

Penerapan K-Medoids untuk Pengelompokan Kepatuhan Wajib Pajak PBB di Kecamatan Bukit Kecil

Muhammad Raffi Firdaus[#], Iis Pradesan[#]

[#] Program Studi Sistem Informasi, Fakultas Ilmu Komputer dan Rekayasa, Universitas Multi Data Palembang, Palembang, Sumatera Selatan, Indonesia

E-mail: [mraffif5\[at\]gmail.com](mailto:mraffif5@gmail.com), [iis\[at\]mdp.ac.id](mailto:iis[at]mdp.ac.id)

ABSTRACTS

Land and Building Tax (PBB) is an important source of revenue for local governments. However, taxpayer compliance levels vary across regions, which makes the process of mapping and evaluation more challenging. This study aims to group PBB taxpayers in Bukit Kecil District based on their compliance levels using the K-Medoids algorithm. The research was conducted following the CRISP-DM stages, which include business understanding, data understanding, data preparation, modeling, evaluation, and deployment. The data used consist of PBB taxpayer data from 2018 to 2022 with attributes including Tax Object Number (NOP), sub-district, tax year, and payment status. Before the clustering process, the data underwent preprocessing stages such as cleaning, transformation, and normalization. The results indicate that the K-Medoids method is able to form several groups of taxpayers with different levels of compliance. This grouping provides an overview of taxpayer compliance patterns in the study area. Based on these results, it can be concluded that the K-Medoids algorithm can be used as an analytical tool to support evaluation and strategic planning of PBB management by the Regional Revenue Agency.

Manuscript received Jan 13, 2026;
revised Feb 24, 2026. accepted Feb
26, 2026 Date of publication Mar
31, 2026. International Journal,
JITSI : Jurnal Ilmiah Teknologi
Sistem Informasi licensed under a
Creative Commons Attribution-
Share Alike 4.0 International
License



ABSTRAK

Pajak Bumi dan Bangunan (PBB) merupakan salah satu sumber pendapatan penting bagi pemerintah daerah. Namun, tingkat kepatuhan wajib pajak di setiap wilayah tidak selalu sama sehingga menyulitkan proses pemetaan dan evaluasi. Penelitian ini bertujuan untuk mengelompokkan wajib pajak PBB di Kecamatan Bukit Kecil berdasarkan tingkat kepatuhan menggunakan algoritma K-Medoids. Penelitian dilakukan mengikuti tahapan CRISP-DM yang meliputi pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan penerapan. Data yang digunakan adalah data wajib pajak PBB periode 2018–2022 dengan atribut NOP, kelurahan, tahun pajak, dan status pembayaran. Sebelum proses klusterisasi, data terlebih dahulu melalui tahap pra-pemrosesan berupa pembersihan, transformasi, dan normalisasi. Hasil penelitian menunjukkan bahwa metode K-Medoids mampu membentuk beberapa kelompok wajib pajak dengan tingkat kepatuhan yang berbeda. Pengelompokan ini dapat memberikan gambaran pola kepatuhan wajib pajak di wilayah penelitian. Berdasarkan hasil tersebut, dapat disimpulkan bahwa algoritma K-Medoids dapat digunakan sebagai alat bantu analisis untuk mendukung evaluasi dan perencanaan strategi pengelolaan PBB oleh Badan Pendapatan Daerah.

Keywords / Kata Kunci — *K-Medoids; Data Mining; Taxpayer Compliance; Land and Building Tax; Clustering*

CORRESPONDING AUTHOR

Muhammad Raffi Firdaus
Program Studi Sistem Informasi, Fakultas Ilmu Komputer dan Rekayasa, Universitas Multi Data Palembang, Palembang,
Sumatera Selatan, Indonesia
Email: mraffif5[at]gmail.com

1. PENDAHULUAN

Masyarakat dan bisnis yang memiliki atau menggunakan bangunan dan tanah wajib membayar pajak yang disebut Pajak Tanah dan Bangunan (PBB). PBB merupakan sumber pendapatan utama yang membantu pemerintah daerah membiayai pembangunan [1]. Oleh karena itu, pendanaan PBB sangat penting untuk menjaga pertumbuhan daerah, khususnya di Kota Palembang.

