

Date: April 16th, 2025

LETTER OF ACCEPTANCE

Paper Number #827

Dear, Buchori Alwi, Rizki Muliono

This is to inform you that the manuscript entitled: "**Analisis Klustering Menggunakan Algoritma DBSCAN untuk Deteksi Anomali dalam Data Transaksi Keuangan**", which was sent on April 16th 2025, is **ACCEPTED**.

We keep to ensuring a high standard of articles published in the **INCODING: Journal of Informatics and Computer Science Engineering**, and the manuscript that is being sent to you has been submitted after a first selection process based on the agreement of the **Associate Editors**. In general, the standard of manuscripts forwarded to me after the vetting is **good**.

This paper is well organized and follows the manuscript guidelines of the journal to a large extent. The introduction section is good and shows the importance of the study. The literature review is adequate. The outcomes of the study are consistent with the findings. The approach used is praiseworthy. In my opinion, it should be published without **revision again**

Based on the review results, this manuscript is **ACCEPTED**, and **PUBLISHED** in **Mei 2025** for **Volume 3, No. 2, 2025**.

Thank you very much for your contribution. Congratulations on a wonderful job.

Warmest Regards, Editor In Chief


INCODING
2776-432X (Online - Elektronik)

Agung Suharyanto, S.Sn, M.Si.

Editorial Office:

Mahesa Research Center

Perumahan Griya Nafisa 2, Blok A No 10, Jalan Benteng Hilir
Titi Sewa, RT 06, Dusun XVI Flamboyan,
Kecamatan Percut Sei Tuan, Deli Serdang, 20371
Sumatera Utara, Indonesia
Phone: 08126493527

Email: incodingjournal@gmail.com

INCODING: Journal of Informatics and Computer Science Engineering



UNIVERSITAS MEDAN AREA

© Hak Cipta Di Lindungi Undang-Undang

1. Dilarang Mengutip sebagian atau seluruh dokumen ini tanpa mencantumkan sumber
2. Pengutipan hanya untuk keperluan pendidikan, penelitian dan penulisan karya ilmiah
3. Dilarang memperbanyak sebagian atau seluruh karya ini dalam bentuk apapun tanpa izin Universitas Medan Area

Document Accepted 28/5/25

Access From (repository.uma.ac.id)28/5/25

INCODING: Journal of Informatic and Computer Science Engineering

<https://journal.mahesacenter.org/index.php/incoding/index> | ISSN xxxx-xxxx
(online)

Vol (Issue) Year: Page

DOI:

Genesis:



Analisis Klustering Menggunakan Algoritma DBSCAN untuk Deteksi Anomali dalam Data Transaksi Keuangan

Clustering Analysis Using DBSCAN Algorithm for Anomaly Detection in Financial Transaction Data

Buchori Alwi¹⁾, Rizki Muliono²⁾

Teknik informatika, Teknik, Universitas medan area, Indonesia

Abstrak

Deteksi anomali dalam data transaksi keuangan menjadi aspek penting dikarenakan semakin banyaknya pengguna e-money yang mengakibatkan kemungkinan terjadinya aktivitas yang mencurigakan, seperti fraud, pencucian uang atau penyimpangan lainnya. Algoritma *Density-Based Spatial Clustering of Applications with Noise* (DBSCAN) digunakan dalam penelitian ini untuk melakukan klusterisasi guna mendeteksi transaksi yang bersifat anomali berdasarkan tiga variabel utama, yaitu jumlah transaksi, frekuensi transaksi, dan saldo akhir. Penentuan parameter optimal DBSCAN dilakukan dengan mengevaluasi berbagai kombinasi nilai epsilon (ϵ) dan jumlah minimum titik dalam satu cluster (minPts) berdasarkan nilai Davies-Bouldin Index (DBI) terbaik. Hasil analisis menunjukkan bahwa parameter optimal adalah ϵ sebesar 0.2727 dan minPts sebesar 6, dengan nilai evaluasi DBI sebesar 1.1753, dengan total keseluruhan data sebesar 2.512 data. algoritma DBSCAN berhasil membentuk 6 cluster yang dapat digunakan untuk mendeteksi pola transaksi anomali. Dengan pendekatan ini, deteksi anomali dalam transaksi keuangan dapat dilakukan secara lebih akurat, sehingga dapat membantu dalam pengawasan transaksi keuangan.

