

Analisis Konsistensi Metode Elbow dan Silhouette Score dalam Klasterisasi pada Dataset Multisektor

Nita Sutantri¹, Vinna Yunitasari², Ghany Rahmat Sa'adi³, Syerikha Ananda⁴, Zurnan Alfian⁵

^{1,2,3,4,5}Fakultas Ilmu Komputer, Teknik Informatika, Universitas Pamulang, Pamulang, Indonesia

Corresponding Author: nitasutantri306@gmail.com

Published: July, 2025

ABSTRACT

Penelitian ini menganalisis konsistensi metode Elbow dan Silhouette Score dalam menentukan jumlah kluster optimal pada dataset multisektor menggunakan algoritma K-Means. Empat dataset dari sektor publik digunakan dalam penelitian ini, yaitu data mediasi peradilan (2006-2009), data koperasi simpan pinjam 2013, data penanganan kasus korupsi KPK (2004-2016), dan laporan keuangan PT Bank Artha Makmur 2017. Penelitian kuantitatif eksploratif ini menerapkan teknik preprocessing menggunakan StandardScaler, visualisasi data dengan PCA, dan evaluasi klasterisasi menggunakan kedua metode validasi. Hasil penelitian menunjukkan bahwa pada tiga dataset (mediasi peradilan, koperasi SP 2013, dan kasus korupsi KPK), kedua metode memberikan rekomendasi jumlah kluster yang konsisten. Namun, pada dataset laporan keuangan bank terjadi diskrepansi dimana Elbow Method merekomendasikan K=3 sedangkan Silhouette Score mengindikasikan K=2 sebagai optimal. Analisis lebih lanjut dengan pertimbangan domain knowledge mendukung pemilihan K=3 untuk dataset keuangan berdasarkan visualisasi PCA dan relevansi bisnis. Penelitian ini menyimpulkan bahwa kombinasi kedua metode validasi dengan pertimbangan konteks domain dapat meningkatkan akurasi penentuan kluster optimal, terutama pada data dengan kompleksitas tinggi. Temuan ini memberikan kontribusi pada pengembangan metodologi klasterisasi yang lebih robust untuk aplikasi di sektor publik.

Kata Kunci : Klasterisasi, K-Means, Elbow Method, Silhouette Score, Dataset Multisektor, Sektor Publik, Validasi Kluster, Data Mining, Penentuan Kluster Optimal, Principal Component Analysis

ABSTRACT

This study analyzes the consistency of the Elbow and Silhouette Score methods in determining the optimal number of clusters in a multi-sector dataset using the K-Means algorithm. Four datasets from the public sector were used in this study, namely judicial mediation data (2006-2009), savings and loan cooperative data 2013, KPK corruption case handling data (2004-2016), and PT Bank Artha Makmur financial reports 2017. This exploratory quantitative study applies preprocessing techniques using StandardScaler, data visualization with PCA, and clustering evaluation using both validation methods. The results show that in three datasets (judicial mediation, SP cooperative 2013, and KPK corruption cases), both methods provide consistent recommendations for the number of clusters. However, in the bank financial report dataset, there is a discrepancy where the Elbow Method recommends K = 3 while the Silhouette Score indicates K = 2 as optimal. Further analysis considering domain knowledge supports the selection of K = 3 for the financial dataset based on PCA visualization and business relevance. This study concludes that the combination of both validation methods with consideration of domain context can improve the accuracy of optimal cluster determination, especially in data with high complexity. This finding contributes to the development of a more robust clustering methodology for applications in the public sector.

Keywords: Clusterization, K-Means, Elbow Method, Silhouette Score, Multisector Dataset, Public Sector, Cluster Validation, Data Mining, Optimal Cluster Determination, Principal Component Analysis

© The Author(s). 2021 Open Access This article is licensed under a Creative Commons Attribution 4.0 International License, which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source, provide a link to the Creative Commons licence, and indicate if changes were made. The images or other third party material in this article are included in the article's Creative Commons licence, unless indicated otherwise in a credit line to the material. To view a copy of this licence, visit <http://creativecommons.org/licenses/by/4.0>

PENDAHULUAN

Pada era transformasi digital dan ledakan data yang masif di abad ke-21 ini, peran data telah berevolusi dari sekadar catatan menjadi aset strategis yang krusial bagi berbagai organisasi. Instansi-instansi di sektor publik, termasuk lembaga peradilan, unit

usaha mikro, kecil, dan menengah (UMKM) di bawah naungan pemerintah, hingga berbagai badan pemerintah pusat dan daerah, kini secara proaktif mengumpulkan dan menghasilkan volume data yang sangat besar dari setiap aspek operasional dan interaksi dengan masyarakat. Data yang melimpah ini, mencakup rekam jejak litigasi, informasi transaksi bisnis, demografi layanan publik, dan banyak lagi, menyimpan potensi tak terbatas untuk dieksplorasi dan dianalisis. Namun, data mentah yang belum terstruktur sering kali tidak langsung memberikan wawasan yang berarti. Di sinilah pengelompokan data menjadi esensial. Klasterisasi merupakan pembagian kelompok ke dalam kelompok yang memiliki tingkat kesamaan dan kemiripan yang tinggi dan kelompok lain yang memiliki tingkat perbedaan yang tinggi (tingkat kemiripan yang rendah) [1]. Aplikasi klasterisasi dalam sektor publik berpotensi merevolusi cara pengambilan keputusan, memungkinkan perumusan kebijakan yang lebih berbasis bukti, optimasi alokasi sumber daya, dan personalisasi layanan publik yang lebih responsif terhadap kebutuhan masyarakat. Meski demikian, implementasi klasterisasi, khususnya dengan algoritma populer seperti K-Means, karena algoritma ini fleksibel dan mudah digunakan, kompleksitas waktu jalannya lebih rendah dibandingkan dengan algoritma pengelompokan lainnya [2]. Namun sering kali dihadapkan pada tantangan signifikan, yaitu penentuan jumlah klaster optimal (K) [3]. Akurasi dan kebermaknaan hasil klasterisasi sangat bergantung pada ketepatan nilai K yang dipilih.