Tingkat kepatuhan wajib pajak PBB sebenarnya bervariasi menurut daerah. Salah satu cara untuk mendefinisikan kepatuhan wajib pajak adalah seberapa baik masyarakat umum memahami dan ingin membayar pajak. Namun, ditemukan bahwa wajib pajak belum membayar PBB tepat waktu, yang telah menyulitkan daerah untuk mengumpulkan pajak.

Hal yang sama terjadi di Kecamatan Bukit Kecil, Kota Palembang. Untuk memahami pola kepatuhan wajib pajak, kita perlu melihat rendahnya tingkat kepatuhan pembayaran PBB. Pemerintah daerah harus memanfaatkan studi ini sebagai dasar untuk merumuskan kebijakan efektif yang bertujuan untuk meningkatkan kepatuhan pembayaran PBB dari tahun 2018 hingga 2022.

Studi ini dapat menggunakan metode K-Medoids. K-Medoids adalah cara untuk mengelompokkan data berdasarkan seberapa mirip objek satu sama lain dengan menggunakan medoid sebagai pusat kelompok [2]. Metode ini memiliki keunggulan mampu menciptakan kelompok data yang lebih stabil dan tidak terpengaruh oleh outlier [3]. Penelitian ini bertujuan untuk mengklasifikasikan wajib pajak PBB di Kabupaten Bukit Kecil berdasarkan tingkat kepatuhan mereka dengan menggunakan metode K-Medoids, memanfaatkan atribut seperti Nomor Objek Pajak (NOP), kecamatan, tahun pajak, dan status pembayaran.

2. METODOLOGI PENELITIAN

Studi ini menggunakan algoritma pengelompokan K-Medoids sebagai metodologi penambangan data kuantitatif. Strategi ini masuk akal karena metode K-Medoids bekerja lebih baik dengan dataset yang memiliki outlier. Metode pengelompokan K-Medoids lebih baik daripada K-Means dalam menangani dataset dengan outlier [4].

1. Sumber dan Jenis Data

Data penelitian diperoleh dari Badan Pendapatan Daerah (Bapenda) Kota Palembang berupa data Wajib Pajak PBB Kecamatan Bukit Kecil periode 2018–2022, dengan atribut NOP, Kelurahan, Tahun Pajak, dan Status Pembayaran. Pendekatan penggunaan data historis multi-tahun untuk analisis kepatuhan pajak merupakan metode yang umum pada penelitian PBB seperti pada penelitian sebelumnya, di mana data pembayaran pajak dianalisis dalam rentang waktu tertentu untuk menentukan tingkat kepatuhan wajib pajak [5].

2. Tahapan CRISP-DM


Model pengembangan ini didasarkan pada fase CRISP-DM. Metode CRISP-DM memiliki enam langkah: Pemahaman Bisnis, Pemahaman Data, Persiapan Data, Pemodelan, Evaluasi, dan Penerapan. Gambar 1 menunjukkan cara menganalisis hal tersebut [6].

1. Business Understanding

Pengetahuan Bisnis: Ini mencakup memahami kebutuhan dan tujuan proyek secara detail dalam unit penelitian atau lingkup bisnis, mengubah kebutuhan dan tujuan tersebut menjadi formulasi masalah penambangan data, dan membuat rencana kasar untuk mencapai tujuan tersebut [7].

2. Data Understanding

"Pemahaman Data," yang merupakan langkah pertama dalam proses persiapan, melibatkan pengumpulan data awal memeriksa kualitasnya, dan memastikan data yang digunakan benar. Setiap bagian data akan dijelaskan saat



GAMBAR 1. Tahapan CRISP-DM

- diinterpretasikan [8].
3. Data Preparation
Untuk memperbaiki masalah data dan mendapatkan hasil yang diinginkan, langkah ini digunakan [9].
4. Modeling
Fase ini adalah tentang memilih model penambangan data yang tepat [10] untuk menyelesaikan masalah bisnis yang telah disebutkan. [10].
5. Evaluation
Tahap ini berfokus pada pengujian dan penilaian model untuk memastikan mereka memenuhi tujuan bisnis [11].
6. Deployment
Deployment adalah fase implementasi hasil model dan hasil analisis ke dalam lingkungan bisnis [12].