Kata kunci: DBSCAN, klusterisasi, deteksi anomali, transaksi keuangan, *Davies-Bouldin Index*.

Abstract

Anomaly detection in financial transaction data is an important aspect due to the increasing number of e-money users which results in the possibility of suspicious activities, such as fraud, money laundering or other irregularities. Density-Based Spatial Clustering of Applications with Noise (DBSCAN) algorithm is used in this study to perform clustering to detect anomalous transactions based on three main variables, namely the number of transactions, transaction frequency, and final balance. Determination of the optimal DBSCAN parameters is done by evaluating various combinations of epsilon (ϵ) values and the minimum number of points in a cluster (minPts) based on the best Davies-Bouldin Index (DBI) value. The analysis results show that the optimal parameters are ϵ of 0.2727 and minPts of 6, with a DBI evaluation value of 1.1753, with a total of 2,512 data. DBSCAN algorithm successfully formed 6 clusters that can be used to detect anomalous transaction patterns. With this approach, anomaly detection in financial transactions can be done more accurately, so that it can help in monitoring financial transactions.

Keywords: DBSCAN, clustering, anomaly detection, financial transactions, Davies-Bouldin Index.

1. PENDAHULUAN

Di era digital dewasa ini transaksi keuangan semakin meningkat dikarenakan kemudahan penggunaan dan akses layanan perbankan dan e-commerce. Potensi penggunaan *e-money* akan terus berkembang dikarenakan adanya fasilitas pengisian yang dapat di akses oleh siapapun (Dewi et al., 2021). Ditahun 2019 menurut bank Indonesia tercatat 319.535.688 transaksi dengan nilai 314 triliyun rupiah (Hendarsyah, 2020). Meskipun begitu peningkatan transaksi online juga diiringin resiko penyalah gunaan seperti penipuan, pencurian identitas dan aktivitas yang tidak wajar. Kondisi ini bukan hanya merugikan konsumen, tetapi juga bisnis dikarenakan ketidakpercayaan pelanggan terhadap platfrom yang di gunakan (Polgan et al., 2024). Bahkan transaksi online juga bisa jadi alat dalam pencucian uang untuk menyembunyikan asal usul uang (Rahma, 2022). Oleh karena itu diperlukan sistem yang dapat mendeteksi anomali pada transaksi keuangan.

Clustering merupakan salah satu teknik *machine learning* yang dapat mengelompokkan pola yang memiliki kemiripan dari yang sangat mirip hingga yang tidak mirip (Arafat et al., 2023). Salah satu metode dari *clustering* adalah DBSCAN. DBSCAN(*Density-Based Spatial Clustering of Applications with Noise*) merupakan algoritma yang mengelompokkan titik-titik data berdasarkan tingkat kepadatan dan mengabaikan data *noise* atau *outlier* (Simbolon & Friskila, 2024). DBSCAN terdiri dari *min_samples* dan *epsilon*(ϵ). *Epsilon*(ϵ) menyatakan jarak antara data dan *min_samples* adalah jumlah tetangga data. kelebihan dari algoritma ini adalah tidak perlu mengatur jumlah *cluster* diawal. Jumlah *epsilon* dalam DBSCAN akan mengatur seberapa banyak *cluster* yang dapat di temukan(Chopra & Khurana, 2023).

Algoritma DBSCAN banyak digunakan dalam melakukan pengelompokkan data. Seperti penelitian yang dilakukan oleh Aulia Fadhli Boer, dkk yang menerapkan DBSCAN untuk mengelompokkan data rawan bencana di Sumatra utara (Boer et al., 2023). Hasil penelitian menunjukkan DBSCAN menghasilkan 2 klaster dengan nilai *silhouette coefficient* sebesar 0,46. DBSCAN juga digunakan dalam penelitian Medy Wisnu Prihatmono dalam melakukan pengelompokkan pengunjung mall berdasarkan usia dan pendapatan (Prihatmono, 2025). Hasil

penelitian menunjukkan, dari 200 data DBSCAN mampu mendeteksi 4 klaster dan 1 noise.

