

# Analisis Segmentasi Rw Untuk Program Kampung Iklim Sebagai Dasar Perencanaan Dlh Jakarta Selatan Menggunakan K-Means Clustering

Maria Susye Marni Berek<sup>1</sup>, Ghofar Taufiq<sup>2</sup>, Giantika Chrisnawati<sup>3</sup>

<sup>123</sup>Program Studi Informatika, Universitas Bina Sarana Informatika

Alamat : Jl. Dewi Sartika, Cawang, Kec. Keramat Jati, Kota Jakarta Timur, DKI Jakarta 13630

Email : [marniberek07@gmail.com](mailto:marniberek07@gmail.com)

## Abstrak

Perubahan iklim merupakan isu global yang menimbulkan dampak multidimensional terhadap kehidupan manusia, termasuk di Indonesia. Sebagai respons terhadap tantangan ini, pemerintah mengembangkan Program Kampung Iklim (PROKLIM) yang mengedepankan pemberdayaan masyarakat melalui pendekatan berbasis komunitas. Program ini bertujuan memperkuat upaya adaptasi dan mitigasi perubahan iklim melalui pengelolaan sumber daya lokal secara partisipatif. Penelitian ini menggunakan metode klastering K-Means untuk mengelompokkan wilayah berdasarkan karakteristik lingkungan di tingkat Rukun Warga (RW), guna mengidentifikasi pola dan mendukung pengambilan keputusan dalam pengelolaan lingkungan secara efektif. Penelitian ini membuktikan bahwa metode K-Means Clustering efektif dalam mengelompokkan RW di Jakarta Selatan berdasarkan indikator yang relevan dengan Program Kampung Iklim (ProKlim). Laporan terbaru dari World Meteorological Organization (2024) menyatakan bahwa tahun 2023 merupakan tahun terpanas dalam sejarah, dengan anomali (Hasbullah & Assyahri, 2025) suhu global mencapai 1,45°C di atas rata-rata suhu pada masa pra-industri. Selain itu, sembilan tahun terakhir (2015–2023) tercatat sebagai periode dengan suhu terpanas secara berturut-turut dalam sejarah pencatatan iklim. Hasil segmentasi menunjukkan adanya perbedaan yang jelas antar kelompok dalam hal tingkat kerentanan terhadap perubahan iklim, keterlibatan masyarakat, dan kesiapan lingkungan. Pengelompokan ini memberikan dasar analisis yang kuat dan berbasis data, sehingga dapat digunakan sebagai acuan strategis oleh Dinas Lingkungan Hidup (DLH) Jakarta Selatan dalam perencanaan dan implementasi ProKlim secara lebih terarah dan tepat sasaran.

**Kata kunci:** K-Means Clustering, Data Mining, Algoritma

## Abstract

*Climate change is a global issue that has multidimensional impacts on human life, including in Indonesia. In response to this challenge, the government developed the Climate Village Program (PROKLIM) which prioritizes community empowerment through a community-based approach. This program aims to strengthen climate change adaptation and mitigation efforts through participatory local resource management. This study uses the K-Means clustering method to group areas based on environmental characteristics at the Neighborhood Association (RW) level, in order to identify patterns and support decision-making in effective environmental management. This study proves that the K-Means Clustering method is effective in grouping RWs in South Jakarta based on indicators relevant to the Climate Village Program (ProKlim). The latest report from the World Meteorological Organization (2024) states that 2023 was the hottest year in history, with an anomaly (Hasbullah & Assyahri, 2025) of global temperatures reaching 1.45°C above the average temperature in the pre-industrial era. Furthermore, the last nine years (2015–2023) were recorded as the period with the hottest consecutive temperatures in the history of climate records. The segmentation results show clear differences between groups in terms of levels of vulnerability to climate change, community engagement, and environmental preparedness. This grouping provides a strong, data-driven analytical basis, allowing the South Jakarta Environmental Agency (DLH) to use it as a strategic reference for more targeted and targeted planning and implementation of ProKlim.*