3. HASIL DAN PEMBAHASAN

Proses klasterisasi pada penelitian ini mengikuti alur CRISP-DM. Pada tahap *Business Understanding* dan *Data Understanding*, dilakukan analisis kebutuhan pemetaan kepatuhan wajib pajak serta penelaahan struktur data pembayaran PBB. Tahap *Data Preparation* mencakup pembersihan data, perhitungan persentase kepatuhan, dan pemilihan fitur utama untuk proses klasterisasi. Selanjutnya, tahap *Modeling* menerapkan algoritma K-Medoids melalui sistem klasterisasi yang dikembangkan. Hasil yang ditampilkan pada bab ini merupakan keluaran dari proses *Evaluation* dan *Deployment* dalam CRISP-DM.

Secara umum, nilai persentase kepatuhan pada dataset menunjukkan distribusi yang tidak merata. Sebagian besar wajib pajak berada pada nilai ekstrem, yaitu sangat tinggi ($\geq 80\%$) atau sangat rendah (0%), sementara kelompok menengah relatif lebih sedikit. Pola distribusi ini menegaskan pentingnya proses klasterisasi untuk mengidentifikasi pengelompokan perilaku pembayaran secara lebih terstruktur. Selain itu, karakteristik data yang mengandung nilai ekstrem memperkuat pemilihan algoritma K-Medoids karena metode ini lebih stabil terhadap outlier dibandingkan algoritma centroid.

1. Data Preparation

Dataset penelitian terdiri dari 423 NOP yang memiliki riwayat pembayaran PBB selama lima tahun (2018–2022). Pada tahap ini dilakukan beberapa prosedur penting untuk memastikan kualitas data.

1. Pemeriksaan Konsistensi Data
Setiap NOP diperiksa apakah memiliki jumlah tahun catatan yang konsisten. Pada proses ini ditemukan beberapa entri yang tidak lengkap sehingga perlu diperbaiki melalui *data cleaning*. Langkah ini penting agar perhitungan persentase kepatuhan tidak bias.
2. Penanganan Data Tidak Valid dan Duplikasi
Sistem mendeteksi adanya data duplikat pada beberapa entri tahun pajak yang sama. Seluruh duplikasi dihapus agar tidak menyebabkan distorsi nilai kepatuhan.
3. Rekonstruksi Riwayat Pembayaran
Untuk setiap NOP dihitung.
 - total tahun pengamatan (5),
 - jumlah tahun patuh ($\text{status} = 1$),
 - jumlah tahun tidak patuh ($\text{status} = 0$),
 - dan persentase kepatuhan yang menjadi fitur utama.
4. Justifikasi Pemilihan Fitur
Dari seluruh atribut, Persentase Patuh (%) dipilih karena.
 - memberi representasi paling ringkas,
 - memudahkan interpretasi,
 - cocok untuk K-Medoids yang berbasis perbedaan numerik antar objek.
 Tahap preparation ini menghasilkan data yang lebih stabil untuk proses pemodelan.

2. Penentuan Jumlah Cluster (K)

Jumlah klaster ditetapkan menjadi $k = 5$ sehingga kepatuhan dapat dibagi menjadi lima kelompok: sangat rendah, rendah, cukup rendah, cukup tinggi, dan sangat tinggi. Pilihan ini juga menghasilkan distribusi klaster yang stabil dan mudah dipahami dalam konteks manajemen kepatuhan wajib pajak dan kebijakan peningkatan kepatuhan.

3. Proses Klasterisasi Menggunakan K-Medoids

Metode K-Medoids, yang berbeda dari K-Means, memberikan perlindungan yang lebih kuat terhadap noise dan outlier. K-Medoids menggunakan item data nyata sebagai pusat klaster (medoid), sedangkan K-Means menggunakan centroid yang dihitung. Metode ini membuat K-Medoids lebih stabil saat bekerja dengan data yang tidak terdistribusi normal atau memiliki fitur dengan ukuran yang berbeda. [13].

K-Medoids bekerja dengan mencari objek yang menjadi pusat cluster (medoid). Pada penelitian ini, jarak antar objek dihitung menggunakan Manhattan Distance sehingga lebih sensitif terhadap perbedaan absolut nilai kepatuhan. Tahapan teknis proses K-Medoids dalam penelitian.