Penelitian ini bertujuan untuk menerapkan algoritma DBSCAN dalam mendeteksi data transaksi yang tidak wajar berdasarkan fitur utama seperti jumlah transaksi, saldo, dan frekuensi transaksi. Diharapkan metode DBSCAN dapat membantu mendeteksi aktivitas yang mencurigakan dan meningkatkan keamanan dalam transaksi keuangan.

2. METODE PENELITIAN

2.1 Pra pemrosesan

Pra pemrosesan adalah dalam konteks pemrosesan data adalah sekumpulan teknik atau langkah yang diterapkan ke data mentah sebelum masuk ke pemodelan. Tujuan dari pra pemrosesan adalah untuk membersihkan data, normalisasi, dan pengisian data kosong sehingga data dapat diolah dengan lebih efektif dan tepat (Permatasari et al., 2023). Salah satu teknik yang digunakan peneliti untuk menormalisasi data adalah z-score

$$n = \frac{x - \mu}{\sigma} \quad (1)$$

Dimana:

n = hasil penjumlahan


μ = rata-rata dalam sebuah kolom data

σ = standar deviasi data

2.2 DBSCAN (*Density-Based Spatial Clustering of Application with Noise*)

DBSCAN merupakan algoritma yang mengelompokkan titik-titik data berdasarkan tingkat kepadatan dan mengabaikan data *noise* atau *outlier* (Simbolon & Friskila, 2024). Menurut (Anwar et al., 2019) DBSCAN dapat mendeteksi *cluster* dengan data yang sedikit dan berubah-ubah. Untuk menemukan klaster DBSCAN menghitung jarak epsilon(ϵ) dan menghitung minPts yang ada disekitarnya (Lu, 2025). Semakin kecil nilai epsilon(ϵ) maka semakin banyak klaster yang terbentuk (Al-Batah et al., 2024). Algoritma ini juga cocok untuk mengelompokkan data sedang, dan mampu membedakan bentuk kluster dengan ukuran yang berbeda (Arafat et al., 2023). DBSCAN. Bisa dilihat gambar 1. DBSCAN memiliki 3 pengelompokkan N merupakan *noise point*, A

merupakan *core point*, B dan C adalah *border point*. *core point* adalah titik yang memenuhi syarat kurang dari nilai *epsilon* dan minPts yang sesuai, *border point* adalah titik yang memenuhi *epsilon* namun tidak memenuhi minPts sedangkan *noise* adalah titik yang tidak memenuhi *epsilon* maupun minPts (Schubert et al., 2017).



Gambar 1. Ilustrasi model cluster DBSCAN (Schubert et al., 2017)

DBSCAN memiliki dua parameter utama yaitu:

- A. **Epsilon (ϵ)**: Yaitu jarak maksimum antara titik dalam sebuah kluster
- B. **MinPts**: Jumlah minimum tetangga suatu titik dalam sebuah kluster

Adapun tahapan dari DBSCAN:

1. menentukan nilai *epsilon* dan minPts
2. menghitung semua jarak *epsilon* dengan rumus *Euclidian distance*

$$E = \sqrt{\sum_{i=1}^n (x_i - xp_i)^2} \quad (2)$$

E = Jarak antar titik

x_i = kordinat titik tujuan

xp_i = kordinat pusat

3. kluster terbentuk berdasarkan jika memenuhi syarat *epsilon* dan minPts
4. Menguji kluster menggunakan Davies-Bouldin Index (DBI) dengan persamaan (Xiao et al., 2017):

$$DBI = \frac{1}{K} \sum_{i=1}^K \max_{j \neq i} \frac{s_i + s_j}{d_{ij}} \quad (3)$$

K = Jumlah klister

S = Rata-rata seluruh titik masing-masing kluster i

D = Jarak antara pusat klaster

Semakin kecil nilai evaluasi maka klastering akan semakin baik

5. melakukan visualisasi kluster.

2.3 Perhitungan Manual DBSCAN

Dataset yang digunakan peneliti bersumber dari Kaggle. Dataset terdiri dari 15 variabel diantaranya, Id_Transaksi, id_akun, jumlah_transaksi, tanggal_transaksi, tipe_transaksi, lokasi, id_perangkat, ip_address, id_penjual, channel, umur_konsumen, pekerjaan, durasi_transaksi, frekuensi_transaksi, dan saldo_akhir. Variabel bisa dilihat pada tabel 1.