Apabila nilai K terlalu kecil, klaster yang terbentuk mungkin terlalu lebar dan mengaburkan perbedaan penting antar kelompok; sebaliknya, jika terlalu besar, klaster bisa menjadi terlalu spesifik dan rentan terhadap *overfitting* atau menangkap *noise* dalam data. Secara praktis, penentuan nilai K ini sering kali dilakukan dengan mengandalkan metode validasi seperti Elbow Method atau Silhouette Score secara terpisah. Elbow Method menawarkan pendekatan visual yang intuitif dengan memplot kurva antara nilai WCSS (Within Cluster Sum of Square) yang dihitung dan jumlah cluster K; titik lengkung yang tajam atau titik yang terlihat seperti lengan dianggap sebagai nilai K terbaik [4], sementara Silhouette Score digunakan untuk mengukur kualitas dan kekuatan cluster dan seberapa baik suatu objek ditempatkan di dalamnya [5]. Namun, mengandalkan salah satu metode saja berpotensi menghasilkan klasterisasi yang kurang akurat. Hal ini disebabkan karena setiap metode memiliki kekuatan dan kelemahan inherennya sendiri: Metode siku berfungsi dengan baik jika pola dari dataset yang relevan menguntungkan. Sebaliknya, skor siluet tidak bergantung pada jenis dataset, karena metode siluet berbasis jarak skor siluet dihitung berdasarkan jarak rata-rata antara objek intra-kluster dan kluster terdekat [6]. Oleh karena itu, pendekatan yang tidak mempertimbangkan keunggulan komplementer dan potensi batasan kedua metode secara bersamaan dapat mengurangi validitas dan reliabilitas hasil klasterisasi.

Lebih jauh, tinjauan terhadap literatur menunjukkan bahwa sebagian besar penelitian sebelumnya yang mengkaji metode penentuan K optimal cenderung menerapkan analisis pada satu jenis atau sektor data tertentu, seperti data medis, citra, atau finansial, yang mungkin memiliki karakteristik dan distribusi yang homogen. Belum banyak studi yang secara mendalam mengkaji dan membandingkan kinerja serta konsistensi kedua metode validasi tersebut, yaitu Elbow dan Silhouette Score, pada dataset sektor publik yang beragam. Data di sektor publik seringkali memiliki karakteristik unik seperti volume yang sangat besar, potensi bias, serta variabilitas struktur antar sektor (misalnya, data tabular di pengadilan versus data transaksional di UMKM, atau data survei di lembaga pemerintah). Keterbatasan penelitian sebelumnya dalam cakupan data multisektor dan perbandingan metode validasi secara komprehensif ini menciptakan kesenjangan penelitian (research gap) yang signifikan. Mengingat implikasi klasterisasi yang tidak akurat dapat berdampak langsung pada efektivitas kebijakan dan layanan publik, kebutuhan akan pemahaman yang lebih kokoh mengenai penentuan K optimal pada konteks data yang relevan ini menjadi sangat mendesak.

Dalam konteks inilah, penelitian ini hadir sebagai solusi yang inovatif dengan menawarkan pendekatan analisis komparatif yang mendalam terhadap Elbow Method dan Silhouette Score. Kami akan menerapkan klasterisasi K-Means pada data sektor publik yang beragam, mencakup dataset dari instansi pengadilan, UMKM, dan lembaga pemerintah, untuk mengevaluasi konsistensi dan efektivitas kedua metode validasi

tersebut di bawah karakteristik data yang berbeda. Pendekatan ini diharapkan mampu mengidentifikasi jumlah kluster optimal yang lebih akurat dan relevan terhadap struktur intrinsik serta karakteristik spesifik dari masing-masing jenis data sektor publik. Dengan demikian, penelitian ini tidak hanya akan memperkaya literatur ilmiah di bidang klusterisasi dan analisis data sektor publik, tetapi juga dapat menjadi panduan praktis yang lebih robust bagi para pengambil keputusan dalam memanfaatkan data untuk meningkatkan efisiensi dan efektivitas layanan publik.

Sejumlah penelitian sebelumnya telah mengkaji penerapan Elbow dan Silhouette Score dalam konteks K-Means. Habib (2021) membahas perbandingan kedua metode tersebut untuk menentukan jumlah kluster optimal, dan menekankan pentingnya mengombinasikan Elbow dan Silhouette agar hasil kluster lebih representatif. Namun, studi ini hanya menggunakan satu jenis dataset umum tanpa mempertimbangkan konteks sektor publik atau dataset multisektor. Selanjutnya, Permadi et al. (2023) menerapkan K-Means dan metode Elbow untuk mengelompokkan data penerima PKH, namun belum membandingkannya dengan Silhouette Score dan tidak menggunakan StandardScaler, sehingga evaluasi kluster masih terbatas.

Herdiana et al. (2025) mengusulkan modifikasi Elbow Method berbasis rumus geometris untuk meningkatkan objektivitas dalam penentuan titik elbow, namun penelitian ini fokus pada data kontinu dan belum memanfaatkan Silhouette Score sebagai pembanding. Sementara itu, Edutic (2025) membandingkan performa Elbow dan Silhouette pada algoritma K-Prototypes untuk data campuran, dan mendapati Silhouette Score lebih stabil pada data jenis tersebut, walaupun tidak menggunakan K-Means untuk data numerik murni. Alam (2023) menggabungkan K-Means dengan algoritma optimasi Firefly dengan memanfaatkan Elbow dan Silhouette Score untuk menentukan jumlah kluster pada data berdimensi tinggi, tetapi fokus utamanya lebih pada efisiensi algoritma daripada evaluasi mendalam kedua metode validasi secara terpisah.

