

IMPLEMENTASI K-MEANS CLUSTERING UNTUK MENENTUKAN TINGKAT BENCANA RAWAN BANJIR DI WILAYAH SUMATERA UTARA

Reimer Fernando Purba✉, Astri Agnes Panjaitan, Labora Triasi Butar-Butar,
John Franz E.D.L. Sitorus, Rosanti Rumapea, Indra M. Sarkis S.

Falkutas Ilmu Komputer, Universitas Methodist Indonesia, Medan, Indonesia

Email: reimeroeey@gmail.com

ABSTRACT

This study focuses on identifying flood-prone areas in North Sumatra, one of the provinces in Indonesia that is very vulnerable to natural disasters such as floods. The impact of floods often results in significant material losses and fatalities. Therefore, it is important to identify high-risk areas so that prevention and mitigation strategies can be implemented effectively. This study uses the K-Means clustering method and Rapid Miner software to determine the area's most vulnerable to flooding. The results of the analysis show that areas with high flood risk are included in cluster 1, which includes areas with high potential flood vulnerability based on historical data and flood risk indicators that have been analyzed. These findings can be used to design strategies that are implemented and provide greater contributions to the region.

Keyword: Disaster-Prone Areas, K-Means, North Sumatra, Floods, Mitigation Measures.

ABSTRAK

Penelitian ini berfokus pada identifikasi wilayah rawan banjir di Sumatera Utara, salah satu provinsi di Indonesia yang sangat rentan terhadap bencana alam seperti banjir. Dampak banjir sering kali mengakibatkan kerugian materiil dan korban jiwa yang tidak sedikit. Oleh karena itu, penting untuk mengidentifikasi wilayah yang berisiko tinggi supaya strategi pencegahan dan penanggulangan dapat dilaksanakan secara efektif. Penelitian ini menggunakan metode clustering K-Means dan perangkat lunak RapidMiner untuk menentukan wilayah yang paling rentan terhadap banjir. Hasil analisis menunjukkan bahwa wilayah dengan risiko banjir tinggi termasuk dalam cluster 1, yang meliputi wilayah dengan potensi kerentanan banjir yang tinggi berdasarkan data riwayat dan indikator risiko banjir yang telah dianalisis. Temuan ini dapat digunakan untuk merancang strategi yang dilaksanakan dan memberikan kontribusi yang lebih besar bagi wilayah tersebut.

Kata Kunci: Daerah Rawan Bencana, K-Means, Sumatera Utara, Banjir, Langkah Mitigasi.

PENDAHULUAN

Sumatera Utara adalah salah satu provinsi di Indonesia yang memiliki potensi besar terhadap berbagai jenis bencana alam, khususnya bencana banjir. Dampak dari bencana banjir ini sering kali sangat merugikan, baik dari segi materi maupun korban jiwa. Berdasarkan data dari Data Informasi Bencana Indonesia (DIBI) dan Badan Pusat Statistika Provinsi Sumatera Utara (BPS), periode 2020-2023 Sumatera Utara mengalami 194 kasus bencana banjir (BPS Sumut, 2024).

K-Means Clustering adalah algoritma dalam metode clustering yang bersifat unsupervised learning yang digunakan untuk mengelompokkan data ke dalam kelompok atau cluster berdasarkan karakteristik atau persamaan maupun perbedaan (Nainggolan & Lumbantoruan, 2018). Tujuan penelitian menggunakan metode Clustering K-Means adalah untuk mengelompokkan atau mengidentifikasi data daerah yang rawan bencana banjir di Provinsi Sumatera Utara.

Manfaat penelitian menggunakan metode Clustering K-Means diharapkan informasi yang diperoleh dapat digunakan oleh pemerintah dan lembaga terkait untuk merencanakan dan melaksanakan langkah-langkah mitigasi yang lebih efektif, seperti membangun infrastruktur tahan bencana, menyediakan sistem peringatan dini, serta mendidik dan melatih masyarakat setempat.