1. Inisialisasi medoid awal, Sistem memilih lima nilai persentase kepatuhan dari dataset sebagai kandidat pusat.
 2. Perhitungan jarak setiap NOP ke kelima medoid, Setiap nilai %Patuh dibandingkan dengan seluruh medoid menggunakan $|x_i - m_j|$.
 3. Pembentukan cluster awal, NOP dikelompokkan berdasarkan jarak terdekat.
 4. Evaluasi cost cluster. Cost dihitung sebagai total jarak semua NOP terhadap medoid terdekat.
 5. Proses swap, Medoid diuji dengan menukar posisi dengan non-medoid. Swap diterima jika cost menurun.
 6. Konvergensi, Iterasi berhenti ketika tidak ada swap yang menghasilkan perbaikan cost.
- Tahapan ini menghasilkan cluster yang paling stabil dan optimal untuk dataset kepatuhan pajak.

4. Perhitungan Sederhana dengan $K = 5$

Algoritma K-Medoids digunakan pada data studi dengan enam NOP dari dataset wajib pajak Pajak Tanah dan Bangunan (PBB) Kabupaten Bukit Kecil. Keenam NOP ini dipilih karena mencakup seluruh rentang tingkat kepatuhan, dari 0% hingga 100%. Contoh ini dengan jelas menunjukkan cara menghitung jarak, menemukan medoid, menentukan biaya, dan bertukar informasi.

- a. Data yang digunakan ada pada Tabel 1.

Tabel 1. Data Perhitungan K-Medoids			
No	NOP	% Patuh	Nilai Desimal
1	167111000100100590	100%	1.00
2	167111000100100040	80%	0.80
3	167111000100700930	60%	0.60
4	167111000101200220	40%	0.40
5	167111000100100230	20%	0.20
6	167111000100100260	0%	0.00

- b. Inisialisasi Medoid ($k = 5$)
Lima medoid dipilih secara acak dari dataset awal.

$$M = \{1.00, 0.80, 0.60, 0.20, 0.00\} \quad (1)$$

Nilai 0.40 (NOP 167111000101200220) menjadi kandidat *swap* (non-medoid).
Metode jarak.

$$d(x_i, m_j) = |x_i - m_j| \quad (2)$$

- c. Perhitungan Jarak ke Lima Medoid pada Tabel 2.

Tabel 2. Jarak Setiap Data ke Medoid							
NOP	Nilai	1.00	0.80	0.60	0.20	0.00	Jarak Terdekat
167111000100100590	1.00	0.00	0.20	0.40	0.80	1.00	0.00
167111000100100040	0.80	0.20	0.00	0.20	0.60	0.80	0.00
167111000100700930	0.60	0.40	0.20	0.00	0.40	0.60	0.00
167111000101200220	0.40	0.60	0.40	0.20	0.20	0.40	0.20
167111000100100230	0.20	0.80	0.60	0.40	0.00	0.20	0.00
167111000100100260	0.00	0.80	0.80	0.60	0.20	0.00	0.00

- d. Perhitungan Cost Awal
Cost awal dihitung sebagai.
 $Cost = 0.20 \quad (3)$
- e. Keputusan Swap
Karena.
 $Cost = 0.20 \quad (4)$
Swap ditolak, dan medoid awal dipertahankan.

5. Hasil Klasterisasi

Proses klasterisasi menghasilkan pengelompokan wajib pajak ke dalam lima cluster yang berbeda. Setiap cluster memiliki pola kepatuhan yang unik berdasarkan nilai persentase patuh. Ringkasan hasil klasterisasi ditunjukkan pada Tabel 3.

Tabel 3. Hasil Klasterisasi Tingkat Kepatuhan

Cluster	Rata-rata % Patuh	Jumlah NOP	Tingkat Kepatuhan
Cluster 5	96.53%	242	Sangat Tinggi
Cluster 4	60%	17	Cukup Tinggi
Cluster 3	40%	22	Cukup Rendah
Cluster 2	20%	36	Rendah
Cluster 1	0%	106	Sangat Rendah

6. Pembahasan Hasil Klasterisasi

- Cluster 5 – Sangat Tinggi (242 NOP), Memiliki rata-rata kepatuhan 96.53%. Kelompok ini menunjukkan perilaku pembayaran pajak yang sangat konsisten.
- Cluster 4 – Cukup Tinggi (17 NOP), Rata-rata kepatuhan 60%. Terdapat beberapa tahun keterlambatan pembayaran.
- Cluster 3 – Cukup Rendah (22 NOP), Rata-rata kepatuhan 40%. Kelompok ini tidak stabil dalam pembayaran dan memerlukan pendekatan persuasif.
- Cluster 2 – Rendah (36 NOP), Rata-rata kepatuhan 20%. Mayoritas tahun tidak dilakukan pembayaran.
- Cluster 1 – Sangat Rendah (106 NOP), Tidak ada satu pun tahun pembayaran (0%). Termasuk kelompok prioritas evaluasi dan penanganan.

