

Pengelompokan Mahasiswa Calon Penerima Bantuan Pendidikan UPZ UNP Menggunakan Metode Simple K-Medoids Partitioning

Venia Wulan Dari, Devni Prima Sari

Departemen Matematika, Universitas Negeri Padang

Article Info

Article history:

Received July 29, 2025
Revised August 5, 2025
Accepted September 5, 2025

Keywords:

UPZ UNP
Gower Distance
Simple K-Medoids Partitioning
Medoid Shadow Value

Kata Kunci:

UPZ UNP
Jarak Gower
Simple K-Medoids Partitioning
Medoid Shadow Value

ABSTRACT

UPZ UNP is a Zakat Collector established by BAZNAS West Sumatra within the UNP environment. The manual selection process for educational assistance recipients is considered inefficient. The Simple K-Medoids Partitioning method with Gower distance was applied in this study to objectively group student data. The data used comes from UPZ UNP for the period July-December 2024. Tests were conducted from two to seven clusters, and validation using Medoid Shadow Value showed that cluster two was the best result with a value of 0.4632. The 45th and 146th objects became the cluster centers. The final results showed that cluster one consisted of 405 students and cluster two consisted of 265 students. Judging from the characteristics of the clusters, cluster two was prioritized as a potential recipient of assistance. The results of this study are expected to assist UPZ UNP in making decisions more precisely and efficiently.

ABSTRAK

UPZ UNP merupakan Amil Zakat yang dibentuk oleh BAZNAS Sumatera Barat di lingkungan UNP. Proses seleksi penerima bantuan pendidikan yang masih manual dinilai kurang efisien. Metode Simple K-Medoids Partitioning dengan jarak Gower diterapkan dalam penelitian ini untuk melakukan pengelompokan data mahasiswa secara objektif. Data yang digunakan berasal dari UPZ UNP periode Juli-Desember 2024. Uji dilakukan dari dua hingga tujuh klaster, dan validasi menggunakan Medoid Shadow Value menunjukkan bahwa klaster dua adalah hasil terbaik dengan nilai 0,4632. Objek ke-45 dan ke-146 menjadi pusat klaster. Hasil akhir menunjukkan klaster satu terdiri dari 405 mahasiswa dan klaster dua sebanyak 265 mahasiswa. Dilihat dari karakteristik klasternya, klaster dua diprioritaskan sebagai calon penerima bantuan. Hasil penelitian ini diharapkan dapat membantu UPZ UNP dalam pengambilan keputusan secara lebih tepat dan efisien.

This is an open access article under the [CC BY-SA](#) license.



Penulis Korespondensi:

Venia Wulan Dari

Departemen Matematika, Universitas Negeri Padang,
Email: veniawulandari737@gmail.com

1. PENDAHULUAN

Pendidikan merupakan aspek fundamental dalam pembangunan manusia dan kemajuan bangsa. Pendidikan tinggi memegang peranan strategis dalam mencetak lulusan yang berkualitas, profesional, dan dapat berkompetisi dalam era globalisasi yang penuh persaingan [1]. Namun, partisipasi masyarakat dalam pendidikan tinggi di Indonesia masih rendah, sebagaimana terlihat dari Angka Partisipasi Kasar (APK) tahun 2024 yang hanya mencapai 32%, salah satu penyebab utamanya adalah kendala ekonomi [2] [3]. Untuk mengatasi hal ini, berbagai lembaga termasuk Unit Pengumpul Zakat Universitas Negeri Padang (UPZ UNP) menyalurkan bantuan pendidikan kepada mahasiswa yang membutuhkan.

UPZ UNP sebagai Lembaga Amil Zakat di lingkungan Universitas Negeri Padang menghimpun dan menyalurkan dana ZIS dari ASN untuk bantuan pendidikan. Dana ZIS yang terkumpul kemudian dialokasikan untuk bantuan pendidikan bagi Mahasiswa UNP [4]. Bantuan beasiswa ini umumnya diberikan berdasarkan kondisi ekonomi keluarga, terutama penghasilan orang tua, dan sangat ditujukan untuk peserta didik berprestasi yang mengalami keterbatasan finansial. Beasiswa seperti ini mencerminkan prinsip pemberdayaan sosial melalui akses pendidikan bagi kaum kurang mampu. [5]. Meskipun proses pendaftaran dilakukan secara online, penentuan kelayakan penerima bantuan masih bersifat manual, sehingga kurang efisien mengingat banyaknya jumlah pendaftar. Pada periode Juli–Desember 2024 tercatat 684 mahasiswa mendaftar, sehingga diperlukan sistem pendukung keputusan yang objektif, cepat, dan berbasis data [6].