Dalam studi ini, peneliti menggunakan algoritma clustering K-Means untuk mengelompokkan desa/kelurahan berdasarkan tindakan antisipasi dan mitigasi bencana alam di setiap wilayah. Tujuan dari penerapan metode ini adalah untuk menemukan pola atau kelompok desa/kelurahan yang memiliki tingkat kesiapsiagaan atau strategi mitigasi yang serupa. Algoritma K-Means dipilih karena mampu mengelompokkan data berdasarkan kesamaan karakteristik (Gustientiedina, 2019), sehingga dapat memberikan gambaran lebih jelas mengenai wilayah

yang membutuhkan fokus dan intervensi lebih lanjut dalam hal kesiapsiagaan bencana (Sadewo et al., 2018).

Penelitian ini menggunakan algoritma K-Means untuk melakukan clustering atau pengelompokan data bencana alam berdasarkan beberapa variabel penting, yaitu wilayah, waktu kejadian, jumlah korban, dan tingkat kerusakan fasilitas. Algoritma K-Means bekerja dengan membagi data ke dalam sejumlah cluster berdasarkan kesamaan karakteristik yang dimiliki (Na, Xumin & Yong, 2010). Dalam konteks ini, desa atau wilayah dengan pola kejadian bencana yang mirip, termasuk jumlah korban yang hampir sama, akan dikelompokkan dalam satu cluster. Hasil dari pengelompokan ini diharapkan dapat memberikan informasi yang lebih terstruktur dan mendalam mengenai pola-pola kejadian bencana, termasuk bagaimana bencana mempengaruhi jumlah korban di berbagai wilayah. Dengan demikian, pihak berwenang dapat menggunakan informasi ini untuk menyusun strategi mitigasi yang lebih tepat, seperti memperkuat sistem peringatan dini, meningkatkan kesiapan fasilitas medis, atau melakukan edukasi kepada masyarakat di wilayah yang rawan terhadap dampak bencana yang besar (Murdiaty et al., 2020).

METODE PENELITIAN

Tahapan-tahapan yang dilakukan pada penelitian ini ditunjukkan pada gambar berikut



Gambar 1. Tahapan Penelitian Tingkat Bencana Rawan Banjir

Pengumpulan Data

Pada tahapan ini dilakukan pengumpulan data Rawan banjir di wilayah Provinsi Sumatera Utara, dengan mengambil data dari Data Informasi Bencana Indonesia (DIBI) dan Badan Pusat Statistika Provinsi Sumatera Utara (BPS), periode 2020-2023. Variabel yang digunakan yaitu Data Banjir.

Penelitian ini mengelompokkan Bencana alam Banjir di Provinsi Sumatera Utara menjadi 3 Cluster yaitu: (C1) untuk Bencana Alam yang memiliki potensi Tinggi (C2) untuk Bencana Alam yang memiliki potensi sedang, (C3) untuk Bencana alam yang memiliki potensi rendah.

Pada tahapan ini dilakukan pengumpulan data Rawan banjir di wilayah Provinsi Sumatera Utara, dengan mengambil data dari Data Informasi Bencana Indonesia (DIBI) dan Badan Pusat Statistika Provinsi

Sumatera Utara (BPS), periode 2020-2023. Variabel yang digunakan yaitu Data Banjir.

Penelitian ini mengelompokkan Bencana alam Banjir di Provinsi Sumatera Utara menjadi 3 Cluster yaitu: (C1) untuk Bencana Alam yang memiliki potensi Tinggi (C2) untuk Bencana Alam yang memiliki potensi sedang, (C3) untuk Bencana alam yang memiliki potensi rendah.