Berdasarkan kajian terhadap literatur yang ada, tampak bahwa penelitian sebelumnya umumnya hanya fokus pada satu metode validasi (misalnya hanya Elbow atau hanya Silhouette) atau terbatas pada satu jenis data, tanpa secara komprehensif mengkaji kedua metode tersebut secara bersamaan pada data sektor publik yang beragam dan memiliki karakteristik unik. Kesenjangan ini menciptakan kebutuhan akan studi yang lebih holistik untuk memahami bagaimana kedua metrik validasi ini berperilaku dan seberapa konsisten mereka dalam merekomendasikan jumlah kluster optimal pada konteks dataset yang berbeda. Oleh karena itu, penelitian ini hadir sebagai solusi dengan menawarkan keterbaruan substansial berupa pendekatan analisis komparatif dan studi konsistensi terhadap Elbow Method dan Silhouette Score dalam klusterisasi menggunakan algoritma K-Means. Penerapan akan dilakukan pada dataset multisektor yang berasal dari instansi sektor publik. Dengan analisis mendalam terhadap hasil dari kedua metode ini, penelitian ini diharapkan dapat memberikan pemahaman yang lebih kuat dan akurat mengenai penentuan jumlah kluster optimal yang lebih relevan terhadap karakteristik spesifik setiap sektor data. Hasil dari penelitian ini akan berkontribusi pada pengembangan metodologi klusterisasi yang lebih robust untuk data sektor publik, mendukung pengambilan keputusan yang lebih informatif, dan mengoptimalkan pemanfaatan sumber daya di lingkungan pemerintahan.

METODE PENELITIAN

Tahapan Penelitian

Jenis penelitian ini adalah kuantitatif eksploratif, di mana kami menerapkan metode klusterisasi tidak terawasi untuk mengelompokkan data berdasarkan pola kemiripan tanpa variabel target. Pendekatan ini dipilih untuk mengidentifikasi struktur atau pola tersembunyi dalam dataset yang kompleks, yang tidak dapat diungkap dengan metode analisis tradisional. Kami menggunakan empat dataset yang diambil dari empat buku berbeda. Setiap dataset memiliki struktur dan jumlah data yang berbeda, merepresentasikan skenario klusterisasi yang bervariasi. Adapun deskripsi masing-masing dataset adalah sebagai berikut:

1. **Dataset Mediasi Peradilan** Dataset pertama memuat data keberhasilan mediasi dari tahun 2006 sampai 2009 yang berasal dari Pengadilan Negeri Bandung, Pengadilan

Negeri Jakarta Selatan, Pengadilan Negeri Bogor, dan Pengadilan Negeri Depok. Fitur yang digunakan adalah jumlah perkara dan persentase keberhasilan mediasi. Rentang waktu dan cakupan geografis ini dipilih untuk menganalisis tren mediasi dalam sistem peradilan perdata. Dataset ini diambil dari buku Mediasi Peradilan: Mediasi dalam Sistem Peradilan Perdata Indonesia dalam Rangka Mewujudkan Proses Peradilan yang Sederhana, Cepat, dan Biaya *Ringan* karya Dr. I Made Sukadana, S.H., M.H.

2. **Dataset Koperasi SP 2013** Dataset kedua berasal dari buku Pengawasan Koperasi di Indonesia karya Dr. Ahmad Subagyo, SE., M.M., yang diterbitkan oleh Mitra Wacana Media. Dataset ini memuat data tentang koperasi simpan pinjam di Indonesia per 31 Desember 2013 yang bersumber dari Kementerian Koperasi dan UKM. Fitur yang digunakan meliputi jumlah koperasi (KSP/USP, KJKS, dan UIKS), jumlah anggota, volume usaha (total aset), serta Sisa Hasil Usaha (SHU). Dataset ini digunakan untuk mengelompokkan koperasi berdasarkan karakteristik operasional dan finansialnya.
3. **Dataset Data Penanganan Kasus Korupsi 2004-2016** Dataset ketiga Data diambil dari buku *Data Mining Untuk Perguruan Tinggi* karya Efori Buulolo, S.Kom., M.Kom., karena datanya tidak terlalu lengkap maka saya lengkapi dengan sumber: aclc.kpk.go.id yang memuat jumlah kasus pada tahap: penyelidikan, penyidikan, penuntutan, inkracht, dan eksekusi dari tahun 2004 hingga 2016. Dataset ini digunakan untuk mengelompokkan data penanganan korupsi dari Komisi Pemberantasan Korupsi (KPK) agar dapat diketahui karakteristik kelompok tahun-tahun tertentu berdasarkan intensitas tindak lanjut penanganan kasus.
4. **Dataset Laporan Keuangan PT Bank Artha Makmur** Dataset ini memuat laporan laba/rugi PT Bank Artha Makmur per 31 Desember 2017. Informasi yang tercakup meliputi pendapatan dan beban operasional serta non-operasional, termasuk pendapatan bunga, beban bunga, pendapatan operasional lainnya, beban administrasi dan umum, laba sebelum dan setelah pajak penghasilan. Dataset ini memberikan gambaran menyeluruh tentang kinerja keuangan perusahaan perbankan pada akhir tahun fiskal 2017. Dataset ini diambil dari buku *Bab 30 Laporan Keuangan Gabungan* yang merupakan bagian dari dokumen laporan keuangan PT Bank Artha Makmur.

Proses klasterisasi dilakukan menggunakan bahasa pemrograman Python yang diimplementasikan melalui perangkat lunak Visual Studio Code (VSCode) sebagai lingkungan pengembangan. Dalam implementasinya, peneliti memanfaatkan pustaka *pandas* untuk pengolahan data (termasuk pembersihan data, penanganan nilai hilang, dan normalisasi jika diperlukan), *scikit-learn* untuk penerapan algoritma K-Means, serta *matplotlib* untuk visualisasi hasil klasterisasi. Seluruh tahapan dari pre-processing hingga klasterisasi dikembangkan secara mandiri sesuai kebutuhan dan karakteristik data. Tahapan pra-pemrosesan data mencakup, normalisasi atau standarisasi fitur menggunakan *StandardScaler* untuk memastikan fitur dengan skala yang berbeda tidak mendominasi proses klasterisasi, dan penentuan jumlah klaster optimal menggunakan metode *elbow method* dan *silhouette score*. Setelah pra-pemrosesan, algoritma K-Means diimplementasikan untuk mengelompokkan data, diikuti dengan interpretasi dan visualisasi hasil klaster.

