



**KLASTERING UNTUK ANALISIS POLA KERUGIAN
KLAIM ASURANSI RUMAH SAKIT
(STUDI KASUS: [RS. XYZ])**

Muhammad Fajar Dianqori

22917012

Tesis diajukan sebagai syarat untuk meraih gelar Magister Komputer

Konsentrasi Sains Data

Program Studi Informatika Program Magister

Fakultas Teknologi Industri

Universitas Islam Indonesia

2026

Lembar Pengesahan Pembimbing

**KLASTERING UNTUK ANALISIS POLA KERUGIAN
KLAIM ASURANSI RUMAH SAKIT
(STUDI KASUS: [RS. XYZ])**

Muhammad Fajar Dianqori

22917012

Yogyakarta, Juni 2026



Pembimbing Pertama

DThomas Hatta Fudholi, S.T., M.Eng., Ph. D.

Pembimbing Kedua

Dr. Syarif Hidayat, S.Kom., M.I.T.

Lembar Pengesahan Penguji

KLASTERING UNTUK ANALISIS POLA KERUGIAN KLAIM ASURANSI RUMAH SAKIT (STUDI KASUS: [RS. XYZ])

Muhammad Fajar Dianqori
22917012

Yogyakarta, Juni 2026

Tim Penguji,

Dhomas Hatta Fudholi, S.T., M.Eng., Ph. D.

Ketua

Dr. Syarif Hidayat, S.Kom., M.I.T.

Anggota I

Ahmad Fathan Hidayatullah, S.T., M.Cs., Ph.D.

Anggota II

Mengetahui,

Ketua Program Studi Informatika Program Magister

Universitas Islam Indonesia



Ir. Irving Vitra Paputungan, S.T., M.Sc., Ph.D.

Abstrak

KLASTERING UNTUK ANALISIS POLA KERUGIAN KLAIM ASURANSI RUMAH SAKIT (STUDI KASUS: [RS. XYZ])

Sistem klaim INA-CBG (Indonesian Case-Based Groups) yang berbasis tarif paket menempatkan rumah sakit pada risiko defisit ketika biaya pelayanan aktual melampaui tarif yang ditetapkan. Pada data rawat inap tahun 2023–2024 di suatu rumah sakit yang menjadi konteks penelitian, sebanyak 6.018 dari 9.789 episode perawatan (61,48%) tercatat sebagai kasus defisit dengan total kerugian sebesar Rp 15,56 miliar. Pendekatan analitik konvensional yang berfokus pada rata-rata biaya populasi belum mampu mengungkap karakteristik kelompok pasien dan pola tindakan medis yang menjadi pemicu defisit, sehingga rekomendasi penanganan klinisnya cenderung bersifat umum dan tidak terarah. Kebutuhan akan *framework* analitik yang dapat memetakan konsentrasi defisit pada sub-populasi spesifik menjadi mendesak agar strategi pengendalian keuangan rumah sakit lebih tajam dan *actionable*.

Penelitian ini bertujuan untuk mengembangkan *framework* analitik berbasis kerugian klaim (*Loss-Oriented Analytical Framework, LOAF*) yang mengidentifikasi karakteristik kelompok pasien dan pola tindakan medis yang berkaitan dengan defisit klaim INA-CBG. *Framework* LOAF ini menjalankan klastering K-Means secara terpisah per-kelompok INA-CBG (*per-CBG stratification*), sehingga setiap perbedaan antar klaster dapat diatribusikan secara sah dan murni kepada perbedaan pola tindakan medis, bukan kepada perbedaan *diagnosis* atau tarif paket.

Penelitian menggunakan pendekatan analitik retrospektif pada data klaim dengan total 9.789 episode rawat inap (Januari 2023 – Desember 2024). Sebanyak 6.018 kasus rugi distratifikasi menjadi 329 kelompok INA-CBG, lalu selanjutnya dipilih berdasarkan kriteria sehingga menjadi 52 kelompok layak klastering ($n \geq 30$ kasus rugi), dan dipilih *top-10* kelompok CBG prioritas dengan total defisit terbesar. Matriks fitur dibangun dari hasil *count encoding* tindakan medis (1.849 fitur) yang ditransformasi dengan menggunakan *log-transform* dan dinormalisasi dengan *RobustScaler*, kemudian diaplikasikan reduksi dimensi menggunakan *Principal Component Analysis* (PCA) dengan dua komponen utama. Pemilihan komponen PCA divalidasi secara empiris melalui enam konfigurasi PCA (50%–95% *varians* vs *n_components* = 2). Juga dengan pemilihan algoritma, divalidasi melalui *benchmark*

terhadap algoritma *K-Medoids*, *Gaussian Mixture Model* dan *Agglomerative Hierarchical Clustering*. Klastering k-means dijalankan per-CBG dengan rentang K adaptif (2 sampai 5), dengan jumlah klaster optimal ditentukan melalui *rank aggregation* terhadap tiga metrik validasi internal *Silhouette Score*, *Davies-Bouldin Index* dan *Calinski-Harabasz Index*. Validitas hasil diuji melalui lima lapis triangulasi, justifikasi pemilihan PCA, *benchmark* algoritma, uji *robustness* antar model (Model A: variabel *treatment* + LOS + ICU vs Model B: *treatment-only variable*), uji stabilitas *bootstrap* 50 iterasi, dan uji *Mann-Whitney U* dengan koreksi FDR *Benjamini-Hochberg* untuk perbedaan klaster. Analisis pasca-klaster mencakup analisis profil finansial-klinis, analisis komparatif rugi-vs-untung dalam CBG identik dengan koreksi *case-mix*, serta identifikasi anomali statistik dan semantik-klinis pada lima CBG kandidat efisiensi dengan estimasi *excess cost* terbesar.

Framework LOAF berhasil memecah sepuluh CBG prioritas menjadi 35 klaster, dengan struktur klaster yang terbukti stabil melalui kelima lapis triangulasi (kesesuaian Model A vs B sebesar 92,0%–100%; rata-rata ARI *bootstrap* di atas 0,80 pada sembilan dari sepuluh CBG; LOS dan SELISIH sebagai variabel paling diskriminatif dengan 78,33% dan 59,00% pasangan klaster signifikan). Pada setiap CBG ditemukan klaster fokus dengan rata-rata defisit per kasus 2,76 sampai 4,52 kali lebih dalam dibandingkan klaster paling efisien (defisit rendah), membuktikan bahwa defisit tidak terdistribusi merata melainkan terkonsentrasi pada sub-populasi tertentu. Hasil analisis menyimpulkan bahwa defisit terbentuk dari dua mekanisme yang berbeda secara fundamental, (1) kompleksitas klinis terminal pada CBG kasus berat dengan ICU di atas 80% dan mortalitas 12%–61% (2) inefisiensi operasional pada CBG kasus ringan dengan tingkat kesembuhan 100%. Analisis komparatif pada *top-5* CBG kandidat efisiensi (K-4-17-I, A-4-13-I, I-4-20-I, M-1-80-I, O-6-10-I) menghasilkan estimasi *excess cost* yang konservatif dengan total Rp 231,15 juta (*adjusted*) dari 330 kasus rugi pada lima klaster fokus, yang dibentuk oleh perpanjangan LOS (rasio 1,32–2,08 kali), eskalasi tindakan keperawatan rutin, peningkatan pemeriksaan penunjang lintas-CBG, dan kemunculan item dengan *unit-cost* tinggi yang asimetris. Identifikasi anomali statistik menemukan 388 pola *deficit-only* pada lintas *top-10* CBG, sedangkan analisis anomali semantik-klinis mengungkap kandidat audit yang lebih kuat seperti kemunculan *treatment* Vulva Hygiene di CBG prosedur anggota tubuh atas yang tidak terkait secara anatomis dan visite dokter spesialis ICU pada CBG dengan proporsi ICU 0%.

Framework LOAF yang penelitian ini usulkan terbukti dapat menerjemahkan data klaim retrospektif menjadi instrumen pengambilan keputusan prospektif yang spesifik,

terkuantifikasi, dan *actionable*. Kontribusi utama penelitian meliputi (1) integrasi metodologis stratifikasi per-CBG, klastering K-Means per-kelompok, dan validasi berlapis dalam satu alur operasional. (2) pembedaan konseptual antara dua mekanisme pembentuk defisit yang berimplikasi pada strategi penanganan klinis berbeda. (3) penerapan *framework* sebagai *early warning system* defisit klaim. Implementasi rekomendasi berbasis temuan, mencakup standarisasi *clinical pathway* untuk tindakan keperawatan rutin berulang dan penyusunan standar pemilihan alat dengan *value-based*, berpotensi meningkatkan efisiensi operasional rumah sakit tanpa mengurangi mutu pelayanan klinis.

Hasil akhir dari penelitian ini diharapkan dapat memberikan wawasan strategis bagi manajemen rumah sakit dalam mengevaluasi kasus-kasus berisiko terhadap kerugian, mengoptimalkan proses perawatan, dan meningkatkan efisiensi operasional untuk mencapai profitabilitas yang lebih baik.

Kata kunci

loss-oriented analytical framework, klastering k-means, ina-cbg, defisit klaim bpjs, pola tindakan medis, analisis komparatif rugi-untung, efisiensi pelayanan rumah sakit.

Abstract

CLUSTERING FOR LOSS PATTERN ANALYSIS IN HOSPITAL INSURANCE CLAIMS (CASE STUDY: [XYZ HOSPITAL])

The INA-CBG (Indonesian Case-Based Groups) claims system, which is based on package rates, puts hospitals at risk of operating at a deficit when actual service costs exceed the established rates. In the 2023–2024 inpatient data from a hospital serving as the study context, 6,018 out of 9,789 care episodes (61.48%) were recorded as deficit cases, resulting in a total loss of Rp 15.56 billion. Conventional analytical approaches focused on population-average costs have failed to uncover the patient group characteristics and medical practice patterns driving these deficits, resulting in intervention recommendations that tend to be general and unfocused. The need for an analytical framework capable of mapping deficit concentrations within specific subpopulations has become urgent to ensure hospital financial control strategies are more precise and actionable.

This study aims to develop a loss-oriented analytical framework (LOAF) that identifies patient group characteristics and medical treatment patterns associated with INA-CBG claim deficits. The LOAF framework performs K-Means clustering separately for each INA-CBG group (per-CBG stratification), so that any differences between clusters can be legitimately and purely attributed to differences in medical treatment patterns, rather than to differences in diagnoses or package rates.

The study employed a retrospective analytical approach using claims data comprising a total of 9,789 inpatient episodes (January 2023–December 2024). A total of 6,018 loss cases were stratified into 329 INA-CBG groups, then further selected based on criteria to yield 52 clustering-eligible groups ($n \geq 30$ loss cases), and the top-10 priority CBG groups with the largest total deficits were selected. The feature matrix was constructed from the results of medical procedure count encoding (1,849 features) transformed using log-transform and normalized with RobustScaler, followed by dimension reduction using Principal Component Analysis (PCA) with two principal components. The selection of PCA components was empirically validated through six PCA configurations (50%–95% variance vs. $n_components = 2$). Additionally, the choice of algorithm was validated through benchmarking against the K-Medoids algorithm, the Gaussian Mixture Model, and Agglomerative Hierarchical Clustering. K-means clustering was performed per CBG with

an adaptive K range (2 to 5), with the optimal number of clusters determined through rank aggregation of three internal validation metrics: Silhouette Score, the Davies-Bouldin Index, and the Calinski-Harabasz Index. The validity of the results was tested through five-fold triangulation, justification of PCA selection, algorithm benchmarking, inter-model robustness testing (Model A: treatment variable + LOS + ICU vs. Model B: treatment-only variable), a 50-iteration bootstrap stability test, and a Mann-Whitney U test with Benjamini-Hochberg FDR correction for cluster differences. Post-cluster analysis included financial-clinical profile analysis, comparative loss-vs-gain analysis within identical CBGs with case-mix correction, and identification of statistical and clinical-semantic anomalies in the five candidate intervention CBGs with the highest estimated excess costs.

The LOAF framework successfully clustered the ten priority CBGs into 35 clusters, with a cluster structure that proved stable across all five rounds of triangulation (Model A vs. B fit ranging from 92.0% to 100%; average bootstrap ARI above 0.80 in nine of the ten CBGs; LOS and DIFFERENCE were the most discriminative variables with 78.33% and 59.00% of significant cluster pairs). In each CBG, focus clusters were identified with an average deficit per case 2.76 to 4.52 times deeper than the most efficient clusters (low deficit), proving that the deficit is not evenly distributed but concentrated in specific subpopulations. The analysis concluded that deficits arise from two fundamentally different mechanisms: (1) terminal clinical complexity in severe-case CBGs with ICU occupancy above 80% and mortality rates of 12%–61%, and (2) operational inefficiency in mild-case CBGs with a 100% recovery rate. Comparative analysis of the top 5 CBGs for efficiency intervention candidates (K-4-17-I, A-4-13-I, I-4-20-I, M-1-80-I, O-6-10-I) provide a conservative estimate of excess costs totaling Rp 231.15 million from 330 loss cases across five focus clusters, characterized by extended length of stay (LOS) (ratio of 1.32–2.08 times), escalation of routine nursing interventions, increased cross-CBG diagnostic tests, and the emergence of items with asymmetric high unit costs. Identification of statistical anomalies found 388 deficit-only patterns across the top-10 CBGs, while semantic-clinical anomaly analysis revealed stronger audit candidates such as the occurrence of Vulva Hygiene treatment in the upper body procedure CBG, which is not anatomically related, and ICU specialist visits in CBGs with a 0% ICU proportion.

The LOAF framework proposed in this study has proven capable of translating retrospective claims data into specific, quantifiable, and actionable prospective decision-making tools. The main contributions of the study include (1) the methodological integration of per-CBG stratification, per-group K-Means clustering, and multilevel validation into a single

operational workflow; (2) the conceptual distinction between two deficit-forming mechanisms that imply different intervention strategies; and (3) the application of the framework as an early warning system for claim deficits. Implementation of findings-based recommendations, including standardization of clinical pathways for routine, repetitive nursing interventions and the development of value-based equipment selection standards, has the potential to improve hospital operational efficiency without compromising the quality of clinical care. The final results of this study are expected to provide strategic insights for hospital management in evaluating cases at risk of loss, optimizing care processes, and improving operational efficiency to achieve better profitability.

Keywords

loss-oriented analytical framework, k-means clustering, INA-CBG, BPJS claim deficit, medical treatment patterns, comparative cost-benefit analysis, hospital service efficiency

Pernyataan Keaslian Tulisan

Dengan ini saya menyatakan bahwa tesis ini merupakan tulisan asli dari penulis, dan tidak berisi material yang telah diterbitkan sebelumnya atau tulisan dari penulis lain terkecuali referensi atas material tersebut telah disebutkan dalam tesis. Apabila ada kontribusi dari penulis lain dalam tesis ini, maka penulis lain tersebut secara eksplisit telah disebutkan dalam tesis ini.

Dengan ini saya juga menyatakan bahwa segala kontribusi dari pihak lain terhadap tesis ini, termasuk bantuan analisis statistik, desain survei, analisis data, prosedur teknis yang bersifat signifikan, dan segala bentuk aktivitas penelitian yang dipergunakan atau dilaporkan dalam tesis ini telah secara eksplisit disebutkan dalam tesis ini.

Segala bentuk hak cipta yang terdapat dalam material dokumen tesis ini berada dalam kepemilikan pemilik hak cipta masing-masing. Apabila dibutuhkan, penulis juga telah mendapatkan izin dari pemilik hak cipta untuk menggunakan ulang materialnya dalam tesis ini.

Yogyakarta, Juni 2026



Muhammad Fajar Dianqori, S.Kom

Daftar Publikasi

Publikasi berikut menjadi bagian dari Bab 3

Dianqori, M., Fudholi, D., Utomo, G., & Paputungan, I. (2026). Hybrid DBSCAN - K-Means Clustering for Financial Loss Identification in INA-CBG Claims Based on Medical Treatment Patterns. Building of Informatics, Technology and Science (BITS), 7(4), 2640-2656. <https://doi.org/10.47065/bits.v7i4.9483>

Kontributor	Jenis Kontribusi
Muhammad Fajar Dianqori	Mendesain eksperimen (85%) Mengumpulkan dan mengolah data (90%) Menulis paper (85%) Analisis dan interpretasi hasil (90%)
Dhomas Hatta Fudholi	Konseptualisasi awal penelitian (10%) Pembimbingan tahap awal (50%)
Galih Aryo Utomo	Penyediaan data (100%)
Irving Vitra Paputungan	Pembimbingan tahap akhir publikasi (50%) Pemeriksaan dan penyuntingan paper (15%)

Halaman Kontribusi

Penulis berterimakasih kepada selaku pihak IT dan unit rekam medis salah satu rumah sakit swasta yang terletak di Yogyakarta.

Halaman Persembahan

Halaman persembahan ini penulis tujukan dengan penuh rasa syukur dan hormat kepada orang-orang yang telah memberikan dukungan, doa, serta peran besar dalam perjalanan penyusunan tesis ini. Terutama kepada istri tercinta, yang senantiasa memberikan kasih sayang, pengertian, kesabaran, dukungan serta semangat di setiap proses yang dilalui. Kepada kedua orang tua tercinta, khususnya almarhum bapak, yang semasa hidupnya selalu mendorong dan menginginkan penulis untuk melanjutkan pendidikan ke jenjang S2. Meskipun pada akhir hayat beliau penulis belum sempat menyelesaikan pendidikan ini, harapan, nasihat, dan doa beliau tetap menjadi kekuatan terbesar yang mengiringi langkah penulis hingga tesis ini dapat diselesaikan. Kepada Ibu, terima kasih atas doa, cinta, dan dukungan tanpa henti yang selalu menguatkan penulis dalam setiap proses. Penulis juga menyampaikan penghargaan dan terima kasih yang sebesar-besarnya kepada Bapak dosen pembimbing atas arahan, ilmu, waktu, serta kesabaran dalam membimbing penyusunan tesis ini hingga selesai. Ucapan terima kasih turut penulis sampaikan kepada pihak rumah sakit yang telah banyak membantu, khususnya dalam penyediaan data dan dukungan selama proses penelitian berlangsung. Tidak lupa, kepada pihak kampus, akademik dan teman-teman yang telah membantu, baik melalui dukungan moral, motivasi, masukan, maupun kebersamaan selama proses studi dan penyusunan tesis ini, penulis mengucapkan terima kasih yang tulus. Semoga segala kebaikan, perhatian, dan bantuan yang telah diberikan mendapat balasan yang berlipat ganda.

Kata Pengantar

Assalamu'alaikum, Warahmatullahi Wabarakatuh.

Alhamdulillah puji syukur penulis ucapkan kehadiran Allah SWT atas berkat, rahmat, hidayah-Nya penulis dapat menyelesaikan laporan tesis. Serta tak lupa shalawat dan salam kepada junjungan kita Nabi Muhammad SAW karena beliau lah kita berada di jaman terang benderang penuh ilmu yang jauh akan kebodohan.

Laporan tesis ini dibuat sebagai salah satu syarat yang harus penulis selesaikan untuk memperoleh gelar Magister Komputer, Konsentrasi Sains Data, Program Studi Informatika Program Magister, Fakultas Teknologi Industri, Universitas Islam Indonesia dan untuk menerapkan ilmu yang telah didapat selama belajar di bangku kuliah.

Penulis menyadari bahwa penyusunan ini tidak akan terwujud tanpa adanya bantuan, bimbingan, dan dorongan berbagai pihak. Oleh karena itu, penulis menyampaikan terima kasih banyak kepada:


1. ALLAH SWT, atas segala pertolongan dan izin-Nya sehingga saya dapat menyelesaikan kegiatan Tugas Akhir ini.
2. Kedua Orang Tua Saya, Almarhum Bapak dan Ibu yang telah membesarkan saya dan selalu memberikan doa dan segalanya untuk kemudahan menjalankan studi ini.
3. Ir. Irving Vitra Paputungan, S.T., M.Sc., Ph.D. selaku Ketua Jurusan Program Magister Informatika Fakultas Teknologi Industri Universitas Islam Indonesia.
4. Bapak Chandra Kusuma Dewa, S.Kom., M.Cs., Ph.D. selaku Dosen Pembimbing Akademik di Program Magister Informatika Fakultas Teknologi Industri Universitas Islam Indonesia.
5. Bapak DThomas Hatta Fudholi, S.T., M.Eng., Ph. D. dan Bapak Dr. Syarif Hidayat, S.Kom., M.I.T. selaku Dosen Pembimbing 1 dan 2 Tesis di Program Magister Informatika Fakultas Teknologi Industri Universitas Islam Indonesia. Segenap Dosen Jurusan Teknik Informatika yang telah membimbing dan berbagi ilmunya kepada penulis.
6. Bapak Galih Aryo Utomo, S.Pd.T., M.Kom. yang telah menjembatani saya dalam mengerjakan penelitian ini.

7. Istri sekaligus teman hidup, Ana Ghoyatul Qusway, S.Pd. yang telah memberikan segala bentuk dukungan selama studi dan pengerjaan tesis ini.
8. Teman-teman SFGH dosen dan pengajar yaitu Septian Rico S.Kom., M.Eng., Ir. Irkhas Bayu Faveryan, S.T., M.Eng., Ikhwani Alfath Nurul Fathony, S.Kom., M.Kom., dan Ali Masykur Fathurrahman, S.H., M.H. Juga segenap teman-teman SFGH dan sejawat Magister Informatika UII '22 dan '24 yang turut serta membantu saya dalam proses belajar maupun mengerjakan Tesis ini hingga selesai.
9. Semua pihak yang turut andil membantu penulis dalam proses penyelesaian Tugas Akhir yang tidak dapat disebutkan satu persatu.

Penulis menyadari sepenuhnya bahwa dalam pelaksanaan Tesis tersebut, terdapat banyak kekurangan, oleh karena itu segala kritik dan saran yang membangun demi kesempurnaan laporan ini sangat penulis harapkan. Semoga dari apa yang telah penulis kerjakan dari laporan Tesis ini dapat bermanfaat untuk referensi serta Universitas, Fakultas dan semua pihak terkait.

Wassalamu'alaikum Warahmatullahi Wabarokatuh

Yogyakarta, 23 Juni 2026


(Muhammad Fajar Dianqori)

Daftar Isi

Lembar Pengesahan Pembimbing	i
Lembar Pengesahan Penguji.....	ii
Abstrak.....	iii
Abstract.....	vi
Pernyataan Keaslian Tulisan	ix
Daftar Publikasi	x
Halaman Kontribusi.....	xi
Halaman Persembahan	xii
Kata Pengantar.....	xiii
Daftar Isi	xv
Daftar Tabel.....	xix
Daftar Gambar	xxi
Glosarium	xxii
1.1 Latar Belakang.....	1
1.1.1 Dampak Paket Tarif INA-CBGs JKN	2
1.1.2 Klastering Sebagai Pendekatan dalam Evaluasi.....	2
1.1.3 Kontribusi Penelitian	4
1.2 Rumusan Masalah.....	4
1.3 Tujuan Penelitian	4
1.4 Batasan Masalah	5
1.5 Manfaat Penelitian	5
1.6 Metodologi Penelitian.....	6
1.7 Sistematika Penulisan	8
2.1 Sistem Jaminan Kesehatan Nasional dan Mekanisme Tarif Paket INA-CBG	10
2.2 Defisit Klaim Rumah Sakit dalam Sistem BPJS.....	10

2.3	Data Rekam Medis sebagai Sumber Data Analitik.....	10
2.4	Representasi Data Tindakan Medis	11
2.4.1	Encoding Data Tindakan Medis	11
2.5	Pra-pemrosesan: Data Transformasi Logaritmik dan Normalisasi.....	16
2.5.1	Transformasi Logaritmik Data	16
2.5.2	Normalisasi Data	16
2.6	Klastering.....	18
2.6.1	Dasar Penggunaan Klastering Sebagai Landasan Utama Penelitian.....	18
2.6.2	Klastering untuk Analisis pada Data Medis	19
2.7	Metrik Validasi Internal Kluster	24
2.8	Tantangan Dimensionalitas Tinggi.....	25
2.8.1	Dimensionality Reduction	26
3.1	Desain Penelitian	27
3.2	Sumber Data dan Populasi.....	29
3.2.1	Sumber Data	29
3.2.2	Periode Data	29
3.2.3	Kriteria Inklusi.....	29
3.2.4	Struktur Dataset	30
3.3	Tahap 1: Persiapan Data (<i>Data Preparation</i>)	31
3.3.1	Integrasi dan Validasi Data.....	31
3.3.2	Pembentukan Kolom Bantu.....	31
3.4	Tahap 2: Pra-pemrosesan Data (<i>Data Pre-processing</i>)	32
3.4.1	Penanganan Missing Value	32
3.4.2	Transformasi Kolom Tindakan Medis: Count Encoding	35
3.4.3	Kategorisasi Dataset: Kasus Rugi vs. Kasus Untung	36
3.4.4	Seleksi Variabel untuk Proses Klastering.....	37
3.4.5	Transformasi Logaritmik.....	39

3.4.6	Normalisasi Data: RobustScaler	39
3.4.7	Reduksi Dimensi: Principal Component Analyst (PCA)	40
3.5	Tahap 3: Klastering (Clustering)	42
3.5.1	Stratifikasi per INA-CBG	42
3.5.2	Penentuan Jumlah Klaster Optimal (k).....	44
3.5.3	Algoritma Pengelompokan K-Means	45
3.5.4	Evaluasi Hasil Klastering	48
3.6	Tahap 4: Analisis Pasca-Klaster (Post-Clustering Analysis).....	51
3.6.1	Profiling Klaster per CBG (Case-Based Group)	51
3.6.2	Analisis Komparatif.....	52
4.1	Gambaran Umum Data dan Konteks Defisit Klaim	58
4.2	Persiapan Data: Pembentukan Kolom Bantu.....	59
4.3	Pra-pemrosesan Data	59
4.3.1	Penanganan Missing Value	59
4.3.2	Pembersihan Artefak Data pada Variabel List	61
4.3.3	Prefix dan Transformasi Kolom Tindakan Medis	62
4.3.4	Konstruksi Matriks Klaster per CBG (Cased-Based Group).....	64
4.3.5	Stratifikasi dan Seleksi Kelompok CBG Prioritas.....	66
4.4	Pengelompokan: Klastering K-Means per CBG (Case-Based Group).....	69
4.4.1	Benchmark Algoritma Klastering.....	69
4.4.2	Pemilihan Jumlah Klaster Optimal.....	71
4.4.3	Uji Robustness: Model Utama (A) v.s Model B	74
4.4.4	Analisis Stabilitas Bootstrap.....	75
4.5	Evaluasi Hasil Klastering.....	76
4.5.1	Analisis Profil Kerugian	76
4.5.2	Analisis Visualisasi Hasil Klaster.....	80
4.5.3	Uji Signifikansi Statistik Antar Klaster (Mann-Whitney U)	82

4.5.4	Simpulan Hasil Evaluasi.....	84
4.6	Analisis Pasca-Klaster (Post-Clustering Analysis).....	85
4.6.1	Gambaran Umum Klaster.....	85
4.6.2	Profil Klinis Klaster.....	89
4.7	Analisis Komparatif pada Top-5 Kelompok CBG.....	100
4.7.1	Analisis Gap Pola dan Intensitas Frekuensi Tindakan Medis	102
4.7.2	Analisis Treatment Cost pada Top-5 Tindakan pada Klaster Fokus	106
4.7.3	Temuan Pola Tindakan Medis Asimetris (Anomaly Candidate).....	112
4.8	Simpulan Hasil Analisis Komparatif	121
4.9	Implikasi dan Kontribusi Penelitian.....	122
5.1	Kesimpulan	125
5.2	Saran	125
5.2.1	Saran bagi Manajemen Rumah Sakit.....	125
5.2.2	Saran bagi BPJS Kesehatan dan Regulator	126
5.2.3	Saran bagi Penelitian Lanjutan	127

Daftar Tabel

Tabel 2.1 Contoh Penerapan <i>One-Hot Encoding</i>	11
Tabel 2.2 Contoh Penerapan Metode <i>Binary Encoding</i>	13
Tabel 2.3 Contoh Penerapan Metode <i>Count Encoding</i>	13
Tabel 2.4 Contoh Penerapan Metode <i>Frequency Encoding</i>	14
Tabel 2.5 Ringkasan Penelitian Terkait Penerapan Klustering Untuk Analisis Data Medis	21
Tabel 3.1 Struktur Dataset	30
Tabel 3.2 Penanganan Missing Value	32
Tabel 3.3 Data Tindakan Sebelum Count Encoding (Contoh)	36
Tabel 3.4 Data Tindakan Setelah Count Encoding (Contoh)	36
Tabel 3.5 Perbandingan Model	38
Tabel 3.6 Parameter Stratifikasi dan Klustering	43
Tabel 3.7 Indikator Profil Tindakan Medis per-Klaster	52
Tabel 4.1 Distribusi Dataset	58
Tabel 4.2 Perbandingan Silhouette Terbaik pada Enam Konfigurasi PCA di kedua Model	65
Tabel 4.3 Top-10 Kelompok CBG Prioritas Berdasarkan Total Defisit	67
Tabel 4.4 Perbandingan ARI pada Kedua Model	71
Tabel 4.5 Jumlah Klaster Optimal dan Skor Silhouette per-CBG	73
Tabel 4.6 Hasil Uji Robustness Antar Model per-CBG	74
Tabel 4.7 Hasil Analisis Stabilitas Bootstrap per-CBG (50 Iterasi, 80% Rasio Subsample)	75
Tabel 4.8 Analisa Profil Kerugian Klaster per-CBG dalam Rupiah (Juta)	77
Tabel 4.9 Variabel Paling Diskriminatif Antar Klaster (Lintas CBG)	82
Tabel 4.10 Hasil <i>Uji Mann-Whitney U</i> dengan Koreksi FDR pada CBG Paling Defisit (K- 4-17-I)	83
Tabel 4.11 Profil Kerugian Tiap Klaster pada Top-10 CBG dalam Rupiah (Juta)	86
Tabel 4.12 Profil Klinis Klaster per-CBG (numerik)	94
Tabel 4.13 Profil Klinis Klaster per-CBG (Proporsi Kategorik (%))	96
Tabel 4.14 Profil Klaster Fokus pada Top-5 CBG Kandidat	102
Tabel 4.15 Top-5 Gap Pola dan Intensitas Frekuensi Tindakan Medis Klaster Fokus per- CBG	103

Tabel 4.16 Estimasi Excess Cost Top-5 Tindakan pada Klaster Fokus Top-5 CBG	
Kandidat.....	107
Tabel 4.17 Ringkasan Total Estimasi Excess Cost per CBG Kandidat.....	110
Tabel 4.18 Anomaly Statistik (Prevalensi Untung = 0%) pada Klaster Fokus top-5 CBG	
.....	113
Tabel 4.19 Anomaly Semantik-Klinis (Kandidat Audit) pada Top-5 CBG	117

Daftar Gambar

Gambar 1.1 Konsep Tarif INA-CBG's BPJS oleh (Firmanto, 2021).....	1
Gambar 3.1 Pipeline Metodologi Loss-Oriented Analytical Framework (LOAF) dengan Stratifikasi per-CBG	28
Gambar 4.1 Hasil penambahan kolom bantu kompleksitas diagnose dan prosedur	59
Gambar 4.2 Kolom tindakan medis sebelum dan sesudah penanganan <i>missing value</i>	60
Gambar 4.3 Sebelum dan setelah penanganan artefak <i>none</i>	62
Gambar 4.4 Sebelum dan sesudah pemberian prefix pada kolom tindakan medis	63
Gambar 4.5 Hasil transformasi kolom tindakan medis (<i>count encoding</i>)	63
Gambar 4.6 Hasil skor metrik validasi internal tanpa penerapan PCA.....	64
Gambar 4.7 Perbandingan skor Silhouette, DBI dan CHI pada setiap algoritma di kedua model	69
Gambar 4.8 Kurva metrik per K pada setiap algoritma di kedua model	70
Gambar 4.9 Hasil visualisasi PCA distribusi klaster pada top-10 CBG prioritas	81
Gambar 4.10 Rata-rata defisit (SELISIH) per-CBG pada top-10 CBG paling defisit	88
Gambar 4.11 Distribusi demografis dan <i>outcome</i> klinis agregat pada Top-10 CBG.....	89
Gambar 4.12 Perbandingan mortalitas CBG J-1-20-III, N-1-12-II, I-4-20-I, A-4-14-I, O-6- 10-I, dan M-1-80-I.....	92

Glosarium

AHC	- Agglomerative Hierarchical Clustering
ARI	- Adjusted Rand Index
BHP	- Bahan Habis Pakai
BPJS	- Badan Penyelenggara Jaminan Sosial
CBG	- Case-Based Group
CHI	- Calinski-Harabasz Index
CP	- Clinical Pathway
CSV	- Comma-Separated Values
DBI	- Davies-Bouldin Index
DBSCAN	- Density-Based Spatial Clustering of Applications with Noise
DRG	- Diagnosis-Related Group
EHR	- Electronic Health Record
EWS	- Early Warning System
FDR	- False Discovery Rate
GMM	- Gaussian Mixture Model
ICD-9	- International Classification of Diseases, Ninth Revision
ICD-10	- International Statistical Classification of Diseases and Related Health Problems, Tenth Revisions
ICU	- Intensive Care Unit
IGD	- Instalasi Gawat Darurat
INA-CBG	- Indonesian Case-Based Groups
IQR	- Interquartile Range
IT	- Information Technology
IUD	- Intra-Uterine Device
JKN	- Jaminan Kesehatan Nasional
KODING	- Kode paket tarif INA-CBG lengkap (termasuk <i>severity</i>)
LOAF	- Loss-Oriented Analytical Framework
LOS	- Length of Stay (lama rawat inap)
MCU	- Medical Check-Up
ML	- Machine Learning
PAM	- Partitioning Around Medoids
PC	- Principal Component

PCA	- Principal Component Analysis
PMK	- Peraturan Menteri Kesehatan
RME	- Rekam Medis Elektronik
RS	- Rumah Sakit
SSE	- Sum of Squared Errors
UMAP	- Uniform Manifold Approximation and Projection
USG	- Ultrasonografi
VT	- Vaginal Toucher
WCSS	- Within-Cluster Sum of Squares
XML	- Extensible Markup Language


BAB 1

Pendahuluan

1.1 Latar Belakang

Sejak diberlakukannya Jaminan Kesehatan Nasional (JKN), cara rumah sakit mendapat pembayaran dari pelayanan pasien telah berubah secara mendasar. Pada sistem lama, rumah sakit dibayar berdasarkan setiap item layanan yang diberikan (*fee for service*) semakin banyak tindakan yang dilakukan, semakin besar pula klaim yang ditagihkan. Sistem baru menggantinya dengan tarif paket di muka berdasarkan diagnosis pasien, yang dikenal sebagai tarif *Indonesian-Case Based Groups* (INA-CBG). Dengan sistem ini, rumah sakit menerima nominal yang sudah ditetapkan untuk setiap kelompok diagnosis, tidak peduli berapa banyak tindakan yang sebenarnya diberikan kepada pasien (Irwandy & Sjaaf, 2018).

Besaran tarif paket diatur oleh Peraturan Menteri Kesehatan Nomor 64 Tahun 2016 dan dikelompokkan menurut wilayah dan kelas rumah sakit. Tarif ini sudah mencakup seluruh komponen biaya yang dibutuhkan untuk merawat pasien, baik biaya medis maupun nonmedis (Firmanto, 2021). Secara umum, struktur tarif terdiri dari dua bagian utama: (a) jasa sarana, yaitu biaya fasilitas rumah sakit yang terbagi menjadi biaya tetap dan biaya variabel; dan (b) jasa pelayanan, yang mencakup jasa dokter, jasa perawat, jasa laboratorium, jasa radiologi, dan jasa manajemen. Detil struktur pembiayaan dalam sistem JKN dapat dilihat pada Gambar 1.1.