Tabel 1. Data Rawan Bencana Banjir

No.	Kabupaten/Kota	Jumlah 2020	Jumlah 2021	Jumlah 2022	Jumlah 2023
1	Nias Nias	1	3	3	2
2	Mandailing Natal	4	2	0	1
3	Tapanuli Selatan	1	4	3	2
4	Tapanuli Tengah	1	0	1	0
5	Tapanuli Utara	0	0	0	0
6	Toba	0	1	2	2
7	Labuhan Batu	1	2	0	4
8	Asahan	7	8	0	3
9	Simalungun	0	0	0	2
10	Dairi	0	0	0	0
11	Karo	0	0	0	2
12	Deli Serdang	4	0	6	0
13	Langkat	5	4	11	2
14	Humbang Hasundutan	0	0	0	1
15	Nias Selatan	1	0	0	4

K-Means

K-Means adalah algoritma klusterisasi *non-hierarchical* atau Partitional Clustering yang mengelompokkan data berdasarkan karakteristik yang serupa (Ahmed et al., 2020). Dalam konteks ini, K-Means mengkategorikan daerah-daerah berdasarkan frekuensi kejadian bencana dan jenis bencana yang sering terjadi di Sumatera Utara.

Berikut adalah langkah-langkah algoritma K-Means, yaitu (Jananto, 2022; Wakhidah, 2014):

1. Menentukan jumlah *cluster* pada data sebagai nilai *centroid*.
2. tentukan pusat *cluster* (*centroid*) dan nilai *centroid*, Dalam menentukan nilai centroid untuk awal iterasi, nilai awal centroid dilakukan secara acak.
3. kemudian hitung jarak objek data ke *centroid*.
4. kita melakukan pengelompokan objek data berdasarkan jarak minimum terhadap *centroid*, siklus proses *k-means clustering* disebut juga dengan 1 iterasi.
5. Kemudian kita menghitung hitung pusat cluster yang baru, setelah itu dilanjutkan dengan menghitung jarak data ke pusat cluster yang prosesnya sama dengan itersi pertama.
6. Jika hasil pengelompokan iterasi ke-2 dan iterasi ke-1yang kita lakukan belum sama, kemudian

lanjutkan ke iterasi ke-3 atau berikutnya. Namun jika hasil pengelompokan iterasi sudah sama, maka proses *k-means clustering* berhenti di iterasi yang nilainya sudah sama dengan iterasi sebelumnya dan itulah hasil dari pengelompokan akhir.

Tabel 2. Data yang dipakai dalam Penilaian

W	B20	B21	B22	B23
W1	1	3	3	2
W2	4	2	0	1
W3	1	4	3	2
W4	1	0	1	0
W5	0	0	0	0
W6	0	1	2	2
W7	1	2	0	4
W8	7	8	0	3
W9	0	0	0	2
W10	0	0	0	0
W11	0	0	0	2
W12	4	0	6	0
W13	5	4	11	2
W14	0	0	0	1
W15	1	0	0	4
W16	0	0	0	0
W17	0	0	0	0
W18	0	11	7	3
W19	10	10	6	1
W20	10	0	0	1
W21	0	3	1	5
W22	0	0	0	1
W23	2	3	2	0
W24	2	3	1	2
W25	0	0	1	2
W26	0	0	0	2
W27	1	3	0	1
W28	1	0	0	1
W29	2	4	3	1
W30	3	13	16	2
W31	2	2	3	2
W32	3	3	0	3
W33	0	3	0	1

Setiap data diukur jaraknya dengan *centroid* awal. Penentuan titik *cluster* dibagi menjadi tiga *Cluster* yaitu *cluster* Tinggi (C1), sedang (C2), dan kurang (C3). menghitung jarak data ke setiap titik terdekat dengan pusat *cluster* digunakan *Euclidean distance*. Tabel 3 merupakan hasil jarak setiap data dengan setiap *centroid* yang didapat dari perhitungan pada iterasi ke-1. Setiap data *cluster* ditentukan berdasarkan jarak terpendek. Tabel 4 merupakan hasil penentuan *cluster* setiap data.