Pendekatan yang bisa digunakan dalam penelitian adalah analisis klaster, yaitu metode untuk mengelompokkan mahasiswa sesuai dengan karakteristik yang dimilikinya. Analisis klaster berperan sebagai sarana eksploratif dalam mengidentifikasi pola dalam data, di mana objek-objek dalam satu klaster bersifat seragam, sedangkan antar klaster menunjukkan perbedaan [7]. Metode pengelompokan dikategorikan menjadi dua, yaitu hirarki dan non-hirarki. Metode non-hirarki lebih dipilih karena mampu menghemat waktu komputasi pada data berukuran besar. Metode ini menetapkan jumlah klaster k sejak awal, meskipun memiliki kelemahan terkait keberadaan *outlier*, pemilihan ukuran jarak, serta variabel yang kurang relevan. Sebaliknya, metode hirarki cenderung kurang efisien untuk data berskala besar dan menghadapi kendala serupa, seperti sensitivitas terhadap *outlier*, perbedaan ukuran jarak, serta penggunaan variabel yang tidak tepat. Beberapa metode non-hirarki yang umum digunakan antara lain *k-means* dan *k-medoids*.

Mengacu pada penelitian terdahulu mengenai penerapan metode *Simple K-Medoids Partitioning* pada pengelompokan Sekolah Menengah Atas (SMA) berdasarkan komponen kesiapan teknologi informasi [8]. Penelitian ini memberikan kesimpulan bahwa pengelompokan menggunakan *seeding* = 20 dan *iterate* = 10 memperlihatkan bahwa klaster $k = 2$ merupakan klaster yang optimal. Dan penelitian yang dilakukan oleh [9] yang berjudul Efektivitas Algoritma *K-Means*, *K-Medoids*, dan Optimal Jumlah klaster Untuk Modifikasi Algoritma *K-Medoids* Pada Kumpulan Data Besar. Penelitian tersebut membandingkan rata-rata waktu komputasi algoritma *k-means*, *k-medoids* dan modifikasi *k-medoids*, dengan hasil bahwa algoritma modifikasi *k-medoids* memiliki waktu komputasi lebih cepat pada data berukuran besar.

Simple K-Medoids Partitioning (SKM) merupakan salah satu varian dari *K-Medoids* yang dikembangkan untuk mengelompokkan data dengan variabel campuran (numerik, biner, dan kategorik). Algoritma ini memanfaatkan *medoid* sebagai pusat klaster dan dirancang untuk mengatasi permasalahan *local optima* serta terbentuknya klaster kosong pada *k-medoids*. Permasalahan *local optima* terjadi karena inisialisasi pusat klaster dilakukan secara acak, sehingga hasil pengelompokan tidak konsisten. Untuk mengatasi hal tersebut, SKM diterapkan sebagai alternatif dalam pengelompokan data bertipe campuran. [10].

Penelitian ini akan mengelompokkan mahasiswa calon penerima bantuan pendidikan UPZ UNP berdasarkan variabel campuran menggunakan jarak *Gower*. Validasi hasil klaster dilakukan dengan *Medoid Shadow Value* (MSV).

2. METODE

Jenis penelitian ini merupakan penelitian terapan. Jenis data yang digunakan pada penelitian ini adalah data sekunder. Sumber data dalam penelitian diperoleh dari Direktorat Kemahasiswaan dan Alumni UNP, berupa dataset 669 mahasiswa pendaftar bantuan pendidikan UPZ UNP periode Juli-Desember tahun 2024. Penelitian ini menggunakan 7 variabel yang merupakan karakteristik dari data pendaftar bantuan pendidikan UPZ UNP. Variabel yang digunakan dalam penelitian ini adalah IPK (X_1), status ayah (X_2), status ibu (X_3), semester (X_4), penghasilan ayah (X_5), penghasilan ibu (X_6) dan status rumah (X_7). Pengelompokan data menggunakan metode *Simple K-Medoids Partitioning* dengan bantuan *software R*.

Tahapan analisis data yang dilakukan pada penelitian ini adalah sebagai berikut:

- Menyediakan data yang akan digunakan dalam pengelompokan.

