

Pengelompokan Regu Penyelamat Non-Kebakaran di Kabupaten Cirebon dengan *K-Means Clustering*

Arye Fandia Kusuma^{1*}, Nana Suarna¹, Irfan Ali¹, Dodi Solihudin¹

¹Program Studi Teknik Informatika, STMIK IKMI Cirebon, Indonesia

*Email: aryefandia6@gmail.com

Info Artikel

Kata Kunci :

layanan darurat, algoritma k-means, pengelompokan, kabupaten cirebon, *davies bouildin index (DBI)*

Keywords :

emergency services, k-means algorithm, clustering, cirebon regency, davies bouildin index (DBI)

Tanggal Artikel

Dikirim : 11 Desember 2024

Direvisi : 2 Januari 2025

Diterima : 10 Februari 2025

Abstrak

Layanan darurat non kebakaran di Kabupaten Cirebon menghadapi beberapa kendala, seperti alokasi sumber daya yang tidak efisien dan terbatasnya pemanfaatan analisis data. Penelitian ini bertujuan untuk meningkatkan pengelolaan regu penyelamat dengan memanfaatkan algoritma K-Means sebagai metode pengelompokan data. Menggunakan pendekatan *data mining* dan penerapan *Knowledge Discovery in Database (KDD)*, penelitian ini menganalisis 874 data layanan darurat non kebakaran yang dikumpulkan pada tahun 2023-2024. Data yang dianalisis meliputi Lokasi kejadian, jenis penyelamatan, tingkat keparahan insiden, waktu respons, dan distribusi regu penyelamat. Proses penelitian dimulai dengan konversi data kedalam format numerik. Hasil menunjukkan nilai DBI terendah sebesar 0,080 dengan empat klaster optimal, yang meningkatkan efisiensi distribusi regu penyelamat.

Abstract

Non-fire emergency services in Cirebon Regency face several obstacles, such as inefficient resource allocation and limited utilization of data analysis. This study aims to improve the management of rescue squads by utilizing the K-Means algorithm as a data clustering method. Using a data mining approach and the application of Knowledge Discovery in Database (KDD), this study analyzed 874 non-fire emergency service data collected in 2023-2024. The data analyzed included Location of incident, type of rescue, severity of incident, response time, and distribution of rescue squads. The research process started with converting the data into numerical format. The results showed the lowest DBI value of 0.080 with four optimal clusters, which improved the efficiency of rescue squad distribution.

1. PENDAHULUAN

Layanan Darurat merupakan komponen yang sangat penting bagi masyarakat untuk menjaga keselamatan, terutama dalam kasus non-kebakaran. Pengelolaan layanan darurat di Kabupaten Cirebon menghadapi sejumlah masalah tentang tantangan yang ada dalam pengelolaan layanan darurat ini mencakup alokasi sumber daya yang tidak efektif dan kurangnya data untuk analisis [1]. Seiring dengan meningkatnya jumlah insiden dan kompleksitas situasi yang dihadapi oleh Dinas Pemadam kebakaran, masalah ini menjadi sangat penting [2]. Dalam hal pengelolaan risiko, ada ketidakpastian dalam pengambilan keputusan karena keterbatasan teknologi informasi untuk analisis data [3]. Dalam *data mining* algoritma K-Means dapat digunakan untuk mengelompokkan data layanan darurat berdasarkan tingkat risiko [4]. Studi sebelumnya menunjukkan bahwa algoritma *clustering* dapat meningkatkan responsivitas dan efisiensi dalam analisis data layanan publik [5].

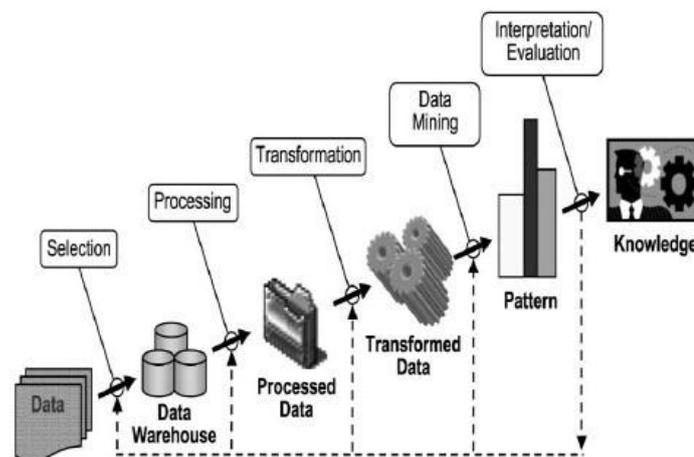
Pengelolaan layanan darurat menghadapi berbagai tantangan, terutama dalam hal alokasi sumber daya [6]. Tidak adanya data analisis yang tepat di Kabupaten Cirebon dapat menyebabkan ketidakpastian dalam pengambilan keputusan terkait penanganan insiden [7]. Studi menunjukkan bahwa banyak Lembaga yang masih bergantung pada metode konvensional untuk mengelola layanan darurat, yang seringkali tidak cukup untuk menangani situasi yang kompleks [8]. Dengan meningkatkan pengelolaan layanan darurat melalui analisis data yang lebih baik, diharapkan sistem yang lebih cepat tanggap dan efisiensi bisa tercipta [9].