Tabel 3. Data Hasil Perhitungan Centroid Pertama

	C1	C2	C3	Jarak terdekat	Cluster
	0	9.746794	10.48809	0	1
9.539392	10.0995	9.746794	9.539392014	1	1
9.327379	11.40175	12.60952	9.327379053	1	1
9	2.44949	16.52271	2.449489743	2	2
11.26943	3.162278	19.46792	3.16227766	2	2
8.944272	2.645751	15.93738	2.645751311	2	2
11.6619	3.316625	20.04994	3.31662479	2	2
12.8841	4.123106	20.92845	4.123105626	2	2
10.72381	3.464102	18.68154	3.464101615	2	2
12.04159	4.690416	19.62142	4.69041576	2	2
11.91638	7.937254	17.26268	7.937253933	2	2
12.72792	4.582576	20.83267	4.582575695	2	2
12.8841	4.123106	20.92845	4.123105626	2	2
12.72792	4.582576	20.83267	4.582575695	2	2
6.78233	5.385165	16.55295	5.385164807	2	2
12.76715	4.242641	20.85665	4.242640687	2	2
12.52996	5.477226	20.80865	5.477225575	2	2
12.8841	4.123106	20.92845	4.123105626	2	2
12.8841	4.123106	20.92845	4.123105626	2	2
12.76715	8.831761	21.79449	8.831760866	2	2
11.61895	5.477226	18.52026	5.477225575	2	2
12.76715	4.242641	20.85665	4.242640687	2	2
9.746794	0	17.34935	0	2	2
10.48809	2.236068	18.05547	2.236067977	2	2
11.87434	4.242641	20.07486	4.242640687	2	2
12.72792	4.582576	20.83267	4.582575695	2	2
11.78983	2.44949	19	2.449489743	2	2
12.40967	3.872983	20.73644	3.872983346	2	2
8.602325	1.732051	15.87451	1.732050808	2	2
8.774964	2.44949	17.05872	2.449489743	2	2
11.26943	3.741657	18.89444	3.741657387	2	2
12.16553	3	19.13113	3	2	2
10.48809	17.34935	0	0	3	3

Tabel 4. Hasil Pengelompokan Iterasi Pertama

W	B20	B21	B22	B23	C1	C2	C3	Jarak terdekat	Cluster
W8	7	8	0	3	8.313309	8.681441	17.26268	8.313309276	1
W13	5	4	11	2	5.270463	10.99162	10.48809	5.270462767	1
W18	0	11	7	3	5.840472	11.46607	9.746794	5.840471823	1
W19	10	10	6	1	5.725188	13.07097	12.60952	5.725188012	1
W1	1	3	3	2	8.333333	2.656516	16.52271	2.656515558	2
W2	4	2	0	1	10.30102	2.770878	19.46792	2.770877941	2
W3	1	4	3	2	7.731609	3.320029	15.93738	3.320028938	2
W4	1	0	1	0	11.76624	2.225674	20.04994	2.225674422	2
W5	0	0	0	0	12.74537	2.777093	20.92845	2.777093323	2
W6	0	1	2	2	10.71344	1.970954	18.68154	1.970954367	2
W7	1	2	0	4	11.14052	2.695176	19.62142	2.69517559	2
W9	0	0	0	2	12.58747	2.346348	20.83267	2.346348391	2
W10	0	0	0	0	12.74537	2.777093	20.92845	2.777093323	2
W11	0	0	0	2	12.58747	2.346348	20.83267	2.346348391	2
W12	4	0	6	0	8.856887	6.090284	16.55295	6.090283874	2
W14	0	0	0	1	12.62713	2.36829	20.85665	2.368290322	2
W15	1	0	0	4	12.38727	3.054986	20.80865	3.054985594	2
W16	0	0	0	0	12.74537	2.777093	20.92845	2.777093323	2
W17	0	0	0	0	12.74537	2.777093	20.92845	2.777093323	2
W20	10	0	0	1	12.62713	8.715138	21.79449	8.71513786	2
W21	0	3	1	5	10.55673	4.037134	18.52026	4.037134407	2
W22	0	0	0	1	12.62713	2.36829	20.85665	2.368290322	2
W23	2	3	2	0	8.800253	2.468108	17.34935	2.468108115	2
W24	2	3	1	2	9.29755	1.636388	18.05547	1.636387658	2
W25	0	0	1	2	11.97683	2.170771	20.07486	2.170771136	2
W26	0	0	0	2	12.58747	2.346348	20.83267	2.346348391	2
W27	1	3	0	1	10.46157	1.881445	19	1.881444533	2
W28	1	0	0	1	12.26558	1.908738	20.73644	1.908738276	2
W29	2	4	3	1	7.333333	3.340737	15.87451	3.340736923	2
W31	2	2	3	2	8.608781	2.264076	17.05872	2.264076065	2
W32	3	3	0	3	9.871395	2.720644	18.89444	2.720643765	2
W33	0	3	0	1	10.88322	2.346348	19.13113	2.346348391	2
W30	3	13	16	2	9.475114	19.03867	0	0	3