Data dalam penelitian diperoleh dari Direktorat Kemahasiswaan dan Alumni UNP. Data diinputkan ke dalam *Microsoft Excel*. Kemudian akan diolah menggunakan *R Studio* dan *Microsoft Excel*.

- Melakukan analisis deskriptif untuk data numerik dan data kategorik.

Analisis deskriptif digunakan untuk menggambarkan karakteristik data yang akan digunakan dalam penelitian ini. Pada tahap ini, peneliti akan memberikan gambaran data yang akan digunakan dalam penelitian.

- Menghitung ukuran jarak *Gower* data campuran [11]. Jarak Gower dihitung menggunakan persamaan 1.

$$d_{ij} = \left\{ \frac{1}{p_n + p_b + p_c} \left[\sum_{r=1}^{p_n} \frac{1}{R_r} |x_{ir} - x_{jr}| + p_b \sum_{t=1}^{p_b} \delta_b(x_{it}, x_{jt}) + p_c \sum_{s=1}^{p_c} \delta_c(x_{is}, x_{js}) \right] \right\} \quad (1)$$

- Melakukan pengelompokan data menerapkan metode *Simple K-Medoids Partitioning* (SKM).

Algoritma SKM memiliki tahapan sebagai berikut [9]:

- Langkah awal dilakukan dengan memilih satu set *medoid* awal M_k dari himpunan objek X_n . *Medoid* awal dipilih dari objek yang paling sentral, di mana inisialisasi acak yang diulang beberapa kali dianggap sebagai pendekatan terbaik. Untuk menghindari keterbatasan, salah satu medoid acak digantikan oleh objek yang paling sentral. *Medoid* optimal untuk $k = 1$ adalah objek yang berada di pusat dengan meminimalkan total jarak terhadap objek lain, sedangkan penentuan objek paling sentral dapat dilakukan melalui jumlah baris atau kolom dari matriks jarak sesuai dengan persamaan 2.

$$a_i = \sum_{j=1}^n d_{ij} = \sum_{j=1}^n d_{ji}, \quad i = 1, 2, 3, \dots, n \quad (2)$$

Dimana:

a_i = jumlah jarak dari objek ke- i menuju objek ke- j

Jika vektor a_i diurutkan, maka M_k pertama dipilih dari nilai terkecil, yang objek yang berada pada posisi paling sentral.

- Setiap objek $x_n \in X_n$, $l(x_n)$ diberi label atau keanggotaan pada *medoid* M_k yang memiliki jarak terdekat.
- Perbaharui set *medoid* M_k baru dengan mempertahankan label klaster $l(x_n)$ yang tetap dengan Persamaan 3.

$$m_p := \underset{p \in K}{\operatorname{argmin}} \sum_{n:l(x_n)=m_p} d(x_n, m_p), \quad p = 1, 2, 3, \dots, k \quad (3)$$

Dimana:

m_p = Objek yang meminimalkan total jarak terhadap anggota lain dalam satu klaster.

4. Hitung total jarak tiap klaster (E), yaitu jarak antara setiap objek dengan medoidnya sebagaimana ditunjukkan pada Persamaan 4.

$$E = \sum_{p=1}^k \sum_{n:l(x_n)=m_p} d(x_n, m_p) \quad (4)$$

5. Ulangi langkah 2 – 4 sampai nilai E tidak berubah dari iterasi sebelumnya, himpunan *medoid* tetap sama, atau jumlah iterasi maksimum telah tercapai.
6. Untuk memperoleh beberapa *seeding* acak dari *medoid* awal, langkah 1–5 dilakukan berulang. Objek yang terletak di pusat klaster dipilih sebagai *medoid* awal, dan *medoid* final ditentukan dari nilai E paling kecil.
7. Tetapkan keanggotaan setiap objek pada *medoid* akhir yang memiliki jarak terdekat.
- e. Memvalidasi klaster dengan *Medoid Shadow Value* (MSV).
- Nilai MSV dihitung dengan menggunakan rumus yang ditunjukkan pada Persamaan 5 [12].
- $$msv = \frac{d[x, m'(x)] - d[x, m(x)]}{d[x, m'(x)]} \quad (5)$$
- f. Menginterpretasi hasil pengklasteran.

3. HASIL DAN PEMBAHASAN

3.1. Gambaran Data Penelitian

Sebelum analisis pengelompokan diperlukan gambaran data mahasiswa calon penerima bantuan pendidikan UPZ UNP periode Juli-Desember 2024. Dari data terdapat 7 kriteria yang digunakan dalam penelitian. Kriteria tersebut ialah IPK (X_1), status ayah (X_2), status ibu (X_3), semester (X_4), penghasilan ayah (X_5), penghasilan ibu (X_6), dan status rumah (X_7). Data tersebut ditampilkan pada Tabel 1.