7. Implikasi Kebijakan

- Cluster 1 & 2: memerlukan tindakan intensif, termasuk edukasi, verifikasi lapangan, dan pengawasan.
- Cluster 3: membutuhkan strategi komunikasi dan pengingat jatuh tempo.
- Cluster 4 & 5: perlu dipertahankan melalui peningkatan layanan dan kemudahan pembayaran digital.
- Segmentasi berbasis cluster ini dapat digunakan sebagai dasar kebijakan penagihan PBB yang lebih terarah dan efektif.

8. Evaluasi Model Klasterisasi

Evaluasi model dilakukan untuk menentukan kecukupan pembangkitan klaster algoritma K-Medoids. Untuk mencapai hal ini, kepadatan data di dalam setiap klaster dan jarak antar klaster dianalisis. Dalam penelitian ini, Klaster 1 dan Klaster 5 tampak paling padat, dengan tingkat kepatuhan masing-masing 0% dan 96–100%. Di sisi lain, jarak antar medoid jelas menunjukkan pemisahan antara kelompok yang sangat patuh dan kelompok yang tidak patuh. Berdasarkan hasil ini, model pengelompokan yang dibuat dapat dilihat sebagai stabil dan secara akurat menunjukkan bagaimana tingkat kepatuhan wajib pajak berubah.

9. Implementasi Sistem Klasterisasi

Algoritma K-Medoids dibuat dengan PHP dan MySQL dalam sistem berbasis web. Algoritma K-Medoids digunakan oleh sistem di web. Sistem ini menghitung jarak, memilih medoid, dan mengelompokkan data secara otomatis. Produk akhirnya adalah tabel temuan klaster dan ringkasan nilai kepatuhan yang dapat digunakan untuk analisis lebih lanjut. Sistem ini membuat tabel hasil klaster, ringkasan data persentase kepatuhan, dan statistik untuk setiap klaster. Proses komputasi penuh yang konsisten dari sistem ini mempermudah analisis dan memungkinkan saran kebijakan dibuat dengan cepat berdasarkan hasilnya.

Secara keseluruhan, hasil klasterisasi memberikan gambaran yang komprehensif mengenai pola kepatuhan wajib pajak dan dapat menjadi dasar analisis lanjutan dalam perumusan kebijakan pada tingkat kecamatan maupun kota

4. KESIMPULAN

Berdasarkan hasil penelitian dan penerapan algoritma K-Medoids terhadap 423 data Wajib Pajak PBB Kecamatan Bukit Kecil periode 2018–2022, diperoleh beberapa kesimpulan sebagai berikut.

- Algoritma K-Medoids berhasil mengelompokkan wajib pajak ke dalam lima cluster tingkat kepatuhan dengan karakteristik yang berbeda, yaitu sangat rendah, rendah, cukup rendah, cukup tinggi, dan sangat tinggi.
- Distribusi cluster menunjukkan adanya ketimpangan kepatuhan, di mana dua kelompok terbesar berada pada ekstrem yang berlawanan, yaitu Cluster 5 (242 NOP; 96.53% kepatuhan) dan Cluster 1 (106 NOP; 0% kepatuhan). Hal ini mengindikasikan bahwa sebagian WP sangat patuh, sementara sebagian besar lainnya sama sekali tidak melakukan pembayaran.
- K-Medoids terbukti mampu menghasilkan klaster yang stabil terhadap data ekstrem seperti persentase 0% atau 100%, sehingga metode ini sesuai digunakan dalam analisis kepatuhan PBB yang memiliki variasi data signifikan.

4. Hasil klasterisasi ini membantu menunjukkan pembagian wajib pajak berdasarkan tingkat kepatuhannya, sehingga dapat dijadikan acuan dalam proses penagihan ataupun pemantauan.

UCAPAN TERIMAKASIH

Data wajib pajak PBB yang digunakan dalam penelitian ini berasal dari Dinas Pendapatan Daerah Kota Palembang (Bapenda), dan penulis sangat berterima kasih atas hal tersebut. Beliau juga berterima kasih kepada semua pihak yang telah membantu dan memberikan saran selama tahap perencanaan agar penelitian ini berjalan lancar.