Beberapa penelitian sebelumnya telah membahas penerapan metode pengelompokkan dalam layanan publik dan pengelolaan risiko di Kota Padang dalam upaya pencegahan [10]. Penelitian ini lebih menekankan pentingnya integrasi data dalam pengelolaan layanan publik, tetapi tidak menawarkan solusi spesifik terkait. Teknik pengelompokkan yang dapat diterapkan dalam upaya pencegahan terhadap bencana di Kota Samarinda [11]. Penelitian mengenai pengelolaan data yang baik menunjukkan bahwa akurasi data memiliki peran penting dalam respons terhadap insiden. Namun, studi ini membahas metode pengelompokkan yang dapat meningkatkan efektivitas pengelolaan data layanan darurat [12].

Penelitian ini bertujuan untuk mengelompokkan data layanan darurat non-kebakaran di Kabupaten Cirebon menggunakan metode K-Means. Melalui pengelompokkan ini, diharapkan dapat ditemukan pola insiden yang mendukung rekomendasi alokasi regu penyelamat secara lebih efisien dan efektif [13]. Tujuan utama penelitian ini adalah untuk mempercepat waktu tanggap serta meningkatkan efisiensi pemanfaatan sumber daya dalam menangani situasi darurat non-kebakaran. Penerapan metode k-means dalam penelitian ini tidak hanya berkontribusi secara akademis, tetapi juga memberikan manfaat praktis dengan menunjukkan bahwa teknologi berbasis data dapat mendukung pengambilan keputusan yang lebih akurat dan responsive [14]. Tren terbaru menunjukkan bahwa Algoritma pembelajaran mesin, seperti Algoritma K-Means bisa membantu meningkatkan efisiensi dalam mengelola data layanan darurat. Secara khusus, temuan ini akan memberikan wawasan baru tentang cara pemanfaatan data insiden darurat dapat meningkatkan efisiensi alokasi sumber daya dan mendukung pengambilan keputusan strategis yang lebih baik di lapangan [15].

2. METODE PENELITIAN

Adapun untuk menganalisis data dalam penerapan data mining ini menggunakan proses tahapan *Knowledge Discovery in Database* (KDD), yaitu :



Gambar 1 KDD

2.1 Preprocessing Data

Penelitian ini menggunakan data layanan darurat non-kebakaran di Kabupaten Cirebon, terdiri atas 874 data dengan 20 atribut. Atribut tersebut mencakup informasi lokasi kejadian seperti desa dan kecamatan, waktu kejadian hingga penyelesaian (Waktu Kejadian, Waktu Penyelesaian Darurat, Waktu tiba di Lokasi), jenis insiden seperti evakuasi hewan, evakuasi cincin, dll. Serta data korban meliputi jumlah korban terancam, selamat, luka berat, dan luka ringan. Analisis distribusi data berdasarkan wilayah membantu mengidentifikasi daerah rawan insiden, sedangkan atribut jenis penyelamat dan situasi tempat kejadian memberikan wawasan terkait pola insiden yang sering terjadi dan kebutuhan peralatan penyelamat. Dari sisi waktu respons, atribut waktu kejadian, waktu tiba di lokasi, dan waktu selesai digunakan untuk menghitung rata-rata durasi respons serta memahami faktor-faktor yang memengaruhinya, seperti jenis insiden dan lokasi. Informasi tambahan seperti pihak yang hadir dalam kejadian dan alat penyelamat turut mendukung analisis efektivitas penanganan layanan darurat. Pendekatan ini memberikan gambaran menyeluruh mengenai karakteristik data yang digunakan dalam penelitian.