Tabel 1. Gambaran Data Penelitian

Kode Mahasiswa	X_1	X_2	X_3	X_4	X_5	X_6	X_7
A1	3,04	1	0	0	5	5	0
A2	3,28	0	0	1	4	5	0
A3	3,59	0	0	1	4	5	3
A4	3,59	0	0	0	4	5	3
A5	3,41	0	0	0	1	5	3
:	:	:	:	:	:	:	:
A669	3,31	1	0	0	5	4	3

3.2. Pengukuran Jarak *Gower* Objek Variabel Campuran

Kedekatan antar objek dengan variabel campuran diukur menggunakan jarak *Gower*. Pada data numerik digunakan rentang terbobot *Manhattan*, sedangkan untuk data biner dan kategorik diterapkan metode *simple matching*. Hasil perhitungan jarak data campuran dilihat pada Tabel 2.

Tabel 2. Matriks Jarak *Gower* Data Campuran

	A1	A2	A3	A4	A5	...	A669
A1	0	0,47	0,66	0,51	0,49	...	0,33
A2	0,47	0	0,19	0,33	0,45	...	0,72
A3	0,66	0,19	0	0,14	0,31	...	0,61
A4	0,51	0,33	0,14	0	0,17	...	0,47
A5	0,49	0,45	0,31	0,17	0	...	0,44
:	:	:	:	:	:	..	:
A669	0,33	0,72	0,61	0,47	0,44	...	0

Jarak data campuran merepresentasikan tingkat ketidakmiripan antar objek. Nilai jarak 1 menunjukkan kedekatan yang lemah, sedangkan nilai 0 menandakan kedekatan yang sangat kuat.

3.3. Pengelompokan Menggunakan *Simple K-Medoids Partitioning* (SKM)

Dalam penelitian ini, pengelompokan mahasiswa calon penerima bantuan pendidikan UPZ UNP dilakukan dengan 2 kelompok menggunakan perangkat lunak *R studio*. Proses pengelompokan dijalankan dengan *set.seed* (1), *seeding* = 20 dan *iterate* = 10. Penggunaan *set.seed* (1) bertujuan untuk memastikan hasil dapat direproduksi pada mesin yang berbeda. Pemilihan *seeding* = 20 menunjukkan bahwa pembaruan *medoid* awal dilakukan 20 kali, dengan *iterate* paling tinggi 10 kali pada setiap *seeding*. Ringkasan proses pengelompokan dengan *seeding* = 20 ditampilkan pada Tabel 3.

Tabel 3. Ringkasan Hasil Pengelompokan dengan *Seeding* = 20

<i>Seeding</i>	Iterasi	<i>Medoid</i>		Nilai E	<i>Seeding</i>	Iterasi	<i>Medoid</i>		Nilai E
		M1	M2				M1	M2	
1	Awal	A313	A663	161,1677	11	Awal	A196	A663	163,6087
	Akhir	A320	A606	148,9193		Akhir	A382	A635	148,8634
2	Awal	A275	A663	173,8245	12	Awal	A449	A663	164,6056
	Akhir	A427	A606	150,823		Akhir	A104	A505	150,427
3	Awal	A330	A663	163,4907	13	Awal	A196	A663	163,6087
	Akhir	A45	A146	144,2748		Akhir	A382	A635	148,8634
4	Awal	A423	A663	159,6335	14	Awal	A363	A663	162,9969
	Akhir	A45	A146	144,2748		Akhir	A104	A505	150,427
5	Awal	A525	A663	163,5714	15	Awal	A366	A663	156,4612
	Akhir	A320	A606	148,9193		Akhir	A104	A505	150,427
6	Awal	A525	A663	163,5714	16	Awal	A116	A663	186,5342
	Akhir	A320	A606	148,9193		Akhir	A74	A409	154,3649
7	Awal	A331	A663	157,2857	17	Awal	A141	A663	157,6149
	Akhir	A104	A267	154,7314		Akhir	A104	A382	148,8649
8	Awal	A90	A663	183,4752	18	Awal	A389	A663	157,3851
	Akhir	A106	A167	180,9084		Akhir	A104	A505	150,427
9	Awal	A415	A663	167,8292	19	Awal	A479	A663	159,6584
	Akhir	A168	A500	167,3012		Akhir	A45	A146	144,2748
10	Awal	A386	A663	179,1429	20	Awal	A547	A663	176,4286
	Akhir	A320	A606	148,9193		Akhir	A113	A208	165,9488