Gambar 1.1 Konsep Tarif INA-CBG's BPJS oleh (Firmanto, 2021)

1.1.1 Dampak Paket Tarif INA-CBGs JKN

Rumah sakit sebagai salah satu pilar utama pelayanan kesehatan dihadapkan pada tekanan ganda. Bergulat dengan masalah pengendalian biaya dan sekaligus memberikan layanan berkualitas kepada pasien (Firmansyah et al., 2022). Ketidak-kompetenan atau bahkan mis-manajemen dalam penanganan masalah ini akan membuat pihak rumah sakit mengalami banyak kerugian, terutama kerugian finansial (Sukmawati et al., 2023). Hal tersebut dapat mengancam stabilitas operasional, keberlanjutan layanan dan kemampuan rumah sakit untuk berinvestasi dalam teknologi dan fasilitas yang lebih baik (Purwadhi et al., 2024). Disisi lain, tarif INA-CBGs yang ditetapkan oleh pemerintah memiliki selisih 2% sampai dengan 3% lebih rendah dengan tarif yang ditetapkan rumah sakit swasta, sehingga tarif tersebut dianggap membebani rumah sakit swasta (Kenzia, 2021).

Data penelitian pada tahun 2017 sebanyak 65,9% rumah sakit di Indonesia secara teknis belum masuk kategori efisien dengan tarif JKN yang bernilai negatif (Rabiulyati & Nurwahyuni, 2023). Selain itu, INA-CBG's ini juga dipengaruhi oleh hasil dari kodefikasi, salah satunya adalah data tindakan medis pasien (Priwibowo, 2025). Untuk itu diperlukannya langkah intervensi yang proaktif, salah satunya dapat dengan melakukan evaluasi pada proses penanganan kasus (*clinical pathway*) pasien. Yang mana metode *clustering* merupakan pendekatan yang layak untuk dapat menangani masalah ini (Aljohani, 2024).

1.1.2 Klastering Sebagai Pendekatan dalam Evaluasi

Clustering atau pengelompokan adalah metode data mining yang memainkan peran penting dalam mengorganisir dan mengekstrak informasi yang bermakna dari kumpulan data yang sangat besar dan kompleks (Chaudhry et al., 2023). Tidak hanya itu, *clustering* juga merupakan salah satu metode yang populer untuk *pathway mining* (Aspland et al., 2021). Metode ini bekerja dengan menyusun titik-titik data yang memiliki karakteristik atau latar belakang yang sama menjadi klaster unik (Aljohani, 2024). Dengan begitu dalam konteks penelitian ini, metode tersebut dapat digunakan untuk mengelompokkan data berdasarkan pola dan karakteristik medis sebagai sarana evaluasi penanganan klinis pasien.

Namun, saat ini terdapat beragam algoritma pengelompokan (Wegmann et al., 2021). Setiap algoritma *clustering* memiliki karakteristik, asumsi, dan kekuatan yang berbeda-beda, sehingga penggunaan teknik pengelompokan ditentukan oleh sifat data, struktur kluster yang diinginkan, dan domain aplikasi (Chaudhry et al., 2023). Ketidak sesuaian antara metode yang dipilih dengan sifat data dan tujuan dapat menghasilkan interpretasi yang

menyesatkan, oleh karenanya pemilihan teknik yang tepat merupakan langkah kritis yang sangat menentukan keberhasilan analisis data (Wegmann et al., 2021).

Pada penelitian ini algoritma yang digunakan sebagai pendekatan awal adalah K-Means, karena memiliki kelebihan seperti efisiensi komputasi yang baik, mudah diimplementasikan, serta mampu melakukan segmentasi data berukuran besar secara cepat (Chaudhry et al., 2023; Koladiya, 2024; Naeem et al., 2023). Karakteristik tersebut relevan dengan data medis rumah sakit yang akan digunakan dalam penelitian ini, yang memiliki jumlah besar dan banyak variabel tindakan medis. Namun demikian, terdapat beberapa tantangan dalam penerapannya, diantaranya memiliki keterbatasan berupa sensitif terhadap *outlier*, perbedaan skala variabel, serta distribusi data yang *skewed* (melenceng/tidak normal) yang juga merupakan karakteristik pada data kesehatan (Ananda et al., 2025; Rahma, 2025; Rochayani & Utami, 2025). Kedua, dalam ruang berdimensi tinggi, signifikansi ukuran jarak akan berkurang karena jarak antar titik data cenderung menjadi hampir seragam, sehingga menyulitkan algoritma dalam menemukan kelompok yang bermakna (He, 2024).

Oleh karena itu, pada tahap pra-pengolahannya akan diterapkan *RobustScaler* untuk mengurangi pengaruh *outlier* (Pinheiro et al., 2025), transformasi logaritmik untuk menangani *skewness* pada data (Arifuddin et al., 2025), dan *dimensionality reduction* menggunakan untuk mengurangi dimensi data dengan tetap mempertahankan informasi dan variansi data sebanyak mungkin (Ardiansyah et al., 2022; Salman et al., 2025; Yunitaningtyas & Herianti, 2025).

Selain k-means, penelitian ini juga mempertimbangkan beberapa algoritma alternatif lain seperti K-Medoids, *Gaussian Mixture Model* (GMM), dan *Agglomerative Clustering* sebagai *benchmark* guna mengevaluasi algoritma yang paling tepat untuk diimplementasikan pada penelitian ini. Yang selanjutnya detail hasil dari *benchmark* alternatif algoritma tersebut akan dijelaskan pada bab 4 di bagian 4.4.1

Selanjutnya, untuk mengevaluasi kualitas hasil pengelompokan, penelitian ini menggunakan tiga metrik evaluasi internal, yaitu *Silhouette Score* untuk mengukur tingkat kedekatan objek terhadap klaster tempatnya berada dibandingkan dengan klaster lain, semakin tinggi nilainya (mendekati 1) menunjukkan kualitas klaster yang semakin baik (Chicco et al., 2025; Hasugian et al., 2025). *Davies-bouldin index* untuk mengukur tingkat kemiripan antar klaster (semakin rendah menunjukkan pemisahan klaster yang lebih optimal) (Ananda et al., 2025). Dan *calinski-harabasz index* untuk mengukur rasio variasi antar klaster dan variasi di dalam klaster (semakin tinggi skornya menunjukkan struktur

klaster yang lebih baik) (Syafiq et al., 2026). Penggunaan ketiga metrik ini bertujuan agar evaluasi tidak bergantung pada satu indikator saja dan menghasilkan penilaian yang lebih objektif dan informatif.

1.1.3 Kontribusi Penelitian

Penelitian ini mengusulkan sebuah *framework analysis* berbasis kerugian atau dapat juga disebut dengan *loss-oriented analytical framework* (LOAF) dengan mengadopsi algoritma klustering k-means yang secara eksplisit dirancang untuk mengidentifikasi, mengelompokkan, dan menganalisis kasus klaim berdasarkan pola tindakan medisnya. *Framework* LOAF yang diusulkan ini mengintegrasikan *loss concentration* sebagai unit analisis primer yang kemudian diturunkan secara bertingkat dari segmentasi klaster, *profiling treatment*, hingga *excess cost estimation* dalam satu alur yang koheren. Dengan memanfaatkan hasil analisis dari *framework* ini, harapannya dapat memfasilitasi perawatan medis yang lebih efisien, memberikan pemahaman yang lebih mendalam mengenai karakteristik kelompok pasien, serta pola *treatment* yang berkaitan dengan defisit klaim asuransi kesehatan sebagai sarana evaluasi penanganan klinis.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dijabarkan di pendahuluan, rumusan masalah yang diangkat dari penelitian ini adalah “Bagaimana membangun *framework analysis* yang dapat mengidentifikasi karakteristik kelompok pasien dan pola *treatment* yang berkaitan dengan defisit klaim asuransi kesehatan, berdasarkan frekuensi dan pola tindakan medis sebagai sarana evaluasi dan efisiensi pelayanan?”

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah untuk mengusulkan sebuah *framework analysis* berbasis kerugian (*loss-oriented analytical framework*) yang secara eksplisit dirancang untuk mengidentifikasi, mengelompokkan, dan menganalisis kasus kerugian klaim berdasarkan pola tindakan medisnya.

1.4 Batasan Masalah

Untuk menjaga fokus dan kedalaman analisis, penelitian ini dibatasi pada hal-hal berikut:

1. Ruang lingkup data: penelitian ini menggunakan data pasien rawat inap BPJS pada suatu rumah sakit swasta yang ada di Yogyakarta dalam periode satu tahun (2023-2024).
2. Cakupan Analisis Penelitian ini berfokus pada identifikasi pola tindakan medis dan analisis komparatif antara kelompok kasus defisit dan surplus untuk top 5 klaster pada CBG prioritas. Penelitian ini tidak mencakup analisis prediktif, pemodelan probabilitas defisit, maupun pengembangan sistem *decision support* berbasis model yang dihasilkan.

1.5 Manfaat Penelitian

Penelitian ini diharapkan dapat memberikan manfaat pada dua aspek, yaitu manfaat teoritis dan manfaat praktis.

1. Manfaat Teoritis: Pertama, penelitian ini berkontribusi pada pengembangan metodologi analitik di bidang *health informatics* dan sains data terapan, khususnya dalam penggunaan algoritma klustering untuk analisis pola kerugian klaim asuransi kesehatan berbasis data rekam medis dengan mengusulkan *Loss-Oriented Analytical Framework* (LOAF) sebagai pendekatan sistematis yang secara eksplisit merancang proses klustering, profiling, dan analisis komparatif dengan orientasi pada identifikasi pola defisit klaim, suatu pendekatan yang belum banyak dieksplorasi dalam literatur *clinical clustering* di konteks sistem jaminan kesehatan nasional Indonesia. Kedua, penelitian ini memberikan kontribusi empiris mengenai karakteristik data tindakan medis rawat inap BPJS dalam konteks pemodelan *unsupervised learning*, termasuk implikasi metodologis dari dimensionalitas yang tinggi, sparsitas data, dan pemilihan ruang fitur terhadap kualitas klaster yang dihasilkan. Temuan ini dapat menjadi referensi bagi penelitian selanjutnya yang menggunakan data sejenis.
2. Manfaat Praktis:
 - a. Bagi Manajemen Rumah Sakit: penelitian ini menyediakan *framework* analisis berbasis data yang dapat digunakan untuk mengidentifikasi kelompok kasus yang secara konsisten menghasilkan defisit klaim, beserta

pola tindakan medisnya. Dengan dasar pemahaman ini, manajemen dapat merancang penanganan klinis yang lebih terarah.

- b. Bagi Tenaga Medis dan Komite Medik: hasil profiling pola tindakan per-klauster dapat digunakan sebagai bahan evaluasi *clinical practice* secara objektif dan berbasis data. Analisis perbandingan antara kasus defisit dan surplus pada CBG yang sama memberikan gambaran konkret mengenai tindakan medis mana yang memiliki pola yang berlebihan, sehingga dapat mendukung proses *peer review* klinis yang lebih terstruktur.
- c. Bagi Unit Koding dan Case-mix: penelitian ini menghasilkan peta distribusi kasus defisit berdasarkan pola tindakan dan CBG, yang dapat digunakan unit *case-mix* sebagai dasar untuk memprioritaskan audit koding pada kelompok CBG dengan potensi kerugian tertinggi. Selain itu, analisis kombinasi tindakan medis yang berkorelasi dengan defisit dapat menjadi dasar evaluasi proses koding, serta masukan dalam proses negosiasi tarif atau penyusunan *internal benchmark* biaya per-kelompok CBG.
- d. Bagi Pengembangan Kebijakan Rumah Sakit: pada skala yang lebih luas, pendekatan analitik yang dikembangkan dalam penelitian ini dapat diadopsi sebagai bagian dari sistem pemantauan kinerja keuangan berbasis data klinis secara berkala. *Framework* LOAF yang diusulkan dirancang untuk dapat diterapkan ulang (*replicable*) pada periode data yang berbeda atau bahkan pada rumah sakit lain, sehingga memiliki potensi untuk menjadi instrumen evaluasi yang berkelanjutan.

1.6 Metodologi Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk membangun dan mengevaluasi *framework* analisis berbasis klastering pada data klaim rawat inap BPJS. Proses metodologis yang diterapkan dirancang untuk menghasilkan pengelompokan kasus defisit yang bermakna secara klinis dan dapat diinterpretasi secara operasional oleh manajemen rumah sakit.

Langkah-langkah utama dalam metodologi penelitian ini meliputi:

1. Pemahaman Masalah dan Konteks Bisnis: penelitian ini dilatarbelakangi oleh permasalahan yang dihadapi manajemen rumah sakit terkait terjadinya defisit klaim BPJS yang bervariasi antar pasien meskipun memiliki CBG yang sama. Pemahaman konteks bisnis dilakukan melalui identifikasi mekanisme pembayaran sistem INA-

CBG, struktur data rekam medis rawat inap, dan pola pembentukan defisit antara tarif klaim asuransi dan tarif riil rumah sakit.

2. Data Preparation: data yang digunakan merupakan data sekunder rekam medis pasien rawat inap BPJS yang mencakup tiga domain: data demografis pasien, data klinis, serta data administratif keuangan (tarif klaim dan tarif rumah sakit). Integrasi antar sumber data dilakukan berdasarkan identifikasi unik pasien untuk menghasilkan dataset terpadu yang siap dianalisis.
3. Pra-pemrosesan Data: tahapan ini mencakup pembersihan data, penanganan missing value, dan transformasi (*encoding*) kolom tindakan medis yang tersimpan dalam format *semicolon-separated* string menjadi matriks fitur terstruktur menggunakan metode *count encoding* per-pasien. Setiap kode tindakan medis direpresentasikan sebagai kolom fitur dengan nilai berupa total frekuensi kemunculan tindakan tersebut pada masing-masing pasien. Untuk mengatasi distribusi data yang tidak normal dan keberadaan *outlier*, diterapkan transformasi logaritmik $\log(1+x)$ (untuk menangani nilai 0) dan dilanjutkan dengan *RobustScaler*. Setelah itu diterapkan *dimensionality reduction* untuk mengurangi dimensi tindakan medis hasil *encoding* sedikit mungkin, namun tetap mempertahankan *variance* data asli sebanyak mungkin.
4. Perancangan *Framework* Analisis: penelitian ini mengusulkan *Loss-Oriented Analytical Framework* (LOAF) sebagai kerangka analisis yang secara eksplisit dirancang untuk mengidentifikasi, mengelompokkan, dan menganalisis kasus defisit berdasarkan pola tindakan medisnya. *Framework* ini terdiri dari tiga tahap utama: klustering berbasis pola tindakan medis menggunakan algoritma *K-Means*, *profiling* kluster menggunakan data asli pasca-klustering, serta analisis komparatif antara kasus defisit dan surplus pada diagnosis CBG yang sama.
5. Penentuan Jumlah Kluster Optimal: tahap ini dilakukan melalui evaluasi tiga metrik validasi internal secara bersamaan, yaitu *Silhouette Score*, *Davies-Bouldin Index*, dan *Calinski-Harabasz Index*, dengan pendekatan *rank aggregation* untuk menghasilkan konsensus antar metrik. Metode *elbow* juga diterapkan sebagai rujukan pendukung.
6. Validasi dan *Benchmark* Algoritma: untuk menguji performa algoritma k-means sekaligus justifikasi pemilihannya, dilakukan perbandingan metodologis dengan algoritma pembanding, yaitu *Agglomerative*, GMM dan K-Medoids. Selain itu, 2 varian model akan dijalankan dan dibandingkan untuk mengetahui apakah variable lain dapat mempengaruhi kluster yang terbentuk, dimana model utama akan menggunakan fitur tindakan medis dan variabel klinis makro (LOS,

JML_DIAGLIST, HAS_ICU) sebagai fitur tambahan, dan model b menggunakan variabel *treatment-only*. Selanjutnya kedua model tersebut akan di validasi dengan pengujian *bootstrap*, *robustness* dan *mann-whitney u*.

7. Analisis Pasca-klustering: setelah label kluster terbentuk, analisis dilakukan menggunakan data asli tanpa distorsi transformasi. Tahap ini mencakup profiling pola tindakan medis per kluster, analisis demografis dan klinis per kluster, uji signifikansi statistik antar kluster diterapkan menggunakan *Mann-Whitney U* dengan koreksi *False Discovery Rate* (FDR), analisis diagnosis penyakit paling merugikan per kluster, serta analisis pola tindakan medis.

Metodologi ini secara keseluruhan dirancang untuk menghasilkan temuan yang dapat diinterpretasi secara langsung oleh praktisi dan *stakeholder* terkait, baik manajemen rumah sakit, komite medik, maupun unit *casemix*. Serta harapannya dapat direplikasi pada periode data yang berbeda atau pada institusi layanan kesehatan lain dengan struktur data serupa.

1.7 Sistematika Penulisan

Penelitian ini menggunakan sistematika penulisan yang digambarkan sebagai berikut:

BAB I PENDAHULUAN

Bab ini menguraikan latar belakang permasalahan terkait terjadinya defisit klaim BPJS. Bab ini mencakup rumusan masalah, tujuan penelitian, batasan masalah, manfaat penelitian, metodologi penelitian secara umum, dan sistematika penulisan. Secara keseluruhan, Bab I membangun argumentasi mengapa pendekatan analisis berbasis klustering diperlukan untuk mengidentifikasi pola tindakan medis yang berkaitan dengan defisit klaim, serta memperkenalkan *Loss-Oriented Analytical Framework* (LOAF) sebagai kerangka analisis yang diusulkan.

BAB II TINJAUAN PUSTAKA

Bab ini membahas literatur yang relevan sebagai landasan teoritis dan empiris penelitian. Tinjauan mencakup sistem jaminan kesehatan nasional dan mekanisme pembayaran INA-CBG, konsep defisit klaim dalam konteks rumah sakit BPJS, metode klustering khususnya K-Means dan algoritma pembandingnya, teknik representasi data tindakan medis, serta metrik validasi internal kluster. Bagian ini juga menyajikan kajian terhadap penelitian-penelitian terdahulu yang relevan, identifikasi celah riset, dan posisi kebaruan penelitian ini dalam lanskap studi clinical data mining dan analisis klaim asuransi kesehatan di Indonesia.

BAB III METODOLOGI PENELITIAN

Bab ini menjelaskan secara teknis seluruh tahapan penelitian yang dilaksanakan dalam *framework* LOAF. Uraian mencakup sumber dan struktur data yang digunakan, proses integrasi dan pembersihan data, transformasi kolom tindakan medis menjadi matriks fitur menggunakan *count encoding vectorization*, penanganan distribusi data yang tidak normal dan outlier melalui transformasi logaritmik dan *RobustScaler*, prosedur penentuan jumlah kluster optimal menggunakan pendekatan *rank aggregation* atas tiga metrik validasi internal, serta perancangan dua varian model (variable pada model utama: treatment + length of stay + status icu + jumlah diagnose, dan variable pada model b: *treatment-only*) sebagai bagian dari validasi metodologis. Bab ini juga menjelaskan prosedur analisis pasca-kluster yang mencakup profiling tindakan medis, analisis komparatif kasus defisit dan surplus, serta pengujian signifikansi statistik antar kluster.

BAB IV HASIL DAN PEMBAHASAN

Bab ini menyajikan hasil eksperimen dan interpretasi temuan penelitian secara menyeluruh. Pembahasannya meliputi hasil *benchmark* perbandingan algoritma, hasil evaluasi metrik validasi internal untuk setiap nilai k dan setiap varian model, perbandingan kinerja K-Means dengan algoritma pembanding, profil pola tindakan medis per kluster beserta karakteristik klinis dan demografisnya, hasil analisis komparatif antara kasus defisit dan surplus pada kelompok CBG yang sama, serta interpretasi temuan dalam konteks permasalahan manajemen rumah sakit.

BAB V KESIMPULAN DAN SARAN

Bab ini merangkum temuan utama penelitian, mencakup karakteristik kluster kasus defisit yang berhasil diidentifikasi, pola tindakan medis yang berkaitan dengan defisit klaim, serta perbedaan signifikan antar kluster yang terverifikasi secara statistik. Bab ini juga mengevaluasi kontribusi *framework* LOAF sebagai pendekatan analitik yang dapat direplikasi untuk analisis serupa. Selain itu, dipaparkan keterbatasan penelitian beserta saran pengembangan untuk penelitian selanjutnya, termasuk potensi perluasan *framework* ke data multiperiode, integrasi variabel severity yang lebih kaya, serta kemungkinan pengembangan sistem pemantauan defisit klaim berbasis *framework* yang dihasilkan.

BAB 2

Tinjauan Pustaka

2.1 Sistem Jaminan Kesehatan Nasional dan Mekanisme Tarif Paket INA-CBG

Sistem pembayaran di rumah sakit yang sebelumnya menggunakan sistem *fee for service*, diubah menjadi sistem pembayaran *prospective payment system* dengan menggunakan tarif *Indonesian-Case Based Groups (INA-CBG's)* dan BPJS Kesehatan ditunjuk sebagai institusi pelaksana program (Irwandy & Sjaaf, 2018; Kustiwa et al., 2026). Dalam sistem tarif INA-CBG, setiap episode rawat inap dikodekan ke dalam satu kelompok kasus berdasarkan diagnosis utama, diagnosis sekunder, prosedur tindakan, dan karakteristik pasien. Berdasarkan Peraturan Menteri Kesehatan Nomor 64 Tahun 2016 Tentang Perubahan Atas Peraturan Menteri Kesehatan Nomor 52 Tahun 2016 Tentang Standar Tarif Pelayanan Kesehatan Penyelenggaraan Program Jaminan Kesehatan Nasional, tarif yang dibayarkan BPJS bersifat flat per kelompok kasus, dengan besaran pembayaran telah ditetapkan di muka tanpa mempertimbangkan biaya riil yang dikeluarkan rumah sakit selama perawatan berlangsung.

2.2 Defisit Klaim Rumah Sakit dalam Sistem BPJS

Konsekuensi langsung dari mekanisme tarif paket INA-CBG ini adalah adanya risiko defisit finansial yang ditanggung rumah sakit ketika biaya riil perawatan melebihi tarif INA-CBG yang ditetapkan (R et al., 2022). Kondisi ini melahirkan tuntutan operasional baru yang mengharuskan rumah sakit merumuskan respons organisasi bersifat adaptif dan dapat diverifikasi secara sistematis (Kustiwa et al., 2026). Oleh karenanya perlu adanya pengembangan sistem untuk menjaga keseimbangan antara efisiensi finansial dan kualitas pelayanan klinis (Kustiwa et al., 2026). Menjadikannya sebagai dasar landasan penelitian ini diusulkan untuk memberikan perhatian utama pada variasi defisit yang terjadi di antara pasien dengan kelompok CBG yang sama. Dimana variasi ini merupakan indikasi heterogenitas dalam pola tindakan medis yang tidak dapat teridentifikasi melalui analisis agregat berbasis kode diagnosis semata.

2.3 Data Rekam Medis sebagai Sumber Data Analitik

Rekam medis elektronik (RME) menyimpan informasi kaya mengenai perjalanan perawatan setiap pasien, mencakup data demografis, data klinis berupa kode diagnosis dan prosedur

tindakan, serta data administratif keuangan. Dalam tinjauan komprehensif mengenai *deep HER*, (Shickel et al., 2018) menyatakan bahwa data klinis terstruktur seperti kode prosedur dan diagnosis merupakan salah satu modalitas data medis yang paling siap untuk dianalisis secara komputasional. Karakteristik utama data tindakan medis dalam rekam medis rawat inap adalah sifatnya yang *multi-valued* dan *variable-length*, setiap pasien dapat menerima kombinasi tindakan yang berbeda-beda. Sehingga diperlukannya transformasi khusus sebelum data tersebut dapat diproses oleh algoritma machine learning (Shickel et al., 2018). Berdasarkan karakteristik data tersebut, tantangan teknis utama yang harus diantisipasi adalah dimensionalitas tinggi dari ruang fitur yang dihasilkan dan sparsitas matriks yang timbul karena setiap pasien hanya menerima sebagian kecil dari seluruh tindakan yang tersedia.

2.4 Representasi Data Tindakan Medis

Algoritma *machine learning* secara teknis hanya memproses masukan dalam bentuk numerik (Johnson et al., 2023). Karena data tindakan medis merupakan serangkaian data kategorik, oleh karenanya harus dikonversi menjadi variabel numerik.

2.4.1 Encoding Data Tindakan Medis

(Johnson et al., 2023) dalam penelitiannya menyebutkan terdapat beberapa teknik untuk mengubah data kategorik menjadi numerik, beberapa contohnya yaitu *one-hot encoding*, *binary encoding*, *count encoding* dan *frequency encoding* (Bolikulov et al., 2024).

1. One-Hot Encoding

Teknik *one-hot encoding* ini mengubah fitur kategorikal menjadi $N + 1$ variabel biner, dimana N adalah jumlah kategori dalam fitur tersebut, di mana angka “1” menunjukkan adanya kategori tersebut dalam fitur asli (Johnson et al., 2023). Artinya, jika ada k nilai unik dalam satu kolom teks di dataset, k kolom baru ditambahkan ke dataset. Dan dalam kolom-kolom ini diisi dengan 0 atau 1. Namun, metode ini hanya disarankan untuk kasus-kasus di mana tidak banyak nilai unik (Bolikulov et al., 2024). Contoh penerapan dari *one-hot encoding* dapat dilihat pada Tabel 2.1.

Tabel 2.1 Contoh Penerapan *One-Hot Encoding*

Tindakan Medis	One-Hot Tindakan 1	One-Hot Tindakan 2	One-Hot Tindakan 3
Tindakan 1	1	0	0
Tindakan 2	0	1	0
Tindakan 3	0	0	1

Berdasarkan Tabel 2.1, setiap tindakan medis direpresentasikan sebagai satu kolom biner tersendiri, sehingga tiga jenis tindakan menghasilkan tiga kolom baru. Pola angka 1 pada kolom yang bersesuaian dan 0 pada kolom lainnya menunjukkan bahwa metode ini bersifat *mutually exclusive*, dimana setiap baris hanya memiliki tepat satu nilai aktif. Konsekuensi langsung dari pola ini adalah ekspansi dimensi yang proporsional terhadap jumlah jenis tindakan unik, sehingga pada dataset klinis dengan ratusan kode tindakan, *one-hot encoding* akan menghasilkan matriks yang sangat lebar dan jarang (*sparse*).

2. Binary Encoding

Binary encoding merepresentasikan setiap kategori unik sebagai kode biner yang tersebar di seluruh kolom dalam kumpulan data (Johnson et al., 2023). Dalam penerapannya, nilai-nilai unik terlebih dahulu dicocokkan dengan angka-angka berurutan dalam sistem bilangan biner. Selanjutnya, panjang bilangan biner dengan panjang maksimum (l) ditentukan. Nilai-nilai biner dari nilai-nilai unik yang tersisa diperpanjang hingga panjang l (dengan menambahkan angka 0 di depan nilai-nilai biner tersebut). Pada langkah berikutnya, dibuatlah l kolom, dan bit-bit dari nilai biner setiap nilai unik ditempatkan secara berurutan ke dalam kolom-kolom tersebut. Akibatnya, nilai-nilai dalam kolom teks digantikan oleh l kolom yang berisi kombinasi angka 0 dan 1, seperti pada metode *one-hot encoding*. Dalam metode *one-hot encoding*, dibuat k kolom untuk k nilai unik, namun pada *binary encoding*, dibuatlah l kolom baru. Untuk perbandingan, nilai l dihitung menggunakan formula (2.1).

$$l = \begin{cases} \lceil \log_2 k \rceil, & \lceil \log_2 k \rceil = \log_2 k; \\ \lceil \log_2 k \rceil + 1, & \lceil \log_2 k \rceil < \log_2 k \end{cases} \quad (2.1)$$

Variabel kategorikal terlebih dahulu perlu diubah menjadi variabel ordinal. Nilai ordinal untuk kategori tersebut kemudian diterjemahkan menjadi kode biner dengan menggunakan jumlah kolom sesedikit mungkin yang diperlukan untuk merepresentasikan setiap kategori

dalam fitur tersebut (Johnson et al., 2023). Contoh dari penerapan *binary encoding* dapat dilihat pada

Tabel 2.2 Contoh Penerapan Metode *Binary Encoding*.

Tabel 2.2 Contoh Penerapan Metode *Binary Encoding*

Tindakan Medis	Indeks	Biner	Bit1	Bit2	Bit3
Tindakan 1	1	000	0	0	0
Tindakan 2	2	001	0	0	1
Tindakan 3	3	101	1	0	1

Tabel 2.2 menunjukkan bahwa tiga jenis tindakan medis dapat direpresentasikan hanya menggunakan tiga kolom bit (Bit1, Bit2, Bit3), identik dengan jumlah kolom yang dihasilkan *one-hot encoding* pada contoh yang sama. Namun keunggulan *binary encoding* baru terlihat jelas saat jumlah kategori unik membesar, untuk k tindakan, *one-hot* membutuhkan k kolom sedangkan *binary encoding* hanya membutuhkan $\lceil \log_2 k \rceil$ kolom.

3. Count Encoding

Metode *count encoding* bekerja dengan membuat setiap nilai unik dalam kategori diganti dengan jumlah kemunculan nilai unik tersebut (Bolikulov et al., 2024). Secara umum metode ini dijabarkan pada formula (2.2).

$$K(b_i) = \sum_{j=1}^j \quad (2.2)$$

di mana $\sum_{j=1}^j$ adalah jumlah total bidang teks yang nilainya sama dengan b_i (Bolikulov et al., 2024). Contoh dari penerapan count encoding dapat dilihat pada Tabel 2.3.

Tabel 2.3 Contoh Penerapan Metode *Count Encoding*

Tindakan Medis	T1	T2	T3	T4	T5
T1;T3;T2;T1	2	1	1	0	0
T1;T2;T3	1	1	1	0	0

T1;T4;T5	1	0	0	1	1
----------	---	---	---	---	---

Tabel 2.3 memperlihatkan bahwa *count encoding* tidak hanya mencatat “ada-tidaknya” suatu tindakan, tetapi juga merekam intensitas penggunaannya per pasien. Sebagai contoh, pada pasien pertama dengan tindakan list T1;T3;T2;T1, kode T1 muncul dua kali sehingga nilainya tercatat sebagai 2, sedangkan T2 dan T3 masing-masing bernilai 1. Informasi frekuensi ini secara klinis bermakna karena repetisi tindakan medis sering kali mencerminkan kompleksitas kasus.

4. Frequency Encoding

Frequency encoding adalah teknik yang menggantikan nilai literal suatu kategori dengan probabilitas kemunculan kategori tersebut dalam kumpulan data (Johnson et al., 2023). Hampir sama dengan *count encoding*, hanya saja, dalam metode ini, data teks tidak diubah berdasarkan jumlah pengulangan, melainkan berdasarkan frekuensi pengulangan (Bolikulov et al., 2024). Formula dari metode ini adalah seperti yang dijabarkan pada formula (2.3) (Bolikulov et al., 2024):

$$K(b_i) = \frac{\sum_{j=1}^J j}{\sum_{j=1}^J j} \quad (2.3)$$

Contoh penerapan dari *metode frequency encoding* dapat dilihat pada Tabel 2.4.

Tabel 2.4 Contoh Penerapan Metode *Frequency Encoding*

Fitur	Kategori	Frekuensi
Kategorikal Fitur 1	Kategori 1	0.25
	Kategori 2	0.60
	Kategori 3	0.15
Kategorikal Fitur 2	Kategori 1	0.72
	Kategori 2	0.28

Tabel 2.4 memperlihatkan bahwa *frequency encoding* merepresentasikan setiap kategori dengan proporsi kemunculannya dalam keseluruhan dataset, bukan frekuensi absolutnya. Pada Fitur 1, Kategori 2 memiliki nilai tertinggi (0.60) yang berarti 60% dari seluruh *record* mengandung kategori tersebut, sementara Kategori 3 merupakan yang paling jarang (0.15).

Representasi berbasis proporsi ini membuat nilai *encoding* sensitif terhadap distribusi populasi, sehingga kategori yang langka atau jarang secara otomatis mendapat bobot rendah dalam analisis kluster.

Namun demikian, penelitian ini secara eksplisit memilih *count encoding* dibandingkan *frequency encoding* berdasarkan pertimbangan integritas data dan tujuan analisis kerugian (*loss-oriented analysis*). Justifikasi pemilihan metode ini berdasarkan berbagai pertimbangan berikut:

1. Penghindaran Bias Populasi: *Frequency encoding* memberikan nilai berdasarkan prevalensi suatu tindakan di seluruh populasi dataset (Bolikulov et al., 2024). Hal ini menyebabkan tindakan medis umum (seperti contoh administrasi atau infus) memiliki bobot numerik yang jauh lebih besar daripada tindakan medis langka namun kompleks (contoh operasi spesifik). Karena algoritma K-Means sangat sensitif terhadap skala nilai fitur (Ananda et al., 2025), penggunaan *frequency encoding* berisiko membuat model cenderung mengelompokkan pasien berdasarkan tindakan rutin, sehingga dapat mengaburkan pola tindakan spesifik yang sebenarnya berpotensi menjadi pemicu utama defisit finansial.
2. Representasi Intensitas Pelayanan per Pasien: *Count encoding* mempertahankan jumlah mentah (*raw count*) dari setiap tindakan medis yang diterima oleh pasien dan merupakan standar dalam representasi pasien berbasis kode klinis (Zeng et al., 2019). Pendekatan ini memastikan bahwa intensitas penggunaan sumber daya rumah sakit oleh setiap individu pasien terekam secara akurat. Sebagai contoh, jika seorang pasien menerima lima kali prosedur tertentu, nilai fiturnya tetap lima, tanpa terpengaruh oleh seberapa sering prosedur tersebut muncul pada pasien lain dalam populasi dataset.
3. Identifikasi Pola Tindakan Langka (Rare Events): Defisit sering kali dipicu oleh ketidaksesuaian antara kompleksitas tindakan medis yang nyata dengan tarif paket INA-CBGs (Manopo & Susanti, 2025). Tindakan medis yang jarang muncul namun memiliki biaya tinggi dapat menjadi merupakan faktor penentu terjadinya selisih klaim negatif antara biaya riil dan tarif INA-CBG, dengan menggunakan teknik *count encoding* maka dapat menjaga agar identitas dan kuantitas tindakan-tindakan kritis ini tidak terkompresi atau terdistorsi oleh prevalensi populasi.

2.5 Pra-pemrosesan: Data Transformasi Logaritmik dan Normalisasi

Data tindakan medis umumnya memiliki distribusi miring ke kanan (*right-skewed*) (Yu & Zhang, 2025), yang jika tidak ditangani akan menyebabkan fitur dengan nilai ekstrem mendominasi perhitungan (Arifuddin et al., 2025).