Tabel 1. Dataset

No	Sektor	Nama Terancam	No tlp	Desa	Selamat	Regu
1	Babakan	Satih	082145690124	Kalikayu	0	2
2	Ciledug	Dani	085545690124	Pangenan	1	2
3	Pangenan	Kusnadi	083145560124	Sumber	3	2
4	Losari	Anto	082145690321	Sidamulya	5	1
5	Lemah Abang	Sulis	082215690124	Sidaresmi	2	2
6	Sumber	Robi Kurniawan	085145690124	Rawaurip	6	2
7	Greged	lis rahmawati	087145690124	Kalimukti	1	3
8	Waled	Ahmad mujidin	082145620124	Kalikoa	0	3
..
10	Gebang	Tono	085115690124	Buntet	2	3

2.2 Transformation Data

Proses mengubah data mentah menjadi format yang lebih cocok untuk analisis atau pemodelan dikenal sebagai transformasi data. Langkah ini memiliki signifikansi yang krusial, karena memungkinkan data untuk lebih mudah diinterpretasikan oleh algoritma *machine learning*, yang pada akhirnya meningkatkan akurasi model yang dihasilkan. Salah satu pendekatan transformasi yang sering diterapkan adalah *Label Encoding*, yaitu metode yang bertujuan untuk mengubah data kategori menjadi representasi numerik unik untuk setiap kategori. Sebagai ilustrasi, kategori seperti “kucing”, “Beruang”, dan “burung” dapat di representasikan masing-masing sebagai 0, 1, dan 2. Teknik ini sangat efektif karena algoritma machine learning umumnya memproses data numerik dengan lebih baik dibandingkan data kategori.

2.3 Pemodelan

Langkah berikutnya adalah membangun model K-Means Clustering menggunakan *software* Rapid Miner untuk menentukan jumlah cluster yang paling optimal. Model ini berperan dalam pengelompokan data secara efisien berdasarkan karakteristik yang relevan, sehingga dapat memberikan kontribusi signifikan terhadap pengambilan keputusan yang lebih akurat dan terinformasi. Dengan mengatur nilai K yang di sesuaikan dan melakukan percobaan sebanyak 10 kali dengan iterasi optimasi maksimal 100.

2.4 Evaluasi dan Interpretasi Hasil

Hasil *clustering* dari K-Means dengan melakukan lima kali percobaan dengan nilai K yang berbeda mulai dari K = 2, 3, 4, 5, dan 6 yang kemudian di evaluasi menggunakan DBI (*Davies Bouildin Index*), untuk memastikan bahwa model tersebut dapat menggambarkan pola-pola yang berguna dalam distribusi regu penyelamat. Evaluasi ini dilakukan dengan menginterpretasikan dari setiap klaster yang terbentuk untuk memahami pola pengelompokan dan melakukan validasi hasil dengan Rapid Miner.

3 HASIL DAN PEMBAHASAN

Penelitian ini membahas penerapan algoritma K-Means Clustering untuk pengelompokan regu penyelamat. Proses pengelompokan dilakukan berdasarkan berbagai kriteria yang di rancang untuk mendukung efisiensi dalam alokasi regu penyelamat.

3.1 Preprocessing Data

Pada tahapan ini akan dipilih beberapa atribut untuk di olah dengan jumlah data 874 dengan memilih beberapa atribut yang akan di olah seperti Kecamatan, Jenis Penyelamatan, Luka Berat, Luka Ringan, Terancam, Selamat, dan Regu. Data dengan periode bulan Januari sampai Desember 2023 dan bulan Januari sampai September di tahun 2024.

Tabel 2. Data sesudah diseleksi

No	Kecamatan	Jenis Penyelamatan	Luka Berat	Luka Ringan	Terancam	Selamat	Regu
1	Babakan	Evakuasi Tawon	0	1	4	3	2
2	Ciledug	Evakuasi Cincin	0	0	2	2	2
3	Pangenan	Evakuasi Biawak	0	1	3	2	2
4	Losari	Evakuasi Monyet	1	0	5	4	1
5	Lemah Abang	Evakuasi Ular	0	0	2	2	2
6	Sumber	Evakuasi Babi	0	2	6	4	2
7	Greged	Evakuasi Jiwa	0	0	1	1	3
8	Waled	Evakuasi Kucing	0	0	0	0	3
..
10	Gebang	Evakuasi ODGJ	0	0	0	0	3

3.2. Transformasi Data

Langkah selanjutnya adalah mengonversi tipe data kategori menjadi bentuk numerik. Proses ini diperlukan agar data dapat diolah oleh algoritma *machine learning*, yang pada dasarnya hanya dapat bekerja dengan data dalam format numerik.