Berdasarkan Tabel 3, nilai *E* minimum diperoleh ketika *medoid* akhir berada pada objek ke-45 (A45) dan ke-146 (A146), dengan nilai sebesar 144,2748. Dengan demikian, *medoid* final hasil pengelompokan mahasiswa calon penerima bantuan pendidikan UPZ UNP adalah A45 dan A146. Hasil pengelompokan tersebut menunjukkan bahwa klaster 1 terdiri dari 405 anggota, sedangkan klaster 2 terdiri dari 264.

3.4. Validasi Klaster dengan *Medoid Shadow Value* (MSV)

Hasil analisis pengelompokan memerlukan perhitungan tingkat keakuratan. Percobaan dengan variasi jumlah klaster *k* dilakukan untuk memperoleh nilai *Medoid Shadow Value* (MSV) yang ditampilkan pada Tabel 4.

Tabel 4. Nilai *Medoid Shadow Value* (MSV)

Percobaan <i>k</i>	Klaster	Nilai <i>Medoid Shadow Value</i> (MSV) Global
2	Klaster	0,463247
3	Kalster	0,390867
4	Klaster	0,412894
5	Klaster	0,417039
6	Klaster	0,419569
7	Klaster	0,411117

Penentuan nilai *Medoid Shadow Value* (MSV) terbaik dilakukan dengan mempertimbangkan kedekatan nilainya terhadap angka 1, di mana nilai yang semakin mendekati 1 menunjukkan kualitas pengelompokan yang semakin baik. Berdasarkan Tabel 4, diketahui bahwa dari enam percobaan yang dilakukan, nilai MSV tertinggi diperoleh pada percobaan dengan jumlah klaster (k) sebanyak dua. Dengan demikian, jumlah klaster optimal untuk pengelompokan mahasiswa calon penerima bantuan pendidikan UPZ UNP dengan menerapkan algoritma *Simple K-Medoids Partitioning* (SKM) adalah sebanyak dua klaster.

3.5. Karakteristik Klaster

Setelah klaster terbentuk dan jumlah klaster optimal diperoleh kemudian dilakukan analisis karakteristik dari klaster yang optimal tersebut. Pengelompokan ini melibatkan data campuran dengan dua jenis karakteristik, adalah data numerik dan data kategorik. Karakteristik numerik dilihat dari rata-rata, sedangkan karakteristik kategorik ditentukan dari persentase kategori yang paling dominan pada suatu variabel, disajikan dalam Tabel 5.

Tabel 5. Karakteristik Hasil Pengklasteran

		Klaster 1	Klaster 2
X1		3,53	3,47
	0	93,58%	81,44%
X2	1	6,42%	18,56%
	0	98,27%	97,35%
X3	1	1,73%	2,65%
	0	70,86%	28,79%
X4	1	14,81%	58,71%
	2	14,32%	12,50%
	0	0,49%	0,00%
X5	1	2,47%	4,92%
	2	9,63%	6,06%
X6	3	19,26%	19,32%
	4	50,86%	11,36%
	5	17,28%	58,33%
	0	0,25%	1,14%
	1	0,00%	0,76%
X7	2	0,74%	1,14%
	3	2,47%	6,44%
	4	7,41%	6,06%
	5	89,14%	84,47%
X7	0	77,04%	25,76%
	1	0,74%	0,38%
	2	6,91%	11,36%
	3	15,31%	62,50%

Informasi mengenai karakteristik klaster dapat dilihat pada Tabel 5 sebagai berikut:

Klaster 1 merupakan mahasiswa dengan IPK yang tinggi, mayoritas memiliki ayah dan ibu masih hidup, di dominasi semester 3, penghasilan orang tua rendah tapi sedikit lebih baik dari klaster 2, dan status kepemilikan rumah mayoritas milik sendiri. Sedangkan, klaster 2 merupakan mahasiswa yang memiliki rata-rata IPK yang sedikit lebih rendah dari klaster 1, proporsi lebih besar ayah sudah wafat, didominasi oleh semester 5, penghasilan orang tua sangat rendah, dan status kepemilikan rumah mayoritas menumpang (tidak memiliki rumah).