Teknik Analisis Data

1. K-Means

Dengan membagi data saat ini menjadi dua atau lebih kelompok, algoritma K-Means adalah salah satu teknik pengelompokan data non-hierarkis[7]. K-means mengelompokkan data berulang kali, proses ini dilakukan dalam dua tahap utama. Pertama, setiap titik data dimasukkan ke klaster terdekatnya berdasarkan jarak terhadap centroid, pusat klaster. Kemudian, pusat klaster dihitung ulang sebagai rata-rata dari semua titik data yang baru saja dimasukkan ke dalamnya [8]. Jika tidak ada kesamaan, iterasi dilakukan berulang hingga jumlah total 50 kali[9].

2. Reprocessing

Preprocessing data adalah tahap penting dalam analisis data yang bertujuan untuk membersihkan, mengubah format, dan menyiapkan data untuk analisis

yang lebih mudah dan tepat [10] . Skala lebih besar dapat mengontrol proses perhitungan jarak (perhitungan jarak) dan mempengaruhi hasil pembentukan kluster [11] , maka dari itu proses data akan diproses ulang menggunakan standarisasi data. Standarisasi data yang digunakan pada penelitian ini adalah StandardScaler. StandardScaler melakukan standarisasi data dengan terlebih dahulu mengurangi setiap nilai atribut dengan rata-ratanya untuk memusatkan data di sekitar nol, kemudian membagi hasilnya dengan standar deviasi untuk mendapatkan varians unit, sehingga menghasilkan distribusi data dengan karakteristik standar deviasi tepat 1 (yang berarti varians juga 1 karena varians adalah kuadrat standar deviasi) dan rata-rata mendekati nol[12].

3. Elbow methode

Salah satu cara terbaik untuk menghitung jumlah cluster adalah dengan melihat presentase setiap cluster yang akan membentuk siku pada titik tertentu.

Metode elbow biasa digunakan untuk menunjukkan siku yang terbentuk dalam bentuk grafik. Metode Elbow bertujuan untuk mendapatkan nilai k yang kecil sambil tetap memiliki nilai insidens yang rendah. Jumlah cluster k yang dihasilkan dari pengujian dengan k-means dinilai dengan teknik SSE (Sum of Square Error), yang digunakan untuk mengukur perbedaan antara data yang telah dilakukan sebelumnya. Nilai k pada kombinasi siku dengan k-means adalah grafik hubungan cluster dengan penurunan error [13] . Jumlah kluster yang lebih tinggi tidak secara signifikan mengurangi SSE[14].


4. Silhouette score

Indeks Silhouette dapat mengevaluasi hasil pengelompokan tanpa set pelatihan, tetapi sebagian besar metode evaluasi kinerja memerlukan [15] . Karena menggabungkan informasi baik di dalam kluster maupun antar-kluster, silhouette dianggap sebagai ukuran kualitas klustering yang efektif. Secara khusus, siluet akan memberikan nilai tinggi untuk solusi klustering yang menunjukkan kepadatan (compactness) di dalam masing-masing kluster dan pemisahan antar-kluster yang jelas[16].


HASIL DAN PEMBAHASAN

Berdasarkan proses klasterisasi yang telah dilakukan terhadap dataset mediasi peradilan, peneliti memperoleh hasil pengelompokan data ke dalam beberapa kluster berdasarkan kemiripan karakteristik jumlah perkara dan persentase keberhasilan mediasi. Pada subbab ini, akan disajikan penentuan jumlah kluster optimal, visualisasi hasil klasterisasi, serta interpretasi dari masing-masing kluster yang terbentuk.


Elbow dan Silhouette Score




Gambar 1. Elbow Methode dan Silhouette Skor Data Mediasi Peradilan



Gambar 2. Elbow methode dan silhouette Skor Dataset Koperasi SP 2013



Gambar 3. Elbow Methode dan Silhouette Skor Dataset Data Penanganan Kasus Korupsi KPK 2004-2016




Gambar 4. Elbow Method dan Silhouette Skor Laporan Keuangan PT Bank Artha Makmur

Dari hasil analisis komparatif antara Elbow Method dan Silhouette Score pada berbagai dataset sektor publik, terlihat adanya pola konsistensi yang menarik. Untuk dataset mediasi peradilan, data koperasi SP 2013, dan data penanganan kasus korupsi 2004-2016, kedua metode validasi kluster tersebut cenderung mengarah pada penentuan jumlah kluster optimal yang sama. Keselarasan ini mengindikasikan adanya struktur kluster yang relatif jelas dan robust pada dataset-dataset tersebut, di mana Elbow Method dan Silhouette Score sepakat dalam mengidentifikasi pola pengelompokan yang paling representatif.


Namun, pola yang berbeda teramati secara signifikan pada data laporan keuangan PT Bank Artha Makmur. Pada dataset ini, terjadi diskrepansi antara rekomendasi jumlah kluster optimal dari kedua metode. Elbow Method menunjukkan titik siku yang optimal pada tiga kluster ($K=3$), mengindikasikan bahwa penambahan kluster di atas angka tersebut tidak lagi memberikan penurunan distorsi intra-kluster yang signifikan. Di sisi lain, Silhouette Score justru menyoroti skor tertinggi pada dua kluster ($K=2$), menunjukkan bahwa konfigurasi dengan dua kluster memberikan kepadatan internal dan pemisahan eksternal kluster yang paling baik.