Tabel 1. Variabel dataset

No	Id_Transaksi	id_akun	jumlah_transaksi	tanggal_transaksi	tipe_transaksi	lokasi	id_perangkat	ip_address
1	TX000001	AC00128	14.09	2023-04-11 16:29:14	Debit	San Diego	D000380	162.198.218.92
2	TX000002	AC00455	376.24	2023-06-27 16:44:19	Debit	Houston	D000051	13.149.61.4
3	TX000003	AC00019	126.29	2023-07-10 18:16:08	Debit	Mesa	D000235	215.97.143.157
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2510	TX002510	AC00095	28.63	2023-08-21 17:08:50	Debit	San Diego	D000095	58.1.27.124
2511	TX002511	AC00118	185.97	2023-02-24 16:24:46	Debit	Denver	D000634	21.190.11.223
2512	TX002512	AC00009	243.08	2023-02-14 16:21:23	Credit	Jacksonville	D000215	59.127.135.25

No	id_penjual	channel	umur_konsumen	pekerjaan	durasi_transaksi	frekuensi_transaksi	saldo_akhir
1	M015	ATM	70	Doctor	81	1	5112.21
2	M052	ATM	68	Doctor	141	1	13758.91
3	M009	Online	19	Student	56	1	1122.35
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2510	M087	Branch	56	Retired	146	1	3382.91
2511	M041	Online	23	Student	19	1	1776.91
2512	M041	Online	24	Student	93	1	131.25

Sebelum dilakukan perhitungan. Peneliti menghapus beberapa variabel yang tidak relevan dengan pembahasan penelitian. Di tabel 2 diperlihatkan tabel yang relevan dengan penelitian ini. Selanjutnya tabel tersebut akan dilakukan pengukuran jarak menggunakan *Euclidian distance* :

Tabel 2. Dataset transaksi yang relevan

no	Id_Transaksi	Jumlah_Transaksi (\$)	Saldo_Akhir (\$)	Frekuensi_transaksi
1	TX002082	225.10	1547.71	1
2	TX000434	85.35	2173.76	1
3	TX001725	16.27	10971.32	1
4	TX001252	95.78	271.64	1
5	TX000094	442.12	1375.80	1
6	TX000903	328.34	2840.45	2
7	TX002055	156.86	14453.35	1
8	TX000768	327.80	10585.48	4
9	TX000600	435.50	6981.03	1
10	TX001230	17.21	914.16	2

Kemudian lakukan perhitungan jarak menggunakan rumus *Euclidian distance*.

Berikut adalah contoh nya:

$$E(1,2) = \sqrt{(85.35 - 225.10)^2 + (2173.76 - 1547.71)^2 + (1 - 1)^2} = 641,458$$

$$E(1,3) = \sqrt{(16.27 - 225.10)^2 + (10971.32 - 1547.71)^2 + (1 - 1)^2} = 9.425,923$$

$$E(1,4) = \sqrt{(95.78 - 225.10)^2 + (271.64 - 1547.71)^2 + (1 - 1)^2} = 4037.29$$

$$E(1,5) = \sqrt{(442.12 - 225.10)^2 + (1375.80 - 1547.71)^2 + (1 - 1)^2} = 277.06$$

$$E(1,6) = \sqrt{(328.34 - 225.10)^2 + (2840.45 - 1547.71)^2 + (2 - 1)^2} = 1296.35$$

$$E(1,7) = \sqrt{(156.86 - 225.10)^2 + (14453.35 - 1547.71)^2 + (1 - 1)^2} = 12917.67$$

$$E(1,8) = \sqrt{(327.80 - 225.10)^2 + (10585.48 - 1547.71)^2 + (4 - 1)^2} = 9043.20$$

$$E(1,9) = \sqrt{(435.50 - 225.10)^2 + (6981.03 - 1547.71)^2 + (1 - 1)^2} = 5442.34$$


$$E(1,10) = \sqrt{(17.21 - 225.10)^2 + (914.16 - 1547.71)^2 + (2 - 1)^2} = 667.02$$

Sebagai contoh kita menerapkan $\epsilon = 6600$ dan $\text{minPts} = 4$ maka *core point* dan *noise* yang didapat berupa:

- **Klaster 1:** terdapat di titik {1,2,4,5,6,9,10} dimana transaksi dan jumlah saldo berada dalam rentang normal.
- **Anomali(noise):** terdapat di titik {3,7,8} Dimana transaksi dan jumlah saldo berada dalam rentang yang tidak normal.