Analisis karakteristik menunjukkan bahwa klaster 2 merupakan kelompok mahasiswa dengan kondisi sosial ekonomi yang lebih rentan, hal ini mengindikasikan bahwa mahasiswa dalam klaster ini memiliki tingkat kebutuhan bantuan yang lebih tinggi atau menjadi prioritas pertama. Dementara itu, klaster 1 didominasi oleh mahasiswa dengan kondisi sosial ekonomi yang lebih stabil dari klaster 2 dan mayoritas tinggal di rumah milik sendiri, sehingga klaster 1 menjadi prioritas kedua. Hasil pengelompokan ini diharapkan dapat menjadi dasar pertimbangan bagi pengelola UPZ UNP dalam

menetapkan prioritas penyaluran bantuan pendidikan, agar seleksi penerima dapat dilakukan secara lebih objektif, tepat sasaran, dan adil.

4. KESIMPULAN

Penerima bantuan pendidikan UPZ UNP berdasarkan variabel sosial ekonomi dilakukan menggunakan metode *Simple K-Medoids Partitioning* (SKM). Hasil uji validitas *Medoid Shadow Value* (MSV) menunjukkan bahwa total klaster optimal adalah $k = 2$ dengan nilai MSV sebesar 0,463247. Analisis karakteristik mengindikasikan bahwa Klaster 2, dengan 265 anggota, menjadi prioritas pertama, sedangkan Klaster 1, dengan 405 anggota, menjadi prioritas kedua.

REFERENSI

- [1] H. A. R. Tilaar, "Pendidikan, Kebudayaan, dan Masyarakat Madani Indonesia". Bandung: Remaja Rosdakarya, 2003.
- [2] *Statistik Pendidikan* 2024, vol. 13, no. 1. Jakarta: Badan Pusat Statistik, 2024. doi: 10.25104/mtm.v16i1.840.
- [3] T. K. Hamidah, "Pengaruh biaya pendidikan terhadap minat melanjutkan studi ke perguruan tinggi," *J. Pendidik. Ekon.*, vol. 11, pp. 12–20, 2018.
- [4] BAZNAS, *Laporan Zakat Nasional* 2023. Jakarta: Badan Amil Zakat Nasional, 2023.
- [5] A. E. Wicaksono, "Implementasi Data Mining Dalam Pengelompokan Data Peserta Didik Di Sekolah Untuk Memprediksi Calon Penerima Beasiswa Dengan Menggunakan Algoritma K-Means (Studi Kasus Sman 16 Bekasi)," *J. Teknol. Rekayasa*, vol. 21, no. 3, pp. 206–216, 2016. Available: *Jurnal Teknologi Rekayasa*.
- [6] R. N. H. Hutusuht, H. Okprana, and B. E. Damanik, "Penerapan Data Mining Untuk Menentukan Penerima Program Bidikmisi Menggunakan Algoritma K-Medoids," *TIN Terap. Inform. Nusant.*, vol. 2, no. 11, pp. 667–672, 2022, doi: 10.47065/tin.v2i1.1516.
- [7] L. Kaufman, J. E. Gentle, and P. J. Rousseeuw, "Finding Groups in Data: An Introduction to Cluster Analysis.," *Biometrics*, vol. 47, no. 2, p. 788, 1990, doi: 10.2307/2532178.
- [8] S. Irsalina, "Implementasi Simple K-MedoidsPartitioning Pada Pengelompokan SmaBerdasarkan Komponen KesiapanTeknologi Informasi," 2022.
- [9] Ikasakti, N. A. (2017). "Efektivitas Algoritma K-Means, K-Medoids, Dan Optimal Jumlah Cluster Untuk Modifikasi Algoritma K-Medoids Pada Kumpulan Data Besar". Yogyakarta: Universitas Islam Indonesia.
- [10] W. Budiaji and F. Leisch, "Simple k-medoids partitioning algorithm for mixed variable data," *Algorithms*, vol. 12, no. 9, pp. 1–15, 2019, doi: 10.3390/a12090177.
- [11] J. C. Gower, "A general coefficient of similarity and some of its properties.," *Biometrics*, vol. 27, no. 4, pp. 857–871, 1971, [Online]. Available: <https://www.jstor.org/stable/2528823>
- [12] W. Budiaji, "Medoid-based shadow value validation and visualization," *Int. J. Adv. Intell. Informatics*, vol. 5, no. 2, pp. 76–88, 2019, doi: 10.26555/ijain.v5i2.326.