2.5.1 Transformasi Logaritmik Data

Teknik log-transformation merupakan teknik standar yang dapat mengatasi dominasi nilai ekstrem tersebut (*skewness*) (Arifuddin et al., 2025). Hal ini penting dilakukan untuk memastikan bahwa data lebih konsisten dan mengurangi sensitivitas model terhadap *outlier* atau nilai ekstrem yang sering dijumpai dalam data rekam medis (Salman et al., 2025). Log-transform ini umumnya memiliki formula seperti yang dijabarkan pada formula (2.4).

$$\ln(x) \tag{2.4}$$

2.5.2 Normalisasi Data

Setelah tahap transformasi logaritmik, selanjutnya diterapkan *scaling* atau normalisasi data. Normalisasi data adalah proses transformasi yang bertujuan untuk memastikan beberapa variabel dalam sebuah dataset memiliki rentang nilai yang seragam, sehingga tidak ada nilai yang terlalu besar atau terlalu kecil yang dapat mengganggu analisis statistik (Akbar, 2023). Tahapan ini merupakan bagian krusial dari tahap pra-pemrosesan data guna membentuk data dalam posisi rentang nilai yang sama (Akbar, 2023). Menurut para ahli, nilai-nilai atribut data yang berbeda perlu dinormalisasi atau distandarisasi agar proses data mining tidak bias (Akbar, 2023). Terutama pada penggunaan algoritma berbasis jarak seperti k-means, jika variabel kontinu memiliki rentang yang berbeda, maka variabel dengan distribusi yang lebih besar akan mendominasi penentuan penempatan kluster (Wang et al., 2022). Dengan melakukan normalisasi atau *scaling*, setiap fitur dipastikan berkontribusi secara setara dalam proses pengelompokan (Koladiya, 2024). Berikut merupakan beberapa metode yang sering digunakan untuk melakukan normalisasi atau penskalaan data:

1. Min-Max Normalization: metode ini mengubah nilai data asli melalui transformasi linier ke dalam rentang nilai tertentu yang lebih kecil, $[0,1]$ atau $[-1,1]$ (Farissa et al., 2021). Secara umum, formulasinya adalah seperti formula (2.5) (Akbar, 2023).

$$x^1 = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.5)$$

Dengan keterangan sebagai berikut:

x^1 : Nilai hasil normalisasi dalam rentang baru

x : Nilai data asli

x_{min} : Nilai minimum dari atribut tersebut dalam dataset

x_{max} : Nilai maksimum dari atribut tersebut dalam dataset

2. Z-Score Normalization: metode ini menskalakan data berdasarkan nilai rata-rata (*mean*) dan standar deviasi dari setiap nilai (Wang et al., 2022). Hasil dari implementasi metode ini adalah data dengan nilai rata-rata 0 dan standar deviasi 1 (Satriatama et al., 2023). Formula (2.6) berikut merupakan formulasi dari *z-score* normalization (Wang et al., 2022).

$$z = \frac{x - \mu}{\sigma} \quad (2.6)$$

Dengan keterangan sebagai berikut:

z : Nilai hasil standardisasi (skor-z)

x : Nilai data asli

μ (*mean*) : Nilai rata-rata dari seluruh data pada fitur tersebut

σ (*Standard Deviation*): Nilai standar deviasi dari fitur tersebut

Dalam praktiknya, metode ini sering diimplementasikan menggunakan pustaka seperti *StandardScaler* pada python (Akbar, 2023; Oktafiandi et al., 2025). Namun, metode ini sangat sensitif terhadap *outlier* karena nilai ekstrem dari *outlier* dapat mempengaruhi perhitungan rata-rata dan deviasi standar secara signifikan (Hasugian et al., 2025; Pinheiro et al., 2025). Karena hasil transformasi fitur tindakan medis menghasilkan matriks representasi frekuensi dengan karakteristik distribusi yang tidak simetris, kondisi ini meningkatkan probabilitas keberadaan *outliers*. Oleh karena itu, (Pinheiro et al., 2025) dalam penelitiannya menyarankan penggunaan *RobustScaler* yang jauh lebih tahan terhadap *outlier* dibanding *StandardScaler*.

2.6 Klustering

Klustering adalah teknik dalam data mining yang bertujuan untuk mengelompokkan data ke dalam beberapa klaster (Akbar, 2023; Chaudhry et al., 2023). Dalam proses ini, objek-objek yang memiliki tingkat kemiripan yang tinggi akan disatukan dalam klaster yang sama, sementara objek yang memiliki perbedaan signifikan akan ditempatkan pada kelompok yang berbeda (Adha et al., 2021). Prinsip utama dari teknik ini adalah memaksimalkan homogenitas di dalam setiap klaster (intra-klaster) dan memaksimalkan heterogenitas antar klaster (inter-klaster) (Adha et al., 2021). Dalam konteks penelitian ini, klustering memungkinkan peneliti untuk menyederhanakan ribuan rekam medis kasus pasien menjadi beberapa klaster profil pasien yang memiliki karakteristik klinis serupa (Aljohani, 2024).

2.6.1 Dasar Penggunaan Klustering Sebagai Landasan Utama Penelitian

Penggunaan metode klustering dipilih sebagai landasan utama dalam membangun *framework* LOAF karena beberapa alasan:

1. Identifikasi Pola Kerugian yang Tersembunyi: pihak manajemen rumah sakit sering kali kesulitan mengenali pola tindakan medis mana yang secara konsisten menyebabkan biaya riil melampaui tarif paket INA-CBGs (Nabya, 2021). Dengan penerapan klustering mampu mengungkap asosiasi antara frekuensi tindakan tertentu dengan kemunculan defisit klaim yang tidak terlihat melalui analisis statistik deskriptif (Aljohani, 2024; Nabya, 2021).
2. Ketiadaan Label pada Data Klaim: data klaim asuransi kesehatan pada umumnya tidak memiliki label awal yang menunjukkan "*pola tindakan efisien*" atau "*pola tindakan boros*", sehingga klustering menjadi instrumen paling tepat untuk melakukan segmentasi data secara otomatis berdasarkan perilaku medis pasien (Aljohani, 2024; Wandana et al., 2020).
3. Dasar Pengambilan Keputusan Strategis: dengan mengelompokkan kasus berdasarkan pola tindakannya, rumah sakit dapat menentukan layanan prioritas dan melakukan evaluasi pada klaster yang secara konsisten memberikan kontribusi kerugian finansial terbesar (Shepyantoni et al., 2024).
4. Efisiensi Analisis pada Data Besar: algoritma klustering, khususnya K-Means, dikenal memiliki efisiensi tinggi dan kemampuan skalabilitas yang baik untuk memproses volume data rekam medis yang besar dan multidimensi (Aljohani, 2024).

2.6.2 Klastering untuk Analisis pada Data Medis

Penerapan algoritma klastering khususnya k-means, telah banyak diimplementasikan dalam berbagai studi kesehatan untuk mengungkap struktur data yang kompleks pada rekam medis elektronik (*Electronic Health Records*) (An et al., 2023). Penelitian sebelumnya telah membuktikan efektivitas klastering dalam melakukan stratifikasi pasien guna mendukung pengobatan yang terpersonalisasi (Aljohani, 2024; Oktafiandi et al., 2025). Selain itu, (Laksono et al., 2024; Nanda et al., 2023) pada penelitiannya telah menerapkan klastering untuk mengidentifikasi pola penyebaran penyakit di wilayah tertentu, memetakan profil risiko pasien berdasarkan karakteristik klinis (Satriatama et al., 2023; Setiawati et al., 2024), hingga mengelola inventaris obat-obatan di fasilitas kesehatan (Farissa et al., 2021; Izzah & Jananto, 2022).

Fokus penelitian terdahulu mengenai klasterisasi dengan tema medis sebelumnya sangat beragam. Beberapa studi berfokus pada efisiensi operasional, seperti analisis kesesuaian tarif riil rumah sakit dengan tarif paket INA-CBGs guna mengidentifikasi kelompok biaya yang merugikan atau menguntungkan (Nabyala, 2021). Studi lain menekankan pada deteksi *outlier* pada klaim rawat inap untuk mengidentifikasi potensi anomali layanan (Sari & Suharjito, 2022). Ada juga penelitian yang berfokus pada perencanaan kebutuhan medis, seperti prediksi penggunaan obat berdasarkan pola konsumsi masa lalu (Farissa et al., 2021; Izzah & Jananto, 2022).

Meskipun banyak penelitian terdahulu yang telah membahas aspek biaya dan diagnosa, masih terdapat celah penelitian (*research gap*) di mana sebagian besar studi masih melakukan analisis secara terpisah antara karakteristik klinis dan konsekuensi finansial. Belum ada yang mengusulkan sebuah *framework* analisis yang secara spesifik menghubungkan frekuensi dan pola tindakan medis secara eksplisit dengan defisit klaim asuransi. Penelitian terdahulu lebih banyak berfokus pada "*apa penyakitnya*" atau "*siapa pasiennya*", namun kurang mendalami "*seperti apa pola tindakannya*" yang secara teknis merupakan pemicu terjadinya kerugian finansial di bawah sistem pembayaran prospektif. Menjadikan hal tersebut sebagai dasar penulis dalam penelitian ini untuk memberikan kontribusi dengan mengusulkan *Loss-Oriented Analytical Framework* (LOAF). Berbeda dengan pendekatan tradisional, *framework* ini dirancang secara eksplisit untuk mengintegrasikan frekuensi dan pola tindakan medis sebagai fitur utama klastering untuk melihat perilaku pelayanan (*treatment pattern*). Mengidentifikasi kelompok pasien yang secara konsisten berkaitan dengan defisit klaim asuransi kesehatan. Menyediakan sarana evaluasi dan efisiensi bagi manajemen rumah sakit untuk melakukan penanganan klinis pada

pola pelayanan yang menyebabkan kerugian finansial tanpa mengurangi mutu medis. Dengan mengadopsi algoritma K-Means, *framework* LOAF ini diharapkan dapat menjadi alat bantu pengambilan keputusan yang objektif dalam mengoptimalkan layanan kesehatan di era jaminan kesehatan nasional. Ringkasan penelitian terdahulu terkait penerapan klustering untuk analisis pada data medis dapat dilihat pada Tabel 2.5

Tabel 2.5 Ringkasan Penelitian Terkait Penerapan Klastering Untuk Analisis Data Medis

No.	Penulis	Metode	Data/Variable	Hasil
1.	(Ali et al., 2021)	K-Means	Rekam medis pasien BPJS dengan variabel: Jenis kelamin, kecamatan, diagnosa (ICD-10)	Mengidentifikasi diagnosa terbanyak (Z38.0, A09, A91) untuk dasar penentuan anggaran rumah sakit
2.	(Nabyala, 2021)	K-Means	Biaya pengeluaran RS vs tarif INA-CBGs; variabel: Deskripsi INA-CBG, selisih tarif	Mengelompokkan biaya yang merugikan RS (selisih negatif) sebagai pendukung keputusan penetapan tarif
3.	(Arfiani et al., 2020)	Mixed Method (Statistik Deskriptif dan Wawancara)	5 Kasus penyakit dalam terbanyak, dengan variabel: Biaya klaim, INA-CBGs, usia, jenis kelamin, hari rawatan, tingkat keparahan	Menemukan akumulasi Cost Recovery Rate hanya 60%, di mana tarif asuransi belum mampu menutup biaya riil RS
4.	(Sari & Suharjito, 2022)	DBSCAN dan K-Means	Klaim rawat inap & billing RS; variabel: Kode klaim, cara keluar, tingkat keparahan, biaya riil	Efektif dalam melakukan deteksi pencilan (outlier) pada klaim untuk mengidentifikasi potensi anomali layanan
5.	(Wandana et al., 2020)	K-Means	Rekam medis pasien BPJS; variabel: Kode penyakit, umur, jenis kelamin, kelas BPJS, faskes	Menemukan pola penyebaran penyakit (Diare & Dispepsia) berdasarkan kelas layanan pasien
6.	(Fitria et al., 2021)	Analisis Implementasi Clinical Pathway	Pasien BPJS Operasi Caesar; variabel: Dokumen CP, biaya riil, tarif INA-CBGs	Menunjukkan bahwa pengisian formulir CP yang lengkap secara signifikan menurunkan lama rawat inap dan biaya aktual RS

7.	(Herdiaman, 2024)	K-Means	Data rawat inap RSUD; variabel: Alamat, usia, jenis kelamin, ruang perawatan, jenis pembayaran, diagnose	Menghasilkan 3 klaster penyakit untuk membantu perbaikan strategi penanganan pasien dan alokasi sumber daya
8.	(Sy, 2022)	K-Means	Rekam medis rawat inap BPJS; variabel: Umur, jenis kelamin, kelas inap, diagnosa penyakit	Mengelompokkan penyebaran penyakit (kanker & fraktur) untuk memberikan wawasan manajemen RS
9.	(Oktafiandi et al., 2025)	K-Means dan Elbow Method	Karakteristik kesehatan pasien; variabel: Usia, tensi, kolesterol, glukosa, BMI, status merokok	Menciptakan profil risiko pasien untuk mendukung sistem perawatan medis yang lebih terpersonalisasi
10.	(Izzah & Jananto, 2022)	K-Means	Stok obat klinik; variabel: Harga, kategori obat, stok awal, total pemakaian	Mengelompokkan tingkat pemakaian obat untuk perencanaan kebutuhan stok dan efisiensi order persediaan

Tabel 2.5 tersebut menunjukkan bahwa meskipun klastering telah luas digunakan dalam konteks analisis data medis di Indonesia, terdapat empat keterbatasan yang konsisten pada penelitian-penelitian terdahulu yang menjadi celah untuk kontribusi penelitian ini.

Pertama, sebagian besar studi tersebut hanya menggunakan variabel administratif dan demografis, seperti kode penyakit, usia, jenis kelamin, kelas BPJS dan alamat sebagai fitur utama klastering (Ali et al., 2021; Herdriaman, 2024; Sy, 2022; Wandana et al., 2020). Hasilnya hanya menggambarkan siapa pasiennya atau apa diagnosisnya, tetapi tidak menjelaskan bagaimana pola tindakan medis yang diterima pasien.

Kedua, penelitian yang langsung menyentuh aspek finansial seperti yang dilakukan oleh (Arfiani et al., 2020; Nabyala, 2021; Sari & Suharjito, 2022) mengelompokkan kasus berdasarkan biaya agregat atau selisih tarif, akan tetapi tidak melakukan dekomposisi terhadap *driver* tindakan medis yang membentuk selisih tersebut. Konsekuensinya, penelitian-penelitian tersebut hanya menyediakan sinyal defisit pada *level* CBG atau kelompok diagnosis saja, dan tidak mampu menjawab pertanyaan tindakan medis spesifik mana yang memicu atau berkolasi dengan defisit pada paket tarif yang identik.

Ketiga, sebagian besar studi klastering medis di Indonesia mengaplikasikan algoritma pada dataset global tanpa stratifikasi berbasis paket tarif (CBG). Konsekuensi metodologisnya cukup signifikan, dimana klaster yang terbentuk pada dataset global mencampur variasi diagnosis, variasi tarif paket, dan variasi pola tindakan, sehingga tidak dapat dipastikan apakah perbedaan antar klaster mencerminkan perbedaan pola tindakan atau perbedaan paket tarif itu sendiri.

Keempat, dimensi *anomaly detection* dalam studi terdahulu yang dilakukan oleh (Sari & Suharjito, 2022) berorientasi pada deteksi *outlier* per-kasus, belum menyentuh anomali tindakan medis, yaitu tindakan tertentu yang muncul sistematis pada kelompok pasien defisit tetapi absen pada kelompok pasien yang dikategorikan untung di paket tarif yang sama.

Berdasarkan keempat celah tersebut, penelitian ini memposisikan kontribusinya pada empat aspek yang saling melengkapi.

1. Unit analisis baru, dengan *loss concentration* sebagai *entry point*: berbeda dengan pendekatan tradisional yang mengelompokkan pasien berdasarkan diagnosis atau biaya, framework yang diusulkan dalam penelitian ini menempatkan konsentrasi kerugian klaim sebagai unit analisis primer. Pendekatan ini bersifat *focus-driven*: hanya CBG dengan total defisit terbesar yang masuk pipeline analisis, sehingga leverage manajerial setiap temuan menjadi optimal.

2. Stratifikasi per-CBG sebagai prinsip metodologis: klustering dijalankan terpisah untuk setiap CBG prioritas, bukan sekali pada dataset global. Stratifikasi ini menjamin bahwa setiap perbedaan antar klaster maupun setiap gap antara kelompok rugi dan untung dapat diatribusikan secara sah kepada perbedaan pola tindakan medis, bukan kepada perbedaan diagnosis atau tarif paket.
3. Pola tindakan medis sebagai fitur utama klustering: frekuensi tindakan medis (melalui *count encoding* pada lebih dari 1.500 kode tindakan) menjadi fitur utama klustering, bukan variabel demografis atau biaya agregat. Pendekatan ini memungkinkan deteksi *driver* tindakan medis yang berkaitan dengan defisit secara spesifik, tidak hanya sekadar mengidentifikasi kelompok pasien yang merugi, melainkan juga tindakan medis apa yang membentuk defisit pada kelompok tersebut.
4. Integrasi analisis komparatif dan analisis anomali pada framework: framework LOAF menyatukan dua dimensi analisis yang selama ini terpisah, yaitu analisis komparatif rugi-vs-untung untuk estimasi *excess cost*, dan analisis anomali statistik-semantik untuk identifikasi tindakan yang tidak terkait. Integrasi ini menghasilkan *output* yang dapat langsung diatribusikan untuk tiga unit kerja rumah sakit secara bersamaan, yaitu pihak manajemen (prioritas tindak lanjut), tim *case-mix* (audit dokumentasi), dan komite medik (*review clinical pathway*).

2.7 Metrik Validasi Internal Klaster

Metrik validasi internal adalah teknik evaluasi yang digunakan untuk mengukur kualitas hasil klustering berdasarkan informasi yang ada di dalam dataset itu sendiri, tanpa memerlukan label referensi atau ground truth (Salman et al., 2025; Syafiq et al., 2026). Fokus utama dari metrik ini adalah menilai dua aspek struktur klaster, yaitu kohesi (seberapa dekat titik-titik data di dalam satu kelompok) dan separasi (seberapa jauh jarak antar kelompok yang berbeda), sehingga relevan untuk konteks pembelajaran tak terawasi (*unsupervised learning*) (Ananda et al., 2025; Hasugian et al., 2025). Dalam penelitian ini, metrik yang digunakan meliputi *silhouette*, *davies-bouldin index* dan *calinski-harabasz index* yang ditujukan untuk mendapatkan hasil yang informatif dan komprehensif.

1. Silhouette

Metrik ini mengevaluasi konsistensi struktur klaster dengan mengukur sejauh mana setiap titik data lebih mirip dengan anggota klasternya sendiri dibandingkan dengan titik-titik pada klaster terdekat. Nilai koefisien yang mendekati 1 merefleksikan partisi yang padat dan

terpisah baik, sedangkan nilai negatif mengisyaratkan potensi misklasifikasi (Chicco et al., 2025; Hasugian et al., 2025).

2. Davies-Bouldin Index

Metrik ini menilai efisiensi struktur kluster dengan membandingkan rata-rata jarak titik data terhadap *centroid* klasternya terhadap jarak minimal antar-*centroid*. Dimana nilai DBI mendekati nol mengindikasikan partisi yang padat secara internal dan terpisah secara eksternal (Almaripat et al., 2025; Hasugian et al., 2025).

3. Calinski-Harabasz Index

Sebagai indikator validasi berbasis analisis varians, CHI menilai efisiensi struktur kluster dengan membandingkan sebaran *centroid* antar-kluster terhadap kerapatan titik data di dalam masing-masing kluster. Skor CHI yang besar merepresentasikan partisi yang mampu memaksimalkan heterogenitas antar-kluster sembari meminimalkan variabilitas intra-kluster (Chicco et al., 2025; Hasugian et al., 2025).

Meskipun ketiga metrik evaluasi internal tersebut dihitung secara simultan, evaluasi dan penentuan K optimal pada tahap *looping optimal k* diprioritaskan berdasarkan skor *silhouette* terbaik. Pertimbangan metodologisnya adalah karena dalam beberapa penelitian sistematis, *silhouette* sering kali digunakan sebagai kriteria utama untuk memilih konfigurasi kluster yang optimal karena metrik ini secara simultan mengevaluasi kohesi dan separasi kluster secara mendalam di tingkat objek (Ananda et al., 2025; Syafiq et al., 2026). Dan karena *concern* terhadap konsistensi penempatan dalam kelompok yang paling mirip dan menghindari tumpang tindih (*overlap*) yang ambigu (Galih & Amanda, 2025; Rahma, 2025). Selanjutnya metrik dbi dan chi akan digunakan untuk verifikasi lanjutan jika terdapat skor metrik *silhouette* yang sama pada rekomendasi optimal k yang berbeda.

2.8 Tantangan Dimensionalitas Tinggi

Data medis sering kali melibatkan *volume* besar dengan banyak variabel (Rinaldi & Sulistiadi, 2025), ditambah dengan hasil dari tahap *encoding* tindakan medis yang menghasilkan banyak fitur. (Aggarwal et al., 2001) dalam penelitiannya mendemonstrasikan secara matematis bahwa pada ruang berdimensi tinggi, jarak *euclidean* antara titik-titik data cenderung terkonsentrasi, perbedaan jarak terdekat dan terjauh menjadi semakin kecil secara relatif. Fenomena *concentration of measure* atau *curse of dimensionality* ini menyebabkan metrik berbasis *euclidean* kehilangan daya diskriminasinya. Konsekuensinya adalah *silhouette score* yang secara natural lebih rendah pada data berdimensi tinggi. Oleh karenanya, untuk mengatasi skor *silhouette* yang rendah tersebut, (Yunitaningtyas &

Herianti, 2025) dalam penelitiannya menyarankan untuk menerapkan teknik *dimensionality reduction*.

2.8.1 Dimensionality Reduction

Dimensionality reduction adalah teknik analisis multivariat yang digunakan untuk mengurangi jumlah variabel atau dimensi dalam suatu kumpulan data dengan tetap mempertahankan sebanyak mungkin informasi asli dan variansi data tersebut (Ardiansyah et al., 2022; Salman et al., 2025; Yunitaningtyas & Herianti, 2025). Dalam pengolahan data besar seperti data pada rekam medis, jumlah variabel yang terlalu banyak dapat menyebabkan masalah "kutukan dimensi" (*curse of dimensionality*), di mana performa algoritma menurun dan risiko *overfitting* meningkat (Naeem et al., 2023). Dengan mereduksi dimensi, variabel-variabel yang redundan atau kurang signifikan akan dihilangkan, sehingga proses analisis data menjadi lebih cepat, efisien, dan mempermudah visualisasi pola yang tersembunyi (Akbar, 2023; Naeem et al., 2023). Berikut merupakan beberapa metode reduksi dimensi yang sering digunakan dalam data mining dan machine learning:

1. Principal Component Analysis (PCA): merupakan teknik transformasi linier yang tertua dan paling populer untuk data kontinu (Akbar, 2023; An et al., 2023). Teknik PCA ini bekerja dengan memproyeksikan data ke ruang baru yang terdiri dari *principal components* yang saling tegak lurus (*ortogonal*) untuk menangkap variansi maksimal sambil meminimalkan *noise* (An et al., 2023; Savander & Lehtomäki, 2023).
2. t-Distributed Stochastic Neighbor Embedding (t-SNE): merupakan teknik reduksi dimensi non-linier yang sangat efektif untuk visualisasi data dimensi tinggi dengan cara mempertahankan struktur lokal dan jarak antar titik data yang berdekatan (An et al., 2023; Savander & Lehtomäki, 2023).
3. Uniform Manifold Approximation and Projection (UMAP): teknik reduksi dimensi non-linier berbasis perkiraan manifold yang mampu menangkap struktur global data lebih baik daripada t-SNE dan sering memberikan hasil klasterisasi yang lebih stabil (Savander & Lehtomäki, 2023).

BAB 3


Metodologi

Dari kajian pustaka bab 2, dapat dirangkum tiga premis metodologis yang menjadi dasar perancangan penelitian ini. Pertama, defisit klaim INA-CBG bukan fenomena yang merata pada seluruh populasi pasien melainkan terkonsentrasi pada sub-kelompok tertentu, sehingga unit analisis perlu bergeser dari rerata populasi ke konsentrasi kerugian. Kedua, pola tindakan medis terbukti merupakan driver langsung biaya riil rumah sakit, sehingga fitur klastering perlu mengangkat frekuensi tindakan sebagai variabel utama, bukan demografi atau diagnosis saja. Ketiga, klastering pada dataset global mencampur variasi diagnosis dan variasi paket tarif, sehingga desain klastering perlu menerapkan stratifikasi berbasis CBG untuk menjamin atribusi sah temuan terhadap pola tindakan. Ketiga premis ini diterjemahkan secara operasional menjadi tahapan penelitian yang akan dijabarkan pada bab ini.

3.1 Desain Penelitian

Dengan dasar permasalahan yang telah dijabarkan pada pendahuluan, penelitian ini akan menggunakan pendekatan kuantitatif yang bersifat eksploratif-deskriptif, yaitu bertujuan untuk mengidentifikasi dan mendeskripsikan pola tersembunyi dalam data. Pendekatan *unsupervised learning* dipilih agar klaster yang terbentuk sepenuhnya ditentukan oleh struktur data tindakan medis itu sendiri. Kerangka analisis yang diusulkan dalam penelitian ini adalah *framework analysis* berbasis kerugian atau dapat juga disebut dengan *loss-oriented analytical framework* (LOAF) yang mengadopsi algoritma klastering *k-means* yang secara eksplisit dirancang untuk mengidentifikasi, mengelompokkan, dan menganalisis kasus kerugian klaim berdasarkan pola tindakan medisnya.

Proses klastering dalam *framework* ini tidak dijalankan secara global pada seluruh data klaim dengan kasus rugi sekaligus, melainkan dijalankan secara terpisah dengan prinsip stratifikasi untuk setiap kelompok *case-based group* (CBG) pada tarif INA-CBG. Dengan menjalankan klastering di dalam CBG yang identik, faktor pembaur seperti perbedaan jenis penyakit dan perbedaan tarif dapat dikendalikan, sehingga klaster yang terbentuk murni mencerminkan perbedaan pola tindakan medis dan bukan perbedaan diagnosis. Secara garis besar *framework* yang diusulkan ini memiliki 4 tahap yang tersusun secara sekuensial. Tahap-tahap ini adalah *data preparation*, *data pre-processing*, *clustering* dan *analysis*. Detil gambaran alur penelitian yang diusulkan dapat dilihat pada Gambar 3.1.



Gambar 3.1 Pipeline Metodologi Loss-Oriented Analytical Framework (LOAF) dengan Stratifikasi per-CBG

3.2 Sumber Data dan Populasi

3.2.1 Sumber Data

Data yang digunakan dalam penelitian ini merupakan data sekunder dari rekam medis elektronik dan data historis klaim INA-CBG dari sebuah rumah sakit kelas C yang terletak di Yogyakarta, yang sudah berdiri sejak tahun 1997 yang sudah memiliki izin operasional sejak tahun 2005. Rumah sakit ini memiliki tenaga kerja sebanyak 450 orang dan fitur unggulan berupa ruang ICU, ruang perawatan jantung, perawatan neonates dan pediatrik dan beragam fasilitas lainnya seperti rawat inap, IGD, poliklinik spesialis (kandunganm, penyakit dalam, ortopedi, dll), pelayanan penunjang (laboratorium, radiologi, dll), fasilitas pendukung, dan layanan khusus (vaksinasi, MCU, dll). Rumah sakit ini telah melayani pasien peserta program JKN sejak tahun 2014. Data diperoleh melalui mekanisme permintaan resmi kepada pihak rumah sakit, divisi IT dan rekam medis rumah sakit dengan persetujuan institusional yang berlaku. Seluruh identitas pasien telah dianonimkan sebelum digunakan dalam analisis. Data yang digunakan dalam penelitian ini meliputi:

1. Data tindakan pasien
2. Data demografis pasien
3. Data klaim INA-CBG's

3.2.2 Periode Data

Data yang akan digunakan untuk dianalisis pada penelitian ini mencakup episode rawat inap dalam periode 1 tahun (Januari 2023 – Januari 2024).

3.2.3 Kriteria Inklusi

Data pasien yang digunakan dalam penelitian ini harus memenuhi kriteria inklusi yang telah ditentukan seperti berikut:

1. Memiliki sekurang-kurangnya satu catatan tindakan medis pada salah satu dari kolom tindakan, item, atau laboratorium, karena episode tanpa tindakan medis tidak memiliki variabel inti yang dapat dianalisis
2. Merupakan pasien dengan data atau informasi keuangan lengkap, yakni nilai tarif klaim asuransi dan tarif rumah sakit terisi, karena kedua variabel ini diperlukan untuk menghitung variabel target SELISIH

Adapun atribut lain yang mengandung nilai hilang, seperti status pulang pasien (*discharge status*), tidak dijadikan dasar eksklusi melainkan ditangani melalui strategi imputasi yang akan dijelaskan pada Tabel 3.2.

3.2.4 Struktur Dataset

Dataset yang akan digunakan memiliki struktur awal seperti yang disajikan pada Tabel 3.1.

Tabel 3.1 Struktur Dataset

No	Kolom	Tipe	Domain	Keterangan
1.	ID	Kategorik	-	Identifiser unik pasien
2.	Sex	Kategorik	{1,2}	Jenis kelamin
3.	Umur	Numerik	≥ 0	Usia pasien dalam tahun
4.	Kelas Rawat	Numerik	{1,2,3}	Kelas perawatan
5.	LOS	Numerik	≥ 1	Length of stay dalam hari
6.	Discharge Status	Kategorik	{1-5}	Status keluar pasien
7.	Has ICU	Biner	{0,1}	Indikator perawatan ICU
8.	KODING	Teks	-	Kode paket tarif INA-CBG mencakup tingkat keparahan (<i>severity level I/II/III</i>)
9.	Deskripsi Penyakit	Teks	-	Label naratif paket diagnosis INA-CBG
10.	Diagnosa List	Teks	-	Daftar kode diagnosis (ICD-10)
11.	Procedure List	Teks	-	Daftar kode prosedur (ICD-9)
12.	Tarif Klaim Asuransi	Numerik	≥ 0	Tarif dibayar BPJS dalam rupiah
13.	Tarif Rumah Sakit	Numerik	≥ 0	Biaya riil rumah sakit dalam rupiah
14.	Tindakan List	Teks	-	Daftar kode tindakan medis
15.	Item List	Teks	-	Daftar kode item medis
16.	Lab List	Teks	-	Daftar kode pemeriksaan laboratorium

Tabel 3.1 menunjukkan bahwa dataset terdiri dari 16 kolom dengan tipe data yang beragam, mencakup variabel kategorik, numerik, biner, dan teks. Kolom inti yang menentukan status

klaim adalah Tarif Klaim Asuransi dan Tarif Rumah Sakit, selisih keduanya menjadi variabel target defisit dalam penelitian ini. Sementara itu, tiga kolom teks (Tindakan List, Item List, dan Lab List) menjadi sumber utama fitur klastering setelah melalui proses transformasi *count encoding*, mengingat kolom-kolom tersebut merekam seluruh riwayat tindakan, item, dan laboratorium yang diterima setiap pasien selama episode rawat inap.

3.3 Tahap 1: Persiapan Data (*Data Preparation*)

3.3.1 Integrasi dan Validasi Data

Data demografi pasien dan data administratif yang diperoleh dari rekam medis elektronik, dan sistem informasi klaim INA-CBGs kemudian diintegrasikan menjadi satu kesatuan *dataframe* baru berdasarkan ID. Proses integrasi ini memastikan bahwa setiap episode rawat inap (ID) memiliki informasi klinis, administratif, dan finansial yang lengkap di dalam satu baris data, sehingga siap untuk diproses pada tahap berikutnya.

3.3.2 Pembentukan Kolom Bantu

Pembentukan kolom bantu ini ditujukan untuk memudahkan model untuk melakukan kuantifikasi, karena beberapa kolom bertipe text yang tidak dapat langsung diproses oleh *machine learning* karena tidak berbentuk numerik (Johnson et al., 2023), berikut merupakan kolom bantu yang terbentuk:

1. Kolom JML_DIAGLIST (*Diagnose List*): kolom ini berisi kode diagnosis ICD-10 dengan format *semicolon-separated*, untuk itu dibentuk kolom baru JML_DIAGLIST untuk merepresentasikan jumlah total diagnosis pasien dalam bentuk numerik dengan metode *count encoding*.
2. Kolom JML_PROCLIST (*Procedure List*): kolom ini berisi kode prosedur ICD-9 dengan format *semicolon-separated*, untuk itu dibentuk kolom baru JML_PROCLIST untuk merepresentasikan jumlah total prosedur pasien dalam bentuk numerik dengan metode *count encoding*.
3. Kolom SELISIH: kolom selisih ini dibentuk untuk membedakan apakah suatu episode pasien termasuk dalam kategori kasus defisit (nilai selisih > 0) atau tidak (nilai selisih < 0). Kolom ini dihitung sebagai selisih antara tarif klaim asuransi dan tarif riil rumah sakit, sebagaimana dirumuskan pada persamaan (3.1).

$$SELISIH = \text{Tarif Klaim Asuransi} - \text{Tarif Rumah Sakit} \quad (3.1)$$

3.4 Tahap 2: Pra-pemrosesan Data (Data Pre-processing)

3.4.1 Penanganan Missing Value

Pada tahap penanganan *missing value*, strategi yang akan dilakukan untuk tiap variabelnya berbeda, hal ini karena didasarkan pada karakteristik dan peran tiap variabelnya dalam proses analisis, sebagaimana dirangkum pada Tabel 3.2.

Tabel 3.2 Penanganan Missing Value

Variabel	Strategi	Justifikasi
ID	Eksklusi baris	Baris tanpa id tidak dapat dianggap pasien yang resmi terdaftar dalam sistem rumah sakit (<i>anomaly</i>).
Sex	Update/Imputasi manual	Karena jenis kelamin pasien dapat dilihat dari nama pasiennya
LOS	Imputasi median	Distribusi right-skewed, dengan imputasi median akan lebih representatif dari mean
Discharge Status	Imputasi nilai 1	Pasien dengan baris yang tidak memiliki nilai pada kolom <i>discharge status</i> akan diimputasi nilai 1 (dinyatakan cukup menerima pelayanan / sembuh atas pernyataan dokter) karena pasien telah menyelesaikan pengobatan (jika kolom tindakan medis dan administrative tidak kosong)
Has ICU	Imputasi nilai 0	Tidak ada bukti ICU, maka anggapannya tidak ada ICU (asumsi konservatif)
KODING	Eksklusi Baris	Pasien yang tidak memiliki koding INA-CBG akan di anggap cacat/tidak layak untuk digunakan
Diagnosa List	Imputasi string kosong	Digunakan sebagai label deskriptif, bukan fitur numerik (jika yang kosong bukan diagnosis primer)
Procedure List	Eksklusi baris	Kasus pasien tanpa tindakan tidak dapat dianalisis (variable inti)
Tarif Klaim Asuransi	Eksklusi baris	Variable inti yang tidak dapat diimputasi
Tarif Rumah Sakit	Eksklusi baris	Variable inti yang tidak dapat diimputasi

Tindakan List	Imputasi string kosong	Pasien bisa saja hanya menjalani tes laboratorium/radiologi dan hanya mendapatkan obat/item tanpa harus menjalani tindakan
Item List	Imputasi string kosong	Pasien bisa saja hanya menjalani tindakan medis dan tes laboratorium/radiologi
Lab List	Imputasi string kosong	Pasien bisa saja tidak menjalankan laboratorium/radiologi tes
Tindakan List + Item List + Lab List	Eksklusi baris	Pasien tidak memiliki kolom tindakan medis untuk digunakan

Tabel 3.2 memperlihatkan strategi penanganan *missing value* yang dirancang tidak seragam, melainkan disesuaikan dengan peran masing-masing variabel dalam analisis. Variabel inti yang tidak dapat disubstitusi, seperti Tarif Klaim, Tarif Rumah Sakit, KODING, dan Procedure List, maka akan diberlakukan strategi eksklusi baris karena ketidakhadiran atau kosongnya nilai fitur tersebut menjadikan kasus tidak dapat dianalisis secara valid. Sebaliknya, variabel pendukung seperti LOS dan Has_ICU akan diimputasi dengan nilai yang konservatif (median atau nilai 0) untuk mempertahankan ukuran sampel, dengan asumsi bahwa tidak adanya rekaman ICU berarti tidak ada penggunaan ICU pada kasus tersebut.

3.4.2 Transformasi Kolom Tindakan Medis: Count Encoding

Kolom tindakan list, item list, dan lab list menyimpan data tindakan medis dalam format *semicolon-separated string*, sebagai contoh: "X300;X100;X250;X300". Diperlukan proses transformasi untuk dapat mengubah data teks tersebut menjadi data numerik agar dapat digunakan (Johnson et al., 2023). Pada penelitian ini sebelum transformasi numerik, setiap kode pada ketiga kolom tersebut terlebih dahulu diberi awalan (*prefix*) sesuai sumbernya, yaitu "TINDAKAN_", "ITEM_", dan "LAB_". Prefiksasi ini ditujukan untuk mencegah tabrakan penamaan kode yang sama dari sumber berbeda, sekaligus memudahkan interpretasi juga pemahaman asal setiap fitur dari sumber aslinya.