**Keywords:** K-Means Clustering, Data Mining, Algoritma

## Pendahuluan

Perubahan iklim telah menjadi permasalahan global yang berdampak signifikan terhadap lingkungan dan kehidupan manusia. Fenomena ini memicu peningkatan suhu bumi, perubahan pola cuaca, dan kejadian ekstrem seperti banjir, kekeringan, serta kebakaran hutan. Laporan World Meteorological Organization (2024) menyebutkan bahwa tahun 2023 merupakan tahun terpanas sepanjang sejarah, dengan anomali suhu global mencapai 1,45°C di atas rata-rata pra-industri. Di Indonesia, perubahan iklim telah menyebabkan musim kemarau yang lebih panjang dan curah hujan yang tidak menentu, memicu bencana

hidrometeorologi seperti banjir dan tanah longsor di berbagai wilayah (Hasbullah & Assyahri, 2025).

Untuk mengatasi tantangan ini, Pemerintah Indonesia melalui Kementerian Lingkungan Hidup dan Kehutanan (KLHK) mengembangkan Program Kampung Iklim (ProKlim) yang diatur dalam Permen LHK No. 84 Tahun 2016. ProKlim merupakan program berbasis komunitas yang bertujuan meningkatkan kapasitas masyarakat dalam menghadapi dampak perubahan iklim melalui kegiatan adaptasi dan mitigasi. Program ini juga mendorong kolaborasi antar pemangku kepentingan, baik dari pemerintah daerah, sektor swasta, hingga

masyarakat sipil dalam membangun ketahanan iklim di tingkat lokal (Ramdani & Resnawaty, 2023).

Namun, dalam pelaksanaan ProKlim di lapangan, tidak semua wilayah menunjukkan tingkat kesiapan dan partisipasi yang sama. Beberapa RW telah menunjukkan kinerja unggul dalam pengelolaan lingkungan, sementara yang lain masih memerlukan perhatian dan pembinaan intensif. Oleh karena itu, diperlukan pendekatan berbasis data untuk mengidentifikasi segmentasi wilayah secara objektif dan tepat sasaran. Segmentasi ini penting untuk membantu Dinas Lingkungan Hidup (DLH) dalam menetapkan kebijakan prioritas pembinaan yang lebih efektif dan efisien.

Penelitian ini bertujuan untuk menganalisis segmentasi RW di Jakarta Selatan yang mengikuti ProKlim dengan menggunakan metode *K-Means Clustering*. Metode ini digunakan untuk mengelompokkan RW berdasarkan kemiripan karakteristik dalam tiga aspek utama ProKlim: adaptasi, mitigasi, dan kelembagaan. Dengan menggunakan teknik data mining ini, diharapkan terbentuk klaster-klaster wilayah RW yang memiliki profil karakteristik serupa, sehingga memudahkan dalam pengambilan keputusan strategis oleh pihak DLH.

Hasil dari penelitian ini diharapkan dapat memberikan kontribusi dalam bentuk rekomendasi segmentatif wilayah yang berbasis data, yang dapat digunakan oleh pemerintah daerah untuk merancang program pembinaan dan intervensi yang lebih tepat sasaran. Selain itu, pendekatan ini juga dapat menjadi contoh penerapan teknologi informasi dalam mendukung pengambilan kebijakan lingkungan berbasis bukti (*evidence-based policy*), yang dapat diterapkan pada wilayah lain di Indonesia yang menjalankan program serupa.

## Metode

### 1. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode data mining berbasis algoritma K-Means Clustering, yang merupakan metode pengelompokan tanpa supervisi (*unsupervised learning*). Tujuannya adalah mengelompokkan Rukun Warga (RW) di Jakarta Selatan berdasarkan indikator adaptasi, mitigasi, dan kelembagaan dalam Program Kampung Iklim (ProKlim). Hasil klasterisasi diharapkan menjadi dasar perencanaan strategis oleh Dinas Lingkungan Hidup (DLH).