Tabel 3. Konversi data

Kecamatan	Jenis Penyelamatan
0	0
1	1
2	2
3	3
4	4
5	5
6	6
..	..
7	7

konversi data ini mendefinisikan nilai numerik untuk setiap kategori yang dapat di definisikan sebagai berikut :

Keterangan :

- 0 : Kecamatan Babakan
- 1 : Kecamatan Ciledug
- 2 : Kecamatan Pangenan
- 3 : Kecamatan Losari
- 4 : Kecamatan Lemah Abang

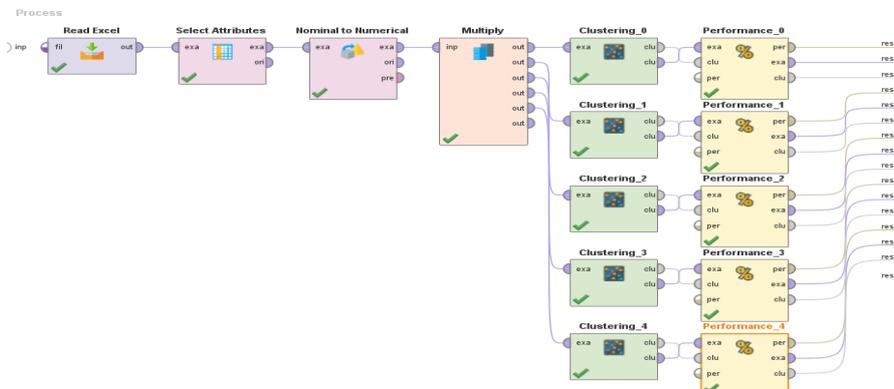
- 5 : Kecamatan Sumber
- 6 : Kecamatan Greged
- 7 : Kecamatan Waled

Begitu pula dengan atribut Jenis penyelamatan yang dapat di definisikan sebagai berikut:

- 0 : Evakuasi Tawon
- 1 : Evakuasi Cincin
- 2 : Evakuasi Biawak
- 3 : Evakuasi Monyet
- 4 : Evakuasi Babi
- 5 : Evakuasi Ular
- 6 : Evakuasi Jiwa
- 7 : Evakuasi ODGJ

3.3 Pemodelan

Pada tahapan ini dilakukan dengan mengelompokkan data ke dalam 5 kluster berdasarkan kesamaan. Nilai K yang diatur mulai dari 2,3,4,5 dan 6 yang berarti data ini akan dibagi menjadi beberapa kluster hingga diperoleh nilai DBI yang paling mendekati 0. Algoritma ini akan melakukan hingga 10 kali percobaan untuk menemukan hasil yang terbaik, dengan memanfaatkan inisialisasi centroid yang optimal. Jarak antar data akan dihitung menggunakan *Euclidean Distance*, yang digunakan untuk mengukur jarak dalam ruang dengan banyak variabel. Data yang digunakan berupa data numerik, dengan batasan jumlah iterasi optimasi maksimal 100 untuk memastikan kestabilan dalam proses klustering.



Gambar 2. Pemodelan K-Means Clustering

Pada gambar 2, ini menunjukkan hasil pemodelan *K-Means Clustering* di RapidMiner. Dengan keterangan Read excel berfungsi mengimpor dataset, *select attributes* berfungsi untuk memilih mana atribut yang akan digunakan untuk di analisis, *Nominal to numerical* yang berfungsi untuk proses data yang awalnya bersifat nominal lalu diubah menjadi kategori numerik, lalu operator *multiply* yang berfungsi untuk menjalankan perintah secara bersamaan guna meningkatkan efisiensi waktu, operator *K-Means* yang berfungsi untuk mengelompokkan data ke dalam sejumlah k kluster berdasarkan kesamaan antar data yang serupa akan dikelompokkan Bersama dalam satu kluster.