Selanjutnya tahap transformasi data akan diterapkan dengan menggunakan metode *count encoding* dengan beberapa pertimbangan yang telah dijelaskan di bagian Encoding Data Tindakan Medis pada bab 2 diatas. Dalam metode *count encoding*, setiap nilai unik (kode tindakan medis) dalam sebuah baris teks digantikan oleh jumlah total kemunculan (*raw count*) dari nilai unik kode tersebut pada setiap pasien (Bolikulov et al., 2024). Transformasi ini merepresentasikan setiap pasien p_i ke dalam sebuah vektor hitung (*count vector*) y_i dengan formula (3.2):

$$y_i = [c_{i,1}, c_{i,2}, \dots, c_{i,|C|}] \quad (3.2)$$

Di mana setiap indeks j dalam vektor tersebut menunjukkan frekuensi kemunculan kode klinis c_j yang diterima oleh pasien p_i . Melalui penerapan metode ini, setiap riwayat pelayanan pasien ditransformasikan menjadi matriks fitur berdimensi $(n_{pasien} \times n_{kode_tindakan})$, di mana nilai setiap elemen mencerminkan intensitas penggunaan tindakan oleh tiap pasien. Sebagai contoh, seorang pasien memiliki baris tindakan list seperti berikut: "X300;X100;X250;X300", maka akan direpresentasikan sebagai: X300=2, X100=1, X250=1, dan nilai 0 untuk semua kode lain yang tidak muncul pada pasien tersebut. Contoh analogi penerapan transformasi menggunakan *count encoding* ini dapat dilihat pada Tabel 3.3 dan Tabel 3.4.

Tabel 3.3 Data Tindakan Sebelum Count Encoding (Contoh)

ID		Tindakan List
A122311CD1		X300;X100;X250;X300
A133244DG1		X500;X100;Y700

Tabel 3.4 Data Tindakan Setelah Count Encoding (Contoh)

ID		X300	X100	X250	X500	Y700
A122311CD1		2	1	1	0	0
A133244DG1		0	1	0	0	1

Perbandingan Tabel 3.3 dan Tabel 3.4 tersebut mengilustrasikan perubahan representasi data secara konkret. Dimana data teks pada kolom tindakan list yang awalnya berupa string tidak terstruktur ("X300;X100;X250;X300") ditransformasikan menjadi vektor numerik di mana setiap kolom merepresentasikan satu kode tindakan unik dan nilainya mencerminkan total frekuensi penggunaannya oleh pasien bersangkutan. Misal pada pasien A122311CD1 yang menerima kode X300 sebanyak dua kali, tercatat dengan nilai 2 pada kolom X300 dan nilai 1 pada X100 serta X250, sedangkan kode yang tidak diterima bernilai 0. Hasil transformasi ini membentuk matriks fitur terstruktur yang siap digunakan sebagai input algoritma klastering.

3.4.3 Kategorisasi Dataset: Kasus Rugi vs. Kasus Untung

Setelah melalui tahap transformasi kolom tindakan, selanjutnya data akan dipecah dan dikategorikan berdasarkan nilai kolom selisih. Seluruh dataset akan dibagi menjadi dua subset seperti berikut:

1. Data defisit: kasus pasien dengan nilai kolom SELISIH < 0 (yang merupakan subset utama yang menjadi fokus analisis).
2. Data untung: kasus pasien dengan nilai kolom SELISIH > 0 (yang akan digunakan sebagai subset pembanding pada tahap analisis komparatif pasca-klaster)

Proses pembelahan data ini merupakan dasar *framework* LOAF yang diusulkan karena kedua subset akan dibandingkan secara langsung di dalam kelompok CBG yang sama pada tahap analisis komparatif. Subset rugi menjadi objek klastering, sedangkan subset untung berperan sebagai tolok ukur (*benchmark*) pola tindakan yang efisien dalam segi biaya. Sedangkan penerapan *clustering* pada CBG dengan kasus defisit saja secara eksplisit bertujuan untuk

memetakan heterogenitas internal dalam populasi yang sudah diketahui mengalami kerugian, bukan dimaksudkan untuk membentuk batas pemisah antara defisit dan surplus. Selanjutnya perbandingan dengan data surplus kemudian akan dilakukan secara *post-hoc* pada level diagnosis, bukan lewat struktur klaster.

3.4.4 Seleksi Variabel untuk Proses Klastering

Pemilihan variabel dalam proses klasterisasi didasarkan pada kebutuhan untuk menangkap struktur data yang paling representatif terhadap realitas klinis dan beban finansial rumah sakit. Berdasarkan rumusan masalah mengenai variasi defisit klaim pada CBG yang sama, penelitian ini menggunakan dua skema model variabel yang dijalankan secara parallel untuk setiap kelompok CBG seperti berikut:

1. Model Utama (*Model A - Mixed Variables*): Model utama mengintegrasikan fitur frekuensi tindakan medis hasil *encoding* dengan variabel klinis dan administratif tambahan, yaitu:
 - a. *Length of Stay (LOS)*: variabel ini dimasukkan karena literatur (Andirasdini, Saputra, Rivai, Eka, et al., 2025; Monica et al., 2021) secara konsisten menunjukkan bahwa lama hari rawat adalah salah satu faktor determinan terbesar yang memengaruhi perbedaan antara biaya riil rumah sakit dengan tarif paket INA-CBGs. Semakin lama pasien dirawat, semakin besar akumulasi biaya variabel (obat, BHP, jasa) yang sering kali melampaui plafon klaim (Monica et al., 2021).
 - b. HAS_ICU (Penggunaan Ruang Intensif): variabel ini berfungsi sebagai indikator tingkat keparahan (*severity level*) dan intervensi (penanganan klinis) kompleks. Penggunaan sumber daya di unit intensif berkontribusi besar pada selisih biaya karena intensitas pelayanan yang jauh lebih tinggi dibandingkan rawat inap biasa (Afrina et al., 2020).

Adapun variabel JML_DIAGLIST yang dibuat untuk merepresentasikan kompleksitas komorbiditas tidak disertakan sebagai fitur klastering. Hal ini karena stratifikasi sudah termasuk dalam kode INA-CBG lengkap (kolom Koding) yang sudah memisahkan tingkat keparahan I, II, dan III. Mengingat tingkat keparahan INA-CBG sangat dipengaruhi oleh jumlah diagnosis sekunder (Afrina et al., 2020; Amalia et al., 2023), maka di dalam satu kelompok Koding kompleksitas diagnosis sudah relatif terkontrol. Oleh karena itu, variabel JML_DIAGLIST dialihfungsikan menjadi variabel kontrol *case-mix* yang digunakan pada tahap analisis komparatif

untuk mengoreksi perbedaan kompleksitas residual antara kasus rugi dan kasus untung.

2. Model Pembanding (Model B - *Treatment-Only*): Untuk menjawab kebutuhan identifikasi pola tindakan medis secara spesifik, penelitian ini juga membangun Model B yang hanya menggunakan variabel hasil *encoding* tindakan medis. Alasan memfokuskan klastering pada tindakan medis adalah untuk mengisolasi "pola tindakan" (*treatment pattern*) murni guna melihat efisiensi pelayanan tanpa pengaruh variabel eksternal seperti durasi inap (VIP et al., 2025).

Perbandingan kedua model ini ditujukan untuk menguji secara empiris dampak penambahan fitur klinis terhadap kualitas pemisahan klaster sekaligus menguji *robustness* struktur klaster yang terbentuk. Mengingat matriks tindakan medis memiliki dimensi yang sangat tinggi dan bersifat *sparse* (banyak bernilai nol) yang dapat menurunkan skor metrik validasi internal seperti *silhouette*, penambahan variabel numerik dengan variansi yang lebih padat diharapkan dapat membantu algoritma dalam menemukan batas klaster yang lebih tegas (Galih & Amanda, 2025). Apabila kedua model menghasilkan struktur klaster yang serupa, dapat disimpulkan bahwa pengelompokan didorong terutama oleh pola tindakan medis dan tidak bergantung secara berlebihan pada variabel pendamping. Perbedaan penggunaan variabel antar model dapat dilihat pada Tabel 3.5.

Tabel 3.5 Perbandingan Model

Variabel	Model Utama	Model B
Encoded tindakan medis	✓	✓
Length of stay	✓	-
Has ICU	✓	-

Tabel 3.5 merangkum perbedaan cakupan variabel antara Model A dan Model B secara ringkas. Model A (*mixed variables*) menggunakan fitur tindakan medis hasil *encoding* yang diperkaya dengan dua variabel klinis tambahan, yaitu *Length of Stay* dan *Has_ICU*, untuk menangkap dimensi durasi rawat dan intensitas pelayanan intensif. Model B (*treatment-only*) hanya menggunakan fitur tindakan medis, sehingga klaster yang terbentuk mencerminkan murni pola tindakan tanpa pengaruh variabel pendamping. Desain paralel ini

akan digunakan sebagai pengujian empiris apakah penambahan variabel klinis memberikan peningkatan kualitas pemisahan klaster yang signifikan.

3.4.5 Transformasi Logaritmik

Karena dataset tindakan medis hasil *encoding* cenderung memiliki rentang nilai yang sangat lebar dan distribusi yang miring (*skewed*), di mana sebagian besar fitur memiliki frekuensi rendah namun terdapat beberapa tindakan medis rutin yang memiliki frekuensi sangat tinggi (Salman et al., 2025). Kondisi distribusi data yang tidak normal ini dapat memengaruhi performa algoritma klustering, terutama berbasis jarak seperti k-means karena fitur dengan variansi besar akan mendominasi perhitungan jarak secara tidak proporsional (Ananda et al., 2025; Bolikulov et al., 2024).

Untuk mengatasi masalah tersebut, penelitian ini menerapkan teknik transformasi logaritmik yang tidak lain bertujuan untuk mengompresi skala data dan mentransformasikan variabel dengan distribusi miring agar mendekati bentuk distribusi normal (Salman et al., 2025). Mengingat data hasil *count encoding* mengandung banyak nilai nol, transformasi dilakukan menggunakan formula *log plus one* seperti yang dijabarkan pada formula (3.3):

$$(\ln(x + 1)) \quad (3.3)$$

Tujuannya adalah untuk menangani tindakan medis yang memiliki nilai frekuensi nol, karena jika tidak ditangani maka $\log(0)$ akan menghasilkan nilai tak terdefinisi ∞ (Salman et al., 2025). Hasil dari transformasi ini akan menjadikan distribusi data yang lebih seimbang, yang pada tahap selanjutnya akan mempermudah algoritma klasterisasi dalam mengidentifikasi pola kelompok pasien secara lebih akurat tanpa menghilangkan informasi esensial mengenai intensitas tindakan medisnya.

3.4.6 Normalisasi Data: RobustScaler

Setelah melalui tahap transformasi logaritmik, normalisasi menggunakan *RobustScaler* diterapkan. Pemilihan ini didasarkan pada karakteristik data tindakan medis yang tetap memiliki risiko *outliers* tinggi meskipun telah melalui tahap transformasi, oleh karenanya *robustscaler* diterapkan sebagai “pengaman ganda” dalam menangani *outliers* yang masih tersisa agar tidak mendistorsi proses klasterisasi (Salman et al., 2025; Zeng et al., 2019). Berbeda dengan *StandardScaler* yang menggunakan rata-rata dan deviasi standar,

RobustScaler menggunakan median dan interquartile range (*IQR*) sebagai parameter normalisasi sehingga lebih tahan terhadap outlier yang masih mungkin tersisa (Pinheiro et al., 2025). Formula *RobustScaler* didefinisikan seperti pada formula (3.4) (Pinheiro et al., 2025):

$$x_{scaled} = \frac{x - x_{median}}{IQR} \quad (3.4)$$

Dengan kombinasi penerapan *log1p* dan *RobustScaler* ini, data menjadi lebih stabil dan siap diproses oleh algoritma K-Means tanpa risiko distorsi skala yang diakibatkan oleh nilai-nilai ekstrem pada riwayat tindakan medis pasien (Ananda et al., 2025). Langkah ini memberikan perlindungan berlapis terhadap dua masalah utama yang ada pada data tindakan medis yang dimiliki (memiliki distribusi tidak normal dan nilai ekstrem), yang juga di tujukan untuk mengatasi kelemahan algoritma k-means sebagaimana yang akan dijelaskan pada sub bab mengenai Algoritma Pengelompokan K-Means.

3.4.7 Reduksi Dimensi: Principal Component Analyst (PCA)

Principal Component Analysis (PCA) bekerja dengan cara mentransformasi variabel-variabel asli yang mungkin saling berkaitan menjadi sekumpulan variabel baru yang tidak saling berhubungan (ortogonal), yang disebut sebagai komponen utama (PC) (Salman et al., 2025; Yunitaningtyas & Herianti, 2025). Tujuan utama penerapan PCA dalam penelitian ini tidak lain adalah:

1. Meningkatkan Efisiensi Komputasi: mengurangi beban kalkulasi pada algoritma klastering dengan bekerja pada ruang dimensi yang lebih rendah (PC1, PC2, PC...) (Salman et al., 2025).
2. Menghilangkan Redundansi: mengompresi informasi dari ratusan kode tindakan medis yang sering muncul bersamaan menjadi komponen yang lebih informatif (Salman et al., 2025; Syafiq et al., 2026).
3. Visualisasi dan Interpretasi: PCA memproyeksikan data ke dalam ruang dua dimensi (2D) untuk mempermudah identifikasi sebaran klaster dan keberadaan *outliers* (Galih & Amanda, 2025; Salman et al., 2025).

Metode ini sangat berguna untuk kumpulan data yang besar atau kompleks yang mengandung banyak variable, karena mengatasi masalah "*curse of dimensionality*" yang sering muncul pada dataset besar (Salman et al., 2025; Yunitaningtyas & Herianti, 2025).

Namun, dalam konteks medis, transparansi model merupakan hal yang paling utama karena prediksi dan analisis yang dihasilkan akan digunakan untuk mempengaruhi pengambilan keputusan medis dan kebijakan manajerial di dunia nyata (Shickel et al., 2018; Zeng et al., 2019). Berdasarkan pertimbangan tersebut, penelitian ini menerapkan PCA hanya untuk proses klasteringnya saja, dengan alasan-alasan fundamental berikut:

1. Kehilangan Kemampuan Interpretasi (*Loss of Interpretability*) pada Level Fitur Asli: secara matematis, PCA bekerja dengan mencari kombinasi linier dari variabel asli untuk membentuk komponen baru atau Principal Components (PC) (Syafiq et al., 2026; Yunitaningtyas & Herianti, 2025). Komponen ini (Z_k) adalah hasil penjumlahan bobot dari ratusan tindakan medis (misalnya, $Z_1 = a_1X_1 + a_2X_2 + \dots$) (Syafiq et al., 2026). Dalam konteks manajerial rumah sakit, identitas asli dari tindakan medis (seperti jenis injeksi atau prosedur laboratorium spesifik) menjadi lebur dan kehilangan maknanya di dalam komponen tersebut. Jika interpretasi dilakukan pada ruang PC, peneliti tidak dapat lagi menarik "benang merah" yang akurat untuk memberikan rekomendasi operasional kepada pihak *stakeholder* terkait mengenai tindakan spesifik mana yang memicu kerugian finansial, karena fitur-fitur tersebut sudah terkompresi menjadi angka abstrak yang tidak memiliki padanan klinis langsung (Sethi, 2020; Shickel et al., 2018).
2. Distorsi Realitas Medis Akibat *Lossy Compression*: meskipun PCA sering digunakan untuk visualisasi pola dalam ruang dimensi rendah (2D atau 3D) (Salman et al., 2025; Syafiq et al., 2026), penerapan ini bersifat *lossy compression*. Seperti yang ditunjukkan oleh (Yunitaningtyas & Herianti, 2025) dalam penelitiannya, dengan mereduksi data dapat membuang sekitar 75% informasi riwayat pasien demi mengejar estetika hasil visual. Dalam domain kesehatan, di mana setiap detail kecil tindakan medis sangat menentukan akurasi klaim INA-CBG, kehilangan varians sebesar itu dapat membuat kluster yang dihasilkan menjadi tidak valid secara klinis karena mengabaikan mayoritas interaksi kompleks antar kode klinis (Kustiwa et al., 2026; Sethi, 2020).
3. Ilusi Kesimpulan dari penerapan *Inverse Transform*: penggunaan fungsi *inverse transform* yang digunakan untuk mengembalikan data hasil PCA ke dimensi aslinya demi interpretasi telah dipertimbangkan, namun penerapan ini menimbulkan potensi distorsi integritas data karena fungsi ini tidak mampu mengembalikan informasi yang sudah hilang, melainkan hanya melakukan rekonstruksi proyektif (estimasi) (Zeng et al., 2019).

Oleh karena alasan-aasan tersebut PCA hanya digunakan sebagai alat bantu teknis untuk proses klasterisasi saja. Setelah label klaster terbentuk, tahap interpretasi dan profiling tetap dilakukan menggunakan fitur asli (data mentah) pasien guna memastikan bahwa setiap rekomendasi manajerial yang dihasilkan tetap merujuk pada tindakan medis riil yang diderita pasien di rumah sakit, bukan pada angka abstrak hasil proyeksi PCA (Yunitaningtyas & Herianti, 2025).

3.5 Tahap 3: Klustering (Clustering)

3.5.1 Stratifikasi per INA-CBG

Dalam proses stratifikasi per-INA-CBG ini, kriteria seleksi CBG yang dianalisis adalah sebagai berikut:

1. CBG yang dipilih merupakan *top-10* CBG dengan total defisit terbesar
2. CBG yang dipilih memiliki minimal 30 kasus rugi per CBG
3. CBG yang dipilih memiliki minimal 5 kasus untung per CBG

Kriteria tersebut dibuat agar analisis dan komparasi hasil klustering valid. CBG yang tidak memenuhi kriteria ini tetap ter-cluster (jika ada), namun pada tahap komparasi rugi-vs-untung akan dilewati.

Sistem INA-CBG (Indonesia Case-Based Groups) merupakan sistem pengelompokan kasus yang menjadi dasar penetapan besaran tarif klaim, sehingga setiap kode INA-CBG merepresentasikan satu paket diagnosis dengan tarif yang telah ditetapkan (Afrina et al., 2020). Sebelum proses klustering dijalankan, dataset rugi distratifikasi berdasarkan kode paket tarif INA-CBG lengkap (Koding), yaitu kode yang turut memisahkan tingkat keparahan I, II, dan III. Stratifikasi ini didasarkan pada pertimbangan metodologis bahwa klustering pada seluruh kasus rugi sekaligus berisiko menghasilkan klaster yang didorong oleh perbedaan jenis penyakit, bukan oleh perbedaan pola tindakan.

Karena tidak seluruh kelompok CBG memiliki jumlah kasus yang memadai untuk klustering, dan karena perhatian penelitian diarahkan pada sumber kerugian terbesar, *framework* terlebih dahulu mengidentifikasi sejumlah kelompok CBG prioritas melalui langkah-langkah berikut.

1. Defisit Ranking: subset rugi diagregasi berdasarkan kolom KODING untuk memperoleh jumlah kasus, total kerugian, rata-rata kerugian dan rata-rata lama rawat inapnya (LOS). Kelompok CBG kemudian diurutkan dari total defisit terbesar ke total defisit terkecil.

2. Penentuan Kriteria Kelayakan: satu kelompok CBG pada kasus rugi dinyatakan layak apabila memiliki setidaknya 30 kasus dan pada kasus untung setidaknya 5 kasus.
3. Pemilihan kelompok CBG prioritas (Top-10): dari kelompok CBG yang memenuhi kriteria, dipilih sepuluh kelompok CBG dengan total defisit terbesar untuk dianalisis secara mendalam. Kelompok CBG yang lolos kelayakan klastering tetapi jika tidak memiliki cukup kasus untung akan tetap di klaster, namun dalam tahap analisis komparatifnya akan dilewati.

Dengan demikian, klastering dilakukan dalam CBG yang memiliki tarif identik dan *severity* terkontrol. Serta perbedaan profil *treatment* antar klaster di dalam CBG yang sama yang akan didapatkan pada tahap analisis komparatif dapat diatribusikan murni pada pola tindakan. Parameter cakupan dan ambang batas analisis yang dilakukan dirangkum pada Tabel 3.6 Parameter Stratifikasi dan Klastering.

Tabel 3.6 Parameter Stratifikasi dan Klastering

Parameter	Nilai	Keterangan
Variabel stratifikasi	Koding	Kode INA-CBG
Jumlah CBG prioritas	10	Kelompok CBG dengan total defisit terbesar
Minimum kasus rugi per kelompok CBG	30	Syarat kelayakan klastering
Minimum kasus untung per kelompok CBG	5	Syarat kelayakan analisis komparatif (rugi-vs-untung)
Rentang jumlah (k)	2~5	Batas atas disesuaikan secara adaptif

Tabel 3.6 merangkum parameter operasional yang menjadi batas dan acuan dalam proses stratifikasi dan klastering. Ambang batas minimum 30 kasus rugi per-kelompok CBG ditetapkan untuk menjamin kecukupan sampel statistik dalam pembentukan klaster yang stabil, sementara minimum 5 kasus untung per-CBG dipersyaratkan khusus untuk tahap analisis komparatif *rugi-v.s-untung*. Rentang jumlah klaster k sebesar 2 hingga 5 dengan batas atas adaptif dirancang agar setiap klaster yang terbentuk memiliki ukuran yang

memadai untuk dianalisis, sekaligus menghindari fragmentasi berlebihan pada kelompok CBG dengan jumlah kasus yang terbatas.

3.5.2 Penentuan Jumlah Kluster Optimal (k)

Penentuan jumlah kluster k merupakan tahapan yang sangat krusial dalam algoritma klastering terutama K-Means, karena pemilihan nilai k yang tidak tepat dapat menyebabkan pembentukan kelompok yang kurang bermakna atau misinterpretasi data (Rahma, 2025). Untuk memastikan objektivitas dan validitas hasil, penelitian ini menerapkan skema looping otomatis dengan menghitung tiga metrik validasi internal secara simultan (*silhouette*, *dbi* dan *chi*). Dalam menentukan nilai k terbaik untuk diterapkan ke dalam *framework*, penelitian ini mengadopsi mekanisme berikut:

1. Adaptive Range K

Rentang kandidat jumlah kluster tidak ditetapkan secara seragam untuk semua kelompok, akan tetapi disesuaikan secara adaptif terhadap ukuran tiap kelompok CBG. Batas bawah dijaga konstan pada $k_{min} = 2$, sedangkan batas atas ditentukan melalui persamaan (3.6) dibawah. Mekanisme bentuk untuk menjamin bahwa jumlah kluster tidak melebihi sepersepuluh jumlah kasus rugi pada kelompok bersangkutan, sehingga setiap kluster yang terbentuk tetap memiliki ukuran sampel yang memadai untuk dianalisis. Misalkan untuk suatu kelompok CBG_g , jumlah kasus rugi dinyatakan sebagai n_g . Rentang kandidat jumlah kluster efektif, K_g , maka didefinisikan seperti formula (3.5).

$$K_g = \{ k \in \mathbb{Z} \mid k_{min} \leq k \leq k_{max}(g) \} \quad (3.5)$$

Dengan formulasi (3.6) batas atas adaptif berikut.

$$k_{max}(g) = \min \left(k_{cap}, \max \left(2, \left\lfloor \frac{n_g}{10} \right\rfloor \right) \right) \quad (3.6)$$

Formula tersebut dibentuk agar tidak terjadi *over-clustering* pada CBG dengan sampel kecil.

2. Rank aggregation pada metrik validasi internal: metode ini menganggap ketiga metrik sama pentingnya. Ini karena secara metodologis tidak ada alasan kuat untuk

mengatakan bahwa silhouette lebih penting dari DBI, CHI ataupun sebaliknya. *Rank aggregation* ini dijabarkan pada formula (3.7).

$$\text{avg_rank} = \frac{\text{rank_sil} + \text{rank_dbi} + \text{rank_chi}}{3} \quad (3.7)$$

Jumlah klaster yang memiliki *avg_rank* terendah akan dipilih sebagai jumlah optimal klasternya. Mekanisme formulasi rank aggregation dari tiga metrik (*silhouette*, DBI, CHI) tersebut dijalankan terpisah untuk setiap CBG.

3. Rujukan Pendukung: karena tidak ada satu jawaban tunggal yang mutlak benar dalam memilih jumlah optimal klaster (Schubert, 2023), nilai inersia *Within-Cluster Sum of Squares* (WCSS) yang dihasilkan tiap kandidat k turut disimpan sebagai rujukan pendukung berbasis metode titik "siku" (*elbow point*) untuk mengonfirmasi bahwa penambahan klaster baru tidak lagi memberikan peningkatan kualitas model secara substansial (Ananda et al., 2025; Rahma, 2025; Yunitaningtyas & Herianti, 2025).

Melalui integrasi tiga metrik validasi internal dan rujukan dukungan dari metode Elbow, penelitian ini dapat memitigasi subjektivitas dalam penentuan jumlah kelompok pasien, sehingga struktur klaster yang dihasilkan benar-benar merepresentasikan profil risiko finansial dan pola tindakan medis pasien secara akurat (Ananda et al., 2025).

3.5.3 Algoritma Pengelompokan K-Means

K-Means adalah algoritma pembelajaran mesin (*machine learning*) tanpa pengawasan (*unsupervised learning*) yang digunakan untuk membagi sekumpulan data ke dalam sejumlah k kelompok yang berbeda berdasarkan kesamaan karakteristik fitur-fiturnya (Aulia et al., 2025; He, 2024; Rahma, 2025; Syafiq et al., 2026; Vardakas & Likas, 2023). K-Mean ini memiliki cara kerja dengan mempartisi ruang fitur menjadi K segmen homogen dengan prinsip memaksimalkan kemiripan intra-klaster sekaligus meminimalkan tumpang-tindih karakteristik antar-klaster (Akheel, 2019; Guntari et al., 2025; Hasugian et al., 2025). Secara formal, k-means meminimalkan fungsi objektif *Within-Cluster Sum of Squares* (WCSS) (Akheel, 2019). K-Means menentukan pusat kelompok yang disebut *centroid* (VIP et al., 2025). Setiap titik data kemudian dialokasikan ke klaster yang memiliki centroid terdekat, biasanya dihitung menggunakan jarak *Euclidean* (Galih & Amanda, 2025). Proses ini terus diulang (pembaharuan posisi *centroid* dan pengalokasian data) hingga posisi centroid stabil

atau mencapai konvergensi (Syafiq et al., 2026). Dengan fungsi matematis WCSS seperti formula (3.8) berikut (Akheel, 2019):

$$J = \sum_{k=1}^K \sum_{x_i \in C_k} ||x_i - \mu_k||^2 \quad (3.8)$$

Dalam formulasi tersebut, J merupakan fungsi objektif yang dioptimalkan melalui minimisasi, K menunjukkan banyaknya segmen klaster, sedangkan $||x_i - \mu_k||^2$ merepresentasikan kuadrat jarak antara setiap observasi dan centroid klaster terkait. Penurunan nilai J hingga mencapai konvergensi menjamin homogenitas intra-klaster, yang pada gilirannya menghasilkan partisi data yang padat struktur dan berkoherensi tinggi (Akheel, 2019).

Pada *framework* LOAF yang diusulkan pada penelitian ini, algoritma K-Means diterapkan dalam sebuah perulangan per-CBG. Untuk setiap kelompok CBG prioritas, dijalankan satu siklus lengkap, yaitu pembentukan matriks fitur, reduksi PCA, penentuan jumlah klaster konsensus, pemasangan model K-Means final, hingga uji stabilitas. Siklus tersebut dijalankan untuk kedua skema model (Model A dan Model B) sebagaimana yang telah dijelaskan pada sub bab 3.4.4 diatas. Untuk menjamin keterulangan hasil, *random seed* ditetapkan tetap dan jumlah inisialisasi diulang sebanyak sepuluh kali per pemasangan model.

Sebagai algoritma klastering yang paling luas diterapkan dalam berbagai bidang analisis data termasuk dalam domain kesehatan (He, 2024; Prabujaya et al., 2025), k-means akan dijadikan kandidat utama untuk diterapkan dalam penelitian ini. Berikut beberapa alasan yang tepat untuk memilih algoritma k-means:

1. K-Means adalah algoritma *unsupervised machine learning* yang paling populer karena konsepnya yang sederhana, mudah dijelaskan, dan dipahami (Thulasidas, 2022).
2. K-Means memiliki kompleksitas komputasi yang rendah dibandingkan dengan banyak metode klasterisasi lainnya (Rahma, 2025).
3. K-Means memiliki efisiensi komputasi yang tinggi (Vardakas & Likas, 2023).
4. K-Means memiliki skalabilitas untuk menangani data yang sangat besar. Hal ini menjadikannya lebih praktis daripada algoritma klastering hierarki yang sering kali tidak dapat menangani skala data besar karena kompleksitas waktu $O(n^2)$ (He, 2024; Rahma, 2025; Syafiq et al., 2026).

5. Dalam konteks layanan kesehatan, K-Means telah terbukti efektif dalam melakukan stratifikasi risiko pasien, mengidentifikasi pola distribusi penyakit, hingga optimalisasi manajemen rekam medis (Andirasdini, Saputra, Rivai, & Putra, 2025; Aulia et al., 2025; Galih & Amanda, 2025; Prabujaya et al., 2025; VIP et al., 2025).
6. Hasil dari penelitian-penelitian yang telah dilakukan oleh (Andirasdini, Saputra, Rivai, & Putra, 2025; Aulia et al., 2025; Galih & Amanda, 2025; Prabujaya et al., 2025; VIP et al., 2025) menunjukkan bahwa algoritma ini mampu mengelompokkan kunjungan pasien berdasarkan tingkat keparahan penyakit dan kompleksitas tindakan medis, yang sangat berguna dalam mendukung pengambilan keputusan klinis dan kebijakan manajerial rumah sakit.

Meski demikian, algoritma ini juga memiliki beberapa kekurangan, yaitu dalam ruang berdimensi tinggi signifikansi ukuran jarak akan berkurang karena jarak antar titik data cenderung menjadi hampir seragam, sehingga menyulitkan algoritma untuk menemukan kelompok yang bermakna (He, 2024). Selanjutnya, algoritma ini juga sangat sensitif terhadap *outlier*, karena keberadaannya dapat secara signifikan mempengaruhi perhitungan titik pusat (*centroid*), yang menyebabkan pergeseran klaster dan hasil pengelompokan yang tidak optimal (Rahma, 2025).

Dalam konteks dataset klinis yang memiliki banyak fitur, mekanisme inisialisasi menjadi faktor determinan terhadap reliabilitas algoritma, inisialisasi acak yang kurang terstruktur dapat memicu penurunan stabilitas struktur klaster dan menghambat reproduktibilitas hasil analisis (Vardakas & Likas, 2023). Untuk menangani masalah inisialisasi tersebut, (Vardakas & Likas, 2023) dalam penelitiannya menyarankan untuk menerapkan salah satu cara yaitu dengan *carefull seeding*. Carefull seeding yang dimaksud adalah memastikan mekanisme inisialisasi disetel ke K-Means++, bukan random. Karena K-Means++ memilih pusat klaster dengan menyebarkan satu sama lain berdasarkan distribusi probabilitas (Vardakas & Likas, 2023). Hal tersebut secara matematis menjamin solusi yang kompetitif ($O(\log k)$) dan terbukti jauh lebih baik daripada inisialisasi acak seragam dalam meminimalkan error klasterisasi (Vardakas & Likas, 2023).

Algoritma lain juga di pertimbangkan sebagai *benchmark* dalam pemilihan algoritma yang akan diimplementasikan kedalam *framework* yang penelitian ini usulkan. Algoritma-algoritma tersebut adalah K-Medoids, GMM, dan Agglomerative. Pemilihan dan kelayakan ketiga algoritma tersebut didasarkan pada hal-hal berikut:

1. K-Medoids (*Partitioning Around Medoids - PAM*): algoritma ini sering dibandingkan dengan k-means karena keduanya adalah metode partisi (Ananda

et al., 2025; Salman et al., 2025). (Ananda et al., 2025; Salman et al., 2025) menyebutkan bahwa k-medoids unggul dalam menangani *outliers* dan data yang distribusinya tidak merata karena menggunakan titik data aktual (*medoid*) sebagai pusat, bukan nilai rata-rata (*centroid*) yang sensitif terhadap nilai ekstrem. Namun (Ananda et al., 2025) dalam penelitiannya, membuktikan bahwa k-means tetap terbukti lebih stabil terhadap kompleksitas data medis yang besar dan memberikan hasil yang lebih konsisten saat jumlah kluster bertambah. Dalam pengujian statistiknya (ANOVA) k-means secara konsisten menghasilkan kluster berkualitas tinggi pada jumlah kluster yang lebih besar dibandingkan k-medoids (Ananda et al., 2025).

2. GMM: GMM adalah pendekatan berbasis model probabilitas yang sering dibandingkan dengan K-Means yang bersifat deterministik (He, 2024; Salman et al., 2025) (He, 2024; Salman et al., 2025). GMM dianggap lebih unggul untuk data medis yang memiliki struktur distribusi kompleks atau tidak sferis (Salman et al., 2025). Dalam pengelompokan rumah sakit di Jakarta berdasarkan tenaga medis dan fasilitas, GMM menunjukkan performa terbaik dengan nilai Davies-Bouldin Index (DBI) sebesar 0.6457, melampaui algoritma DBSCAN dan Hierarchical Clustering (Salman et al., 2025).
3. Agglomerative Hierarchical Clustering (AHC) dengan metode Ward's Linkage: dalam studi indikator pendidikan yang sering kali selaras dengan data administratif kesehatan, *Hierarchical Clustering* menunjukkan performa sedikit lebih kuat dalam hal pemisahan dan kepadatan kluster (*Silhouette Index* 0,591 vs 0,584 pada K-Means) (Syafiq et al., 2026). Meski demikian, k-means masih jauh lebih efisien secara komputasi untuk dataset yang besar (Salman et al., 2025; Syafiq et al., 2026).

Hasil *benchmark* dari algoritma-algoritma tersebut akan dijabarkan pada sub bab 4.4.1.

3.5.4 Evaluasi Hasil Klustering

Tahap evaluasi ini bertujuan untuk memvalidasi kebermaknaan kluster yang terbentuk serta memastikan bahwa perbedaan karakteristik antar kelompok pasien bukan merupakan hasil kebetulan, melainkan benar-benar memiliki validitas teknis, stabilitas, serta kebermaknaan secara klinis dan manajerial (Ahmad et al., 2023; Aulia et al., 2025; Galih & Amanda, 2025). Evaluasi hasil klustering yang dilakukan bertujuan sebagai triangulasi validasi berlapis untuk memastikan kebermaknaan struktur kluster yang terbentuk.

Sebelum menjabarkan tahap evaluasi, perlu diperkenalkan satu metrik kesepakatan antar-klustering yang akan dirujuk pada beberapa tahap evaluasi berikut, yaitu Adjusted Rand Index (ARI). ARI merupakan metrik kesepakatan eksternal yang mengevaluasi kemiripan antara dua skema klustering dengan melakukan koreksi terhadap faktor kebetulan (*correction for chance agreement*) (Lippitt et al., 2026; Vinh et al., 2010). Secara teknis, ARI memiliki rentang nilai yang secara teoretis dapat mencapai +1, di mana skor 1 merepresentasikan kesepakatan sempurna atau pelabelan kluster yang identik (Yeung & Ruzzo, 2001). Sebaliknya, nilai yang mendekati 0 mencerminkan kesepakatan yang murni bersifat acak, sementara nilai negatif mengindikasikan tingkat kesepakatan yang lebih rendah daripada probabilitas acak (Yeung & Ruzzo, 2001). Dalam praktik evaluasi struktur data, ambang batas $ARI > 0,75$ umumnya diakui secara luas sebagai indikator yang menunjukkan tingkat stabilitas struktur yang tinggi atau derajat keserupaan struktur kluster yang sangat kuat (Hubert & Arabie, 1985; Steinley, 2004). Berikut merupakan tahapan evaluasi yang akan dilakukan.