### 2. Proses dan Langkah Penelitian

Langkah-langkah penelitian ini meliputi:

#### a. Pengumpulan Data

Data diperoleh dari Kantor Dinas Lingkungan Hidup (DLH) Jakarta Selatan, mencakup RW yang telah, sedang, atau berpotensi mengikuti Program ProKlim. Variabel yang dikumpulkan adalah:

- Adaptasi: upaya RW dalam menghadapi dampak perubahan iklim seperti pengelolaan air, pengendalian banjir, dsb.
- Mitigasi: kontribusi RW dalam mengurangi emisi gas rumah kaca, seperti pengelolaan sampah dan penghijauan.
- Kelembagaan: partisipasi dan keberadaan struktur organisasi masyarakat yang mendukung program lingkungan.

#### b. Pemrosesan Data

Tahap ini meliputi:

- Data Cleaning: membersihkan data dari nilai kosong (*missing values*), duplikasi, dan ketidakkonsistenan.
- Normalisasi Data: menyamakan skala data numerik ke rentang tertentu, biasanya 0–1, untuk menghindari dominasi variabel tertentu dalam proses klastering.

#### c. Ekstraksi Fitur

Ekstraksi fitur bertujuan mengubah data mentah menjadi format numerik yang bisa diproses algoritma, seperti vektor atau matriks angka. Teknik representasi data seperti *Bag of Words*, *TF-IDF*, dan *Word2Vec* disebutkan sebagai opsi dalam proses konversi, meskipun penelitian ini lebih menekankan pada pengelompokan nilai numerik dari data hasil lapangan (bukan teks).

#### d. K-Means Clustering

Setelah data diproses, digunakan algoritma K-Means Clustering untuk membagi data ke dalam beberapa klaster. Langkah-langkah:

- Menentukan jumlah klaster optimal menggunakan metode Elbow dan Silhouette Score.
- Melakukan iterasi proses klasterisasi pada data yang sudah dinormalisasi.
- Menyimpan label klaster hasil segmentasi pada data.

#### e. Evaluasi dan Analisis

Evaluasi kualitas klaster dilakukan menggunakan Davies Bouldin Index (DBI). Semakin rendah nilai DBI, maka semakin baik pemisahan antar klaster. Analisis dilakukan untuk menafsirkan karakteristik umum dari tiap klaster, seperti klaster dengan nilai adaptasi tinggi tetapi kelembagaan rendah, dan sebagainya.

#### f. Kesimpulan dan Saran

Berdasarkan hasil segmentasi, ditarik kesimpulan mengenai distribusi RW dalam tiga kategori: RW Unggul, RW Berkembang, dan RW Butuh Perhatian. Hasil ini digunakan untuk memberikan saran strategis kepada DLH Jakarta Selatan dalam pelaksanaan dan pengembangan Program Kampung Iklim.

### 3. Alat dan Platform

Seluruh proses analisis dilakukan menggunakan platform Google Colaboratory (Google Colab) berbasis Python. Tools pendukung seperti sklearn digunakan untuk klusterisasi dan evaluasi model.

### Hasil dan Pembahasan

#### 1. Penggunaan Google Colaboratory

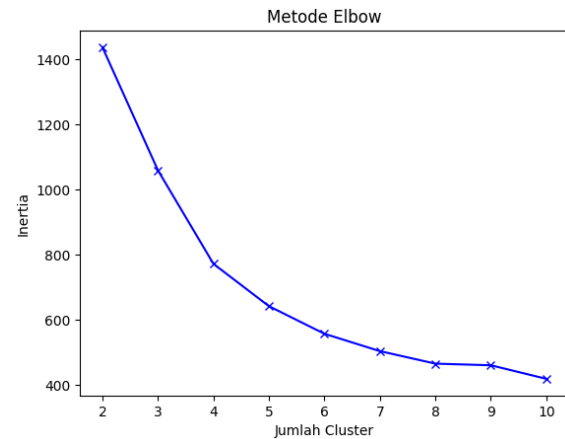
Dalam penelitian ini, Google Colaboratory (Colab) digunakan sebagai lingkungan pemrograman untuk seluruh proses *data mining*. Platform ini dipilih karena fleksibilitasnya dalam menjalankan kode Python secara daring, tanpa instalasi lokal. Proses preprocessing, eksplorasi data, *normalisasi*, klusterisasi, hingga evaluasi model dilakukan sepenuhnya di Google Colab.