Dari perhitungan pada iterasi ke-1 dapat kita simpulkan daerah yang berada pada *cluster* C1 ada 28 daerah, pada *cluster* C2 ada 4 daerah dan pada

Tabel 5. Centroid Baru

Centroid	B20	B21	B22	B23
C1	1.5	1.9	1.0	1.6
C2	5.5	8.25	6.0	2.25
C3	3	13	16	2

Cluster C3 ada 1 daerah. kemudian dilakukan pembaruan *centroid*, yang perhitungannya dilakukan dengan *Euclidean distance* terhadap masing-masing data *cluster* dengan centroidnya.

Berikut ini adalah perhitungan dari *centroid*.

Cluster 1 terdiri dari data ke-1, ke-2, ke-3, ke-4, ke-5, ke-6, ke-7, ke-9, ke-10, ke-11, ke-12, ke-14, ke-15, ke-16, ke-17, ke-20, ke-21, ke-22, ke-23, ke-24, ke-25, ke-26, ke-27, ke-28, ke-29, ke-31, ke-32, ke-33

Centroid 1 baru untuk

B20 =

$$(3+2+4+0+0+1+2+0+0+0+0+0+0+0+0+3+0+3+3+0+0+3+0+4+2+3+3)/2 = 18$$

Centroid 1 baru untuk

B21 =

$$(1+4+1+1+0+0+1+0+0+0+4+0+1+0+0+10+0+0+2+2+0+0+1+1+2+2+3+0)/2 = 18$$

Centroid 1 baru untuk

B22=

$$(3+0+3+1+0+2+0+0+0+0+6+0+0+0+0+0+1+0+2+1+1+0+0+0+3+3+0+0)/2 = 13$$

Centroid 1 baru untuk

B23 = $(2+1+2+0+0+4+2+0+2+0+1+4+0+0+1+5+1+0+2+2+2+1+1+1+2+3+1)/2 = 20$

Cluster 2 terdiri dari data ke-8, ke-13, ke-18, dan ke-19

Centroid 1 baru untuk B20 = $(7+5+0+10) / 4 = 22 / 4 = 5.5$

Centroid 1 baru untuk B21 = $(8+4+11+10) / 4 = 33 / 4 = 8.25$

Centroid 1 baru untuk B22= $(0+11+7+6) / 4 = 24 / 4 = 6.0$

Centroid 1 baru untuk B23 = $(3+2+3+1) / 4 = 9 / 4 = 2.25$

Cluster 3 terdiri dari data ke-33

Centroid 1 baru untuk B20 = $(3)/2 = 3$

Centroid 1 baru untuk B21 = $(13)/2 = 13$

Centroid 1 baru untuk B22= $(16)/2 = 16$

Centroid 1 baru untuk B23 = $(2)/2 = 2$

Persentase distribusi data dalam setiap cluster yaitu:

Cluster 1: Sekitar 84.85%

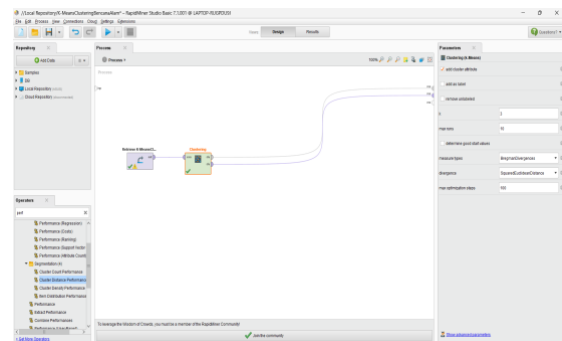
Cluster 2: Sekitar 12.12%

Cluster 3: Sekitar 3.03%

Setelah didapatkan data *centroid* terbaru seperti pada Tabel 6 diatas, maka langkah iterasi Ke-1 dilakukan ulang untuk melakukan perbandingan yang sama antara kelompok *cluster* sebelum dan setelahnya, sampai didapatkan data pada tiap cluster tidak berubah.

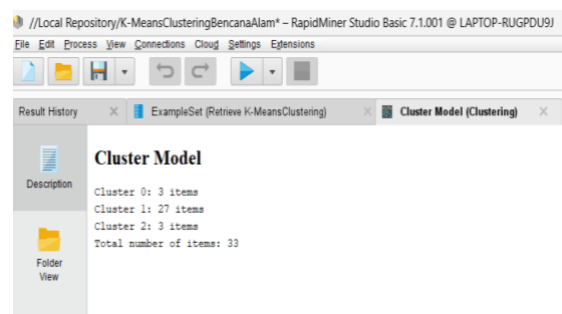
HASIL DAN PEMBAHASAN

Pada proses metode *Clusterisasi* algoritma K-Means digunakan untuk membentuk kelompok Cluster dengan keakurasian yang tepat. Dalam penelitian ini pengujian perhitungan menggunakan *tools* Rapid Miner.




Gambar 2. Proses K-means Clustering di Rapid Miner


Setelah dilakukan *Running Process* pada Rapid Miner, maka hasil pengelompokan klaster yang didapatkan terhadap 33 record data yang diproses dan dapat dilihat pada gambar berikut:



Gambar 3. Hasil Cluster Data



Gambar 4. Hasil Pengelompokan Daerah yang di Cluster



Gambar 4. Grafik Scatter dari Cluster

Dari hasil penelitian yang dilakukan untuk mengelompokkan salah satu di wilayah Kabupaten Langkat, dapat diidentifikasi bahwa kawasan tersebut tergolong rawan terhadap bencana banjir selama tahun tertentu. Berdasarkan analisis data historis kejadian banjir, terutama yang terjadi pada kurun waktu tahun 2020 hingga 2023, dengan Metode yang digunakan dalam pengelompokan ini dengan metode *K-Means Clustering*, yang secara efektif membagi data ke dalam beberapa kluster berdasarkan kesamaan karakteristik. Tingkat terjadi banyaknya korban bencana banjir di wilayah kabupaten langkat menjumlahkan berdasarkan C1 sekitar 84%, ini menunjukkan bahwa masyarakat di wilayah tersebut perlu meningkatkan kewaspadaan dan kesiapsiagaan terhadap potensi bencana banjir. Selain itu, hasil kluster yang dihasilkan oleh metode K-Means ini dapat dijadikan dasar untuk melakukan tindakan pencegahan yang lebih terarah dalam mitigasi bencana banjir yang dihasilkan dapat digunakan sebagai dasar untuk strategi mitigasi yang lebih terarah, ini dapat membantu pemerintah setempat dalam menyusun rencana tindakan pencegahan bencana penanggulangan banjir atau penguatan sistem peringatan dini, sehingga dapat meminimalisir dampak potensi bencana terhadap masyarakat di masa mendatang.