1. Validitas internal kluster: ketiga metrik validitas internal (*silhouette*, *DBI*, dan *CHI*) yang digunakan pada penentuan jumlah kluster turut dilaporkan pada jumlah kluster terpilih untuk setiap kelompok CBG, sebagai ukuran ketegasan separasi antar kluster.
2. Visualisasi Ruang Fitur menggunakan PCA: visualisasi menggunakan PCA diterapkan untuk memproyeksikan data ke dalam ruang dua dimensi. Visualisasi ini berfungsi sebagai alat evaluasi kualitatif untuk mengamati pemisahan antar kelompok pasien (Rahma, 2025). Kluster yang dianggap valid secara teknis adalah yang menunjukkan batas-batas spasial yang jelas dan kepadatan titik data yang konsisten, tanpa tumpang tindih (*overlap*) yang masif (Ananda et al., 2025).
3. Uji Robustness Antar Model: untuk memverifikasi bahwa pembentukan kluster tidak sensitif terhadap pilihan fitur, dilakukan uji robustness dengan membandingkan struktur kluster yang dihasilkan oleh Model Utama (*treatment + LOS + HAS_ICU*) terhadap Model Pembanding (*treatment-only variable*). Kesesuaian label antar kedua model dihitung melalui tabulasi silang (*cross-tabulation*), di mana untuk setiap kluster pada model utama ditentukan kluster model pembanding yang paling banyak beririsan dengannya, lalu proporsi kasus yang bersesuaian dijumlahkan dan dinyatakan sebagai persentase kesesuaian. Tingkat kesesuaian yang tinggi (di atas 90%) menjadi bukti bahwa struktur kluster digerakkan oleh pola tindakan medis itu sendiri, bukan oleh variabel pendamping.

4. Uji Stabilitas Bootstrap: sebagai lapis validasi tambahan, dilakukan uji stabilitas *bootstrap*, uji ini bertujuan untuk melihat apakah hasil yang diperoleh tetap konsisten jika data yang digunakan sedikit berubah (Mayeem et al., 2026). Uji ini merupakan prosedur statistik yang digunakan untuk mengevaluasi kekokohan (*robustness*) dan konsistensi dari hasil suatu model atau parameter statistik terhadap variasi dalam data (Al-Hasani et al., 2023). Selanjutnya untuk memastikan stabilitas, dilakukan 50 kali pengulangan klastering pada 80% sampel acak. Hasil tiap iterasi kemudian divalidasi terhadap label asli menggunakan *Adjusted Rand Index (ARI)*. Penetapan jumlah 50 iterasi ini didasarkan pada pertimbangan metodologis berikut. Pertama, (Hennig, 2007) dalam studi *cluster-wise assessment of cluster stability* menetapkan rentang 50–200 iterasi sebagai standar minimum untuk evaluasi stabilitas klaster berbasis resampling. Kedua, (Leisch & Dolnicar, 2010) dalam evaluasi reproduksibilitas solusi klaster menunjukkan bahwa estimasi *ARI* sudah mendekati konvergensi pada 50–100 iterasi *bootstrap* untuk dataset dengan struktur klaster yang jelas, sehingga penambahan iterasi di luar rentang tersebut memberikan marginal gain yang kecil terhadap estimasi stabilitas. Dimana jika rata-rata *ARI* yang tinggi pada seluruh iterasi, maka memberikan bukti bahwa struktur pengelompokan dapat direplikasi secara stabil pada subset data yang berbeda-beda (Hennig, 2007).
5. Uji Signifikansi Statistik: untuk memverifikasi bahwa perbedaan karakteristik antar klaster tidak terjadi secara kebetulan dan memiliki dasar saintifik, dilakukan beberapa uji signifikansi berikut:
 - a. Uji non-parametrik Mann-Whitney U Test: untuk mengidentifikasi perbedaan spesifik antara klaster (Milenovic, 2011), dengan pertimbangan bahwa data klaim dan klinis sering kali tidak memenuhi asumsi normalitas distribusi sehingga memerlukan metode uji yang lebih *robust* (Andirasdini, Saputra, Rivai, & Putra, 2025).
 - b. Koreksi False Discovery Rate (FDR) - Metode Benjamini-Hochberg: mengingat jumlah variabel tindakan medis yang sangat banyak, pengujian simultan dalam jumlah besar berisiko memunculkan "penemuan palsu" (*false discoveries*). Untuk itu diperlukan koreksi dengan metode FDR dalam mengidentifikasi fitur tindakan yang secara signifikan berbeda antar klaster (Rostami & Saarela, 2023). Fitur yang memiliki *p-value* terkoreksi $< 0,05$ dianggap signifikan secara statistik.

- c. Cliff's Delta: selain *p-value*, kekuatan efek dari setiap perbedaan antar kluster diukur menggunakan *cliff's delta*, yaitu pengukuran kekuatan efek non-parametrik dengan rentang nilai dari -1 sampai +1 yang melengkapi *p-value Mann-Whitney U*. Jika *p-value* hanya menyatakan “*apakah perbedaan signifikan secara statistik*”, *cliff's delta* akan menyatakan seberapa besar perbedaannya secara substantif. Dengan kategorisasi standar yang akan digunakan yaitu $|\Delta| < 0,147$ tergolong negligible, $< 0,33$ tergolong lemah, $< 0,474$ tergolong sedang, dan $\geq 0,474$ tergolong kuat (Hofmann et al., 2026).

3.6 Tahap 4: Analisis Pasca-Klaster (Post-Clustering Analysis)

Setelah label klaster terbentuk dan dikonfirmasi melalui tahap evaluasi, maka selanjutnya tahap analisis pasca-klaster ini dilakukan untuk memahami klaster yang terbentuk beserta dengan kriteria anggota dan tindakan medisnya. Tahap ini dirancang untuk menerjemahkan hasil segmentasi menjadi informasi yang lebih bermakna secara klinis dan manajerial. Karena tujuan penelitian tidak hanya membentuk klaster, tetapi juga menjelaskan pola defisit klaim, maka interpretasi dilakukan secara bertingkat. Mulai dari analisis profil klaster, identifikasi klaster prioritas, pola tindakan, hingga perbandingan kasus rugi terhadap kasus untung pada kelompok CBG yang sama. Secara operasional, tahap ini menggunakan label klaster final dari model utama sebagai dasar seluruh analisis lanjutan.

3.6.1 Profiling Klaster per CBG (Case-Based Group)

Profiling klaster per CBG dilakukan untuk mengidentifikasi karakteristik masing-masing CBG pada tiap klaster. Profil disusun dengan menggabungkan tiga dimensi utama:

1. Dimensi Klinis: meliputi analisis rata-rata LOS, JML_DIAGLIST, JML_PROCLIST, serta distribusi HAS_ICU dan DISCHARGE_STATUS. Dimensi ini digunakan untuk menilai beban kompleksitas kasus pada setiap klaster.
2. Dimensi Finansial: meliputi rata-rata selisih klaim, distribusi kelas rawat dan total selisih pendapatan. Dimensi ini digunakan untuk menentukan klaster prioritas (klaster dengan kontribusi defisit terbesar).
3. Dimensi Tindakan Medis: merupakan analisis yang akan dilakukan dengan menghitung berbagai indikator pada tiap klaster, sebagaimana yang dirangkum pada tabel Tabel 3.7 berikut.

Tabel 3.7 Indikator Profil Tindakan Medis per-Klaster

Indikator	Definisi
<i>prevalence_pct</i>	Presentase pasien dalam klaster yang menerima <i>treatment</i> terkait minimal satu kali.
<i>mean_frequency</i>	Rata-rata frekuensi <i>treatment</i> per pasien dalam klaster.
<i>mean_per_day</i>	Intensitas <i>treatment</i> per hari rawat, untuk menormalisasi efek lama rawat inap (LOS).
<i>total_frequency</i>	Total kemunculan <i>treatment</i> dalam klaster.

Tabel 3.7 mendefinisikan empat indikator yang secara bersama-sama membentuk profil tindakan medis komprehensif untuk setiap klaster. Indikator *prevalence_pct* mengukur seberapa luas suatu tindakan diterima dalam klaster, sedangkan *mean_frequency* mengukur intensitas penggunaannya per-pasien. Kombinasi keduanya memungkinkan identifikasi tindakan yang bersifat *universal-intensif* (prevalensi tinggi sekaligus frekuensi tinggi) yang menjadi kandidat utama penyebab defisit. Sementara itu, *mean_per_day* menormalisasi efek perbedaan lama rawat antar klaster sehingga perbandingan intensitas tindakan menjadi lebih adil, dan *total_frequency* memberikan gambaran beban absolut yang ditanggung rumah sakit dari tindakan tersebut.

Analisis profil ini ditujukan untuk mengidentifikasi *driver* tindakan dominan pada tiap klaster, terutama klaster dengan kerugian tertinggi (prioritas). Untuk menjaga fokus analisis, hanya *treatment* dengan prevalensi sekurang-kurangnya 5% yang ditampilkan dalam profil ringkas tiap klaster.

3.6.2 Analisis Komparatif

Analisis komparatif ini dilakukan untuk mengetahui pola tindakan medis yang membedakan antara CBG klaim untung dengan CBG serupa pada klaim rugi. Strategi yang akan digunakan adalah dengan membandingkan *top-10* CBG pada kasus rugi dengan kasus untung (*case-matched comparison*). Langkah-langkah yang terdapat pada analisis komparatif ini adalah sebagai berikut:

1. Pemilihan klaster fokus per CBG: untuk setiap CBG, diidentifikasi klaster dengan rata-rata SELISIH (defisit) paling rendah sebagai klaster prioritas (paling rugi).

2. Perbandingan rugi vs untung pada CBG yang sama: untuk setiap kasus INA-CBG prioritas akan dihitung: (a) ukuran sampel kelompok (n_{rugi} , n_{untung}). (b) perbandingan LOS dan rata-rata SELISIH. (c) uji beda non-parametrik (Mann–Whitney U) untuk LOS dan SELISIH.
3. Analisis *gap treatment*: untuk setiap *treatment* yang ada pada CBG akan dihitung selisih antara kelompok rugi dengan untung pada indikator prevalensi, rata-rata frekuensi, dan rata-rata frekuensi per hari. Gap yang bernilai positif menunjukkan *treatment* lebih intensif pada kelompok rugi. Namun, frekuensi absolut suatu tindakan dapat tampak tinggi semata-mata karena lama rawat yang panjang, bukan karena intensitas pelayanan yang sesungguhnya berlebih. Untuk mengantisipasi distorsi tersebut, dibentuk fitur turunan berupa frekuensi tindakan per hari rawat, yang akan dihitung dengan membagi frekuensi tindakan dengan lama rawat. Misalkan f_j adalah frekuensi tindakan ke- j pada satu episode dan LOS adalah lama rawat episode tersebut, maka frekuensi per hari dirumuskan dengan persamaan (3.9).

$$f_j(\text{per hari}) = \frac{f_j}{\max(LOS, 1)} \quad (3.9)$$

Metrik per hari ini digunakan sebagai salah satu basis pembanding pada tahap analisis komparatif, berdampingan dengan metrik frekuensi total, agar interpretasi pola tindakan tidak terkonfusikan dengan perbedaan lama rawat

4. Analisis *cost driver*: gap frekuensi *treatment* akan dikonversi menjadi estimasi biaya berlebih per pasien menggunakan tarif *treatment* (*unit cost*), sehingga akan diperoleh *estimated_excess_cost_per_patient* dan indikator pendukung kompleksitas kasus (*severity weight*). Tahap ini memisahkan *treatment* yang mahal karena harga satuan dari *treatment* yang mahal karena frekuensi tinggi.
5. Identifikasi pola asimetris (*anomaly candidate*): menandai *treatment* yang muncul pada kelompok rugi tetapi tidak muncul pada kelompok untung (*deficit-only pattern*) pada kelompok CBG yang sama. Pola ini diposisikan sebagai sinyal isyarat audit utilisasi, bukan justifikasi langsung terhadap kesalahan klinis.

Secara formal, dimisalkan kelompok CBG diasumsikan sebagai d dan *treatment* t , dimana:

R_d : himpunan pasien rugi ($n = n_r$)

U_d : himpunan pasien untung ($n = n_u$)

$x_{i,t}$: frekuensi *treatment* t pada pasien i

LOS_i : lama rawat pasien i

Berdasarkan notasi tersebut, indikator-indikator komparatif tersebut dirumuskan sebagai berikut:

(a) Prevalence (%)

Merepresentasikan persentase pasien yang menerima treatment minimal 1 kali, dirumuskan dengan formulasi (3.10):

$$\begin{aligned} \text{prevalence}_r(t) &= \frac{\#\{i \in R_d: x_{i,t} > 0\}}{n_r} \times 100 \\ \text{prevalence}_u(t) &= \frac{\#\{i \in U_d: x_{i,t} > 0\}}{n_u} \times 100 \end{aligned} \quad (3.10)$$

(b) Mean Frequency (Semua Pasien)

Merepresentasikan rata-rata frekuensi *treatment* untuk seluruh pasien grup (termasuk yang tidak menerima *treatment*, nilainya 0) dengan formulasi (3.11):

$$\begin{aligned} \text{mean_frequency_all}_r(t) &= \frac{1}{n_r} \sum_{i \in R_d} x_{i,t} \\ \text{mean_frequency_all}_u(t) &= \frac{1}{n_u} \sum_{i \in U_d} x_{i,t} \end{aligned} \quad (3.11)$$

(c) Mean Frequency (Pasien yang Menerima)

Merepresentasikan rata-rata frekuensi hanya pada pasien yang benar-benar menerima *treatment* dengan formulasi (3.12):

$$\begin{aligned} \text{mean_frequency_reciever}_r(t) &= \frac{\sum_{i \in R_d, x_{i,t} > 0} x_{i,t}}{\#\{i \in R_d: x_{i,t} > 0\}} \\ \text{mean_frequency_reciever}_u(t) &= \frac{\sum_{i \in U_d, x_{i,t} > 0} x_{i,t}}{\#\{i \in U_d: x_{i,t} > 0\}} \end{aligned} \quad (3.12)$$

(d) Mean per Day

Merepresentasikan intensitas *treatment* per hari rawat dengan formulasi (3.13):

$$\begin{aligned}\text{mean_per_day_all}_r(t) &= \frac{1}{n_r} \sum_{i \in R_d} \frac{x_{i,t}}{LOS_i} \\ \text{mean_per_day_all}_u(t) &= \frac{1}{n_u} \sum_{i \in U_d} \frac{x_{i,t}}{LOS_i}\end{aligned}\tag{3.13}$$

(e) GAP Indikator

Gap didefinisikan sebagai selisih nilai indikator kelompok rugi dikurangi kelompok untung seperti pada formulasi (3.14).

$$\begin{aligned}\text{gap_prevalence_pct}(t) &= \text{prevalence}_r(t) - \text{prevalence}_u(t) \\ \text{gap_mean_frequency_all}(t) &= \text{mean_frequency_all}_r(t) - \text{mean_frequency_all}_u(t) \\ \text{gap_mean_per_day_all}(t) &= \text{mean_per_day_all}_r(t) - \text{mean_per_day_all}_u(t)\end{aligned}\tag{3.14}$$

Dimana jika gap bernilai nilai positif, maka *treatment* lebih intensif pada kelompok rugi. Namun sebaliknya jika gap bernilai negatif, maka *treatment* lebih intensif pada kelompok untung.

(f) Estimated_excess_cost_per_patient

Indikator ini menghitung estimasi biaya berlebih per pasien untuk tiap *treatment*, dengan memperhitungkan gap frekuensi, harga satuan, dan faktor kompleksitas kasus. Perhitungannya dilakukan melalui langkah berikut:

Langkah 1 mengambil harga satuan treatment (*unit cost*):

Setiap *treatment* dipetakan ke *dictionary* tarif master untuk memperoleh:

$$\text{unit_cost}(t)\tag{3.15}$$

Langkah 2 menghitung skor *case-mix*:

Skor kompleksitas dihitung terpisah untuk grup rugi dan untung, berbasis kombinasi diagnosis, LOS dan ICU sebagaimana pada persamaan (3.16):

$$\text{case_mix_score} = 0.45(\text{diag_term}) + 0.35(\text{los_term}) + 0.2(\text{icu_term})\tag{3.16}$$

Dengan formulasi dari *case_mix_score* tersebut, kompleksitas diagnosis akan diposisikan paling dominan, selanjutnya LOS pada posisi kedua, dan terakhir ICU

pada posisi ketiga. Dengan penjelasan komponen *diag_term*, *los_term* dan *icu_term* sebagai berikut:

diag_term pada persamaan (3.17):

$$\text{diag_term} = \frac{\max(\bar{D}, 1)}{3} \quad (3.17)$$

los_term pada persamaan (3.18):

$$\text{los_term} = \text{clip} \left(\frac{\max(\bar{L}, 1)}{5}, 0.5, 2.5 \right) \quad (3.18)$$

icu_term pada persamaan (3.19):

$$\text{icu_term} = 1 + \bar{I} \quad (3.19)$$

Langkah 3 membentuk severity weight:

Severity weight dihitung sebagai rasio skor *case-mix* pada kelompok rugi terhadap kelompok untung, dengan pembatasan rentang sebagaimana terdapat pada persamaan (3.20).

$$\text{severity_weight} = \text{clip} \left(\frac{\text{score}_{\text{rugi}}}{\text{score}_{\text{untung}}}, 0.7, 1.4 \right) \quad (3.20)$$

Langkah 4 menghitung biaya *excess cost* per pasien:

Biaya berlebih per pasien dihitung dari gap frekuensi yang dibatasi tidak negatif, dikalikan *unit cost* dan *severity weight*, sebagaimana yang dijabarkan pada persamaan (3.21)

$$\text{estimated_excess_cost} = \max(0, \text{gap_freq}) \times \text{unit_cost} \times \text{severity_weight} \quad (3.21)$$

Dengan penjelasan komponen-komponen yang terdapat pada formulasi tersebut adalah sebagai berikut:

$\bar{D}$: mean (jml_diaglist)

$\bar{L}$: mean (LOS)

$\bar{I}$: mean (Has_ICU) (karena 0/1, mean = proporsi ICU)

Fungsi *severity_weight* tersebut ditujukan sebagai pembatas (regularisasi) agar faktor *severity* tidak terlalu ekstrem. Artinya koreksi maksimal akan ditahan dalam rentang “turun 30%” sampai “naik 40%”. Koefisien pembobotan pada komponen *case-mix* dan batas *clipping severity* tersebut ditetapkan sebagai parameter heuristik (metode praktis) yang terkontrol untuk menjaga kestabilan estimasi *excess cost* serta mencegah inflasi atau deflasi koreksi yang berlebihan. Parameter ini belum merepresentasikan standar klinis baku, sehingga interpretasi hasil dilakukan secara operasional dan akan dilengkapi dengan analisis robustnes/sensitivitas.

Dengan begitu, rancangan analisis komparatif tersebut tidak hanya menghasilkan daftar *treatment* dominan, tetapi juga menjelaskan mekanisme finansial defisit pada tingkat CBG dan episode layanan-nya. Hal ini memastikan bahwa *output* dari *framework* LOAF yang diusulkan dalam penelitian ini dapat digunakan sebagai dasar evaluasi efisiensi pelayanan yang tetap mempertimbangkan konteks klinis pasien.

BAB 4

Hasil dan Pembahasan

4.1 Gambaran Umum Data dan Konteks Defisit Klaim

Penelitian ini menggunakan data rawat inap tahun 2023–2024 sebanyak 9.830 episode. Setelah prapemrosesan, 41 pasien tanpa informasi tindakan medis dieliminasi untuk menghindari ambiguitas sehingga data tersisa sebanyak 9.789. Dari jumlah tersebut, 6.018 pasien (61,48%) berada pada kondisi defisit klaim (rugi) dan 3.771 pasien (38,52%) berada pada kondisi surplus (untung). Rata-rata nilai selisih pada kelompok untung adalah + Rp. 2.368.419 per kasusnya, dengan total keuntungan yang diperoleh adalah + Rp. 9.005.668.760 (9 miliar rupiah). Sedangkan pada kasus defisit, rata-rata nilai defisitnya tercatat sebesar – Rp. 2.585.362 per kasus, dengan total defisit sebesar – Rp. 15.558.709.763 (15 miliar rupiah).

Temuan awal tersebut memperkuat dasar pendekatan analitik yang penelitian ini usulkan, yang tidak berhenti pada rata-rata biaya, tetapi mampu memetakan heterogenitas kasus berdasarkan karakteristik klinis dan pola treatment. Distribusi dataset dapat dilihat pada Tabel 4.1.

Tabel 4.1 Distribusi Dataset

Data	Rata-rata	n Kasus	Presentase
Defisit (Rugi)	- Rp. 2.585.362	6.018	61,48%
Impas (BEP)	-	0	-
Surplus (Untung)	+ Rp. 2.368.419	3.771	38,52%
Total		9.789	100%

Dua skenario model akan dijalankan pada penelitian ini. Model utama (Model A) menggabungkan fitur hasil *count encoding* kolom *treatment* dikombinasikan dengan variabel klinis pendukung (LOS, HAS_ICU) untuk mengakomodasi kompleksitas kasus. Selanjutnya model b digunakan sebagai pembanding, yang menggunakan variabel hasil *count encoding* kolom *treatment* saja (*treatment-only variable*) agar dapat diuji apakah struktur klaster dan driver *treatment* tetap konsisten ketika variabel klinis tambahan tidak di ikut sertakan. Dengan desain ini, penelitian tidak hanya menghasilkan klaster, tetapi juga melakukan validasi internal terhadap ketahanan temuan.

4.2 Persiapan Data: Pembentukan Kolom Bantu

Sebelum memasuki tahap pra-pemrosesan data, dilakukan proses pembentukan kolom bantu untuk mengorganisir kolom diagnosa dan *procedure*. Seperti terlihat pada Gambar 4.1, data memiliki informasi mengenai daftar kode diagnosa (DIAGNOSA_LIST) dan *procedure* (PROCEDURE_LIST) beserta informasi jumlahnya (JML_DIAGLIST dan JML_PROCLIST). Kolom-kolom ini dibentuk untuk memudahkan pemahaman karakteristik data pasien yang memungkinkan memiliki lebih dari satu diagnosa dan *procedure* dalam satu kali kunjungan. Kolom bantu yang telah dibentuk dapat dilihat pada Gambar 4.1.

DIAGNOSA_LIST	JML_DIAGLIST	PROCEDURE_LIST	JML_PROCLIST
J18.0	1	93.94;90.59	2
O99.6;K35.8	2	90.59;47.09	2
A01.0;J45.9	2	90.59;87.44;93.96	3
K75.9;J06.9	2	1900-01-03 18:59:00	1
J18.9;R57.2;J96.0;A90	4	90.59;87.44	2

Gambar 4.1 Hasil penambahan kolom bantu kompleksitas diagnose dan prosedur

4.3 Pra-pemrosesan Data

4.3.1 Penanganan Missing Value

Padatahap pra-pemrosesan data, akan diawali dengan identifikasi dan penanganan *missing value* untuk menjamin kualitas dan konsistensi dataset sebelum memasuki tahap lanjutan. Hasil *scan* terhadap seluruh variabel menunjukkan bahwa sebagian besar data bersifat lengkap, dengan nilai *missing value* sebesar nol pada variabel demografis, administratif, dan finansial. Kondisi ini mengindikasikan bahwa sistem pencatatan rumah sakit telah berjalan secara konsisten untuk variabel-variabel inti. Namun, teridentifikasi tiga variabel yang mengandung *missing value*, yaitu kolom TINDAKAN_LIST sebanyak 46 data (0,47%),

kolom ITEM_CODE_LIST sebanyak 62 data (0,63%), dan kolom LAB_LIST sebanyak 3.134 data (31,88%). Keberadaan *missing value* pada kolom LAB_LIST yang cukup signifikan memerlukan penelaahan kontekstual.

Dalam rekam medis elektronik (RME), ketiadaan catatan laboratorium tidak selalu merepresentasikan kesalahan entri data, melainkan bisa saja mencerminkan kondisi klinis di mana pasien memang tidak menjalani pemeriksaan lab selama periode rawat inap tersebut. Oleh karena itu, penanganan pada variabel ini adalah dipertahankan dan diimputasi ulang dengan string kosong agar tidak berisiko membuat bias klinis dan juga mengganggu interpretasi pola perawatan pasien. Metode serupa juga diterapkan pada kolom TINDAKAN_LIST dan ITEM_CODE_LIST. Setelah penyesuaian tersebut, dataset telah melalui tahap pembersihan awal dan memenuhi asumsi kelengkapan yang diperlukan untuk tahapan berikutnya. Hasil handle missing value tersebut dapat dilihat pada Gambar 4.2.

TINDAKAN_LIST	LAB_LIST	ITEM_CODE_LIST
B30060;B30034;A20015;A20009;B30065;B30015b;B30...	LB04G4001;LB02G2002;LB01G11004;LB03G3051	OGB0093;OGB0090;OGB0058;OGB0022;APO20020105163...
B30060;B30034;A20015;B30103;None;None;D10001;B...	NaN	APO20110502162145;APO20110502171749;ALKES0406;...
B30034;B30034;B30015b;B30103;B30087;B30060;A20...	NaN	OGB0077;APO20111008184523;OBA020281;OGB12054;A...
D10015;B30034;B30103;B30060;B30015b;B30034;B30...	LB01G11003;LB02G2006;LB02G2007	OGB0093;OBA030102;APO20111025153112;OGB0033;AP...
B30034;B30060;B30034;B30103;B30015b;B30087;B30...	LB01G11003;LB04G4001	OGB0033;OGB0028;APO20020105163648;APO201012111...

	Missing Values	Percentage	Missing values in df_rugi after handling:	
ID	0	0.000000	ID	0
NAMA_PASIEN	0	0.000000	NAMA_PASIEN	0
SEX	0	0.000000	SEX	0
UMUR_TAHUN	0	0.000000	UMUR_TAHUN	0
KELAS_RAWAT	0	0.000000	KELAS_RAWAT	0
ADMISSION_DATE	0	0.000000	ADMISSION_DATE	0
DISCHARGE_DATE	0	0.000000	DISCHARGE_DATE	0
LOS	0	0.000000	LOS	0
DIAGNOSA_LIST	0	0.000000	DIAGNOSA_LIST	0
JML_DIAGLIST	0	0.000000	JML_DIAGLIST	0
DESKRIPSI_PENYAKIT	0	0.000000	DESKRIPSI_PENYAKIT	0
PROCEDURE_LIST	0	0.000000	PROCEDURE_LIST	0
JML_PROCLIST	0	0.000000	JML_PROCLIST	0
KODING	0	0.000000	KODING	0
TARIF_KLAIM_ASURANSI	0	0.000000	TARIF_KLAIM_ASURANSI	0
TARIF_RS	0	0.000000	TARIF_RS	0
PROFIT_RS	0	0.000000	PROFIT_RS	0
TINDAKAN_LIST	46	0.467955	TINDAKAN_LIST	0
LAB_LIST	3134	31.881994	LAB_LIST	0
ITEM_CODE_LIST	62	0.630722	ITEM_CODE_LIST	0
			dtype: int64	

Gambar 4.2 Kolom tindakan medis sebelum dan sesudah penanganan *missing value*

Data akhir yang akan digunakan pada penelitian ini adalah sebanyak total 9.789 baris, setelah melakukan eliminasi 41 baris pasien yang tidak memiliki data tindakan medis pada ketiga kolom (TINDAKAN_LIST, ITEM_CODE_LIST dan LAB_LIST).

4.3.2 Pembersihan Artefak Data pada Variabel List

Setelah penanganan missing value pada level baris dan secara agregat kolom-kolom ini dianggap terisi, ternyata terdapat “None” di sela sela tindakan list. Fenomena ini umumnya terjadi akibat proses ekstraksi data dari basis sumber data yang merepresentasikan nilai *null* dalam *array* sebagai teks “None”, bukan sebagai nilai kosong yang sebenarnya. Keberadaan string “None” ini berpotensi mendistorsi hasil analisis jika tidak ditangani, karena sistem akan menginterpretasikannya sebagai sebuah kode tindakan atau item yang valid. Oleh karenanya dilakukan pemeriksaan lebih mendalam terhadap integritas data di dalam ketiga kolom bertipe list, yaitu TINDAKAN_LIST, LAB_LIST, dan ITEM_CODE_LIST. Oleh karena itu, diterapkan fungsi pembersihan teks untuk menstandarisasi format data pada ketiga kolom tersebut melalui langkah-langkah berikut.

1. Tokenisasi: memecah isi sel berdasarkan pemisah titik koma (;) menjadi elemen-elemen individual.
2. Filtering dan Validasi: mengiterasi setiap elemen untuk membuang nilai yang tidak relevan, yaitu string kosong, spasi (*whitespace*), dan *string literal* “None” (tanpa membedakan huruf besar/kecil).
3. Rekonstruksi: menggabungkan kembali elemen-elemen yang telah tervalidasi menjadi satu string yang dipisahkan oleh titik koma.

Implementasi pembersihan ini berhasil menghilangkan *noise* data secara efektif. Sebagaimana hasil yang terlihat, nilai “None” yang sebelumnya muncul di tengah-tengah urutan kode pada kolom TINDAKAN_LIST telah dihapus sepenuhnya, menyisakan hanya kode-kode prosedur yang valid. Hasil pembersihan tersebut dapat dilihat pada Gambar 4.3.

TINDAKAN_LIST	LAB_LIST	ITEM_CODE_LIST
B30060;B30034;A20015;A20009;B30065;B30015b;B30...	LB04G4001;LB02G2002;LB01G11004;LB03G3051	OGB0093;OGB0090;OGB0058;OGB0022;APO20020105163...
B30060;B30034;A20015;B30103;None;None;D10001;B...		APO20110502162145;APO20110502171749;ALKES0406;...
B30034;B30034;B30015b;B30103;B30087;B30060;A20...		OGB0077;APO20111008184523;OBA020281;OGB12054;A...
D10015;B30034;B30103;B30060;B30015b;B30034;B30...	LB01G11003;LB02G2006;LB02G2007	OGB0093;OBA030102;APO20111025153112;OGB0033;AP...
B30034;B30060;B30034;B30103;B30015b;B30087;B30...	LB01G11003;LB04G4001	OGB0033;OGB0028;APO20020105163648;APO201012111...

```

Columns cleaned successfully:

                                TINDAKAN_LIST \
0  B30060;B30034;A20015;A20009;B30065;B30015b;B30...
1  B30060;B30034;A20015;B30103;D10001;B30034;B301...
2  B30034;B30034;B30015b;B30103;B30087;B30060;A20...
3  D10015;B30034;B30103;B30060;B30015b;B30034;B30...
4  B30034;B30060;B30034;B30103;B30015b;B30087;B30...

                                LAB_LIST \
0  LB04G4001;LB02G2002;LB01G11004;LB03G3051
1
2
3  LB01G11003;LB02G2006;LB02G2007
4  LB01G11003;LB04G4001

                                ITEM_CODE_LIST
0  OGB0093;OGB0090;OGB0058;OGB0022;APO20020105163...
1  APO20110502162145;APO20110502171749;ALKES0406;...
2  OGB0077;APO20111008184523;OBA020281;OGB12054;A...
3  OGB0093;OBA030102;APO20111025153112;OGB0033;AP...
4  OGB0033;OGB0028;APO20020105163648;APO201012111...

```

Gambar 4.3 Sebelum dan setelah penanganan artefak *none* pada kolom tindakan list

4.3.3 Prefix dan Transformasi Kolom Tindakan Medis

Data tindakan medis tersedia dari tiga sumber kolom berbeda, yakni tindakan medis dari kolom TINDAKAN_LIST, item atau obat dari kolom ITEM_CODE_LIST, dan pemeriksaan laboratorium atau radiologi dari kolom LAB_LIST. Sebelum menerapkan transformasi ketiga kolom tersebut, terlebih dahulu diproses melalui mekanisme *prefixing* untuk mempermudah identifikasi, interpretasi dan mencegah tabrakan kode yang dapat terjadi apabila kode yang identik muncul di lebih dari satu sumber. Data ketiga kolom tersebut sebelum dan sesudah diberikan prefix dapat dilihat pada Gambar 4.4.

TINDAKAN_LIST	LAB_LIST	ITEM_CODE_LIST
B30060;B30034;A20015;A20009;B30065;B30015b;B30...	LB04G4001;LB02G2002;LB01G11004;LB03G3051	OGB0093;OGB0090;OGB0058;OGB0022;APO20020105163...
B30060;B30034;A20015;B30103;D10001;B30034;B301...		APO20110502162145;APO20110502171749;ALKES0406;...
B30034;B30034;B30015b;B30103;B30087;B30060;A20...		OGB0077;APO20111008184523;OBA020281;OGB12054;A...
D10015;B30034;B30103;B30060;B30015b;B30034;B30...	LB01G11003;LB02G2006;LB02G2007	OGB0093;OBA030102;APO20111025153112;OGB0033;AP...
B30034;B30060;B30034;B30103;B30015b;B30087;B30...	LB01G11003;LB04G4001	OGB0033;OGB0028;APO20020105163648;APO201012111...

```

TINDAKAN_LIST \
TINDAKAN_B30060;TINDAKAN_B30034;TINDAKAN_A2001...
TINDAKAN_B30060;TINDAKAN_B30034;TINDAKAN_A2001...
TINDAKAN_B30034;TINDAKAN_B30034;TINDAKAN_B3001...
TINDAKAN_D10015;TINDAKAN_B30034;TINDAKAN_B3010...
TINDAKAN_B30060;TINDAKAN_B30034;TINDAKAN_A2001...

ITEM_CODE_LIST \
ITEM_OGB0093;ITEM_OGB0090;ITEM_OGB0058;ITEM_OG...
ITEM_APO20110502162145;ITEM_APO20110502171749;...
ITEM_OGB0077;ITEM_APO20111008184523;ITEM_OBA02...
ITEM_OGB0093;ITEM_OBA030102;ITEM_APO2011102515...
ITEM_OGB0017;ITEM_OGB0024;ITEM_OBA0250;ITEM_OG...

LAB_LIST
LAB_LB04G4001;LAB_LB02G2002;LAB_LB01G11004;LAB...

LAB_LB01G11003;LAB_LB02G2006;LAB_LB02G2007
LAB_LB01G11041;LAB_LB01G11024;LAB_LB03G3004;LA...

```

Gambar 4.4 Sebelum dan sesudah pemberian prefix pada kolom tindakan medis

Setelah ketiga kolom tindakan medis telah diberikan *prefix*, semua token/kode *treatment* tersebut ditransformasi menjadi fitur numerik menggunakan metode *count encoding*. Dimana setiap fitur merepresentasikan frekuensi kemunculan absolut suatu treatment per pasien, sehingga nilainya langsung bermakna klinis (misal terdapat nilai 5 pada fitur TINDAKAN_B30034 berarti tindakan tersebut dilakukan sebanyak lima kali selama episode perawatan pasien tersebut). Hasil dari proses encoding ini menghasilkan matriks fitur dengan panjang 1.849 kolom treatment yang mencakup seluruh jenis tindakan, item, dan pemeriksaan yang tercatat dalam dataset. Hasil dari transformasi kolom tindakan medis menggunakan metode *count encoding* tersebut dapat dilihat pada Gambar 4.5.

AS_RAWAT	LOS	DISCHARGE_STATUS	HAS_ICU	DIAGNOSA_LIST	JML_DIAGLIST	DESKRIPSI_PENYAKIT	...	LAB_F10002	LAB_F10115	LAB_F10088	LAB_LB02G2037	LAB_LB03G3034	LAB_LB02G2010	LAB_LB02G2011	LAB_F10044	LAB_LB06G6002	LAB_F10020
2	5	1.0	False	J18.0	1	SIMPLE PNEUMONIA & WHOOPING COUGH (RINGAN)	...	0	0	0	0	0	0	0	0	0	0
2	3	1.0	False	O99.6;K35.8	2	PROSEDUR APPENDIK (RINGAN)	...	0	0	0	0	0	0	0	0	0	0
1	5	1.0	False	A01.0;J45.9	2	PENYAKIT INFEKSI BAKTERI DAN PARASIT LAIN-LAIN...	...	0	0	0	0	0	0	0	0	0	0
1	3	1.0	False	K75.9;J06.9	2	GANGGUAN HATI LAIN-LAIN (RINGAN)	...	0	0	0	0	0	0	0	0	0	0
3	5	1.0	False	K56.6	1	PROSEDUR SISTEM PENCERNAAN LAIN-LAIN (RINGAN)	...	0	0	0	0	0	0	0	0	0	0

Gambar 4.5 Hasil transformasi kolom tindakan medis (*count encoding*)

4.3.4 Konstruksi Matriks Klaster per CBG (Cased-Based Group)

Pada *framework* LOAF ini, matriks fitur untuk klustering tidak dibangun secara global terhadap seluruh 6.018 kasus rugi, melainkan dibangun secara terpisah untuk setiap kelompok CBG prioritas. Proses identifikasi kelompok CBG prioritas dilakukan sebagaimana yang telah diuraikan pada CBG yang dipilih merupakan *top-10* CBG dengan total defisit terbesar diatas. Untuk setiap kelompok CBG, akan dijalankan dua skema model. Pada Model Utama (Model A), matriks fitur dibangun dengan menggabungkan fitur *treatment* hasil *count encoding* dengan dua fitur klinis tambahan, yaitu lama rawat inap (LOS) dan indikator perawatan ICU (HAS_ICU). Pada Model B, matriks fitur hanya berisi fitur *treatment* hasil *count encoding* saja (*treatment-only variable*).