Cluster Model

```
Cluster 0: 427 items
Cluster 1: 208 items
Cluster 2: 166 items
Cluster 3: 73 items
Total number of items: 874
```

Gambar 3. Cluster Model

Pada gambar 3, ini menampilkan hasil klasterisasi menggunakan algoritma K-Means, dimana data dibagi menjadi empat klaster. Klaster 0 memiliki jumlah item terbesar yaitu 427 items dengan pola insiden atau kejadian darurat di kecamatan ini umumnya memiliki intensitas rendah dan sedikit variasi dalam jenis penyelamatan. diikuti oleh klaster 1 dengan 208 items dengan pola insiden yang sedikit lebih tinggi dibandingkan dengan cluster 0, dengan jenis kejadian yang lebih beragam seperti evakuasi cincin, sarang tawon, ular, dan biawak, yang melibatkan korban ringan atau bencana kecil. Klaster 2 sebanyak 166 items dengan pola insiden yang lebih sering atau lebih berat dibandingkan dengan klaster 1. Misalnya, kejadian berulang seperti evakuasi jiwa, pohon tumbang, evakuasi cincin, dan sarang tawon dengan korban luka berat atau bencana alam skala menengah. Klaster 3 dengan jumlah paling sedikit yaitu 73 items dengan kelompok terkecil yang mencakup wilayah dengan pola kejadian paling ekstrem dan jaran terjadi, wilayah ini sering kali menghadapi bencana besar dengan banyak korban atau kerusakan yang signifikan seperti evakuasi pohon tumbang, ular, sarung tawon, evakuasi jiwa, atau mitigasi bencana alam besar. Secara keseluruhan, terdapat 874 item yang berhasil dikelompokkan. Setiap klaster menggambarkan sekumpulan item dengan pola atau karakteristik tertentu yang serupa, sebagaimana diidentifikasi oleh algoritma.

3.4 Evaluasi dan Interpretasi

Tahap selanjutnya adalah evaluasi dan interpretasi hasil dari proses *K-Means clustering*.

PerformanceVector

```
PerformanceVector:  
Avg. within centroid distance: 21.561  
Avg. within centroid distance_cluster_0: 16.677  
Avg. within centroid distance_cluster_1: 22.018  
Avg. within centroid distance_cluster_2: 23.151  
Avg. within centroid distance_cluster_3: 45.212  
Davies Bouldin: 0.080
```

Gambar 4. PerformanceVector

Gambar 4 menunjukkan hasil evaluasi *Davis-Bouldin Index* (DBI) pada percobaan ketiga, dengan nilai DBI sebesar 0,080. Rata-rata jarak data ke pusat klaster (centroid) adalah 16,677 untuk cluster 0, 22,018 untuk cluster 1, 23,151 untuk cluster 2, dan 45,212 untuk cluster 3, yang menunjukkan bahwa cluster 3 memiliki data yang lebih tersebar, sedangkan cluster 0 lebih terkonsentrasi. Nilai DBI yang rendah ini menunjukkan pengelompokan yang efisien, di mana jarak antar klaster lebih signifikan dibandingkan jarak dalam klaster, sehingga distribusi data terhadap centroid menjadi lebih terstruktur. Nilai DBI yang rendah umumnya dianggap sebagai indikator pengelompokan yang efektif, karena menunjukkan klaster yang memiliki konsistensi internal tinggi dan perbedaan yang jelas antar klaster. Dengan demikian, hasil clustering ini dapat dikatakan optimal sesuai dengan standar literatur.

4. KESIMPULAN

Penelitian ini berhasil menerapkan algoritma k-means untuk mengelompokkan data layanan darurat non kebakaran di Kabupaten Cirebon. Dengan menganalisis 874 data menggunakan pendekatan *Knowledge Discovery in Database* (KDD), algoritma tersebut membagi data menjadi empat klaster optimal berdasarkan evaluasi *Davis-Bouldin Index* (DBI), yang menghasilkan nilai terendah sebesar 0,080. Klasterisasi ini membantu mengidentifikasi pola insiden yang dapat mendukung distribusi regu penyelamat secara lebih efektif. Penelitian ini membuktikan bahwa pendekatan berbasis data, seperti *K-Means clustering*, tidak hanya meningkatkan efisiensi pengelolaan sumber daya tetapi juga mempercepat respons dalam menghadapi situasi darurat non kebakaran. Hasil temuan ini memberikan manfaat praktis dalam mendukung pengambilan keputusan strategis yang lebih efektif terkait alokasi regu penyelamat. Penelitian di masa depan disarankan untuk mengintegrasikan sistem dengan teknologi *Internet of Things* (IoT) guna memungkinkan pengumpulan data secara *real-time*. Dengan adanya data yang terus diperbarui, analisis dapat dilakukan dengan lebih akurat, sehingga meningkatkan kecepatan dan efisiensi respons terhadap insiden.