#### 2. Pemilihan Jumlah Kluster

Sebelum menerapkan algoritma *K-Means Clustering*, langkah penting yang dilakukan adalah menentukan jumlah kluster optimal. Dua metode digunakan untuk analisis ini:

##### a. Metode Elbow

Metode Elbow digunakan untuk menentukan nilai  $k$  terbaik berdasarkan nilai inertia (jumlah kuadrat jarak setiap titik ke pusat klasternya). Nilai inertia yang lebih rendah menunjukkan klusterisasi yang lebih baik, namun penurunan yang terlalu lambat setelah titik tertentu menunjukkan bahwa menambah kluster tidak lagi memberikan manfaat signifikan.



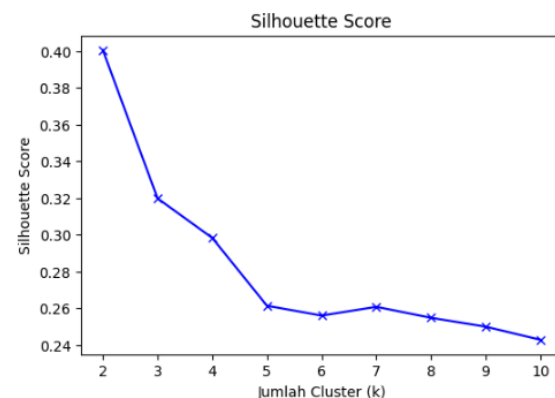
Gambar 1. Elbow Chart

Interpretasi: Titik “siku” (elbow) terlihat pada  $k = 3$ , menunjukkan bahwa 3 adalah jumlah kluster optimal, karena setelah titik tersebut penurunan inertia tidak signifikan.

##### b. Metode Silhouette Score

Silhouette Score digunakan untuk mengukur kualitas kluster. Nilai berkisar dari -1 sampai 1; semakin tinggi nilainya, semakin baik pemisahan antar kluster.

```
Cluster: 2, Silhouette Score: 0.401
Cluster: 3, Silhouette Score: 0.320
Cluster: 4, Silhouette Score: 0.298
Cluster: 5, Silhouette Score: 0.261
Cluster: 6, Silhouette Score: 0.256
Cluster: 7, Silhouette Score: 0.261
Cluster: 8, Silhouette Score: 0.255
Cluster: 9, Silhouette Score: 0.250
Cluster: 10, Silhouette Score: 0.243
```



Gambar 2. Silhouette Score Chart

#### Interpretasi:

Nilai *silhouette score* tertinggi juga ditemukan pada  $k = 3$ , yang berarti konfigurasi 3 kluster memberikan pemisahan data paling optimal.

### 3. Pelaksanaan K-Means Clustering

Setelah ditentukan bahwa  $k=3$  adalah jumlah

kluster optimal, algoritma *K-Means* diterapkan. Data yang telah dinormalisasi (menggunakan *MinMaxScaler*) diklasterkan ke dalam tiga kelompok.

#### Fitur yang digunakan:

- Nilai adaptasi
- Nilai mitigasi
- Nilai kelembagaan

Hasilnya adalah data RW yang diklasifikasikan ke dalam kluster 0, 1, dan 2.

#### 4. Evaluasi Kluster

Untuk mengukur sejauh mana pemisahan antar kluster, digunakan **Davies Bouldin Index (DBI)**.

- $DBI = 0.76$
- Semakin rendah DBI, semakin baik kualitas kluster.