Pada kedua model, fitur *treatment* dan LOS digabungkan (pada model b hanya fitur *treatment* saja), lalu diaplikasikan transformasi logaritmik menggunakan $\log(1 + x)$ untuk mengurangi pengaruh nilai ekstrem, kemudian dinormalisasi dengan menggunakan *RobustScaler*. Transformasi log akan “memadatkan” distribusi data agar *RobustScaler* tidak bekerja terlalu keras pada nilai ekstrem. Sementara itu, kolom HAS_ICU tidak diaplikasikan transformasi logaritmik maupun penskalaan karena merupakan variabel biner (0,1).

Setelah transformasi logaritmik dan normalisasi *RobustScaler*, selanjutnya diterapkan reduksi dimensi menggunakan *Principal Component Analysis* (PCA) dengan jumlah komponen yang ditetapkan sebanyak dua komponen utama. Penetapan jumlah komponen ini konsisten untuk seluruh kelompok CBG, dengan dua pertimbangan berikut: pertama, untuk meredam fenomena *curse of dimensionality* akibat banyaknya fitur *treatment* hasil *encoding* yang membuat skor metrik validasi internal (*silhouette*, *dbi* dan *chi*) buruk, 2x lebih rendah dibanding dengan diterapkannya *dimensionality reduction* PCA (*n_components*=2). Hasil skor metrik validasi internal tanpa penerapan PCA dapat dilihat pada Gambar 4.6.

```
K=2 → Silhouette: 0.2037, DBI: 2.7627, CHI: 610.2859
K=3 → Silhouette: 0.0853, DBI: 2.5925, CHI: 592.2827
K=4 → Silhouette: 0.0818, DBI: 2.8995, CHI: 487.4028
K=5 → Silhouette: 0.0694, DBI: 2.7443, CHI: 434.6427
K=6 → Silhouette: 0.0749, DBI: 2.6965, CHI: 388.6061
K=7 → Silhouette: 0.0615, DBI: 2.8474, CHI: 354.3065
K=8 → Silhouette: 0.0571, DBI: 2.8793, CHI: 328.4513
K=9 → Silhouette: 0.0665, DBI: 2.7300, CHI: 308.5491
K=10 → Silhouette: 0.0712, DBI: 2.7305, CHI: 291.8637
```

Gambar 4.6 Hasil skor metrik validasi internal tanpa penerapan PCA

Kedua, agar hasil klastering dapat divisualisasikan langsung pada bidang dua dimensi untuk evaluasi kualitatif. Sebagaimana telah dijustifikasi pada sub bab 3.4.7 diatas, reduksi dimensi PCA hanya digunakan sebagai alat bantu teknis pada proses klastering, sedangkan interpretasi dan pemrofilan tetap dilakukan pada fitur asli.

Penetapan jumlah komponen sebanyak dua ini didukung oleh eksperimen yang telah menguji enam konfigurasi PCA yang berbeda. Pada eksperimen ini, K-Means dijalankan pada data agregat 6.018 kasus rugi untuk masing-masing konfigurasi dengan rentang $K = 2$ sampai $K = 10$, kemudian skor Silhouette puncak dari tiap konfigurasi dibandingkan. Tabel ringkasan hasil eksperimen tersebut dapat dilihat pada Tabel 4.2 Perbandingan Silhouette Terbaik pada Enam Konfigurasi PCA di kedua Model.

Tabel 4.2 Perbandingan Silhouette Terbaik pada Enam Konfigurasi PCA di kedua Model

Variance (A)	n_components (A)	Sill (A)	Opt. K (A)	n_components (B)	Opt. K (B)	Sill (B)
24%	2	0,491	3	2	3	0,496
...	...	...	...	...	...	...
50%	14	0,265	2	15	2	0,262
70%	48	0,223	2	48	2	0,225
80%	90	0,214	2	91	2	0,215
90%	193	0,208	2	194	2	0,209
95%	321	0,208	2	323	2	0,206

Hasil uji pada Tabel 4.2 menunjukkan pola yang konsisten pada kedua model, semakin banyak komponen yang dipertahankan justru semakin buruk kualitas klaster yang dihasilkan. Konfigurasi varians 95% (321–323 komponen) hanya menghasilkan Silhouette puncak sebesar 0,208, sedangkan konfigurasi dengan dua komponen saja menghasilkan Silhouette puncak 0,491 (Model A) dan 0,496 (Model B), dua kali lipat lebih tinggi. Selain itu, konfigurasi dengan banyak komponen secara konsisten memilih jumlah optimal $K = 2$, sedangkan konfigurasi dua komponen mampu mengidentifikasi jumlah klaster yang lebih informatif ($K = 3$).

Dengan demikian, pemilihan $n_components = 2$ pada kerangka LOAF tidak semata-mata didasarkan pada pertimbangan visualisasi, melainkan didukung secara empiris oleh

kualitas klaster yang superior pada data penelitian ini. Pertimbangan visualisasi pada bidang dua dimensi menjadi keuntungan tambahan, bukan sebagai alasan utama. Keterbatasan terkait konservasi varians ini juga ditangani melalui validasi berlapis yang akan dijelaskan pada sub bab 4.4 dibawah, yaitu dengan menerapkan uji *robustness* antar-model, *benchmark* algoritma, dan uji stabilitas *bootstrap*.

4.3.5 Stratifikasi dan Seleksi Kelompok CBG Prioritas

Sebelum tahap klastering dijalankan, *framework* terlebih dahulu mengidentifikasi sejumlah kelompok CBG prioritas. Pada subset kasus rugi yang berjumlah 6.018 episode, terdapat sebanyak 329 kelompok CBG unik. Selanjutnya pada setiap 329 kelompok CBG unik tersebut diterapkan kriteria kelayakan klastering, yaitu memiliki sebanyak minimum 30 kasus rugi per kelompok. Menyaring kelompok tersebut menjadi 52 kelompok CBG yang memiliki ukuran sampel memadai. Dari 52 kelompok CBG yang layak tersebut, selanjutnya akan dipilih 10 kelompok CBG prioritas dengan total defisit terbesar untuk dianalisis secara mendalam.

Kesepuluh kelompok prioritas ini secara kumulatif menyumbang defisit sebesar Rp3,72 miliar atau sekitar 23,9% dari total defisit seluruh kasus rugi, meskipun jumlah kasusnya hanya mencakup 1.693 dari 6.018 total kasus rugi. Profil kesepuluh kelompok prioritas disajikan pada Tabel 4.3

Tabel 4.3 Top-10 Kelompok CBG Prioritas Berdasarkan Total Defisit

No.	Kode CBG	Deskripsi INA-CBG	Rugi (n)	Untung (n)	Mean Defisit (Rp)	Total Defisit (Rp)
1	K-4-17-I	Nyeri Abdomen & Gastroenteritis Lain-lain (Ringan)	387	25	1.526.064	590.586.810
2	A-4-13-I	Infeksi Viral & Non-Bakterial Lain (Berat)	409	72	1.418.550	580.187.003
3	K-1-13-I	Prosedur Apendik (Ringan)	150	0	3.632.710	544.906.451
4	J-1-20-III	Prosedur Sistem Pernafasan Non-Kompleks (Berat)	36	222	11.528.645	416.975.215
5	I-4-20-I	Angina Pektoris dan Nyeri Dada (Ringan)	105	9	3.336.146	350.295.331
6	A-4-14-I	Penyakit Infeksi Bakteri dan Parasit Lain-lain (Ringan)	206	52	1.275.881	262.831.486
7	O-6-10-I	Operasi Pembedahan Caesar (Ringan)	205	10	1.264.332	259.187.974
8	M-1-80-I	Prosedur Anggota Tubuh Atas (Ringan)	96	80	2.612.605	250.810.123
9	N-1-12-II	Membuat Baru, Merevisi dan Memindahkan Alat Dialisis (Sedang)	50	20	4.702.264	235.113.175
10	N-4-10-III	Tumor Ginjal dan Saluran Urin & Gagal Ginjal (Berat)	49	20	4.763.427	233.407.935


Hasil yang terdapat pada Tabel 4.3 tersebut mengungkap dua pola defisit yang berbeda secara fundamental. Pola pertama adalah defisit bervolume tinggi dengan nilai per kasus relatif kecil, sebagaimana terlihat pada CBG Nyeri Abdomen & Gastroenteritis Lain-lain (Ringan) (K-4-17-I) dan Infeksi Viral & Non-Bakterial Lain (Berat) (A-4-13-I). Kedua kelompok ini merupakan kasus ringan dengan rata-rata defisit di kisaran Rp1,4 juta hingga Rp1,5 juta per-kasus, namun karena jumlah kasusnya sangat besar (387 dan 409), total defisitnya menjadi *top-2* yang terbesar. Pola kedua adalah defisit bervolume rendah dengan nilai per-kasus yang sangat besar, sebagaimana terlihat pada kelompok CBG Prosedur Sistem Pernafasan Non-Kompleks (Berat) (J-1-20-III) yang hanya memiliki 36 kasus, namun memiliki rata-rata defisit sebesar - Rp11,58 juta per kasusnya. Perbedaan kedua pola ini penting karena menyiratkan strategi penanganan klinis yang berbeda.

Catatan khusus dinotasikan untuk kelompok CBG Prosedur Apendik (Ringan) (K-1-13-I) yang lolos kriteria kelayakan klastering (dengan 150 kasus rugi), akan tetapi tidak memiliki satu pun kasus untung ($n_{\text{untung}} = 0$). Kelompok ini tetap diklaster, namun analisis komparatifnya tidak dapat dilakukan. Menunjukkan bahwa seluruh kasus prosedur appendik pada periode pengamatan mengalami defisit, yang mengindikasikan kemungkinan persoalan struktural pada penetapan tarif paket CBG tersebut.


4.4 Pengelompokan: Klastering K-Means per CBG (Case-Based Group)

4.4.1 Benchmark Algoritma Klastering

Sebagai validasi tambahan untuk memperkuat justifikasi pemilihan algoritma K-Means sebagai algoritma utama, dilakukan uji *benchmark* terhadap tiga algoritma alternatif yang berbeda, yaitu K-Medoids (*partitioning* berbasis medoid), *Gaussian Mixture Model* atau GMM (*model-based* probabilistik), dan *Agglomerative Hierarchical Clustering* dengan *linkage Ward*. Keempat algoritma diuji secara adil pada ruang fitur yang sama (PCA $n_components = 2$) dengan rentang kandidat dan mekanisme pemilihan K konsensus yang identik, serta dihitung *Adjusted Rand Index* (ARI) terhadap label K-Means sebagai indikator konsistensi struktur klaster lintas paradigma yang dijelaskan pada analisis stabilitas bootstrap. Hasil *benchmark* algoritma untuk Model A dan Model B dapat dilihat pada Gambar 4.7 dan Gambar 4.8.



Gambar 4.7 Perbandingan skor Silhouette, DBI dan CHI pada setiap algoritma di kedua model



Gambar 4.8 Kurva metrik per K pada setiap algoritma di kedua model

Tabel 4.4 Perbandingan ARI pada Kedua Model

Algoritma	Optimal K	ARI vs K-Means (A)	ARI vs K-Means (B)
K-Means	3	1.0000	1.0000
K-Medoids	4	0.6344	0.6403
GMM	3	0.8969	0.9148
Agglomerative	3	0.6365	0.8350

Hasil grafik dan Tabel 4.4 tersebut menunjukkan bahwa algoritma K-Means secara konsisten unggul pada ketiga skor metrik validasi internal di kedua model. Pada Model Utama (A), K-Means memperoleh skor *Silhouette* tertinggi yaitu 0,491, skor *Davies-Bouldin Index* terendah yaitu 0,742, dan skor *Calinski-Harabasz Index* tertinggi yaitu 5.530,7, dengan GMM sebagai pesaing terdekat (*Silhouette* 0,485). Pada Model B, pola superioritas yang sama muncul (*Silhouette* 0,496; DBI 0,737; CHI 5.476,6). Selain itu, konsistensi label antara K-Means dan algoritma alternatif tergolong tinggi, dengan ARI GMM mencapai 0,897 pada Model Utama dan 0,915 pada Model B, serta Agglomerative pada Model B mencapai 0,835. Sedangkan ARI K-Medoids yang lebih rendah (0,634–0,640), ini dikarenakan K-Medoids memiliki optimal K yang berbeda ($K = 4$), bukan karena perbedaan struktur klaster yang fundamental.

Hasil *benchmark* ini memperkuat justifikasi pemilihan algoritma K-Means, dimana K-Means unggul pada ketiga metrik validitas internal absolut di kedua model, dan struktur klaster yang dihasilkan beririsan kuat dengan algoritma berparadigma berbeda. Dengan demikian, pemilihan K-Means sebagai algoritma utama LOAF terjustifikasi secara empiris, tidak hanya berdasarkan pertimbangan teoretis terkait kesederhanaan, skalabilitas, dan interpretabilitas.

4.4.2 Pemilihan Jumlah Klaster Optimal

Penentuan jumlah klaster optimal dilakukan dengan metode *elbow* serta mengevaluasi tiga metrik validasi internal, yaitu *Silhouette Score*, *Davies-Bouldin Index* (DBI), dan *Calinski-Harabász Index* (CHI) dalam skema *looping* pada rentang adaptif yang telah dijelaskan pada sub bab mengenai *Adaptive Range K* diatas. Karena setiap metrik mengukur aspek struktur klaster yang berbeda dan kadang memberi kesimpulan yang tidak seragam, penentuan

jumlah klaster optimal tidak digantungkan pada satu metrik tunggal, melainkan melalui mekanisme *rank aggregation* yang juga telah dijelaskan pada sub bab *Rank aggregation* pada metrik validasi internal: metode ini menganggap ketiga metrik sama pentingnya. Ini karena secara metodologis tidak ada alasan kuat untuk mengatakan bahwa silhouette lebih penting dari DBI, CHI ataupun sebaliknya. *Rank aggregation* ini dijabarkan pada formula (3.7). diatas. Dimana secara garis besar mekanisme ini bekerja dengan mengakumulasi peringkat ketiga metrik. Untuk setiap kandidat k , ketiga metrik diberi peringkat lalu dirata-ratakan, dan nilai k dengan rata-rata peringkat terbaik dipilih sebagai jumlah klaster konsensus. Mekanisme ini dijalankan secara independen untuk setiap kelompok CBG, sehingga jumlah klaster optimal yang dihasilkan oleh setiap kelompok CBGnya dapat berbeda.

Hasil penentuan jumlah klaster menunjukkan variasi yang bermakna antar kelompok CBG, yaitu berkisar antara 2 hingga 5 klaster. Dimana seluruh kelompok CBG pada Model A dan Model B menghasilkan jumlah klaster optimal yang identik, merupakan sebuah indikasi awal bahwa struktur klaster tidak bergantung secara berlebihan pada variabel pendamping. Ringkasan hasil masing-masing kelompok CBG pada kedua model dapat dilihat pada Tabel 4.5.

Tabel 4.5 Jumlah Klaster Optimal dan Skor Silhouette per-CBG

Kode CBG	Deskripsi INA-CBG	Opt. K (A)	Sil. (A)	Opt. K (B)	Sil. (B)
K-4-17-I	Nyeri Abdomen & Gastroenteritis Lain-lain (Ringan)	4	0,418	4	0,421
A-4-13-I	Infeksi Viral & Non-Bakterial Lain (Berat)	4	0,410	4	0,408
K-1-13-I	Prosedur Apendik (Ringan)	4	0,389	4	0,402
J-1-20-III	Prosedur Sistem Pernafasan Non-Kompleks (Berat)	3	0,425	3	0,432
I-4-20-I	Angina Pektoris dan Nyeri Dada (Ringan)	2	0,738	2	0,742
A-4-14-I	Penyakit Infeksi Bakteri dan Parasit Lain-lain (Ringan)	5	0,420	5	0,415
O-6-10-I	Operasi Pembedahan Caesar (Ringan)	3	0,454	3	0,464
M-1-80-I	Prosedur Anggota Tubuh Atas (Ringan)	4	0,426	4	0,425
N-1-12-II	Membuat Baru, Merevisi dan Memindahkan Alat Dialisis (Sedang)	3	0,508	3	0,511
N-4-10-III	Tumor Ginjal dan Saluran Urin & Gagal Ginjal (Berat)	3	0,474	3	0,475

Variasi jumlah klaster antar kelompok CBG menunjukkan bahwa heterogenitas pola tindakan medis berbeda-beda menurut jenis CBG. CBG tertentu, seperti I-4-20-I (angina pektoris), memiliki pola pelayanan yang relatif seragam sehingga terpecah menjadi dua klaster dengan skor silhouette tertinggi (0,738). Sebaliknya, paket lain seperti A-4-14-I (penyakit infeksi bakteri ringan) memuat beragam pola pelayanan yang berbeda sehingga terpecah menjadi lima klaster. Heterogenitas tersebut yang menjadi sumber perbedaan defisit di dalam paket CBG yang sama, dan menjadi sasaran utama analisis framework LOAF yang diusulkan pada penelitian ini.

4.4.3 Uji Robustness: Model Utama (A) v.s Model B

Untuk memverifikasi bahwa pembentukan klaster tidak sensitif terhadap pilihan fitur, dilakukan uji robustness dengan membandingkan model utama (a) terhadap model b pada masing-masing kelompok CBG. Kesesuaian label antar kedua model dihitung melalui tabulasi silang, dimana untuk setiap klaster Model A, ditentukan klaster Model B yang paling banyak beririsan dengannya, lalu proporsi kasus yang bersesuaian dijumlahkan dan dinyatakan sebagai persentase kesesuaian. Hasil uji robustness tersebut dapat dilihat pada Tabel 4.6.

Tabel 4.6 Hasil Uji Robustness Antar Model per-CBG

CBG	K Model A	K Model B	Kesesuaian (%)	Interpretasi
K-4-17-I	4	4	93,8%	Sangat Konsisten
A-4-13-I	4	4	93,4%	Sangat Konsisten
K-1-13-I	4	4	92,0%	Sangat Konsisten
J-1-20-III	3	3	97,2%	Sangat Konsisten
I-4-20-I	2	2	100%	Identik
A-4-14-I	5	5	94,7%	Sangat Konsisten
O-6-10-I	3	3	98%	Sangat Konsisten
M-1-80-I	4	4	100%	Identik
N-1-12-II	3	3	100%	Identik
N-4-10-III	3	3	100%	Identik

Hasil Tabel 4.6 tersebut menunjukkan bahwa kesesuaian label antar model utama (A) dan model B sangat tinggi yaitu berkisar dari 92,0% hingga 98%, dengan empat kelompok mencapai kesesuaian identik (100%). Pada seluruh kelompok, kedua model juga menghasilkan jumlah klaster optimal yang sama. Temuan mengenai tingginya tingkat kesesuaian antara kedua model ini membuktikan bahwa struktur utama klaster digerakkan oleh pola tindakan medis itu sendiri, dan bukan oleh variabel pendamping LOS maupun HAS_ICU. Dengan kata lain, penambahan variabel klinis pada Model A tidak mengaburkan sinyal *treatment* utama dan tidak mengubah struktur pengelompokan secara berarti.

Dengan demikian, dapat disimpulkan bahwa struktur klaster pada data ini didorong secara dominan oleh pola tindakan medis itu sendiri, sementara variabel klinis makro

berperan untuk memperkaya konteks *severity* pada tahap *profiling*, bukan sebagai penentu batas klaster. Model utama (Model A) tetap dipertahankan sebagai model utama analisis karena memberikan kekayaan interpretatif pada tahap pasca-klaster.

4.4.4 Analisis Stabilitas Bootstrap

Sebagai lapisan validasi tambahan, dilakukan analisis stabilitas bootstrap untuk setiap kelompok CBG. Dimana pada setiap kelompok dijalankan 50 iterasi pengambilan ulang sampel tanpa pengembalian sebesar 80% dari jumlah kasus. Pada tiap iterasi, klastering diulang lalu label hasilnya dibandingkan dengan label acuan menggunakan *Adjusted Rand Index* (ARI). Hasil uji stabilitas bootstrap untuk model utama dapat dilihat pada Tabel 4.7.

Tabel 4.7 Hasil Analisis Stabilitas Bootstrap per-CBG (50 Iterasi, 80% Rasio Subsample)

Kode CBG	K	Mean ARI	Std ARI	Stabilitas
K-4-17-I	4	0,937	0,080	Stabil
A-4-13-I	4	0,929	0,058	Stabil
K-1-13-I	4	0,892	0,137	Stabil
J-1-20-III	3	0,855	0,167	Stabil
I-4-20-I	2	1,000	0,000	Sangat Stabil
A-4-14-I	5	0,806	0,155	Stabil
O-6-10-I	3	0,919	0,063	Stabil
M-1-80-I	4	0,761	0,219	Cukup Stabil
N-1-12-II	3	0,897	0,206	Stabil
N-4-10-III	3	0,804	0,184	Stabil

Hasil dari Tabel 4.7 tersebut menunjukkan bahwa nilai rata-rata ARI berkisar dari 0,761 hingga 1,000, dengan sembilan dari sepuluh kelompok CBG memiliki ARI di atas 0,80. Nilai ini tergolong stabilitas tinggi berdasarkan panduan interpretasi standar ($ARI > 0,75$ dianggap stabil). Kelompok I-4-20-I bahkan mencapai ARI sempurna (1,000) dengan simpangan baku nol (Std ARI 0,000), yang mencerminkan pemisahan dua klaster yang sangat tegas, hal ini juga konsisten dengan nilai *silhouette* tertingginya mencapai 0,738. Disisi lain, kelompok CBG M-1-80-I memiliki ARI rata-rata terendah (0,761) dengan simpangan baku terbesar (Std ARI 0,219). Meski demikian, hasil kesesuaian antar-model yang ditunjukkan pada

Tabel 4.6 tetap sempurna (100%), sehingga dasar analisis dan interpretasi terhadap struktur klaster pada kelompok CBG ini tetap dapat dipertahankan.

Secara keseluruhan, hasil temuan stabilitas bootstrap telah membuktikan bahwa klaster yang dihasilkan oleh *framework* LOAF ini bersifat stabil, dimana apabila penelitian ini direplikasi dengan subset data yang berbeda-beda, struktur pengelompokan yang sama akan terbentuk kembali (sama).

4.5 Evaluasi Hasil Klastering

Setelah mendapatkan jumlah optimal klaster untuk tiap kelompok CBG, maka nilai tersebut akan digunakan sebagai parameter k pada klastering k -means pada masing-masing CBG. Dan hasil klaster terbentuk akan dilakukan evaluasi dengan tahap-tahap berikut.

4.5.1 Analisis Profil Kerugian

Setelah klaster terbentuk, maka selanjutnya dilakukan *profiling* secara komprehensif untuk setiap klaster pada setiap kelompok CBG. Tahap ini mencakup profil finansial, klinis juga mengungkap korelasi erat antara tingkat kerugian dengan kompleksitas medis dan durasi perawatan. Hasil analisis profil dapat dilihat pada Tabel 4.8.

Tabel 4.8 Analisi Profil Kerugian Klaster per-CBG dalam Rupiah (Juta)

CBG	K	Kasus (total)	Defisit (total)	Defisit (mean)	LOS (mean)	Umur (mean)	Diaglist (mean)	Proclist (mean)
K-4-17-I	0	83	85,9	1,03	2.93	45.92	1.40	1.84
	1	80	183	2,29	4.35	48.25	1.52	2.05
	2	134	246	1,83	4.27	37.60	1.18	1.87
	3	90	74,6	0,83	3.16	4.58	1.18	1.74
A-4-13-I	0	88	54,7	0,62	3.14	29.24	1.18	1.25
	1	150	258	1,72	4.47	30.36	1.23	1.32
	2	63	163	2,59	6.02	12.43	1.40	1.52
	3	108	103	0,95	3.89	7.36	1.23	1.24
K-1-13-I	0	29	111	3,85	3.48	19.86	1.17	2.45
	1	48	144	3,00	2.44	33.92	1.10	2.50
	2	57	197	3,45	3.63	35.40	1.18	2.39
	3	16	91,5	5,72	5.69	24.06	1.31	2.94
J-1-20-III	0	18	275	15,2	9.78	60.72	6.17	7.94
	1	11	93,6	8,51	5.55	49.18	5.55	8.64
	2	7	48,1	6,87	9.57	67.86	5.86	7.14
I-4-20-I	0	99	344	3,47	4.39	57.07	1.76	3.05
	1	6	5,77	0,96	4.50	63.67	2.67	3.17

A-4-14-I	0	72	97,9	1,36	4.24	40.68	1.32	1.57
	1	18	39,1	2,17	5.11	8.11	1.33	2.22
	2	55	52,9	0,96	3.76	4.56	1.31	1.96
	3	44	26,5	0,60	3.36	35.75	1.23	1.55
	4	17	46,1	2,71	6.06	36.06	1.53	1.53
O-6-10-I	0	83	99,8	1,20	3.25	29.94	3.71	3.02
	1	71	97,9	1,37	3.86	31.89	3.90	2.97
	2	51	61,3	1,20	2.92	30.25	3.67	2.78
M-1-80-I	0	51	111	2,18	3.18	47.88	1.33	3.55
	1	17	84,5	4,97	3.94	41.82	1.41	3.76
	2	8	23,5	2,94	2.75	52.62	1.50	3.50
	3	20	31,4	1,57	2.45	46.95	1.29	3.35
N-1-12-II	0	11	130	11,8	8.55	55.55	4.36	6.73
	1	34	89,2	2,62	5.44	56.82	3.47	5.85
	2	5	15,7	3,14	4.40	57.60	3.20	5.00
N-4-10-III	0	10	128	6,41	5.85	54.5	3.95	4.45
	1	1	46,8	46,8	21.0	66.0	6.00	9.00
	2	28	58,1	2,07	4.00	50.5	3.50	4.29

Data pada Tabel 4.8 tersebut mengungkap empat pola penting yang menjadi landasan analisis pasca-klaster pada subbab berikutnya. Berikut adalah uraian masing-masing pola tersebut.

1. Dalam setiap kelompok CBG, selalu terdapat satu klaster yang memiliki rata-rata defisit yang jauh lebih dalam dibandingkan klaster lain pada CBG yang sama. Pola ini sangat konsisten dan menjadi temuan inti penelitian. Sebagai contoh, pada CBG K-4-17-I, klaster 1 mencatat rata-rata defisit sebesar Rp 2,29 juta per kasus, atau 2,76 kali lebih dalam dibandingkan klaster 3 yang hanya Rp 0,83 juta per kasus. Pola serupa muncul pada CBG A-4-13-I (rasio 4,18 kali antara klaster 2 dan klaster 0), A-4-14-I (rasio 4,52 kali antara klaster 4 dan klaster 3), M-1-80-I (rasio 3,17 kali antara klaster 1 dan klaster 3), dan N-1-12-II (rasio 4,50 kali antara klaster 0 dan klaster 1). Bahkan pada CBG J-1-20-III yang seluruh klasternya tergolong memiliki defisit yang besar, masih terdapat rentang dari Rp 6,87 juta sampai Rp 15,2 juta per kasus, atau rasio 2,21 kali. Konsistensi pola ini memperkuat tesis mengenai defisit klaim yang tidak terdistribusi merata di antara seluruh pasien dengan diagnosis CBG yang sama, melainkan terkonsentrasi pada sub-kelompok pasien tertentu yang dapat diidentifikasi melalui pola tindakannya.
2. Terdapat korelasi yang sangat erat antara rata-rata defisit dengan lama rawat inap (LOS) di dalam tiap kelompok CBG. Pada hampir seluruh CBG, klaster dengan rata-rata defisit paling besar juga merupakan klaster dengan rata-rata LOS yang paling panjang. Sebagai contoh pada CBG N-1-12-II, klaster 0 yang paling defisit (Rp 11,8 juta) memiliki LOS 8,55 hari, sedangkan pada klaster 1 (Rp 2,62 juta) hanya 5,44 hari. Pola yang sama juga terdapat pada CBG N-4-10-III dengan LOS klaster 0 mencapai 5,85 hari, sedangkan pada klaster 2 hanya 4,00 hari, pada CBG M-1-80-I dengan LOS klaster 1 (3,94 hari) lebih panjang dibandingkan Klaster 3 (2,45 hari), dan pada CBG J-1-20-III LOS klaster 0 mencapai sampai dengan 9,78 hari. Karena tarif CBG bersifat paket tetap yang sudah disepakati di awal, perpanjangan lama rawat ini secara langsung akan menggerus margin klaim, oleh karenanya LOS menjadi salah satu mekanisme utama terbentuknya defisit.
3. Pada beberapa kelompok CBG, klaster terpecah berdasarkan kelompok usia pasien. Pada CBG K-4-17-I, klaster 0 dan klaster 1 didominasi oleh pasien dewasa dengan rata-rata usia 45,9 dan 48,3 tahun, sedangkan pada klaster 2 didominasi pasien dewasa dengan usia muda (37,6 tahun) dan pada klaster 3 didominasi oleh pasien


anak-anak (rata-rata umur 4,6 tahun). Rentang umur antar klaster pada CBG ini mencapai 43,7 tahun. Pola serupa juga muncul pada CBG A-4-14-I, dimana rentang usia antar klaster mencapai 36,1 tahun (klaster 1 dan 2 didominasi oleh pasien anak-anak dengan rata-rata umur 8,1 dan 4,6 tahun, sementara klaster 0, 3, dan 4 didominasi oleh pasien dewasa). Hal ini menunjukkan bahwa di dalam satu paket CBG yang identik, profil usia pasien dapat menjadi salah satu dimensi pembeda klaster selain intensitas pelayanan.

4. Kompleksitas kasus secara umum sejalan dengan tingkat defisit, sebagaimana ditunjukkan oleh rata-rata jumlah diagnosis dan prosedur per klaster. Klaster pada CBG kasus berat (J-1-20-III, N-1-12-II, N-4-10-III) memiliki rata-rata diagnosis sebanyak 3,5 sampai 6,2 dan rata-rata prosedur sebanyak 4,3 sampai 8,6, yang jauh lebih tinggi dibandingkan klaster pada CBG kasus ringan (K-4-17-I, A-4-13-I, A-4-14-I) yang umumnya hanya memiliki 1,2 sampai 1,5 diagnosis dan 1,2 sampai 2,1 prosedur. Pola ini konsisten dengan kerangka *case-mix* INA-CBG yang memang memperhitungkan tingkat keparahan dalam pengelompokan tarif.

Notasi diberikan kepada satu temuan khusus pada CBG N-4-10-III, yaitu klaster 1 yang hanya terdapat satu kasus dengan defisit ekstrem sebesar Rp 46,8 juta dan LOS 21 hari. Klaster berukuran satu ini lebih tepat diperlakukan sebagai *outlier* individual daripada sebagai pola kelompok, dan dengan demikian temuan pada klaster tersebut tidak dapat digeneralisasi. Secara keseluruhan, empat pola yang terdapat pada Tabel 4.8 tersebut memberikan landasan yang kuat untuk analisis pasca-klaster pada subbab berikutnya, khususnya analisis komparatif pada kasus rugi vs untung yang akan mengkuantifikasi mekanisme pembentuk defisit melalui gap pola tindakan medis.

4.5.2 Analisis Visualisasi Hasil Klaster

Untuk memvalidasi pemisahan klaster secara kualitatif dan memahami distribusi data dalam ruang dimensi yang lebih rendah, dilakukan visualisasi sebaran klaster pada ruang dua komponen utama hasil PCA untuk kesepuluh kelompok CBG prioritas. Hasil visualisasi PCA dapat dilihat pada Gambar 4.9 Hasil visualisasi PCA distribusi klaster pada top-10 CBG prioritas dalam format 10 subplot, satu subplot per kelompok CBG berikut.



Gambar 4.9 Hasil visualisasi PCA distribusi kluster pada top-10 CBG prioritas

Dari hasil visualisasi tersebut, kesepuluh subplot menunjukkan pemisahan antar klaster yang dapat diamati, dengan kepadatan titik yang konsisten di dalam masing-masing klaster. Subplot kelompok I-4-20-I memperlihatkan pemisahan dua klaster yang paling tegas, konsisten dengan skor silhouette dan ARI tertinggi pada kelompok CBG tersebut. Sementara itu, subplot kelompok CBG dengan jumlah klaster yang lebih banyak (seperti A-4-14-I dengan 5 klaster) memperlihatkan separasi yang lebih halus namun tetap dapat dibedakan.

4.5.3 Uji Signifikansi Statistik Antar Klaster (Mann-Whitney U)

Sebagai langkah evaluasi tambahan, selanjutnya dilakukan uji non-parametrik *Mann-Whitney U pairwise* antar klaster pada setiap kelompok CBG, untuk memverifikasi bahwa pemisahan klaster merepresentasikan subpopulasi pasien yang berbeda secara substantif. Uji dilakukan pada empat variabel, yaitu SELISIH, LOS, JML_DIAGLIST, dan JML_PROCLIST. Selanjutnya, hasil setiap pengujian dikoreksi dengan menggunakan metode *False Discovery Rate (FDR) Benjamini-Hochberg* secara independen per-CBG, dan kekuatan efek dinyatakan melalui *Cliff's Delta*. Pengujian dijalankan terpisah pada setiap CBG karena tarif dan tingkat keparahan sudah terkontrol melalui stratifikasi, sehingga *p-value* yang signifikan langsung dapat diinterpretasikan sebagai perbedaan pola tindakan atau intensitas pelayanan di dalam paket tarif CBG yang sama. Ringkasan hasil pengujian ranking variabel paling diskriminatif lintas CBG dapat dilihat pada Tabel 4.9.

Tabel 4.9 Variabel Paling Diskriminatif Antar Klaster (Lintas CBG)

No.	Variable	Rata-rata % Pasangan Signifikan	Mean Cliff's Delta	Max Cliff's Delta	n CBG
1	LOS	78,33%	0,600	1,000	10
2	SELISIH	59,00%	0,502	0,943	10
3	JML_PROCLIST	9,00%	0,156	0,527	10
4	JML_DIAGLIST	5,00%	0,188	0,495	10

Pada Tabel 4.9 tersebut, hasil menunjukkan bahwa variabel LOS merupakan dimensi paling diskriminatif antar klaster, dengan presentase rata-rata sebesar 78,33% pasangan klaster menunjukkan perbedaan signifikan setelah koreksi FDR, dan rata-rata kekuatan efek

tergolong "Kuat" (*Cliff's $\Delta = 0,600$*). Selanjutnya variabel SELISIH menempati peringkat kedua dengan presentase sebesar 59,00% pasangan signifikan. Sebaliknya, pada variabel JML_DIAGLIST dan JML_PROCLIST hanya signifikan pada sedikit pasangan klaster (5% dan 9%) dengan kekuatan efek "*Negligible*" sampai "Lemah". Temuan ini sekaligus mengonfirmasi keputusan rancangan pada sub bab 3.4.4 diatas, yang mengalihfungsikan JML_DIAGLIST dari fitur klastering menjadi variabel kontrol *case-mix* di dalam paket tarif yang sama, jumlah diagnosis memang tidak menjadi pembeda utama antar klaster karena tingkat keparahan sudah terkontrol melalui stratifikasi CBG. Sebagai ilustrasi mendalam, hasil uji *pairwise* pada kelompok CBG K-4-17-I (CBG dengan total defisit terbesar) dituliskan pada Tabel 4.10.