2.4 Diagram Alur Algoritma DBSCAN

Berikut ini merupakan diagram alur dari algoritma DBSCAN dalam menentukan jumlah kluster



Gambar 2. Flowchart Algoritma DBSCAN

3. HASIL DAN PEMBAHASAN

Dataset yang digunakan dalam penelitian ini didapat dari Kaggle. Berdasarkan dari contoh dataset di tabel 2, terdapat 3 variabel utama (x_1) jumlah transaksi, (x_2) saldo akhir, (x_3) frekuensi transaksi. Secara keseluruhan dataset memiliki 2512 baris data. Berikut adalah analisis deskriptif:

Tabel 3. Analisi deskriptif transaksi keuangan

variabel	Maximum	minimum	Rata-rata	Simpangan baku
Jumlah_Transaksi (x_1)	1919.110 \$	0.260 \$	297.593	291.946
Saldo_Akhir(x_2)	14977.990 \$	101.250 \$	5114.302	3900.942
Frekuensi_transaksi(x_3)	5	1	1.124	0.602

3.1 Normalisasi data


Pada prakteknya data-data akan dilakukan normalisasi dikarenakan adanya atribut yang memiliki perbedaan skala yang jauh. Perbedaan data yang sangat jauh akan sangat mempengaruhi hasil perhitungan jarak antara titik. Hasil perhitungan dari normalisasi menggunakan z-score dapat dilihat pada tabel 4.

Tabel 4. Hasil normalisasi data transaksi

No	Jumlah_Transaksi (\$)	frekuensi_Transaksi	Saldo_Akhir (\$)
1	-0.971275	1	-0.000537
2	0.269440	1	2.216472
3	-0.586882	1	-1.023534
⋮	⋮	⋮	⋮
2511	-0.382420	1	-0.855705
2512	-0.186763	1	-1.277652

3.2 Algoritma DBSCAN


Dalam penentuan nilai epsilon(ϵ) dan minPts peneliti menggunakan Davies-Bouldin Index (DBI) sebagai evaluasi satu persatu nilai. Hasilnya dapat dilihat pada gambar 2 dan 3:



Gambar 2. Nilai epsilon(ϵ) dan minPts

Seperti yang terlihat di grafik Setelah melakukan operasi evaluasi Davies-Bouldin Index (DBI) didapatkan nilai epsilon(ϵ) = 0.2727 dan minPts=6 dikarenakan memiliki nilai DBI yang paling kecil, setelah diketahui nilai

epsilon(ϵ) dan minPts adapun visualisasi penerapan algoritma DBSCAN pada gambar 3.



Gambar 3. Visualisasi hasil DBSCAN

Tanda silang merah pada visualisasi diatas menandakan *noise* sedangkan titik warna biru, hitam, ungu, biru muda, hijau dan kuning manandakan data yang terklaster. Hasil pengujian algoritma DBSCAN berdasarkan nilai epsilon(ϵ) dan minPts yang telah ditentukan sebelumnya, didapatkan 6 klaster dan 1 *noise*.

3.3 Evaluasi hasil

Hasil evaluasi klastering bertujuan untuk mengetahui kualitas klaster. Hasil evaluasi menggunakan Davies-Bouldin Index (DBI) didapatkan nilai sebesar 1.1753. Untuk hasil pengelompokan yang lebih detail dapat dilihat pada tabel 5.

