [8] A. Johar, A. Vatesia, and I. A. Donny, "IMPLEMENTASI METODE SPATIO- TEMPORAL CLUSTERING DENGAN ALGORITMA ST-DBSCAN PADA TITIK (2015-2020)," vol. 11, no. 1, pp. 1–9, 2023.
- [9] P. Tahun, D. A. N. Berdasarkan, B. A. Suryani, M. N. Hayati, and S. Prangga, "Pengelompokan Kabupaten / Kota Di Pulau Kalimantan Pembangunan Manusia Menggunakan Metode Algoritma ST-DBSCAN Data ," vol. 6, pp. 1–9, 2023.
- [10] I. S. Sitanggang, A. A. N. Risal, and L. Syaufina, "Incremental Clustering on Hotspot Data as Forest and Land Fires Indicator in Sumatra," *IOP Conf. Ser. Earth Environ. Sci.*, vol. 187, no. 1, 2018, doi: 10.1088/1755-1315/187/1/012043.
- [11] K. El Faraouk, H. Witriyono, D. Deslianti, N. David, and M. Veronika, "ST-DBSCAN Algorithm Implementation At Riau Province Forest Fire Points (2015-2022) Implementasi

- Algoritma ST-DBSCAN Pada Titik Api Kebakaran Hutan Provinsi Riau (2015-2022),” vol. 3, no. 1, pp. 97–104, 2023.
- [12] R. R. A. Rahman and A. W. Wijayanto, “Pengelompokan Data Gempa Bumi Menggunakan Algoritma Dbscan,” *J. Meteorol. dan Geofis.*, vol. 22, no. 1, p. 31, 2021, doi: 10.31172/jmg.v22i1.738.
- [13] N. Hendrastuty, “Penerapan Data Mining Menggunakan Algoritma K-Means Clustering Dalam Evaluasi Hasil Pembelajaran Siswa,” *J. Ilm. Inform. Dan Ilmu Komput.*, vol. 3, no. 1, pp. 46–56, 2024, [Online]. Available: <https://doi.org/10.58602/jima-ilkom.v3i1.26>
- [14] A. N. Fahira and R. Nooraeni, “Optimasi Parameter ST-DBSCAN dengan KNN dan Algoritma Genetika Studi Kasus: Data Bencana Alam di Pulau Jawa 2021,” *J. Komputasi*, vol. 11, no. 1, pp. 24–33, 2023, doi: 10.23960/komputasi.v11i1.3175.
- [15] A. Putra, D. Abdullah, and M. Daud, “Klasterisasi Kualitas Biji Kopi Berdasarkan Taraf Penyusutan Menggunakan Metode K-Harmonic Means dengan Validasi Silhouette Index,” vol. 4, no. 2, pp. 73–86, 2024, doi: 10.59395/janitra.v4i2.203.
- [16] W. B. Syamhuri, M. T. Furqon, and C. Dewi, “Pengelompokan Film Berdasarkan Alur Cerita menggunakan Metode Self Organizing Maps dan Silhouette Coefficient,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 12, pp. 5898–5904, 2022, [Online]. Available: <http://j-ptiik.ub.ac.id>