Tabel 4.10 Hasil Uji Mann-Whitney U dengan Koreksi FDR pada CBG Paling Defisit (K-4-17-I)

Variabel	Pasangan	p-value (FDR)	Cliff's Delta	Kekuatan Efek	Signifikasi FDR
SELISIH	K0 vs K1	2,30e-09	0,560	Kuat	✓
SELISIH	K0 vs K2	1,98e-08	0,469	Sedang	✓
SELISIH	K0 vs K3	0,0548	-0,192	Lemah	✗
SELISIH	K1 vs K2	0,1399	-0,137	Negligible	✗
SELISIH	K1 vs K3	6,51e-13	-0,659	Kuat	✓
SELISIH	K2 vs K3	8,13e-13	-0,579	Kuat	✓
LOS	K0 vs K1	4,14e-25	-0,889	Kuat	✓
LOS	K0 vs K2	2,17e-30	-0,886	Kuat	✓
LOS	K0 vs K3	0,001085	-0,208	Lemah	✓
LOS	K1 vs K2	0,6029	0,042	Negligible	✗
LOS	K1 vs K3	2,44e-21	0,790	Kuat	✓
LOS	K2 vs K3	6,97e-26	0,781	Kuat	✓

Dari 24 pasangan pengujian pada CBG Nyeri Abdomen & Gastroenteritis Lain-lain (Ringan) dengan kode CBG K-4-17-I, sebanyak 17 di antaranya menunjukkan perbedaan signifikan setelah koreksi FDR. Pada variabel SELISIH, klaster 1 yang merupakan klaster paling

defisit, terbukti dengan memiliki perberbedaan yang signifikan dengan kekuatan efek "kuat" terhadap klaster 3 dan klaster 2, dengan *cliff's delta* masing-masing -0,659 dan -0,579. Pada variabel LOS, hampir seluruh pasangan menunjukkan perbedaan dengan kekuatan efek "kuat" ($|d| > 0,78$), kecuali pasangan klaster 1 vs klaster 2 yang memiliki rata-rata LOS hampir setara (4,35 vs 4,27 hari pada Tabel 4.8 diatas). Pola serupa, yaitu dominasi LOS dan SELISIH sebagai variabel pembeda antar klaster, juga ditemukan pada kesembilan CBG prioritas lainnya.

Temuan ini merupakan bukti statistik yang kuat bahwa klaster yang terbentuk bukan sekadar pengelompokan geometris pada ruang PCA, melainkan merepresentasikan subpopulasi pasien dengan karakteristik klinis-finansial yang berbeda secara nyata di dalam paket tarif CBG yang identik. Hal ini sekaligus menjustifikasi penggunaan klaster sebagai unit analisis pada tahap pasca-klaster.

4.5.4 Simpulan Hasil Evaluasi

Rangkaian evaluasi hasil klaster membentuk lima lapis triangulasi validasi yang saling memperkuat dan menjadi landasan validitas analisis pasca-klaster pada tahap berikutnya.

1. Justifikasi pemilihan komponen PCA yang hasil pengujiannya terdapat pada sub bab 4.3.4 memberikan bukti empiris bahwa konfigurasi $n_components = 2$ menghasilkan kualitas klaster yang dua kali lipat lebih tinggi dibandingkan konfigurasi dengan ratusan komponen.
2. Hasil *benchmark* algoritma pada sub bab 4.4.1 menunjukkan bahwa algoritma K-Means unggul pada ketiga metrik validitas internal secara absolut di kedua model, dengan struktur klaster yang beririsan kuat dengan algoritma berparadigma berbeda (ARI GMM 0,897–0,915).
3. Hasil uji *robustness* antar model A dan model B yang terdapat pada sub bab 4.4.3 menghasilkan rentang presentase kesesuaian label sebesar 92,0%–100%, memberikan bukti bahwa struktur klaster murni digerakkan oleh pola tindakan medis itu sendiri, bukan oleh variabel pendamping.
4. Hasil uji stabilitas *bootstrap* pada sub bab 4.4.4 menghasilkan rata-rata ARI di atas 0,80 pada sembilan dari sepuluh kelompok CBG, memberikan bukti stabilitas struktur klaster terhadap variasi sampel.
5. Hasil uji *Mann-Whitney U* dengan koreksi FDR pada sub bab 4.5.3 memberikan bukti statistik bahwa klaster yang terbentuk merepresentasikan subpopulasi pasien

yang berbeda secara substantif, terutama pada dimensi LOS (78,33% pasangan signifikan) dan SELISIH (59,00% pasangan signifikan).

Kelima lapis validasi tersebut memberikan landasan validitas yang sangat kuat bagi kesimpulan dan interpretasi yang akan diperoleh pada tahap analisis pasca-klaster berikutnya.

4.6 Analisis Pasca-Klaster (Post-Clustering Analysis)

Setelah klaster terbentuk dan divalidasi pada tahap sebelumnya, selanjutnya dilakukan profiling secara komprehensif untuk setiap klaster pada setiap kelompok CBG. Tahap ini mencakup empat sudut pandang yang saling melengkapi, yaitu gambaran umum klaster, profil klinis pasien, profil kelompok CBG, dan profil tindakan medis dominan. Tujuannya adalah tidak lain untuk menerjemahkan hasil segmentasi menjadi informasi yang bermakna secara klinis dan manajerial.

4.6.1 Gambaran Umum Klaster

Sebagaimana telah disajikan pada Tabel 4.8 diatas, framework LOAF berhasil memecah kesepuluh kelompok CBG prioritas menjadi total 35 klaster, dengan distribusi sebagai berikut:

1. Empat CBG terpecah menjadi 4 klaster (K-4-17-I, A-4-13-I, K-1-13-I, M-1-80-I)
2. Empat CBG terpecah menjadi 3 klaster (J-1-20-III, O-6-10-I, N-1-12-II, N-4-10-III)
3. Satu CBG terpecah menjadi 5 klaster (A-4-14-I)
4. Satu CBG terpecah menjadi 2 klaster (I-4-20-I).


Profil kerugian klaster mengungkap satu pola yang sangat konsisten pada lintas kelompok CBG, yaitu bahwa di dalam setiap paket CBG yang identik selalu terdapat satu atau dua klaster dengan rata-rata defisit yang jauh lebih dalam dibandingkan klaster lain. Tabel profil kerugian klaster pada tiap CBG dapat dilihat pada Tabel 4.11.

Tabel 4.11 Profil Kerugian Tiap Klaster pada Top-10 CBG dalam Rupiah (Juta)

CBG	Deskripsi INA-CBG	K	Kasus (total)	Defisit (total)	Defisit (mean)
K-4-17-I	Nyeri Abdomen & Gastroenteritis Lain-lain (Ringan)	0	83	85,9	1,03
		1	80	183	2,29
		2	134	246	1,83
		3	90	74,6	0,83
A-4-13-I	Infeksi Viral & Non-Bakterial Lain (Ringan)	0	88	54,7	0,62
		1	150	258	1,72
		2	63	163	2,59
		3	108	103	0,95
K-1-13-I	Prosedur Apendik (Ringan)	0	29	111	3,85
		1	48	144	3,00
		2	57	197	3,45
		3	16	91,5	5,72
J-1-20-III	Prosedur Sistem Pernafasan Non-Kompleks (Berat)	0	18	275	15,2
		1	11	93,6	8,51
		2	7	48,1	6,87
I-4-20-I	Angina Pektoris dan Nyeri Dada (Ringan)	0	99	344	3,47
		1	6	5,77	0,96

A-4-14-I	Penyakit Infeksi Bakteri dan Parasit Lain-lain (Ringan)	0	72	97,9	1,36
		1	18	39,1	2,17
		2	55	52,9	0,96
		3	44	26,5	0,60
		4	17	46,1	2,71
O-6-10-I	Operasi Pembedahan Caesar (Ringan)	0	83	99,8	1,20
		1	71	97,9	1,37
		2	51	61,3	1,20
M-1-80-I	Prosedur Anggota Tubuh Atas (Ringan)	0	51	111	2,18
		1	17	84,5	4,97
		2	8	23,5	2,94
		3	20	31,4	1,57
N-1-12-II	Membuat Baru, Merevisi dan Memindahkan Alat Dialisis (Sedang)	0	11	130	11,8
		1	34	89,2	2,62
		2	5	15,7	3,14
N-4-10-III	Tumor Ginjal & Saluran Urin & Gagal Ginjal (Berat)	0	10	128	6,41
		1	1	46,8	46,8
		2	28	58,1	2,07

Dari tabel tersebut, pada CBG K-4-17-I (Nyeri Abdomen & Gastroenteritis Lain-lain (Ringan)), klaster 1 memiliki rata-rata defisit sebesar Rp 2,29 juta per kasus, hampir tiga kali lipat lebih besar dibandingkan dengan klaster 3 yang hanya Rp 0,83 juta. Sedangkan pada CBG J-1-20-III (Prosedur Sistem Pernafasan Non-Kompleks (Berat)), klaster 0 memiliki rata-rata defisit sebesar Rp 15,2 juta per kasus, lebih besar dua kali lipat dari klaster 2 (Rp 6,87 juta). Konsistensi temuan ini merupakan bukti bahwa defisit klaim tidak terdistribusi merata di antara seluruh pasien dengan diagnosis CBG yang sama, melainkan terkonsentrasi pada sub-kelompok pasien tertentu yang dapat diidentifikasi melalui pola tindakannya. Visualisasi menggunakan bar *chart* mengenai informasi rata-rata defisit per-CBG ditampilkan pada Gambar 4.10.




Gambar 4.10 Rata-rata defisit (SELISIH) per-CBG pada top-10 CBG paling defisit

Pada hasil visualisasi rata-rata kerugian Gambar 4.10 tersebut menunjukkan dua pola defisit yang sangat jelas berbeda. Dimana top-5 CBG dengan rata-rata defisit paling besar (ditandai dengan warna merah) didominasi oleh kasus sedang dan berat (*severity level* II dan III), yaitu J-1-20-III (Prosedur Sistem Pernafasan Non-Kompleks (Berat)) dengan rata-rata defisit terbesar (Rp 11,5 juta per kasus), diikuti oleh N-4-10-III, N-1-12-II, K-1-13-I, dan I-4-20-I. Lima CBG lainnya (warna oranye) merupakan kasus ringan (*severty level* I) dengan rata-rata defisit di kisaran Rp 1,2 juta sampai Rp 2,5 juta per kasus, namun memiliki volume kasus yang jauh lebih tinggi.

4.6.2 Profil Klinis Klaster

Untuk melengkapi pemahaman karakteristik klinis pasien pada *top-10* CBG prioritas, dilakukan analisis distribusi demografis dan *outcome* klinis secara agregat. Total sebanyak 1.693 kasus rugi pada *top-10* CBG dianalisis dari sudut pandang jenis kelamin, kelas rawat, dan status pulang. Hasil analisis distribusi agregat dapat dilihat pada Gambar 4.11.




Gambar 4.11 Distribusi demografis dan *outcome* klinis agregat pada Top-10 CBG

Dari hasil visualisasi Gambar 4.11 tersebut, populasi pasien pada *top-10* CBG didominasi oleh perempuan (53,9%, n=913) dibandingkan laki-laki (46,1%, n=780). Dari sisi kelas perawatan, mayoritas pasien dirawat di kelas 3 (46,6%, n=789), diikuti kelas 2 (34,8%, n=589) dan kelas 1 (18,6%, n=315). Distribusi status pulang menunjukkan tingkat keberhasilan klinis yang tinggi secara agregat, dengan mayoritas pasien (97,5%, n=1.650) berstatus sembuh.


Meski demikian, setelah dilakukan analisis mendalam kepada masing-masing kelompok CBGnya temuan yang kontras ditemukan pada Gambar 4.12 dibawah, dimana kelompok CBG J-1-20-III (Prosedur Sistem Pernafasan Non-Kompleks (Berat)) memiliki tingkat mortalitas sebesar 61%, angka yang sangat tinggi dan jauh di atas rata-rata agregat. Tingginya tingkat mortalitas pada CBG ini memberikan konteks klinis yang menjelaskan mengapa rata-rata defisit per kasusnya juga merupakan yang paling besar (Rp 11,5 juta), sebab kasus-kasus dengan tingkat keparahan ekstrem yang berujung pada kematian umumnya juga membutuhkan tindakan medis yang lebih intensif dan berbiaya tinggi. Kelompok CBG N-1-12-II (Membuat Baru, Merevisi dan Memindahkan Alat Dialisis


(Sedang)) juga mencatat tingkat mortalitas sebesar 12%, dengan 6% tambahan pasien yang dirujuk. Namun sebaliknya pada kelompok-kelompok kasus ringan seperti I-4-20-I, A-4-14-I, O-6-10-I, dan M-1-80-I, yang mencatatkan tingkat kesembuhan sempurna (100%). Hasil visualisasi perbandingan mortalitas tersebut dapat dilihat pada Gambar 4.12.

**J-1-20-III
(n=36)**



**N-1-12-II
(n=50)**





Gambar 4.12 Perbandingan mortalitas CBG J-1-20-III, N-1-12-II, I-4-20-I, A-4-14-I, O-6-10-I, dan M-1-80-I

Selanjutnya, profil klinis numerik tiap klaster yang terdapat pada Tabel 4.12, yang juga turut menunjukkan adanya pemisahan klaster berdasarkan kelompok usia pada beberapa CBG. Pada CBG K-4-17-I, klaster 0 dan 1 didominasi pasien dewasa dengan rata-rata umur 45,9 dan 48,3 tahun, sedangkan pada klaster 2 dan 3 didominasi oleh pasien anak-anak dengan rata-rata umur 37,6 dan 4,6 tahun. Pola pemisahan dewasa-anak yang serupa juga muncul pada A-4-13-I dan A-4-14-I. Hal ini menunjukkan bahwa di dalam satu paket CBG yang sama, profil usia pasien dapat menjadi salah satu dimensi pembeda klaster di samping intensitas pelayanan. Distribusi usia dan jenis kelamin pasien tersebut dapat dilihat pada Tabel 4.13.

Tabel 4.12 Profil Klinis Klaster per-CBG (numerik)

CBG	Deskripsi INA-CBG	K	LOS (mean)	Umur (mean)	Diaglist (mean)	Proclist (mean)
K-4-17-I	Nyeri Abdomen & Gastroenteritis Lain-lain (Ringan)	0	2.93	45.92	1.40	1.84
		1	4.35	48.25	1.52	2.05
		2	4.27	37.60	1.18	1.87
		3	3.16	4.58	1.18	1.74
A-4-13-I	Infeksi Viral & Non-Bakterial Lain (Ringan)	0	3.14	29.24	1.18	1.25
		1	4.47	30.36	1.23	1.32
		2	6.02	12.43	1.40	1.52
		3	3.89	7.36	1.23	1.24
K-1-13-I	Prosedur Apendik (Ringan)	0	3.48	19.86	1.17	2.45
		1	2.44	33.92	1.10	2.50
		2	3.63	35.40	1.18	2.39
		3	5.69	24.06	1.31	2.94
J-1-20-III	Prosedur Sistem Pernafasan Non-Kompleks (Berat)	0	9.78	60.72	6.17	7.94
		1	5.55	49.18	5.55	8.64
		2	9.57	67.86	5.86	7.14
I-4-20-I	Angina Pektoris dan Nyeri Dada (Ringan)	0	4.39	57.07	1.76	3.05
		1	4.50	63.67	2.67	3.17

A-4-14-I	Penyakit Infeksi Bakteri dan Parasit Lain-lain (Ringan)	0	4.24	40.68	1.32	1.57
		1	5.11	8.11	1.33	2.22
		2	3.76	4.56	1.31	1.96
		3	3.36	35.75	1.23	1.55
		4	6.06	36.06	1.53	1.53
O-6-10-I	Operasi Pembedahan Caesar (Ringan)	0	3.25	29.94	3.71	3.02
		1	3.86	31.89	3.90	2.97
		2	2.92	30.25	3.67	2.78
M-1-80-I	Prosedur Anggota Tubuh Atas (Ringan)	0	3.18	47.88	1.33	3.55
		1	3.94	41.82	1.41	3.76
		2	2.75	52.62	1.50	3.50
		3	2.45	46.95	1.29	3.35
N-1-12-II	Membuat Baru, Merevisi dan Memindahkan Alat Dialisis (Sedang)	0	8.55	55.55	4.36	6.73
		1	5.44	56.82	3.47	5.85
		2	4.40	57.60	3.20	5.00
N-4-10-III	Tumor Ginjal & Saluran Urin & Gagal Ginjal (Berat)	0	5.85	54.5	3.95	4.45
		1	21.0	66.0	6.00	9.00
		2	4.00	50.5	3.50	4.29

Tabel 4.13 Profil Klinis Klaster per-CBG (Proporsi Kategorik (%))

CBG	K	ICU		Kelas Rawat			Jenis Kelamin		Discharge Status				
		Y	T	1	2	3	L	P	1	2	3	4	5
K-4-17-I	0	0	100	34.9	31.3	33.7	38.5	61.5	98.8	0	0	1.2	0
	1	0	100	33.7	26.2	40	33.7	66.3	98.7	0	0	0	1.25
	2	0	100	16.4	59.7	23.8	67.1	32.9	99.2	0	0	0	0.75
	3	0	100	22.2	45.5	32.2	64.4	35.6	98.8	1.11	0	0	0
A-4-13-I	0	1.14	1.14	12.5	38.6	48.8	51.1	48.9	95.4	2.27	0	2.27	0
	1	0.67	0.67	17.3	30.6	52	54.6	45.4	99.3	0	0.67	0	0
	2	0	100	9.52	46	44.4	58.7	41.3	98.4	0	1.59	0	0
	3	0	100	9.44	44.4	36.1	50.9	49.1	100	0	0	0	0
K-1-13-I	0	0	100	13.7	34.4	51.7	68.9	31.1	100	0	0	0	0
	1	2.08	97.0	10.4	29.1	60.4	39.5	60.5	97.9	0	0	2.08	0
	2	1.75	98.2	12.2	29.8	57.8	45.6	54.4	100	0	0	0	0
	3	0	100	37.5	18.7	43.7	62.5	37.5	100	0	0	0	0
J-1-20-III	0	77.7	22.2	16.6	11.1	72.2	55.5	44.5	50	0	0	50	0
	1	100	0	0	0	100	63.6	36.4	9.09	0	0	90.9	0
	2	71.4	28.6	28.5	0	71.4	57.1	42.9	42.8	0	14.2	42.8	0
I-4-20-I	0	23.2	76.8	26.2	16.1	57.5	59.6	40.4	100	0	0	0	0

	1	0	100	16.6	0	83.3	50	50	100	0	0	0	0
A-4-14-I	0	0	100	31.9	31.9	36.1	36.1	63.9	100	0	0	0	0
	1	0	100	22.2	55.5	22.2	50	50	100	0	0	0	0
	2	0	100	25.4	63.6	10.9	56.3	43.7	100	0	0	0	0
	3	0	100	38.6	45.4	15.9	43.1	56.9	100	0	0	0	0
	4	0	100	35.2	11.7	52.9	58.8	41.1	100	0	0	0	0
O-6-10-I	0	0	100	7.23	31.3	61.4	0	100	100	0	0	0	0
	1	0	100	7	38	54.9	0	100	100	0	0	0	0
	2	0	100	11.7	33.3	54.9	0	100	100	0	0	0	0
M-1-80-I	0	0	100	15.6	15.6	68.6	47	53	100	0	0	0	0
	1	0	100	11.7	35.2	52.9	52.9	47.1	100	0	0	0	0
	2	0	100	0	50	50.0	50	50	100	0	0	0	0
	3	0	100	5	20	75.0	25	75	100	0	0	0	0
N-1-12-II	0	100	0	9	18.1	72.7	45.4	54.6	90.9	0	0	9.09	0
	1	100	0	2.9	20.5	76.4	55.8	44.2	88.2	2.94	0	8.82	0
	2	80	20	0	60	40.0	60	40	60	0	0	40	0
N-4-10-III	0	95	15	5	15	80.0	70	30	90	0	5.0	5.0	0
	1	100	0	0	0	100	0	100	100	0	0	0	0
	2	100	0	14.2	17.8	67.8	64.2	35.8	100	0	0	0	0

Tabel 4.13 menunjukkan distribusi proporsi data kategorik (HAS_ICU, jenis kelamin, kelas rawat, dan status pulang) untuk seluruh 35 klaster pada lintas *top-10* kelompok CBG prioritas. Dari informasi distribusi tersebut, terdapat enam temuan penting yang melengkapi pemahaman karakteristik klinis klaster pada 4.6.1 sebelumnya.

Pertama, distribusi ICU memperlihatkan bahwa terdapat pemisahan yang sangat tegas antara CBG kasus berat dan CBG kasus ringan. Tiga CBG kasus berat seperti N-4-10-III (Tumor Ginjal & Saluran Urin & Gagal Ginjal (Berat)), N-1-12-II (Membuat, Baru, Merevisi dan Memindahkan Alat Dialisis (Sedang)), dan J-1-20-III (Prosedur Sistem Pernafasan Non-Kompleks (Berat)) menunjukkan rata-rata penggunaan ICU pada seluruh klasternya sangat tinggi, masing-masing 98,3%, 93,3%, dan 83,1%. Bahkan pada beberapa klaster mencatat proporsi ICU 100% seperti J-1-20-III pada klaster 1, N-1-12-II pada klaster 0 dan 1, serta N-4-10-III pada klaster 1 dan 2. Sebaliknya, CBG kasus ringan seperti K-4-17-I, A-4-14-I, O-6-10-I, dan M-1-80-I mencatat proporsi ICU 0% pada seluruh klasternya.

Kedua, distribusi jenis kelamin pada CBG O-6-10-I (Operasi Pembedahan Caesar) yang seluruh klasternya didominasi 100% perempuan. Hal ini sesuai dengan sifat klinis prosedur caesar yang memang eksklusif pada pasien perempuan, sehingga pemisahan klaster pada CBG ini tidak dipengaruhi oleh jenis kelamin, melainkan oleh faktor lain seperti intensitas tindakan dan lama rawat inap. Pada sebagian besar CBG lainnya, distribusi jenis kelamin cenderung berimbang. Namun, pada CBG K-4-17-I terdapat pola pemisahan menarik di mana klaster 0 dan 1 (yang didominasi pasien dewasa) memiliki proporsi perempuan yang lebih tinggi (61,45% dan 66,25%), sedangkan pada klaster 2 dan 3 (yang didominasi pasien anak-anak) memiliki proporsi laki-laki yang lebih dominan (67,16% dan 64,44%). Hal ini kemungkinan karena perbedaan epidemiologi gastroenteritis pada kedua kelompok usia.

Ketiga, distribusi kelas rawat menunjukkan bahwa kelas 3 dominan pada hampir seluruh CBG. Beberapa CBG menunjukkan dominasi kelas 3 yang sangat ekstrem seperti pada CBG J-1-20-III di klaster 1 (100% kelas 3), CBG N-4-10-III di klaster 1 (100% kelas 3), dan CBG N-1-12-II di klaster 1 (76,47% kelas 3). Pada beberapa CBG, klaster dengan rata-rata defisit lebih besar justru cenderung memiliki proporsi kelas 3 yang lebih tinggi. Sebagai contoh, pada CBG M-1-80-I, klaster 3 (defisit Rp 1,57 juta) memiliki proporsi kelas 3 sebesar 75%, sedangkan pada klaster 1 yang paling defisit (Rp 4,97 juta) memiliki proporsi kelas 3 sebesar 52,94% dengan tambahan 35,29% di kelas 2. Temuan ini mengindikasikan bahwa beban defisit terbesar tidak semata-mata oleh fasilitas kelas rawat.

Keempat, distribusi status pulang mengungkap temuan klinis yang paling mencolok pada penelitian ini. Dimana pada CBG J-1-20-III mencatat tingkat mortalitas yang sangat ekstrem pada seluruh klasternya, yaitu pada klaster 1 sebesar 90,91%, klaster 0 sebesar 50,00%, dan klaster 2 sebesar 42,86%. Angka mortalitas ini jauh di atas rata-rata agregat pada top-10 CBG (2,5%) dan memberikan konteks klinis penting yang menjelaskan mengapa CBG ini juga merupakan kelompok dengan rata-rata defisit terbesar per-kasus (Rp 11,58 juta). Kasus-kasus dengan kompleksitas terminal yang berujung pada kematian umumnya membutuhkan intensitas tindakan medis yang sangat tinggi pada periode akhir untuk menunjang kehidupan pasien, yang tidak dapat sepenuhnya terakomodasi oleh paket tarif INA-CBG standar. Tingkat mortalitas yang lebih moderat namun tetap signifikan juga ditemukan pada CBG N-1-12-II pada klaster 2 (40,00%) dan klaster-klaster lain pada CBG N-1-12-II (8,82% sampai 9,09%).

Kelima, terdapat sekelompok CBG dengan tingkat keberhasilan klinis yang sangat tinggi. Seperti pada CBG I-4-20-I, A-4-14-I, O-6-10-I, dan M-1-80-I yang mencatat tingkat kesembuhan sebesar 100% pada seluruh klasternya, tanpa kasus meninggal, dirujuk, atau memaksa pulang. Hal ini menunjukkan bahwa defisit pada keempat CBG tersebut bukan terkait dengan kegagalan klinis, melainkan murni terkait dengan inefisiensi operasional pada kasus dengan *outcome* klinis yang baik. Keempat CBG ini menjadi kandidat yang kuat untuk diberlakukannya penanganan berupa efisiensi operasional (seperti standardisasi *clinical pathway* dan pengendalian intensitas tindakan), sedangkan CBG dengan tingkat mortalitas tinggi seperti J-1-20-III dan N-1-12-II memerlukan tinjauan ulang yang lebih bersifat klinis-aktuarial mengenai kecukupan tarif paket.

Keenam, korelasi yang kuat terjadi antara ICU dan tingkat mortalitas dapat dilihat secara konsisten. Dimana klaster dengan ICU 100% pada J-1-20-III (klaster 1) juga merupakan klaster dengan mortalitas tertinggi (90,91%), sedangkan klaster dengan ICU lebih rendah pada CBG yang sama (klaster 2, ICU 71,43%) memiliki mortalitas yang juga lebih rendah (42,86%). Pola serupa muncul pada CBG N-1-12-II pada klaster 2 dengan ICU 80% dan mortalitas 40%. Korelasi antara ICU dan mortalitas ini bersifat klinis logis, karena pasien yang membutuhkan perawatan intensif umumnya berada pada kondisi yang lebih kritis. Temuan ini mengindikasikan perlunya pemantauan khusus terhadap unit perawatan intensif sebagai *cost center* sekaligus *high-risk care unit*.

Secara keseluruhan, berdasarkan profil kerugian, profil klinis, dan distribusi kategorik yang telah dipaparkan tersebut, maka dapat ditarik kesimpulan menyeluruh bahwa defisit klaim pada *top-10* CBG prioritas terbentuk dari dua mekanisme yang berbeda secara

fundamental. Mekanisme pertama adalah defisit yang terkait dengan kompleksitas klinis terminal pada CBG kasus berat (J-1-20-III, N-1-12-II, N-4-10-III), yang ditandai dengan ICU yang tinggi (>80%) dan tingkat mortalitas signifikan (12%–61%). Mekanisme kedua adalah defisit yang terkait dengan inefisiensi operasional pada CBG kasus ringan (K-4-17-I, A-4-13-I, I-4-20-I, A-4-14-I, O-6-10-I, M-1-80-I), yang ditandai dengan tingkat kesembuhan mendekati 100% dan ICU yang sangat rendah atau bahkan nol.

Pembedaan kedua mekanisme ini memiliki implikasi penting bagi arah analisis komparatif selanjutnya. Pada CBG kasus berat, defisit tidak dapat dianalisis secara komparatif rugi-vs-untung yang valid karena populasi "untung" pada CBG tersebut cenderung merupakan pasien dengan severity yang lebih rendah, bukan pasien yang dilayani lebih efisien. Sebaliknya, pada CBG kasus ringan dengan *outcome* klinis yang baik, analisis komparatif justru dapat menghasilkan sinyal inefisiensi operasional yang murni dan *actionable* bagi manajemen rumah sakit. Oleh karena itu, analisis komparatif pada subbab berikutnya difokuskan pada lima CBG kasus ringan yang menjadi kandidat utama penanganan efisiensi operasional.

4.7 Analisis Komparatif pada Top-5 Kelompok CBG

Pada tahap ini, dilakukan analisis komparatif kasus rugi-vs-untung pada lima CBG yang dipilih sebagai kandidat utama. Pemilihan kelima CBG ini didasarkan pada justifikasi metodologis dan manajerial berikut.

1. Kelima CBG yang dipilih semuanya tergolong kasus ringan (*severity level I*) dengan tingkat kesembuhan pada klaster fokusnya mendekati atau mencapai 100% dan ICU 0% (kecuali I-4-20-I dengan ICU 23,23%). *Outcome* klinis yang baik ini memastikan bahwa defisit pada kelima CBG tersebut tidak dapat dijelaskan oleh kompleksitas klinis terminal, melainkan terkait dengan inefisiensi operasional yang dapat dikoreksi melalui kebijakan internal rumah sakit.
2. Kelima CBG ini merupakan *top-5* CBG dengan estimasi *excess cost* terbesar pada kelompok CBG ringan, dengan total mencapai Rp 128,73 juta atau sekitar 71,3% dari total estimasi *excess cost* pada keseluruhan klaster fokus *top-10* CBG (Rp 180,4 juta). Pemilihan berdasarkan kriteria *excess cost* memastikan bahwa penanganan klinis yang direkomendasikan akan menyasar titik defisit dengan *leverage* perbaikan tertinggi.
3. CBG K-1-13-I (Prosedur Apendik (Ringan)) yang juga tergolong kasus ringan dengan defisit besar tidak dapat dimasukkan dalam analisis komparatif karena tidak

memiliki kasus untung pembanding ($n_{\text{untung}} = 0$). Temuan bahwa seluruh kasus apendik mengalami defisit pada CBG ini sendiri merupakan sinyal struktural yang lebih tepat ditindaklanjuti melalui evaluasi kecukupan tarif paket.

4. CBG A-4-14-I yang juga tergolong kasus ringan dengan kesembuhan 100% tidak dimasukkan dalam Top-5 karena memiliki estimasi *excess cost* paling rendah pada klaster fokusnya (Rp 2,32 juta), sehingga *leverage* manajerial yang dapat diperoleh dari penanganan klinis pada CBG ini relatif kecil.

Selanjutnya, dari setiap CBG kandidat tersebut dipilih satu klaster fokus yang menjadi sasaran analisis komparatif. Kriteria pemilihan klaster fokus adalah klaster dengan rata-rata defisit per kasus paling besar pada CBG bersangkutan, dengan pertimbangan bahwa klaster inilah yang per-kasusnya menghasilkan beban defisit terbesar dan paling layak dijadikan target efisiensi. Kriteria ini dipilih sebagai pengganti kriteria "defisit total" karena defisit total dipengaruhi oleh ukuran klaster (n kasus), sehingga klaster bervolume besar dapat mendominasi temuan walaupun karakter inefisiensinya per-kasus relatif moderat. Dengan kriteria mean defisit, sinyal inefisiensi per-pasien lebih murni terisolasi.

Berdasarkan kriteria tersebut, klaster fokus yang terpilih pada masing-masing CBG adalah sebagai berikut. Pada CBG K-4-17-I, klaster 1 dipilih dengan mean defisit Rp 2,29 juta (terbesar dibanding K0 Rp 1,03 juta, K2 Rp 1,83 juta, dan K3 Rp 0,83 juta). Pada CBG A-4-13-I, klaster 2 dipilih dengan mean defisit Rp 2,59 juta (terbesar dibanding K0 Rp 0,62 juta, K1 Rp 1,72 juta, dan K3 Rp 0,95 juta). Pada CBG I-4-20-I yang hanya terbentuk menjadi dua klaster, klaster 0 dipilih dengan mean defisit sebesar Rp 3,47 juta, yang jauh lebih besar dibanding K1 yang hanya Rp 0,96 juta. Pada CBG M-1-80-I, klaster 1 dipilih dengan mean defisit Rp4,97 juta (terbesar dibanding K0 Rp 2,18 juta, K2 Rp 2,94 juta, dan K3 Rp 1,57 juta). Selanjutnya pada CBG O-6-10-I, klaster 1 dipilih dengan mean defisit Rp 1,37 juta. Pada CBG ini selisih mean defisit antar klaster relatif tipis (K0 dan K2 masing-masing Rp1,20 juta), namun Klaster 1 tetap memenuhi kriteria mean defisit terdalam dan juga menampung 71 kasus rugi yang merupakan jumlah substantif untuk dianalisis. Profil agregat klaster fokus pada kelima CBG dapat dilihat pada Tabel 4.14.

Tabel 4.14 Profil Klaster Fokus pada Top-5 CBG Kandidat

Kode CBG	Klaster Fokus	Rugi (n)	Untung (n)	Defisit Mean (Rp Jt)	LOS Mean (Hari)	Rasio LOS (R:U)
K-4-17-I	K1	80	25	2,29	4,35	1,70
A-4-13-I	K2	63	72	2,60	6,02	2,08
I-4-20-I	K0	99	9	3,48	4,39	1,32
M-1-80-I	K1	17	80	4,97	3,94	1,55
O-6-10-I	K1	71	10	1,38	3,86	1,54
Total		330	196			

Tabel 4.14 tersebut menunjukkan bahwa kelima klaster fokus secara akumulatif memuat 330 kasus rugi dan 196 kasus untung, sampel yang sangat memadai untuk dapat melakukan analisis komparatif statistik. Rasio LOS rugi terhadap untung pada kelimanya konsisten berada di atas satu (rentang 1,32 sampai 2,08 kali), yang mengindikasikan bahwa perpanjangan lama rawat merupakan salah satu mekanisme pembentuk defisit yang konsisten.

4.7.1 Analisis Gap Pola dan Intensitas Frekuensi Tindakan Medis

Pada tahap ini, analisis difokuskan pada profil tindakan medis yang membentuk gap antara klaster fokus pada kelompok rugi dan kelompok pasien untung di CBG yang sama. Profil tindakan diukur melalui dua indikator utama, yaitu prevalensi (proporsi pasien dalam kelompok yang menerima tindakan tersebut minimal sekali) dan *mean frequency* (rata-rata jumlah pemberian tindakan per-pasien dalam kelompok CBG). Kedua indikator ini memberikan gambaran yang saling melengkapi, dimana prevalensi bertujuan untuk memberikan pengetahuan mengenai "*seberapa luas tindakan ini diberikan?*", sedangkan *mean frequency* ditujukan untuk memberikan pengetahuan mengenai "*seberapa intens tindakan ini diberikan kepada pasien yang menerimanya?*". Gap kedua indikator antara kelompok rugi dan untung selanjutnya menjadi sinyal pola tindakan yang membedakan kedua kelompok. Hasil analisis pada lima tindakan dengan magnitude gap terbesar pada klaster fokus kelima CBG kandidat dapat dilihat pada Tabel 4.15.