KESIMPULAN

Berdasarkan hasil penelitian pengelompokan provinsi Sumatera Utara terhadap Bencana Banjir

menggunakan algoritma *K-means clustering*, Data dikelompokkan menjadi 3 cluster yaitu daerah yang Bencana Banjir Tingkat tinggi(C1) Bencana Banjir Tingkat Sedang (C2), Bencana Banjir Tingkat Rendah (C3), pada penelitian ini menghasilkan hingga 3 iterasi. hasil akhir dari pengelompokan daerah menjadi 3 Cluster : ada 3 daerah untuk (C1) untuk wilayah kota langkat, serdang bedagai, medan, untuk (C2) ada 27 kabupaten sebagai berikut: Nias, Mandailing Natal, Tapanuli Selatan, Tapanuli Tengah, Tapanuli Utara, Toba, Labuhan Batu, Simalugun, dairi, Karo, Deli Serdang, Humbang Hasudutan, Nias Selatan, Pakpak Barat, Samosir, Padang Lawas, Labuhan Batu Selatan, Labuhan Batu Utara, Nias Utara, Nias Barat, Sibolga, Tanjung Balai, Pematang Siantar, Tebing Tinggi, Binjai, Padang Sidempuan, Gunung Sitoli. untuk (C3) ada 3 wilayah : Asahan, Batu Bara, Padang Lawas Utara. Daerah di Sumatera Utara Yang rawan Akan Bencana Banjir adalah Daerah yang berada di dalam kelompok Cluster 1,

DISEMINASI

Artikel ini telah diseminasikan pada Seminar Nasional Teknologi Informasi dan Komunikasi (SEMNASTIK) APTIKOM Tahun 2024 yang diselenggarakan oleh Universitas Methodist Indonesia pada tanggal 24-26 Oktober 2024.

DAFTAR PUSTAKA

- Ahmed, M., Seraj, R., & Islam, S. M. S. (2020). The k-means algorithm: A comprehensive survey and performance evaluation. *Electronics*, 9(8), 1295.
- BPS Sumut, (2024).
- Gustientiedina, G., Adiya, M. H., & Desnelita, Y. (2019). Penerapan algoritma K-Means untuk clustering data obat-obatan. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 5(1), 17-24.
- Jananto, A. (2022). Penerapan Algoritma K-Means Clustering Untuk Perencanaan Kebutuhan Obat Di Klinik Citra Medika. *Progresif: Jurnal Ilmiah Komputer*, 18(1), 69-76.
- Murdiaty, M., Angela, A., & Sylvia, C. (2020). Pengelompokan Data Bencana Alam Berdasarkan Wilayah, Waktu, Jumlah Korban dan Kerusakan Fasilitas Dengan Algoritma K-Means. *Jurnal Media Informatika Budidarma*, 4(3), 744. <https://doi.org/10.30865/mib.v4i3.2213>
- Na, S., Xumin, L., & Yong, G. (2010, April). Research on k-means clustering algorithm: An improved k-means clustering algorithm. In *2010 Third International Symposium on intelligent information technology and security informatics* (pp. 63-67). Ieee.
- Nainggolan, R., & Lumbantoruan, G. (2018). Optimasi performa cluster K-Means menggunakan Sum of Squared Error (SSE).

- METHOMIKA: Jurnal Manajemen Informatika & Komputerisasi Akuntansi*, 2(2), 103-108.
- Sadewo, M. G., Windarto, A. P., & Wanto, A. (2018). Penerapan Algoritma Clustering Dalam Mengelompokkan Banyaknya Desa/Kelurahan Menurut Upaya Antisipasi/ Mitigasi Bencana Alam Menurut Provinsi Dengan K-Means. *KOMIK (Konferensi Nasional Teknologi Informasi Dan Komputer)*, 2(1), 311–319. <https://doi.org/10.30865/komik.v2i1.943>
- Wahidah, N. (2014). Clustering Menggunakan K-Means Algorithm (K-Means Algorithm Clustering). *Fakultas Teknologi Informasi*, 21(1), 70–80.