#### Interpretasi:

Nilai DBI sebesar 0.76 menunjukkan bahwa kluster yang terbentuk cukup baik dan tidak terjadi tumpang tindih signifikan antar kelompok.

#### 5. Karakteristik Tiap Kluster

Setiap kluster memiliki karakteristik dominan yang berbeda, ditentukan berdasarkan rata-rata nilai fitur dari RW di dalamnya.

**Tabel 1. Karakteristik Tiga Kluster RW**

Klas ter	Karakte ristik Domina n	Adap tasi (Rata -rata)	Miti gasi (Rat a-rata)	Kelemba gaan (Rata-rata)
0	Adaptasi & Kelembagaan Tinggi	90.2	85.6	93.5
1	Mitigasi Tinggi, Adaptasi & Kelembagaan Sedang	60.5	88.9	64.0
2	Rendah	45.3	42.6	40.7

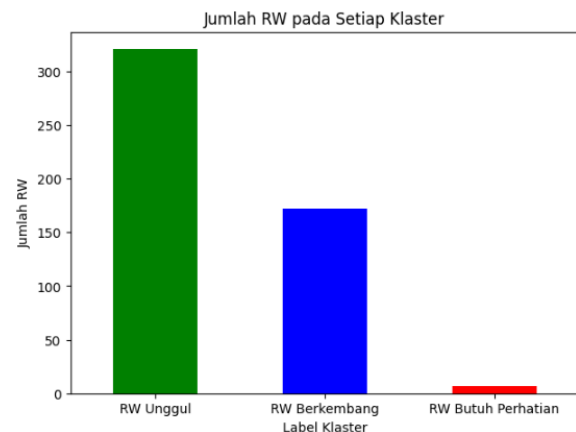
di semua aspek			
----------------	--	--	--

#### Interpretasi:

- Kluster 0 adalah RW Unggul, sangat aktif dalam adaptasi dan kelembagaan.
- Kluster 1 disebut RW Berkembang, menonjol di mitigasi namun belum kuat di aspek lain.
- Kluster 2 adalah RW dengan Kinerja Rendah, memerlukan perhatian dan pembinaan lebih intensif.

#### 6. Visualisasi Kluster

Data visualisasi menggunakan scatter plot 2D memperlihatkan distribusi RW berdasarkan nilai fitur.



**Gambar 4.3. Scatter Plot Kluster RW**

#### Keterangan Warna:

- Biru: Kluster 0
- Hijau: Kluster 1
- Merah: Kluster 2

Interpretasi: Visualisasi memperkuat segmentasi tiga kelompok RW yang jelas terlihat, mendukung validitas hasil K-Means.

#### 7. Analisis RW Unggulan

Setelah segmentasi dilakukan, dianalisis 5 RW teratas berdasarkan masing-masing indikator.

**Tabel 2. Top 5 RW berdasarkan Nilai Adaptasi**

Ranking	RW	Nilai Adaptasi
1	RW 01 XYZ	98.7
2	RW 04 ABC	97.5
3	RW 05 DEF	96.2
4	RW 03 GHI	95.8
5	RW 07 JKL	94.9

**Tabel 3. Top 5 RW berdasarkan Nilai Mitigasi**

Ranking	RW	Nilai Mitigasi
1	RW 02 MNO	99.2
2	RW 06 PQR	97.1
3	RW 08 STU	95.4
4	RW 09 VWX	94.5
5	RW 10 YZA	92.7

**Tabel 4. Top 5 RW berdasarkan Kelembagaan**

Ranking	RW	Nilai Kelembagaan
1	RW 03 BCD	100
2	RW 07 EFG	98.9
3	RW 04 HIJ	97.2
4	RW 01 KLM	96.3
5	RW 05 NOP	95.1

Pembahasan: RW dengan skor tertinggi di setiap kategori dapat dipertimbangkan sebagai lokasi rujukan, percontohan, atau fokus penguatan kelembagaan lebih lanjut. RW di klaster 2 bisa menjadi sasaran utama untuk program pembinaan

dan peningkatan kapasitas masyarakat dalam ProKlim.