Meskipun perbedaan jumlah kluster antara dua dan tiga hanya memiliki selisih satu angka dan terkesan tidak signifikan secara numerik, implikasi terhadap hasil klusterisasi yang dihasilkan dapat sangat substantif. Perbedaan satu kluster ini secara fundamental dapat mengubah interpretasi pola data, segmentasi grup, dan pada akhirnya, rekomendasi kebijakan atau keputusan strategis. Misalnya, di sektor keuangan, membedakan antara dua segmen ($K=2$) dibandingkan tiga segmen ($K=3$) dapat berdampak besar pada strategi pemasaran, manajemen risiko, atau penawaran produk yang ditargetkan. Hal ini menekankan pentingnya analisis mendalam ketika terjadi ketidaksepakatan antar metode validasi, terutama dalam konteks data yang sensitif seperti laporan keuangan.

Persebaran Data



Gambar 5. Scatter plot mediasi peradilan



Gambar 6. PCA jumlah unit dengan indikator keuangan koperasi

varians intra-klaster yang substansial, mengindikasikan adanya struktur data yang lebih granular pada K=3 yang secara statistik relevan.

Kedua, dan ini adalah faktor penentu utama, pilihan K=3 secara kuat didukung oleh visualisasi data melalui PCA Plot (Gambar 8) dan relevansinya dengan kebutuhan bisnis dalam industri perbankan. PCA Plot secara visual mengilustrasikan bagaimana fitur-fitur keuangan mengelompok menjadi tiga formasi yang berbeda dan bermakna. Tiga klaster ini secara intuitif mengorganisir berbagai komponen laporan keuangan ke dalam kelompok-kelompok yang dapat diinterpretasikan sebagai aspek-aspek fungsional yang berbeda dari operasi bank. Misalnya, terlihat adanya klaster yang berfokus pada pendapatan dan beban bunga inti, klaster yang mewakili item-item non-operasional atau insidental, dan klaster lain yang mencakup indikator kinerja operasional dan profitabilitas inti. Pemisahan menjadi tiga segmen ini memungkinkan bank untuk mendapatkan wawasan yang lebih spesifik dan detail mengenai profil keuangannya, yang sangat krusial untuk pengembangan strategi yang lebih tertarget, seperti manajemen risiko yang lebih akurat, pengembangan produk yang disesuaikan, atau optimasi biaya.

Dengan demikian, meskipun Silhouette Score memberikan perspektif tentang separasi global klaster, dalam kasus ini, kemampuan K=3 untuk mengungkapkan struktur data yang lebih kaya dan dapat ditindaklanjuti dari perspektif bisnis dan tujuan analisis domain menjadi prioritas. Keputusan ini mencerminkan pemahaman bahwa memilih metode yang tepat untuk menentukan jumlah klaster yang optimal memerlukan pertimbangan yang cermat, dengan mempertimbangkan faktor-faktor seperti karakteristik data dan tujuan analisis, untuk memastikan hasil pengelompokan yang bermakna dan akurat[20].

Hasil Klasterisasi

Tabel 1. Hasil klasterisasi dataset mediasi peradilan

Tahun	Pengadilan	Jumlah Perkara	Mediasi Berhasil	Persentase Keberhasilan	Cluster
2006	Bandung	370	19	5.14	1
2007	Bandung	360	16	4.44	1
2008	Bandung	425	45	1.58	1
2009	Bandung	305	26	8.52	1
2006	Jakarta Selatan	2173	12	0.55	0
2007	Jakarta Selatan	2439	14	0.57	0
2008	Jakarta Selatan	1663	10	0.6	0
2009	Jakarta Selatan	1479	13	0.87	0
2006	Bogor	83	3	3.52	1
2007	Bogor	105	6	5.71	1
2008	Bogor	127	3	2.36	1
2009	Bogor	92	26	28.26	2
2006	Depok	90	2	2.22	1
2007	Depok	137	3	2.18	1
2008	Depok	141	5	3.54	1
2009	Depok	105	3	2.85	1

Tabel 2. Hasil klasterisasi dataset Koperasi SP 2013

Uraian	Jumlah Unit	Asset	SHL Tahun Berjalan	Cluster
KSP / Kopdit	10.683	24.54	1.38	1
USP Koperasi	95.059	53.95	3.76	0
KJKS	1167	4.27	0.01	1
UIKS Koperasi	2141	0.81	0.02	1

Tabel 3. Hasil klasterisasi dataset kasus korupsi KPK 2004-2016

Tahun	Penyelidikan	Penyidikan	Penuntutan	Inkracht	Eksekusi	Klaster
2004	23	2	2	1	1	2
2005	105	55	43	27	30	0
2006	124	53	44	27	30	0
2007	172	96	77	33	49	1
2008	177	96	76	41	47	1
2009	193	123	84	49	50	1
2010	144	119	75	56	57	1
2011	144	106	94	67	60	1
2012	166	101	92	64	62	1
2013	179	108	102	71	71	1
2014	194	118	102	72	71	1
2015	172	123	96	79	84	1
2016	136	87	76	61	78	0

Tabel 4. Hasil klasterisasi dataset keuangan PT Bank Artha Makmur

N o	POS	Jumlah	Klaster
1	Beban penurunan nilai surat berharga	74,851.5	0
2	Beban personalia	40,570.0	0
3	Laba sebelum pajak	31,326.0	0
4	Laba operasional	26,514.0	0
5	Laba setelah pajak	22,488.0	0
6	Pendapatan provisi dan komisi	17,202.0	0
7	Beban penyusutan	11,357.6	1
8	Beban lainnya	9,515.5	1
9	Pajak penghasilan	8,837.70	1
10	Pendapatan non operasional	6,055.00	1
11	Beban administrasi umum	5,640.00	1
12	Beban provisi	5,040.00	1
13	Valuta asing (pendapatan)	4,716.05	1
14	Lainnya (pendapatan)	1,800.00	1
15	Valuta asing (beban)	1,300.68	1
16	Beban non operasional	1,243.00	1
17	Pendapatan bunga	331,775.0	2
18	Beban bunga	180,014.0	2

Berdasarkan penentuan jumlah klaster optimal yang telah dibahas sebelumnya menggunakan Elbow Method dan Silhouette Score, Tabel 1 hingga tabel 4 menyajikan hasil klasterisasi untuk masing-masing dataset yang diteliti. Klasterisasi dilakukan menggunakan jumlah klaster (K) yang direkomendasikan oleh kedua metode validasi pada masing-masing dataset, dengan mempertimbangkan justifikasi domain pada kasus diskrepansi seperti pada data laporan keuangan PT Bank Artha Makmur.