REFERENSI

- [1] M. . Sotarduga Sihombing, S.Pd., M.M , Susy Alestriani Sibagariang, S.Pd., *Perpajakan: Teori dan Aplikasi*. 2020.
- [2] F. Alfiah, D. Al Farizi, dan E. Widodo, “Analisis Clustering K-Medoids Berdasarkan Indikator Kemiskinan di Jawa Timur Tahun 2020 K-Medoids Clustering Analysis Based on Poverty Indicators in East Java in 2020,” vol. 22, no. April, hal. 1–7, 2022.
- [3] A. Ayu, D. Sulistyawati, dan M. Sadikin, “Penerapan Algoritma K - Medoids untuk Menentukan Segmentasi Pelanggan,” vol. 10, hal. 516–526, 2021.
- [4] M. Orisa dan A. Faisol, “Analisis Algoritma Partitioning Around Medoid untuk Penentuan Klasterisasi,” vol. 8, no. 2, hal. 86–90, 2021.
- [5] M. A. Putri, N. Rahaningsih, F. M. Basysyar, dan O. Nurdian, “Penerapan Data Mining Menggunakan Metode Clustering Untuk Mengetahui Kelompok Kepatuhan Wajib Pajak Bumi dan Bangunan,” *J. Account. Inf. Syst. (AIMS)*, vol. 5, no. 2, hal. 145–156, 2022, doi: 10.32627.
- [6] Y. Yudiana, A. Yulia, dan N. Khofifah, “Prediksi Customer Churn Menggunakan Metode CRISP-DM Pada Industri Telekomunikasi Sebagai Implementasi Mempertahankan Pelanggan,” vol. 8, no. 1, hal. 1–20, 2023.
- [7] D. A. Dzulhijjah, M. B. Herlambang, M. Haifan, P. Studi, P. Insinyur, dan T. Selatan, “Implementasi framework crisp-dm untuk proses data mining aplikasi credit scoring pt. xyz,” hal. 238–251, 2024.
- [8] P. Studi, T. Informatika, F. I. Komputer, U. Singaperbangsa, dan A. K-means, “Implementasi K-Means Clustering untuk Pengelompokan Daerah Rawan Bencana Kebakaran Menggunakan Model,” vol. 12, hal. 64–77, 2022, doi: 10.34010/jati.v12i1.
- [9] J. Nasional, S. Informasi, T. Angelya, A. Rahman, dan I. Pradesan, “Implementasi Sistem Klasifikasi Tim Kerja Menggunakan Algoritma Naïve Bayes (Studi Kasus : PT . MNL),” vol. 02, hal. 86–94, 2023.
- [10] I. Fitrianti, A. Voutama, Y. Umaidah, S. Informasi, dan T. Timur, “Clustering Film Populer Pada Aplikasi Netflix Dengan Menggunakan Algoritma K-Means Dan Metode CRISP-,” vol. 4, no. 2, hal. 301–311, 2023.
- [11] S. Santiastry dkk., “PENERAPAN ALGORITMA NAIVE BAYES DAN METODE CRISP-DM DALAM,” vol. 8, no. 5, hal. 10432–10439, 2024.
- [12] R. Winurputra dan D. E. Ratnawati, “PERAMALAN PENJUALAN PRODUK MENGGUNAKAN EXTREME GRADIENT BOOSTING (XGBOOST) DAN KERANGKA KERJA CRISP-DM UNTUK PENGOPTIMALAN MANAJEMEN PERSEDIAAN (STUDI KASUS : UB MART) PRODUCT SALES FORECASTING USING EXTREME GRADIENT BOOSTING (XGBOOST) AND CRISP-DM FRAMEWORK FOR INVENTORY MANAGEMENT OPTIMIZATION (CASE STUDY : UB MART),” vol. 12, no. 2, hal. 417–428, 2025, doi: 10.25126/jtiik.2025129451.
- [13] E. R. Arya Pratama Putra, Jihan Tshivana, “PERBANDINGAN TEORITIS DAN EKSPERIMEN ALGORITMA K-MEANS DAN K-MEDOIDS DALAM KLASTERISASI DATA,” vol. 10, no. 2, hal. 1–24, 2025