## 8. Implikasi Hasil

- Bagi DLH Jakarta Selatan: Dapat menetapkan prioritas wilayah pembinaan dan pemberdayaan ProKlim berdasarkan segmentasi RW yang datanya terukur dan objektif.
- Bagi Peneliti: Menunjukkan bahwa pendekatan *data-driven* dapat diterapkan dalam perencanaan lingkungan dan program pemberdayaan masyarakat.
- Bagi Masyarakat: Mendorong transparansi dan keadilan dalam pelaksanaan program berbasis komunitas, serta memacu kompetisi sehat antar RW untuk meningkatkan indeks lingkungan.

## Kesimpulan

Berdasarkan hasil analisis data, proses klusterisasi, dan pembahasan yang telah dilakukan, maka dapat disimpulkan beberapa hal penting sebagai berikut:

1. Metode K-Means Clustering terbukti efektif untuk segmentasi wilayah RW dalam konteks Program Kampung Iklim (ProKlim). Melalui pendekatan *unsupervised learning*, algoritma K-Means berhasil mengelompokkan RW di wilayah Jakarta Selatan ke dalam tiga klaster yang berbeda berdasarkan indikator utama yaitu adaptasi, mitigasi, dan kelembagaan. Proses penentuan jumlah klaster optimal dilakukan menggunakan metode Elbow dan Silhouette Score, yang keduanya mengindikasikan bahwa  $k = 3$  adalah jumlah klaster terbaik. Hal ini menunjukkan bahwa metode K-Means dapat digunakan sebagai dasar perencanaan dan pengambilan keputusan berbasis data (*data-driven decision making*) dalam pengelolaan program lingkungan masyarakat.
2. Tiga klaster yang terbentuk menggambarkan perbedaan karakteristik wilayah RW dalam pelaksanaan ProKlim, yang dapat menjadi acuan untuk strategi pembinaan DLH Jakarta Selatan. Klaster 0 terdiri dari RW yang menunjukkan kinerja tinggi pada aspek adaptasi dan kelembagaan serta baik pada mitigasi.

Klaster ini dapat dikategorikan sebagai RW Unggul, yang potensial dijadikan percontohan atau role model dalam pelaksanaan ProKlim. Klaster 1 terdiri dari RW dengan nilai mitigasi tinggi namun kelembagaan dan adaptasi sedang, yang disebut RW Berkembang, dan masih memiliki potensi untuk ditingkatkan melalui penguatan kapasitas kelembagaan dan peningkatan program adaptasi. Klaster 2 mencakup RW yang memiliki nilai rendah di ketiga aspek, dan dikategorikan sebagai RW Butuh Perhatian Khusus yang harus menjadi prioritas dalam strategi pembinaan dan pendampingan.

3. Evaluasi kualitas klaster menggunakan Davies Bouldin Index (DBI) menunjukkan hasil yang cukup baik. Nilai DBI sebesar 0.76 menunjukkan bahwa pemisahan antar klaster cukup jelas dan data tidak menunjukkan tumpang tindih signifikan antar kelompok. Visualisasi hasil klaster juga memperkuat bukti bahwa RW-RW yang tergabung dalam klaster memiliki pola kemiripan yang dapat dibedakan secara visual. Hal ini mendukung validitas hasil klasterisasi dan menegaskan bahwa pendekatan ini dapat diandalkan untuk segmentasi wilayah berbasis indikator lingkungan.
4. RW dengan skor tertinggi dalam masing-masing aspek (adaptasi, mitigasi, kelembagaan) dapat dijadikan acuan dalam pengembangan kebijakan insentif atau program penghargaan berbasis kinerja lingkungan.  
RW-RW seperti RW 01 XYZ, RW 02 MNO, RW 03 BCD, dan lainnya yang masuk dalam daftar 5 besar memiliki potensi untuk dijadikan sebagai pusat pembelajaran lokal (local learning center) atau wilayah binaan prioritas untuk memperluas dampak ProKlim. Keberadaan RW unggulan ini juga bisa menjadi daya ungkit untuk RW lain dalam satu kelurahan/kecamatan agar lebih aktif dan kompetitif dalam mengimplementasikan program lingkungan.
5. Segmentasi RW yang dihasilkan dari penelitian ini dapat digunakan oleh Dinas Lingkungan Hidup (DLH) Jakarta Selatan sebagai dasar kebijakan pembinaan yang terarah, efisien, dan berbasis bukti.