Karakteristik Tiap Klaster

Berdasarkan hasil klasterisasi yang diperoleh pada sub bab sebelumnya, telah diidentifikasi karakteristik khas yang membedakan masing-masing cluster.

1. Karakteristik dataset mediasi peradilan
 - Klaster 0 : Beban tinggi-mediasi rendah
Ciri Utama: Volume perkara sangat tinggi dengan tingkat keberhasilan mediasi terendah
 - Klaster 1: Beban Sedang - Mediasi Cukup
Ciri Utama: Volume perkara moderat dengan pencapaian mediasi sedang

- Klaster 2: Beban Rendah - Mediasi Tinggi
Ciri Utama: Volume perkara rendah dengan kinerja mediasi terbaik
- 2. Karakteristik dataset koperasi sp 2013
 - Klaster 0 : Skala Besar – Dominasi Finansial Tinggi
Ciri Utama : Jumlah unit koperasi dan volume keuangan sangat tinggi, mendominasi sisi aset dan SHU.
 - Klaster 1 : Skala Menengah – Stabilitas Finansial Sedang
Ciri Utama : Memiliki jumlah unit yang moderat dengan nilai aset dan SHU yang relative menengah hingga rendah.
- 3. Karakteristik Dataset Korupsi 2004–2016
 - Klaster 0: Fase Berkembang – Intensitas Penanganan Sedang
Ciri Utama: Tahun-tahun dengan aktivitas penyelidikan dan penuntutan yang sedang, mencerminkan periode pemulihan atau transisi dalam penanganan kasus.
 - Klaster 1: Fase Puncak – Dominasi Penanganan Kasus Tinggi
Ciri Utama: Intensitas tinggi dan menyeluruh pada seluruh fitur penanganan kasus, menunjukkan kapasitas maksimal dalam proses pemberantasan korupsi.
 - Klaster 2: Fase Awal – Aktivitas Penanganan Minim
Ciri Utama: Jumlah kasus dalam semua tahapan sangat rendah, merefleksikan periode awal atau keterbatasan pada tahap awal pembentukan sistem.
- 4. Karakteristik dataset laporan laba rugi
 - Klaster 0: skala besar - Pos Utama dengan Nilai Tinggi
Ciri Utama: Pos-pos dalam klaster ini memiliki nilai yang sangat besar dan mencakup beban dan laba utama dari aktivitas inti perusahaan.
 - Klaster 1: Skala Menengah – Beban & Penyesuaian Non-Inti
Ciri Utama: Mencakup pos dengan nilai sedang hingga kecil yang lebih banyak berkaitan dengan biaya-biaya administratif, non-operasional, dan penyesuaian terhadap kondisi eksternal (seperti pajak dan selisih kurs).
 - Klaster 2: Skala Tinggi – Aktivitas Berbasis Bunga
Ciri Utama: Terdiri dari dua pos yang nilainya sangat tinggi dan berhubungan langsung dengan aspek finansial (pendanaan atau investasi).

Perbandingan Klasterisasi Antar Dataset

1. Konvergensi Metodologi Validasi Klaster dan Implikasi Kompleksitas Data Sektoral:
Evaluasi komparatif antara Elbow Method dan Silhouette Score sebagai metrik validasi internal untuk penentuan jumlah klaster optimal (K) menunjukkan konvergensi hasil yang substansial pada tiga dari empat dataset yang dianalisis, yaitu data mediasi peradilan, data koperasi SP 2013, dan data penanganan kasus korupsi 2004-2016. Keselarasan ini mengindikasikan bahwa pada sebagian besar skenario data sektor publik yang diteliti, kedua metode statistik memberikan rekomendasi yang konsisten mengenai struktur data yang paling optimal, memberikan tingkat kepercayaan yang tinggi terhadap validitas klasterisasi yang dihasilkan.

Namun, sebuah diskrepansi metodologi yang signifikan dan menantang secara analitis secara spesifik teramati pada dataset laporan keuangan PT Bank Artha Makmur. Pada dataset ini, Elbow Method secara visual mengindikasikan K=3 sebagai titik optimal dengan penurunan *inertia* yang signifikan, sementara Silhouette Score mencapai puncak optimalnya pada K=2, menyiratkan pemisahan klaster yang lebih jelas pada konfigurasi yang lebih sederhana. Ketidakselarasan ini secara langsung mengindikasikan kompleksitas inheren tertinggi pada data keuangan tersebut, yang mungkin memiliki interkorelasi fitur yang lebih rumit atau struktur data yang tidak sepenuhnya sferis dan terpisah secara linear. Kondisi ini secara krusial menggarisbawahi urgensi inferensi berbasis domain (domain-driven inference) sebagai faktor penentu kritis. Dalam situasi di mana metrik statistik memberikan rekomendasi yang kontradiktif, pemahaman mendalam tentang konteks bisnis atau fungsional data menjadi esensial untuk membuat keputusan yang tepat mengenai K optimal, memastikan bahwa klaster yang

terbentuk tidak hanya valid secara statistik tetapi juga bermakna dan dapat ditindaklanjuti secara praktis."