Tabel 5. Hasil pengelompokkan DBSCAN

Cluster	Id_transaksi			
0 (noise) terdiri dari 138 data	'TX001619',	'TX001888',	'TX001610',	'TX002263',
	'TX000033',	'TX000177',	'TX002262',	'TX000395',
	'TX001122',	'TX001789',	'TX000548',	'TX001439',
	'TX000533',	'TX000477',	'TX000805',	'TX001532',
	'TX000039',	'TX001048',	'TX001275',	'TX001985',
	'TX001515', 'TX002150', 'TX000415', 'TX001310',...			
Cluster 1 terdiri dari 2344 data	'TX000881',	'TX002255',	'TX001633',	'TX000521',
	'TX000619',	'TX001355',	'TX001267',	'TX002260',

	'TX001184', 'TX000025', 'TX001642', 'TX001206', 'TX001423', 'TX000192', 'TX000264', 'TX001445', 'TX002012', 'TX000908', 'TX001051', 'TX000205', 'TX00240',
Cluster 2 terdiri dari 8 data	'TX001354', 'TX002202', 'TX000476', 'TX001282', 'TX002273', 'TX001918', 'TX001953', 'TX002404'
Cluster 3 terdiri dari 5 data	'TX001043', 'TX001284', 'TX000027', 'TX000509', 'TX000686'
Cluster 4 terdiri dari 4 data	'TX001083', 'TX001666', 'TX002373', 'TX000594'
Cluster 5 terdiri dari 6 data	'TX000670', 'TX001058', 'TX000267', 'TX000552', 'TX002054', 'TX001689'
Cluster 6 terdiri dari 7 data	'TX002493', 'TX001469', 'TX001507', 'TX001169', 'TX000565', 'TX001300', 'TX002272'

Untuk *noice* terdapat perbedaan dengan klaster 1 sampai 6, klaster 1 berwarna biru, klaster 2 biru muda, klaster 3 kuning, klaster 4 hijau, klaster 5 hitam, dan klaster 6 ungu. Perbedaannya dapat terlihat Ketika melakukan operasi rata-rata pada setiap variabel didalam *cluster* terdiri dari 3 variabel utama (x_1) jumlah transaksi, (x_2) saldo akhir, (x_3) frekuensi transaksi.. Berikut nilai disajikan dalam tabel 6.

Tabel 6. Rata-rata variabel setiap *cluster*

	Noice	Cluster 1	Cluster 2	Cluster 3	Cluster 4	Cluster 5	Cluster 6
X ₁	599.709	276.975	1455.367	168.814	120.877	91.658	292.178
X ₂	2.884	1	1	5	3	4	2
X ₃	6610.947	5065.454	1366.428	597.086	804.795	6321.751	903.751

Seperti yang terlihat didalam tabel, meskipun *noice* hanya memiliki 138 data dibandingkan dengan klaster 1 yang memiliki 2344 data, nilai rata-rata ketiga variabel *noice* lebih besar dari pada yang klaster 1. Untuk klaster lainnya dikarenakan jarak data terlalu rapat sehingga data terhitung sebagai klaster.

4. Kesimpulan

Salah satu metode *clustering* adalah algoritma DBSCAN. Berbeda dengan algoritma *clustering* yang membutuhkan penentuan kluster diawal, DBSCAN membentuk klasternya sendiri berdasarkan jarak/epsilon(ϵ) dan jumlah tetangga/minPts dalam data. Jika memenuhi syarat jangkauan jarak dan jumlah minimum tetangga maka data akan membentuk kluster sebaliknya jika tidak memenuhi syarat maka data akan dianggap sebagai *noise*.

Dalam penelitian ini algoritma DBSCAN dapat diterapkan untuk mendeteksi anomali transaksi dengan memperoleh beberapa Kesimpulan sebagai berikut:

- A. Algoritma DBSCAN menghasilkan 6 kluster berdasarkan nilai epsilon dan minPts yang telah ditentukan sebelumnya.
- B. Algoritma DBSCAN seperti yang terlihat pada gambar 3 mampu mengelompokkan kluster berdasarkan kepadatannya serta memisahkan data *noise*.
- C. Nilai evaluasi Davies-Bouldin Index (DBI) bisa dikatakan cukup baik. Berdasarkan gambar 3, algoritma DBSCAN mampu mengelompokkan data dengan baik berdasarkan tingkat kerapatan data.

Penelitian ini masih ada beberapa hal yang bisa dikembangkan seperti jumlah data, variable, atau mungkin beberapa penerapan metode reduksi variabel seperti pca dan lain sebagainya dengan harapan mendapatkan hasil yang lebih baik lagi nanti kedepannya.