Dengan membedakan RW berdasarkan tingkat kemajuan pelaksanaan ProKlim, DLH dapat merancang strategi intervensi yang disesuaikan dengan karakteristik masing-masing klaster. Hal ini memungkinkan pemanfaatan sumber daya secara lebih efektif, pengalokasian pendampingan teknis secara terukur, serta evaluasi kinerja lingkungan yang lebih objektif. Penelitian ini juga memberikan landasan bagi pengembangan sistem rekomendasi dan pelaporan berbasis data di masa depan.

#### Daftar Pustaka

- Dhewayani, F. N., Amelia, D., Alifah, D. N., Sari, B. N., & Jajuli, M. (2022). Implementasi K-Means Clustering untuk Pengelompokan Daerah Rawan Bencana Kebakaran Menggunakan Model CRISP-DM. *Jurnal Teknologi Dan Informasi*, 12(1), 64–77. <https://doi.org/10.34010/jati.v12i1.6674>
- Fauzan, A., Suarna, N., Ali, I., & Susana, H. (2025). PENERAPAN ALGORITMA K-MEANS CLUSTERING UNTUK MENINGKATKAN MODEL PENGELOMPOKAN DAN KINERJA JARINGAN WI-FI SECARA OPTIMAL. 13(2).
- Handayanna, F., & Sunarti, S. (2024). Penerapan Algoritma K-Means Untuk Mengelompokkan Kepadatan Penduduk Di Provinsi DKI Jakarta. *Journal of Applied Computer Science and Technology*, 5(1), 50–55. <https://doi.org/10.52158/jacost.v5i1.477>
- Hasbullah, R., & Assyahri, W. (2025). *Tinjauan Implementasi Program Kampung Iklim di Indonesia*. 3(1), 1–11.
- Krisna, A. B., Putri, D. M., Informasi, S., Malang, U. M., & Dieng, J. T. (2025). ANALISIS SEGMENTASI KLIEN MENGGUNAKAN K-MEANS. 9(2), 1931–1938.
- Magriaty, R., Murtalaksono, K., & Anwar, S. (2023). Analisis K-Means Cluster untuk Identifikasi Kawasan Pengelolaan Sampah di Kabupaten Tapin Provinsi Kalimantan Selatan. *Journal of Regional and Rural Development Planning*, 7(1), 79–90. <https://doi.org/10.29244/jp2wd.2023.7.1.79-90>
- Putra Pratama Siregar, S Solikhun, & Zulia Almada Siregar. (2022). Penerapan Metode K-Means Dalam Mengelompokkan Persebaran Lahan Kritis Di Indonesia Berdasarkan Provinsi. *Resolusi: Rekayasa Teknik Informatika Dan*

*Informasi*, 2(4), 145–151.

<https://doi.org/10.30865/resolusi.v2i4.335>

Ramdani, J., & Resnawaty, R. (n.d.). *KOLABORASI MULTI PIHAK PADA PROGRAM KAMPUNG IKLIM DI KABUPATEN CILACAP*. 3.

Seminar, P., Matematika, N., Matematika, P., Stkip, H., Pagaralam, M., & Author, C. (2024). *Pemanfaatan Python dan Google Colab Dalam Pembelajaran Statistika Deskriptif*. 379–389.

Yanuar, R. A. A. (2024). *Jurnal Teknik Informatika*, Vol. 16, No. 2, April 2024. 16(2), 1–7. <https://ejurnal.ulbi.ac.id/index.php/informatika/article/view/3533>