2. Diferensiasi Struktural Klaster, Anomali Informatif, dan Dinamika Lintas Dataset:

Klasterisasi pada setiap dataset secara empiris mengungkapkan diferensiasi struktural inheren yang unik, merefleksikan karakteristik diskrit dan fenomena multidimensional dari domain masing-masing. Manifestasi pola pengelompokan ini bervariasi secara signifikan:

- a. Pada data mediasi peradilan, klasterisasi berhasil memprofilkan kelompok berdasarkan volume perkara versus efisiensi mediasi. Ini memungkinkan identifikasi pengadilan atau periode dengan volume kasus yang sangat tinggi namun tingkat keberhasilan mediasi yang rendah, kontras dengan entitas yang lebih efisien dalam skala lebih kecil. Secara khusus, data dari Bogor tahun 2009, dengan tingkat keberhasilan mediasi 28.26% yang secara statistik merupakan *outlier* positif, teridentifikasi sebagai anomali yang sangat informatif. Anomali ini menyoroti potensi keberhasilan luar biasa yang memerlukan investigasi lebih lanjut untuk mengidentifikasi praktik terbaik atau faktor-faktor unik yang dapat direplikasi.
- b. Untuk data koperasi SP 2013, klasterisasi mengungkapkan stratifikasi yang jelas berdasarkan skala operasional dan dominasi finansial. Pengelompokan ini membedakan koperasi dengan aset dan Sisa Hasil Usaha (SHU) yang masif, menunjukkan skala ekonomi yang besar, dari koperasi berskala menengah atau kecil yang mungkin beroperasi dengan model bisnis yang berbeda.
- c. Analisis pada data penanganan kasus korupsi 2004-2016 menghasilkan identifikasi pola evolusi institusional yang paling jelas dan bermakna. Klaster-klaster yang terbentuk merefleksikan fase-fase berbeda dalam kapasitas dan intensitas penanganan kasus korupsi, mulai dari periode aktivitas yang minim di awal, fase puncak penanganan yang komprehensif, hingga periode transisi atau pemulihan. Pola temporal ini memberikan wawasan tentang dinamika upaya pemberantasan korupsi di Indonesia.
- d. Terakhir, pada data laporan keuangan bank, klasterisasi berhasil membentuk segmen berdasarkan stratifikasi nilai dan relevansi fungsional komponen finansial. Ini memungkinkan bank untuk mengelompokkan pos-pos laporan laba rugi ke dalam kategori yang bermakna secara bisnis, seperti pos-pos terkait aktivitas bunga inti, beban operasional, dan pos-pos non-operasional."

3. Robustness, Aplikabilitas Lintas Sektor, dan Dinamika Trade-off Analitis:

Secara kolektif, temuan dari berbagai dataset ini secara kuat menegaskan robustness dan adaptabilitas metodologi klasterisasi dalam mengekstrak wawasan yang relevan dan bermakna secara kontekstual dari dataset yang berasal dari berbagai domain sektor publik. Fleksibilitas ini terbukti melalui keberhasilan penerapan algoritma K-Means yang relatif sama, didukung oleh visualisasi PCA dan metrik validasi, pada data dengan struktur dan karakteristik yang sangat bervariasi—mulai dari data tabular yang relatif sederhana hingga data finansial multidimensional. Kesuksesan ini menyoroti potensi signifikan klasterisasi sebagai instrumen analitis yang valid untuk diversifikasi aplikasi, mendukung optimalisasi pengambilan keputusan dan perumusan kebijakan yang lebih efektif di lintas sektor publik, seperti alokasi sumber daya yang lebih tepat, identifikasi area prioritas, atau perancangan program yang lebih tertarget.

Namun, analisis ini juga menyoroti adanya dinamika trade-off inherent antara kompleksitas data dan interpretabilitas hasil klasterisasi. Dataset dengan karakteristik yang lebih kompleks, seperti laporan keuangan PT Bank Artha Makmur yang memiliki dimensi fitur tinggi dan interkorelasi non-linear antar komponen finansial, secara nyata menuntut upaya validasi multidimensional yang lebih ekstensif dan interpretasi yang lebih mendalam dari perspektif domain. Demikian pula, meskipun dataset lain menunjukkan pola yang lebih jelas, karakteristik spesifik seperti adanya anomali pada data mediasi peradilan atau dinamika temporal yang berjenjang pada data penanganan kasus korupsi, juga mengindikasikan bahwa optimalisasi klasterisasi tidak hanya bergantung pada

kekuatan algoritma, tetapi juga pada kemampuan analisis untuk melakukan pertimbangan kontekstual yang cermat. Ini diperlukan untuk memastikan bahwa hasil yang diperoleh tidak hanya valid secara statistik tetapi juga memiliki kebermaknaan, relevansi operasional, dan potensi tindakan yang konkret.

KESIMPULAN

Berdasarkan analisis komparatif yang telah dilakukan terhadap konsistensi metode Elbow dan Silhouette Score dalam klusterisasi dataset multisektor, penelitian ini menghasilkan temuan penting mengenai efektivitas kedua metode validasi tersebut. Evaluasi pada empat dataset sektor publik menunjukkan bahwa metode Elbow dan Silhouette Score memberikan rekomendasi yang konsisten pada tiga dataset, yaitu data mediasi peradilan, koperasi SP 2013, dan penanganan kasus korupsi KPK 2004-2016. Konsistensi ini mengindikasikan bahwa kedua metode dapat diandalkan untuk menentukan struktur kluster optimal pada sebagian besar skenario data sektor publik.

Namun, diskrepansi signifikan teramati pada dataset laporan keuangan PT Bank Artha Makmur, dimana Elbow Method merekomendasikan $K=3$ sedangkan Silhouette Score mengindikasikan $K=2$. Fenomena ini menegaskan bahwa data dengan kompleksitas tinggi dan interkorelasi fitur yang rumit memerlukan pendekatan validasi yang lebih komprehensif. Dalam situasi diskrepansi seperti ini, domain knowledge menjadi faktor penentu kritis, sebagaimana didemonstrasikan melalui keputusan pemilihan $K=3$ berdasarkan visualisasi PCA dan relevansi bisnis.

Penerapan algoritma K-Means dengan dukungan preprocessing StandardScaler dan visualisasi PCA terbukti robust dan adaptabel pada dataset dengan karakteristik yang sangat bervariasi. Klusterisasi berhasil mengidentifikasi pola-pola bermakna pada setiap dataset, mulai dari stratifikasi volume-efisiensi pada data mediasi peradilan, segmentasi skala operasional pada data koperasi, hingga evolusi kapasitas institusional pada data korupsi. Temuan anomali seperti tingkat keberhasilan mediasi 28.26% di Bogor tahun 2009 juga memberikan wawasan berharga untuk investigasi lebih lanjut.