5. Refrensi

- Dewi, S., Febria, G., & Anggraini, R. (2021). *PENGARUH TEKNOLOGI KEUANGAN TERHADAP PREFERENSI KONSUMEN MEMILIH UANG DIGITAL DALAM TRANSAKSI KEUANGAN (Studi Kasus Masyarakat Kota Bukittinggi)*. www.bi.go.id
- Polgan, J. M., Japit, S., Risyani, Y., Selamat, T., Bombongan, C., & Machine, S. V. (2024). *Deteksi Anomali Transaksi E-Commerce Menggunakan Support Vector Machine Berbasis Data Mining*. 13, 1976–1980.

- Simbolon, I. N., & Friskila, P. D. (2024). *ANALISIS DAN EVALUASI ALGORITMA DBSCAN SPATIAL CLUSTERING OF APPLICATIONS WITH NOISE) PADA TUBERKULOSIS*. 12(3).
- Arafat, I. B. F., Hariyadi, M. A., Santoso, I. B., & Crysdiyan, C. (2023). Clustering Gempabumi di Wilayah Regional VII Menggunakan Pendekatan DBSCAN. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 10(4), 823–830.
<https://doi.org/10.25126/jtiik.20241046918>
- Chopra, D., & Khurana, R. (2023). Introduction to Machine Learning with Python. In *Introduction to Machine Learning with Python*.
<https://doi.org/10.2174/97898151244221230101>
- Permatasari, N. A., Chrisnanto, Y. H., & Ningsih, A. K. (2023). Segmentasi Kasus Data Kematian Covid 19 Di Jawa Barat Menggunakan Algoritma DBSCAN. *IJESPG (International Journal of Engineering, Economic, Social Politic and Government)*, 1(4), 119–128.
- Schubert, E., Sander, J., Ester, M., Kriegel, H. P., & Xu, X. (2017). Why and How You Should (Still) Use DBSCAN. *ACM Transactions on Database Systems*, 42(3), 1–21.
- Xiao, J., Lu, J., & Li, X. (2017). Davies Bouldin Index based hierarchical initialization K-means. *Intelligent Data Analysis*, 21(6), 1327–1338.
<https://doi.org/10.3233/IDA-163129>
- Boer, A. F., Haris, M. Al, & Wasono, R. (2023). Pengelompokan Daerah Rawan Bencana di Pulau Sumatera dengan Metode Density Based Spatial Clustering of Applications with Noise (DBSCAN). *Seminar Nasional Unimus*, 389–400.
<https://prosiding.unimus.ac.id/index.php/semnas/article/download/1481/1485>
- Prihatmono, M. W. (2025). ANALISIS CLUSTERISASI PENGUNJUNG MALL BERDASARKAN USIA DAN PENDAPATAN MENGGUNAKAN ALGORITMA DBSCAN. *Nusantara Hasana Journal*, 4(9), 205–212.
<https://doi.org/10.59003/nhj.v4i9.1357>
- Rahma, I. (2022). Urgensi Peran Pusat Pelaporan Dan Analisis Transaksi Keuangan Dalam Penegakkan Hukum Tindak Pidana Pencucian Uang. *MAQASIDI: Jurnal Syariah Dan Hukum*, 2(2), 113–126. <https://doi.org/10.47498/maqasidi.vi.1311>

- Anwar, M. T., Hadikurniawati, W., Winarno, E., & Supriyanto, A. (2019). Wildfire Risk Map Based on DBSCAN Clustering and Cluster Density Evaluation. *Advance Sustainable Science, Engineering and Technology*, 1(1), 1–7. <https://doi.org/10.26877/asset.v1i1.4876>
- Lu, H. (2025). *Evaluating the Performance of SVM , Isolation Forest , and DBSCAN for Anomaly Detection*. 04012, 1–6.
- Al-Batah, M. S., Al-Kwaldeh, E. R., Wahed, M. A., Alzyoud, M., & Al-Shanableh, N. (2024). Enhancement over DBSCAN Satellite Spatial Data Clustering. *Journal of Electrical and Computer Engineering*, 2024. <https://doi.org/10.1155/2024/2330624>
- Hendarsyah, D. (2020). Analisis Perilaku Konsumen Dan Keamanan Kartu Kredit Perbankan. *JPS (Jurnal Perbankan Syariah)*, 1(1), 85–96. <https://doi.org/10.46367/jps.v1i1.204>