DAFTAR PUSTAKA

- [1] Y. Bete Dos Santos *et al.*, “Menentukan Titik Rawan Malaria Di Provinsi Nusa Tenggara Timur Menggunakan Metode K-Means Clustering,” *J. Sist. Inf. dan Ilmu Komput.*, vol. 1, no. 4, pp. 230–236, 2023, [Online]. Available: <https://doi.org/10.59581/jusiik-widyakarya.v1i4.1750>
- [2] Y. E. Wella, O. Okfalisa, F. Insani, F. Saeed, and A. R. C. Hussin, “Service quality dealer identification: the optimization of K-Means clustering,” *Sinergi (Indonesia)*, vol. 27, no. 3, pp. 433–442, 2023, doi: 10.22441/sinergi.2023.3.014.
- [3] I. Nabilla Audy, T. Nur Padilah, and B. Nurina Sari, “Pengelompokan Daerah Rawan Bencana Alam Di Jawa Barat Menggunakan Algoritma Fuzzy C-Means,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 4, pp. 2799–2803, 2024, doi: 10.36040/jati.v7i4.7205.
- [4] I. S. Hidayat, S. Defit, and G. W. Nurcahyo, “Simulasi dalam Optimalisasi Pengadaan Barang menggunakan Metode K-Mean Clustering,” *J. Sistim Inf. dan Teknol.*, vol. 3, pp. 281–286, 2021, doi: 10.37034/jsisfotek.v3i4.79.
- [5] 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>
- [6] R. Prasajo, Y. Retno, W. Utami, and R. T. Vlandari, “Implementasi K-Means Clustering Pada Pengelompokan,” vol. 7, no. 2, pp. 205–216, 2019.
- [7] I. Saleh, G. Mandar, and J. Noh, “Analisis Data Gempa Di Maluku Utara Menggunakan Algoritma K-Means Dan Linear Regression,” *Dintek*, vol. 16, no. 2, pp. 12–19, 2023.
- [8] A. Y. Kartini and D. Fakhriyana, “Journal of Mathematics Education PENERAPAN METODE CLUSTERING UNTUK PEMETAAN,” *J. Math. Educ. Sci. Copyr.*, vol. 7, no. c, pp. 11–19, 2024.
- [9] S. Rahmadhani and Z. Alhadi, “Efektivitas Kinerja Dinas Pemadam Kebakaran Kota Padang dalam Pencegahan Bahaya Kebakaran,” *J. Manaj. dan Ilmu Adm. Publik*, vol. 3, no. September, pp. 261–268, 2021, doi: 10.24036/jmiap.v3i3.277.
- [10] T. K. Titus and M. Jajuli, “Clustering Data Kecelakaan Lalu Lintas di Kecamatan Cileungsi Menggunakan Metode K-Means,” *Gener. J.*, vol. 6, no. 1, pp. 1–12, 2022, doi: 10.29407/gj.v6i1.16103.
- [11] Wisnu Priyo Jatmiko, M. Gillang Ramadhani, M. Gilang Romadhon, Gilang Adhmadani, Rahmad Fardian, and Wawan Joko Pranoto, “Penerapan Metode K-Means Clustering Terhadap Bencana Kebakaran Di Kota Samarinda,” *Jupiter Publ. Ilmu Keteknikan Ind. Tek. Elektro dan Inform.*, vol. 2, no. 1, pp. 01–08, 2024, doi: 10.61132/jupiter.v2i1.36.
- [12] D. Tri Cahaya, D. Puspita, and R. Syahri, “Penerapan Metode K-Means Clustering Untuk Pengelompokan Potensi Padi Di Kota Pagar Alam,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 2, pp. 2187–2193, 2024, doi: 10.36040/jati.v8i2.9432.
- [13] S. Gymnastiar and A. Bahtiar, “Penerapan Algoritma K-Means Clustering Untuk Mengelompokan Data Kejadian Kekeringan Di Kabupaten Cirebon,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 2, pp. 2325–2331, 2024, doi: 10.36040/jati.v8i2.8948.
- [14] D. Rohman, R. Annisa, D. Indriyana Efendi, and D. Solahudin, “Clustering Bencana Alam Menggunakan K-Means Pada Wilayah Jawa Barat,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 493–500, 2024, doi: 10.36040/jati.v8i1.8409.
- [15] R. Utami and S. Pramana, “Klasterisasi Bencana dan Dampaknya di Indonesia: Evaluasi Metode K-means dengan Integrasi PCA,” *SENADA*, vol. 2024, no. Senada, pp. 367–377, 2024.