Penelitian ini berkontribusi pada pengembangan metodologi klusterisasi yang lebih robust untuk sektor publik dengan menekankan pentingnya kombinasi metode Elbow dan Silhouette Score, didukung visualisasi data dan pertimbangan domain knowledge. Pendekatan ini dapat meningkatkan akurasi identifikasi struktur data dan mendukung perumusan kebijakan yang lebih berbasis bukti, serta optimalisasi alokasi sumber daya dan perancangan program yang lebih tertarget di lingkungan pemerintahan.

REFERENSI

- L. Muflikhah, D. E. Ratnawati, dan R. R. M. Putri, *Data Mining*. Malang: UB Press, 2018.
- A. Alam dan M. Muqeem, "Hybridization of K-means with improved firefly algorithm for automatic clustering in high dimension."
- N. T. M. Sagala dan A. A. S. Gunawan, "Discovering the Optimal Number of Crime Cluster Using Elbow, Silhouette, Gap Statistics, and NbClust Methods," *ComTech: Computer, Mathematics and Engineering Applications*, vol. 13, no. 1, hlm. 1–10, Feb 2022, doi: 10.21512/comtech.v13i1.7270.
- W. Setiawan, *Data Mining: Teori dan Aplikasi*. Tasikmalaya: Rumah Cemerlang, 2021.
- S. Pelanggan dkk., "Kredit Menggunakan Metode K-Means Clustering," MEI, 2021. [Daring]. Tersedia pada: <https://www.kaggle.com/arjunbhasin2013/ccdata>.
- A. B. Habib, "Elbow Method vs Silhouette Co-efficient in Determining the Number of Clusters," 2021, doi: 10.13140/RG.2.2.27982.79688.
- H. Mulyani, R. A. Setiawan, dan H. Fathi, "Optimization of K Value in Clustering Using Silhouette Score (Case Study: Mall Customers Data)," *Journal of Information Technology and Its Utilization*, vol. 6, no. 2, hlm. 45–50, Des 2023, doi: 10.56873/jitu.6.2.5243.
- A. Lang dan E. Schubert, "Accelerating k-Means Clustering with Cover Trees," dalam *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, Springer Science and Business Media Deutschland GmbH, 2023, hlm. 148–162. doi: 10.1007/978-3-031-46994-7_13.

- Y. Hasan, "Pengukuran Silhouette Score dan Davies-Bouldin Index pada Hasil Cluster K-Means dan Dbscan," 2024.
- D. Romantika Marpaung, E. Gunawan, F. Rio Fa, dan A. Christianto, "Klasterisasi Negara Dunia Berdasarkan Data Sosioekonomi dan Demografi Tahun 2023 dengan PCA dan K-Means," vol. 14, no. 1, hlm. 2715–7849, 2025, doi: 10.34010/komputa.v14i1.
- Agustia Hananto, Tukino Tukino, dan Elfina Novalia, "Klasterisasi Kesiapan Digital Daerah," *Jurnal Ilmiah Teknik Informatika dan Komunikasi*, vol. 5, no. 1, hlm. 28–41, Mar 2024, doi: 10.55606/juitik.v5i1.979.
- T. Z. Jasman, E. Hasmin, Sunardi, C. Susanto, dan W. Musu, "Perbandingan Logistic Regression, Random Forest, dan Perceptron pada Klasifikasi Pasien Gagal Jantung," *CSRID (Computer Science Research and Its Development Journal)*, vol. 14, no. 3, hlm. 271–286, Des 2022, doi: 10.22303/csrid.14.3.2022.271-286.
- N. A. Maori, "METODE ELBOW DALAM OPTIMASI JUMLAH CLUSTER PADA K-MEANS CLUSTERING," *Jurnal SIMETRIS*, vol. 14, 2023.
- I. Herdiana, M. A. Kamal, Triyani, M. N. Estri, dan Renny, "A More Precise Elbow Method for Optimum K-means Clustering," Feb 2025, [Daring]. Tersedia pada: <http://arxiv.org/abs/2502.00851>
- M. Shutaywi dan N. N. Kachouie, "Silhouette analysis for performance evaluation in machine learning with applications to clustering," *Entropy*, vol. 23, no. 6, Jun 2021, doi: 10.3390/e23060759.
- G. Vardakas, I. Papakostas, dan A. Likas, "Deep Clustering Using the Soft Silhouette Score: Towards Compact and Well-Separated Clusters," Feb 2024, [Daring]. Tersedia pada: <http://arxiv.org/abs/2402.00608>
- D. Marcelina, A. Kurnia, dan T. Terttiaavini, "Analisis Klaster Kinerja Usaha Kecil dan Menengah Menggunakan Algoritma K-Means Clustering," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 3, no. 2, hlm. 293–301, Nov 2023, doi: 10.57152/malcom.v3i2.952.
- E. Elhaik, "Principal Component Analyses (PCA)-based findings in population genetic studies are highly biased and must be reevaluated," *Sci Rep*, vol. 12, no. 1, Des 2022, doi: 10.1038/s41598-022-14395-4.
- N. R. Utami dan S. Pramana, "Klasterisasi Bencana dan Dampaknya di Indonesia: Evaluasi Metode K-means dengan Integrasi PCA," *Seminar Nasional Sains Data*, vol. 2024, 2024.
- D. Arizki Kuswardana, D. Arman Prasetya, dan I. Gede Susrama Mas Diyasa, "Comparison of Elbow and Silhouette Methods in Optimizing K-Prototype Clustering for Customer Transactions," *Jurnal Ilmiah Edutic : Pendidikan dan Informatika*, vol. 12, no. 1, hlm. 43–48, 2025, doi: 10.21107/edutic.v12i1.29744.