Tabel 4.15 Top-5 Gap Pola dan Intensitas Frekuensi Tindakan Medis Klaster Fokus per-CBG

CBG / K	Nama	Gap Prev. (%)	Prev. Rugi (%)	Prev. Untung (%)	Gap Freq.	Mean Freq (R)	Mean Freq (U)
K-4-17-I / K1	Surflo OX 20	61	85	24	0.735	0.975	0.24
	Sput 10 cc_one med / DB	55	95	40	2.857	3.537	0.68
	Omeprazol inj 40mg/ vial	55	75	20	1.985	2.425	0.44
	Aqua P.I 25 ml inj	52.75	88.75	36	2.307	2.987	0.68
	Gelang Dewasa Kuning ID Band	49.50	57.50	8	0.507	0.587	0.08
A-4-13-I / K2	Surflo OX 22 / Abbocath 22	45.63	76.19	30.55	0.728	1.047	0.319
	Dexamethason inj 5mg/ ml	45.23	50.79	5.55	1.087	1.142	0.055
	Visite Dokter Spesialis	31.74	98.41	66.66	2.192	2.984	0.791
	Paket Dresing Dewasa	29.16	33.33	4.16	0.291	0.333	0.041
	Pasang Infus Anak	29.16	33.33	4.16	0.323	0.365	0.041
I-4-20-I / K0	Venax (fondaparinux 2,5 mg)	83.83	94.94	11.11	2.161	2.272	0.111
	Visite Dokter Spesialis ICU	73.73	73.73	0	1.161	1.161	0
	Injeksi intra Sub cutan	73.73	84.84	11.11	1.969	2.191	0.222
	Urobag 2000 ST (Urine Bag)	69.69	91.91	22.22	0.707	0.929	0.222
	Oksigenasi	66.66	77.77	11.11	0.787	0.898	0.111

M-1-80-I / K1	Arm Sling L (Gendongan Tangan) (*)	59.33	70.58	11.25	0.711	0.823	0.112
	Aqua P.I 25 ml inj	52.5	100	47.50	1.396	2.058	0.662
	Tensocrepe 4"	49.70	64.70	15	0.543	0.705	0.162
	Handscoon Gamex 8	45.36	94.11	48.75	0.453	0.941	0.487
	Sewa Alat Orthopedi	45	100	55	0.450	1	0.550
O-6-10-I / K1	D 5% OGB INF	74.50	84.50	10	0.773	0.873	0.1
	Obs. Ps. biasa / shift (VS, DJJ, Pembkan)	58.87	78.87	20	1.446	1.746	0.3
	Bledstop (Methylergometrine Maleate 125mcg)	56.05	76.05	20	0.602	0.802	0.2
	Handscoon Gamex 7	49.01	69.01	20	0.504	0.704	0.2
	Cuticell Clasic (SUFRATULE)/ CM	43.66	43.66	0	0.436	0.436	0

Hasil dari Tabel 4.15 mengungkap dua pola gap profil tindakan yang berbeda secara fundamental dan masing-masing menuntut strategi penanganan klinis yang berbeda. Pola pertama adalah gap intensitas pada tindakan yang sama-sama lazim diberikan pada kedua kelompok (prevalensi serupa, namun mean frequency berbeda nyata). Contoh paling representatif terlihat pada CBG A-4-13-I/K2, yaitu pada treatment *Visite Dokter Spesialis* yang hadir pada 98,4% pasien rugi dan 66,7% pasien untung, prevalensi sama-sama tinggi namun rata-rata pemberiannya 2,98 kali pada rugi dibanding 0,79 kali pada untung, dengan gap 2,19 kali pada paket tarif CBG yang identik. Pola serupa terlihat pada CBG K-4-17-I/K1 untuk *SPUIT 10 CC* (prevalensi 95% rugi vs 40% untung, namun mean frequency 3,54 kali vs 0,68 kali) dan *AQUA P.I 25 ML INJ* (mean frequency 2,99 kali vs 0,68 kali). Pola ini menunjukkan bahwa pasien rugi menerima intensitas pelayanan yang lebih tinggi pada komponen tindakan yang sama, bukan jenis tindakan yang berbeda.

Pola kedua adalah gap prevalensi pada tindakan yang sama sekali atau hampir tidak diberikan kepada kelompok untung, sehingga menunjukkan perbedaan keputusan klinis dalam pemilihan jenis tindakan. Contoh paling mencolok terlihat pada CBG I-4-20-I/K0, yaitu *VENAX* (fondaparinux 2,5 mg) yang hadir pada 94,9% pasien rugi tetapi hanya 11,1% pasien untung (gap 83,8 poin persentase), dan *Visite Dokter Spesialis ICU* yang hadir pada 73,7% pasien rugi vs 0% pada pasien untung. Pola serupa terlihat pada CBG O-6-10-I/K1 untuk *CUTICELL CLASIC* (43,7% rugi vs 0% untung) dan pada CBG M-1-80-I/K1 untuk komponen alat fiksasi ortopedi (akan didetailkan pada Tabel 4.18). Pola ini menunjukkan bahwa pada CBG dan klaster fokus tertentu, perbedaan defisit dibentuk bukan oleh intensitas pelayanan, melainkan oleh pemilihan jenis penanganan klinis tertentu yang absen pada kelompok untung.

Perbedaan kedua pola ini berimplikasi pada strategi penanganan klinis yang berbeda. Pola pertama (gap intensitas) lebih sesuai ditangani melalui standardisasi *clinical pathway* untuk mengendalikan frekuensi tindakan rutin, sedangkan pola kedua (gap prevalensi) lebih sesuai ditangani melalui evaluasi keputusan klinis dalam pemilihan jenis tindakan medis. Kedua pola ini bersama-sama membentuk dasar bagi analisis treatment cost yang akan dibahas pada tahap berikutnya.

4.7.2 Analisis Treatment Cost pada Top-5 Tindakan pada Klaster Fokus

Setelah profil tindakan dipetakan pada sub bab 4.7.1 diatas, langkah selanjutnya adalah mengkonversi gap tindakan tersebut menjadi estimasi biaya berlebih (*excess cost*) yang menggambarkan beban finansial dari perbedaan pola tindakan antara kelompok rugi dan untung pada CBG yang sama. Bentuk pertama adalah *excess cost unadjusted*, dengan formula $gap_unadjusted \times unit_cost \times n_rugi$, di mana *gap_unadjusted* adalah selisih *mean frequency* tindakan antara kelompok rugi dan untung pada CBG yang sama tanpa adanya koreksi tambahan. Nilai ini menggambarkan *magnitude raw* dari gap tindakan sebagaimana terobservasi langsung dari data. Bentuk kedua adalah *excess cost adjusted*, dengan formula $gap_adjusted \times unit_cost \times n_rugi$, di mana *gap_adjusted* adalah *gap_unadjusted* yang sudah dikoreksi terhadap *rasio LOS* dan *rasio severity case – mix* sebagaimana dirumuskan pada analisis cost driver sebelumnya. Koreksi case-mix ini penting, karena sebagian gap tindakan dapat dijelaskan secara legitimate oleh perbedaan LOS yang lebih panjang atau *severity* yang lebih tinggi pada kelompok rugi, sehingga tanpa koreksi *excess cost* akan menjadi *overestimate* dengan mengasumsikan seluruh gap merupakan inefisiensi yang dapat ditangani secara klinis. Estimasi *excess cost* untuk lima tindakan teratas pada klaster fokus kelima CBG kandidat dapat dilihat pada Tabel 4.16.

Tabel 4.16 Estimasi Excess Cost Top-5 Tindakan pada Kluster Fokus Top-5 CBG Kandidat

CBG / K	Nama	Jenis	Unit-Cost (Rp)	Excess Unadjusted (Rp)
K-4-17-I / K1	Injeksi per Shift	Tindakan	16,000	6,915,200
	Tindakan Balance Cairan	Tindakan	14,500	5,976,900
	Obs. pasien biasa per shift (infus & vs)	Tindakan	12,500	5,815,000
	USG Upper Lower Abdomen	Radiologi	267,000	4,806,000
	Tindakan Ganti Infus	Tindakan	9,000	2,813,400
A-4-13-I / K2	DL (MIDRAY) dengan Diff Tabung 2 ml	Lab	73,000	9,946,250
	Obs. pasien biasa per shift (infus & vs)	Tindakan	12,500	9,076,562
	Tindakan Balance Cairan	Tindakan	14,500	8,400,938
	Injeksi per Shift	Tindakan	16,000	8,016,000
	DL (MIDRAY) dengan DIFF tabung 0.5 ml	Lab	60,700	3,930,325
I-4-20-I / K0	Venax_fondaparinux inj 2.5 mg / 0.5ml	Item	232,406	49,734,884
	Diviti PFS 2.5 MG / 0.5 ML	Item	409,313	10,642,138
	Tindakan Balance Cairan	Tindakan	14,500	7,612,500
	Kholesterol Lengkap	Lab	250,000	5,750,000
	Personal Higienis	Tindakan	15,000	3,285,000

M-1-80-I / K1	Small T Plate 3.5mm 3Holes (AMSA)	Item	1,469,085	8,814,510
	Proximal Humerus Philos DCP 3Hole (AMSA)	Item	4,301,250	8,602,500
	2.0mm 3x8 T Plate Locking (OSTEOMED)	Item	4,620,375	4,620,375
	Sewa Alat Orthopedi	Tindakan	486,000	3,717,900
	Cortical Screw Self Tap 3.5mm L-16 (AMSA)	Item	270,563	1,893,941
O-6-10-I / K1	Pasang IUD	Tindakan	202,250	3,842,750
	Tindakan Balance Cairan	Tindakan	14,500	3,226,250
	Obs. pasien biasa per shift (infus & vs)	Tindakan	12,500	2,881,250
	Vaginal Toucher (VT)	Tindakan	41,250	2,516,250
	Asistensi Persalinan/Curretage	Tindakan	120,000	2,352,000

Tabel 4.16 mengungkap dua mekanisme pembentuk *excess cost* yang berbeda. Mekanisme pertama adalah defisit yang didorong oleh item dengan *unit-cost* tinggi meskipun gap frekuensinya relatif kecil. Pola ini paling jelas terlihat pada CBG M-1-80-I/K1: lima komponen alat fiksasi ortopedi (*SMALL T PLATE*, *PROXIMAL HUMERUS PHILOS*, *T PLATE LOCKING*, Sewa Alat Orthopedi, *CORTICAL SCREW*) dengan harga satuan Rp 270 ribu sampai Rp 4,6 juta dan gap frekuensi 0,06 hingga 0,45 menyumbang *excess cost unadjusted* sebesar Rp 27,6 juta pada hanya 17 kasus rugi. Pola serupa terlihat pada CBG I-4-20-I/K0 dengan *VENAX* (harga satuan Rp 232.406, gap frekuensi 2,16) yang menyumbang Rp 49,7 juta. Ciri khas mekanisme ini adalah *excess cost* terpusat pada satu atau beberapa item dengan harga tinggi yang absen pada kelompok untung.

Mekanisme kedua adalah defisit yang didorong oleh akumulasi tindakan dengan *unit-cost* rendah pada gap frekuensi besar. Pola ini terlihat pada CBG K-4-17-I/K1, A-4-13-I/K2, dan O-6-10-I/K1, di mana *Tindakan Balance Cairan* (Rp 14.500), *Injeksi per Shift* (Rp 16.000), dan *Observasi Pasien Biasa per Shift* (Rp 12.500) konsisten muncul di *Top-5 excess cost*. Pada CBG A-4-13-I/K2 misalnya, ketiga tindakan rutin ini secara akumulatif menyumbang Rp 25,5 juta dari *Top-5 excess cost unadjusted* yang mencapai Rp 39,4 juta. Sebaliknya, pada CBG I-4-20-I dan M-1-80-I, selisih relatif kecil.

Penanganan klinis yang sesuai untuk kedua mekanisme berbeda. Untuk mekanisme pertama, Penanganan klinis yang relevan adalah evaluasi pemilihan alat atau obat berdasarkan formularium rumah sakit, audit *value-based* terhadap alternatif yang tersedia, serta negosiasi tarif dengan distributor. Untuk mekanisme kedua, penanganan klinis yang relevan adalah standardisasi frekuensi tindakan rutin melalui *clinical pathway*, penyusunan *order set* lintas unit, serta audit utilisasi pada kasus dengan lama rawat inap yang panjang. Sasaran efisiensi bukan secara gambling "mengurangi layanan yang diperlukan", tetapi memperkecil variasi yang tidak memberikan nilai tambah klinis yang sebanding terhadap biaya.

Tabel 4.17 Ringkasan Total Estimasi Excess Cost per CBG Kandidat

Kode CBG	Klaster Fokus	Rugi (n)	Mean Defisit (Rp)	Excess Cost Unadjusted (Rp)	Excess Cost Adjusted (Rp)	Mekanisme Dominan (1/2)
I-4-20-I	0	99	3,479,958	109,542,812	105,625,702	Item dengan unit-cost tinggi (1)
M-1-80-I	1	17	4,971,917	66,323,313	53,276,483	Item dengan unit-cost tinggi (1)
K-4-17-I	1	80	2,298,934	62,687,632	34,885,928	Mixed (1+2)
O-6-10-I	1	71	1,379,852	43,223,810	22,286,578	Akumulasi frekuensi rutin (2)
A-4-13-I	2	63	2,598,208	61,356,564	15,079,559	Akumulasi frekuensi rutin (2)
Total		330		343,134,131	231,154,250	

Tabel 4.17 tersebut mengagregasi total estimasi *excess cost* untuk seluruh tindakan pada klaster fokus masing-masing CBG, ditampilkan dalam dua bentuk (*unadjusted* dan *adjusted*) sehingga dampak koreksi case-mix dapat dibandingkan langsung antar-CBG. Total *excess cost unadjusted* untuk kelima klaster fokus mencapai Rp 343,13 juta, yang setelah dikoreksi terhadap rasio LOS dan rasio *severity case-mix* turun menjadi Rp 231,15 juta. Selisih Rp 111,98 juta antara kedua angka tersebut menggambarkan bagian dari gap tindakan yang secara *legitimate* dapat dijelaskan oleh perbedaan *case-mix* (LOS yang lebih panjang dan *severity* yang lebih tinggi pada kelompok rugi), sehingga tidak dapat sepenuhnya diatribusikan kepada inefisiensi pola tindakan murni. Setelah koreksi, *ranking excess cost adjusted* digunakan sebagai dasar prioritas penanganan klinis adalah I-4-20-I (Rp 105,63

juta), M-1-80-I (Rp 53,28 juta), K-4-17-I (Rp 34,89 juta), O-6-10-I (Rp 22,29 juta), dan A-4-13-I (Rp 15,08 juta).

Pola selisih *unadjusted vs adjusted* antar-CBG mengungkap informasi penting tentang sumber gap. Pada CBG I-4-20-I/K0, selisih hanya Rp 3,92 juta (3,6% penurunan), mengindikasikan bahwa hampir seluruh *gap excess cost* merupakan inefisiensi pola tindakan murni yang tidak dapat dijelaskan oleh perbedaan LOS atau *severity*. Pada CBG M-1-80-I/K1, selisih moderat Rp 13,05 juta (19,7% penurunan), mengindikasikan dominasi inefisiensi pola tindakan dengan kontribusi *case-mix* yang terbatas. Sebaliknya, pada CBG K-4-17-I/K1, O-6-10-I/K1, dan A-4-13-I/K2, penurunan *unadjusted-adjusted* jauh lebih besar (44–75%), mengindikasikan bahwa proporsi signifikan dari *excess cost* mentah pada ketiga CBG ini dijelaskan oleh perbedaan *case-mix*. Pada CBG-CBG dengan penurunan besar ini, penanganan klinis pola tindakan murni hanya akan menangani sebagian gap, sisanya membutuhkan tinjauan yang lebih mendalam terhadap akurasi *case-mix scoring* dan kelengkapan dokumentasi *LOS-severity*.

Mekanisme dominan defisit per-CBG tergolong menjadi tiga kategori sebagaimana ditampilkan pada kolom Mekanisme Dominan. CBG I-4-20-I dan M-1-80-I tergolong dalam mekanisme 1, yaitu defisit yang didorong oleh item dengan *unit-cost* tinggi yang absen pada kelompok untung, sesuai dengan analisis pada sub bab 4.7.2. CBG O-6-10-I dan A-4-13-I tergolong dalam mekanisme 2, yaitu defisit yang didorong oleh akumulasi tindakan rutin dengan *unit-cost* rendah pada gap frekuensi yang besar. Sedangkan CBG K-4-17-I tergolong dalam mekanisme mixed (1+2), karena defisitnya dibentuk oleh kombinasi yang sebanding antara akumulasi tindakan rutin (*Injeksi per Shift, Tindakan Balance Cairan, Obs. Pasien Biasa per Shift*) dan pemilihan tindakan penunjang dengan *unit-cost* moderat hingga tinggi (*USG Upper Lower Abdomen* Rp 267.000, antibiotik *CEFTRIAXON*, dan *CEFIXIME*). Strategi penanganan klinis pada CBG dengan mekanisme mixed tersebut harus dipersiapkan secara dua-pronged, yaitu menggabungkan standarisasi *clinical pathway* untuk komponen rutin dengan audit kepatuhan pedoman diagnostik (terhadap utilisasi USG dan pemeriksaan penunjang) serta evaluasi pemilihan antibiotik empiris terhadap formularium dan pola resistensi setempat.

4.7.3 Temuan Pola Tindakan Medis Asimetris (Anomaly Candidate)

Selain analisis gap dan *excess cost, framework* LOAF juga mengidentifikasi pola tindakan asimetris yang secara metodologis dapat diklasifikasikan menjadi dua dimensi *anomaly* yang saling melengkapi. Dimensi pertama adalah *anomaly* statistik, yaitu tindakan yang muncul pada kelompok rugi dengan prevalensi tertentu tetapi sama sekali tidak muncul pada kelompok untung (prevalensi 0%) di CBG yang sama. Dimensi ini ditangkap secara otomatis oleh algoritma dengan filter *prevalence_pct_untung* = 0%, *prevalence_pct_rugi* $\geq$ 5%, dan *n_pasien_rugi* $\geq$ 3. Dimensi kedua adalah anomali semantik-klinis, yaitu tindakan yang secara klinis tidak terkait atau tidak berkaitan pada CBG bersangkutan, terlepas dari prevalensinya. Dimensi ini memerlukan penilaian ahli (*domain knowledge*) dan menjadi sinyal audit yang lebih kuat karena mengindikasikan kemungkinan kesalahan kode, salah input, atau variasi praktik yang menyimpang. Temuan anomali pada konteks ini bukan klaim kesalahan klinis. Terdapat setidaknya tiga kemungkinan penjelasan, yaitu (1) kebutuhan klinis yang sah akibat komplikasi atau komorbiditas yang belum tertangkap variabel control. (2) variasi praktik klinis antar pemberi layanan dan (3) variasi kelengkapan dokumentasi layanan. Posisi temuan adalah sebagai sinyal kandidat untuk audit lebih lanjut, bukan sebagai kesimpulan final.

Dimensi pertama, anomali statistik, *framework* LOAF mengidentifikasi total 388 temuan anomali statistik pada lintas seluruh *top-10* CBG. Distribusi temuan pada *top-5* CBG kandidat efisiensi adalah I-4-20-I/K0 (42 temuan), K-4-17-I/K1 (37), O-6-10-I/K1 (20), A-4-13-I (8) dan M-1-80-I (8) dengan total 115 temuan pada lima CBG fokus tersebut. Hasil analisis ini dapat dilihat pada Tabel 4.18.

Tabel 4.18 Anomaly Statistik (Prevalensi Untung = 0%) pada Klaster Fokus top-5 CBG

CBG / K	Tindakan	Jenis	Prev. Rugi (%)	n Pasien (R)	Mean Freq Rugi	Unit Cost (Rp)
K-4-17-I / K1	Ceftriaxon inj 1 gr	Item	46.25	37	1.737	6,251
	Cefixime 200mg kaps	Item	41.25	33	0.450	1,561
	Hyocine N Buthylbromide inj	Item	22.50	18	0.512	12,428
	USG Upper Lower Abdomen	Radiologi	22.50	18	0.225	267,000
	Levofloxacin Infus 5mg/ml (100 ml)	Item	16.25	13	0.475	23,588
A-4-13-I / K2	IgM/IgG Typhoid	Lab	17.46	11	0.174	103,800
	Lacto B Sach	Item	7.93	5	0.285	10,233
	Zink Syrup 20mg/5ml ASK	Item	7.93	5	0.079	4,206
	Paket Dresing Anak	Item	7.93	5	0.095	3,900
	USG Upper Lower Abdomen	Radiologi	7.93	5	0.079	267,000
I-4-20-I / K0	Visite Dokter Spesialis ICU	Tindakan	73.73	73	1.161	-
	Vulva Hygiene/toilet	Tindakan	62.62	62	1.070	15,000
	Atorvastatin Calcium 40mg	Item	53.53	53	1.828	5,550
	Ramipril 5mg tab	Item	36.36	36	1.111	194
	Vulva Higienis	Tindakan	35.35	35	0.424	10,000

M-1-80-I / K1	Cortical Screw Self Tap 3.5mm L-16 (AMSA)	Item	41.14	7	0.411	270,563
	Cortical Screw Self Tap 3.5mm L-14 (AMSA)	Item	41.14	7	0.411	270,563
	T-VIO 2-0 V8 90cm Tapercut 35mm (VCP 517H)	Item	35.29	6	0.411	122,100
	Small T Plate 3.5mm 3Holes (AMSA)	Item	35.29	6	0.352	1,469,085
	Cortical Screw Self Tap 3.5mm L-18 (AMSA)	Item	29.41	5	0.294	270,563
O-6-10-I / K1	Cuticell Clasic (SUFRATULE)/ CM	Item	43.66	31	0.436	265
	Vaginal Toucher (VT)	Tindakan	40.84	29	0.859	41,250
	Rectal/Vaginal Toucher/Suppositoria	Tindakan	30.98	22	0.492	10,000
	Pasang IUD	Tindakan	26.76	19	0.267	202,250
	Gastrul 200MG Tablet_misoprostol 200mg (cytotec)	Item	25.35	18	0.309	20,813

Tabel 4.18 menampilkan *top-5* tindakan dengan prevalensi untung 0% yang paling luas terdampak pada klaster fokus masing-masing CBG. Skala paling luas ditemukan pada CBG I-4-20-I/K0 (Angina Pectoris), di mana *Visite Dokter Spesialis ICU* hadir pada 73 pasien rugi (73,73%) dan *Vulva Hygiene/toilet* pada 62 pasien (62,62%), keduanya tindakan yang secara klinis tidak terkait dengan diagnosis kardiovaskular dan akan dialami sebagai kandidat audit pada Tabel 4.19. Pada CBG yang sama, *ATORVASTATIN CALCIUM 40 mg* dan *RAMIPRIL 5 mg* masing-masing muncul pada 53 dan 36 pasien rugi, keduanya merupakan obat *lipid-lowering* dan antihipertensi yang lazim diberikan pada pasien dengan komorbiditas kardiovaskular, sehingga kemunculan dengan prevalensi tinggi di kelompok rugi dapat mencerminkan komorbiditas yang sah atau variasi farmakoterapi.

Pada CBG O-6-10-I/K1 (Operasi Caesar), anomali paling luas adalah *CUTICELL CLASIC (SUFRATULE)* yang terdapat pada 31 pasien rugi (43,66%), diikuti oleh *Vaginal Toucher* pada 29 pasien (40,84%), *Rectal/Vaginal Toucher* pada 22 pasien (30,99%), Pasang IUD pada 19 pasien (26,76%), dan *GASTRUL 200 mg (misoprostol)* pada 18 pasien (25,35%). Pada CBG K-4-17-I/K1 (Gastroenteritis), pola anomali didominasi oleh antibiotik (*CEFTRIAXON INJ* pada 37 pasien dan *CEFIXIME* pada 33 pasien) dan tindakan penunjang (*USG Upper Lower Abdomen* pada 18 pasien, *HYOCINE N BUTHYLBROMIDE INJ* pada 18 pasien). *USG Abdomen* juga perlu mendapat perhatian khusus karena harga satuannya Rp 267.000 jauh di atas item lain pada klaster ini, sehingga kontribusinya terhadap *excess cost* tergolong signifikan meskipun prevalensinya hanya 22,5%.

Pada CBG M-1-80-I/K1 (Prosedur Anggota Tubuh Atas), kelima anomali statistik teratas seluruhnya merupakan komponen alat fiksasi ortopedi dari brand AMSA. Dua varian *CORTICAL SCREW SELF TAP* (L-14 dan L-16) muncul pada 7 pasien rugi masing-masing (41,18%), satu varian L-18 pada 5 pasien (29,41%), *T-VIO 2-0 suture* pada 6 pasien (35,29%), dan *SMALL T PLATE* pada 6 pasien dengan harga satuan Rp 1.469.085 per-unit.

Pada CBG A-4-13-I/K2 (Infeksi Viral), skala anomali paling kecil dengan total hanya 8 temuan, yaitu *IgM/IgG Typhoid* menjadi item tertinggi pada 11 pasien (17,46%) dan empat item lainnya berkisar 5–7 pasien (7,93%), termasuk *USG Upper Lower Abdomen* dengan unit cost Rp 267.000 yang juga muncul di sini meski prevalensinya rendah.

Perlu ditegaskan kembali bahwa anomali statistik di sini bukanlah klaim kesalahan klinis. Terdapat setidaknya tiga kemungkinan penjelasan yang sah, yaitu (1) kebutuhan klinis legitimate akibat komplikasi atau komorbiditas yang belum tertangkap variabel kontrol, (2) variasi praktik klinis antar pemberi layanan, dan (3) variasi kelengkapan dokumentasi

layanan. Temuan ini adalah sebagai sinyal kandidat untuk audit lanjutan, dan dimensi anomali semantik-klinis. Selanjutnya adalah dimensi kedua, analisis anomali semantik-klinis. Berbeda dengan *anomaly* statistik yang ditangkap algoritma secara otomatis, *anomaly* semantik memerlukan evaluasi *domain knowledge* untuk menilai apakah tindakan tertentu masuk akal atau terkait secara klinis pada CBG bersangkutan. Pada Tabel 4.19 ditampilkan kandidat anomali semantik yang teridentifikasi berdasarkan ketidaksesuaian antara karakter klinis CBG dengan jenis tindakan yang muncul pada kelompok rugi. Penilaian dan justifikasi akhir terhadap status *anomaly* tersebut tetap memerlukan audit klinis multidisiplin.

Tabel 4.19 Anomaly Semantik-Klinis (Kandidat Audit) pada Top-5 CBG

CBG / K	Anomali	Prev. Rugi (%)	Pasien Penerima (n)	Alasan
I-4-20-I / K0 (Angina Pektoris Ringan, mortalitas 0%, HAS_ICU 23,2%)	Visite Dokter Spesialis ICU	73,73	73	Visite ICU hadir pada 73 pasien rugi (73,7%), sementara variabel HAS_ICU pada klaster ini hanya tercatat di 23,2% kasus. Selisih ini mengindikasikan dua kemungkinan: (1) eskalasi perawatan yang tidak terdokumentasi pada variabel HAS_ICU, atau (2) ketidaksesuaian coding antara tindakan vs penggunaan unit perawatan. Audit medical records direkomendasikan.
	Vulva Hygiene/toilet	62,62	62	Tindakan obstetri-ginekologi pada CBG kardiovaskular. Tidak ada keterkaitan anatomis-klinis antara Vulva Hygiene dan Angina Pektoris. Pola ini menjadi indikasi kandidat kuat kesalahan coding/template input pada sistem e-klaim.
O-6-10-I / K1 (Operasi Caesar Ringan, kesembuhan 100%, ICU 0%)	CUTICELL CLASIC (SUFRATULE)/ CM	43,66	31	Sufratule (paraffin-impregnated dressing) lazim digunakan untuk luka bakar atau luka kronis non-healing. Akan tetapi dengan prevalensi 43,7% pada kelompok rugi vs 0% pada kelompok untung mengindikasikan variasi praktik dressing operasi yang perlu dievaluasi terhadap pedoman standar.

	Pasang IUD	26,76	19	Pemasangan IUD bukan tindakan rutin dalam paket sectio caesarea. Kemunculan pada 26,8% kasus rugi mengindikasikan permintaan kontrasepsi pasca-persalinan yang berpotensi dapat diklaim terpisah dari paket caesar, atau perlu klarifikasi cakupan tindakan IUD dalam paket INA-CBG O-6-10-I.
K-4-17-I / K1 (Gastroenteritis Ringan, mortalitas 0%, ICU 0%)	USG Upper Lower Abdomen	22,50	18	Pemeriksaan USG Abdomen tidak selalu termasuk dalam standar diagnosis penatalaksanaan gastroenteritis ringan dengan <i>outcome</i> yang baik. Bersamaan dengan tingginya prevalensi CEFTRIAXON dan CEFIXIME pada klaster ini Tabel 4.18, pola ini perlu diaudit terhadap indikasi medis aktual dan kepatuhan terhadap <i>clinical pathway</i> gastroenteritis ringan.
M-1-80-I / K1 (Prosedur Anggota Tubuh Atas Ringan, mortalitas 0%, ICU 0%)	Konsentrasi implant brand AMSA (multi-varian eksklusif kelompok rugi)	41,18 (tertinggi)	7	7 dari 8 (88%) anomali statistik pada klaster ini berasal dari brand AMSA, dengan total 27 varian implant berbeda (<i>CORTICAL SCREW SELF TAP, CANCELLOUS SCREW, T PLATE, RECONSTRUCTION PLATE, PROXIMAL HUMERUS PHILOS</i> , dan <i>T-VIO suture</i>) yang muncul eksklusif pada kelompok rugi. Pada CBG <i>severity</i> I (ringan), konsentrasi brand- <i>exclusive</i> multi-varian ini mengindikasikan dua kemungkinan: (1) kompleksitas fraktur aktual yang melebihi <i>severity assignment</i> , sehingga <i>case-mix scoring</i> perlu ditinjau ulang; atau (2) variasi pemilihan brand premium tanpa evaluasi <i>value-based</i> terhadap brand alternatif.

Lintas-CBG (I-4-20-I/K0, K-4-17-I/K1, M-1-80-I/K0, O-6-10-I)	Vulva Hygiene/toilet	Mean 22,6 (max 62,6)	104 pasien di lintas 4 CBG	Total 104 pasien lintas empat CBG non-obstetri menerima Vulva Hygiene/toilet. Pola lintas-CBG yang konsisten ini bukan masalah kasus individual, melainkan mengindikasikan kemungkinan masalah sistem <i>coding</i> atau <i>template input</i> pada level rumah sakit. Audit sistem informasi e-klaim direkomendasikan sebagai prioritas tertinggi karena potensi dampaknya pada akurasi data klaim secara menyeluruh.
--	----------------------	-------------------------------	----------------------------------	--

Tabel 4.19 mengungkap pola anomali yang sangat penting untuk ditindaklanjuti pada level kebijakan rumah sakit. Temuan paling mencolok adalah *Vulva Hygiene/toilet* yang muncul pada 104 pasien lintas empat CBG (I-4-20-I, K-4-17-I, M-1-80-I, dan O-6-10-I), termasuk dengan prevalensi 62,6% pada CBG I-4-20-I (Angina Pectoris). Secara klinis, tindakan obstetri-ginekologi ini tidak terkait dengan area anatomis CBG kardiovaskular, gastrointestinal, maupun prosedur anggota tubuh atas. Pola lintas-CBG yang konsisten ini menunjukkan kemungkinan adanya masalah sistem *coding* atau *template input* yang perlu ditinjau pada tingkat kebijakan rumah sakit, bukan sekadar pada level kasus individual.

Temuan kedua yang signifikan adalah *Visite Dokter Spesialis ICU* pada CBG I-4-20-I (Angina Pectoris Ringan) dengan prevalensi 73,7%. Pada kluster fokus ini, mortalitas tercatat 0% dan variabel HAS_ICU hanya menandai 23,2% kasus sebagai pengguna ICU formal. Selisih antara prevalensi visite ICU (73,7%) dan prevalensi HAS_ICU (23,2%) sebesar 50 poin persentase mengindikasikan dua kemungkinan, yaitu (1) terjadi eskalasi perawatan yang tidak terdokumentasi pada variabel HAS_ICU, atau (2) terdapat ketidaksesuaian antara coding tindakan dan *coding* penggunaan unit perawatan. Kedua kemungkinan ini berimplikasi pada akurasi data klaim secara menyeluruh dan perlu dirujuk ke unit medical records untuk audit lebih lanjut. Pola serupa juga muncul pada CBG severity berat (N-1-12-II dan N-4-10-III) dengan total 105 pasien dengan visite ICU lintas seluruh CBG, yang memerlukan analisis terpisah.

Temuan ketiga, pada CBG O-6-10-I (Operasi Caesar Ringan), dua tindakan menjadi kandidat audit yang khas, yaitu *CUTICELL CLASIC (SUFRATULE)* yang lazim digunakan untuk luka bakar atau luka kronis muncul pada 43,7% kasus rugi, dan Pasang IUD pada 26,8% kasus rugi. Untuk CUTICELL, audit yang relevan adalah evaluasi kebijakan dressing pasca-insisi caesar terhadap pedoman standar. Untuk Pasang IUD, audit yang relevan adalah klarifikasi cakupan paket sectio caesarea, apakah pemasangan IUD pasca-persalinan termasuk dalam paket atau dapat diklaim terpisah. Pada CBG K-4-17-I, kemunculan *USG Upper Lower Abdomen* pada 22,5% kasus gastroenteritis ringan dengan *outcome* baik juga layak diaudit terhadap kepatuhan *clinical pathway*.

Temuan keempat ditemukan pada CBG M-1-80-I/K1 (Prosedur Anggota Tubuh Atas) dengan pola yang berbeda secara semantik dari ketiga temuan sebelumnya. Pada CBG ini, seluruh lima anomali statistik teratas merupakan komponen ortopedi yang secara klinis *appropriate* untuk paket tindakan, sehingga tidak ada tindakan yang "tidak terkait area anatomis" sebagaimana pola pada I-4-20-I atau O-6-10-I. Justru yang menjadi flag semantik

adalah dimensi yang berbeda, yaitu konsentrasi brand. 7 dari 8 (88%) anomali statistik pada kluster ini berasal dari *brand AMSA*, dan analisis pada keseluruhan dataset menunjukkan ada 27 varian *implant AMSA* yang muncul secara eksklusif pada kelompok rugi (prevalensi untung 0%), mulai dari *CORTICAL SCREW SELF TAP* dengan berbagai panjang (*L-14* hingga *L-20*), *CANCELLOUS SCREW* (*L-16* hingga *L-40*), hingga komponen kompleks seperti *PROXIMAL HUMERUS PHILOS DCP* dengan harga satuan Rp 4,3 juta. Pada CBG yang diklasifikasikan sebagai *severity* I (ringan), penggunaan kombinasi *multi-implant* yang demikian luas menjadi kandidat audit untuk dua hal: (1) *review* akurasi *case-mix scoring*, apakah kasus-kasus dengan *multi-implant pattern* semestinya diklasifikasikan sebagai *severity* yang lebih tinggi, dan (2) evaluasi *value-based* terhadap pemilihan brand, apakah terdapat brand alternatif yang memberikan *outcome* klinis setara, namun dengan harga yang lebih efisien. Total kontribusi *brand AMSA* terhadap *excess cost unadjusted* CBG M-1-80-I/K1 mencapai Rp 41,93 juta, atau sekitar 63% dari total *excess cost* CBG ini, sehingga audit pada dimensi pemilihan brand memberikan *leverage* perbaikan yang substantif.

Pembedaan kedua dimensi anomali ini bermakna secara strategis. Anomali statistik (Tabel 4.18) memberikan gambaran kuantitatif tentang seberapa luas perbedaan keputusan klinis antara kelompok rugi dan untung, sehingga lebih cocok sebagai dasar diskusi tentang variasi praktik. Sementara itu, anomali semantik (Tabel 4.19) memberikan flag yang lebih spesifik untuk audit kesalahan *coding*, kepatuhan *clinical pathway*, atau kejelasan cakupan paket tarif, sehingga lebih cocok sebagai dasar *review* sistem informasi e-klaim dan tata kelola dokumentasi. Saran tindak lanjut yang ideal adalah diadakannya forum audit multidisiplin yang melibatkan klinisi, tim *case-mix*, keuangan, dan unit mutu rumah sakit, untuk mengevaluasi setiap kandidat anomali dan memutuskan apakah itu kebutuhan klinis yang sah, variasi praktik yang perlu distandardisasi, persoalan dokumentasi yang perlu diperbaiki, atau persoalan sistem *coding* yang perlu ditinjau pada *level* kebijakan.

4.8 Simpulan Hasil Analisis Komparatif

Hasil keseluruhan analisis komparatif pada *top-5* CBG kandidat efisiensi memperlihatkan bahwa perbedaan defisit pada kasus CBG yang sama dibentuk oleh kombinasi dari empat elemen, yaitu perpanjangan lama rawat (LOS), eskalasi intensitas tindakan keperawatan rutin, peningkatan pemeriksaan penunjang dan kemunculan item dengan *unit-cost* tinggi yang asimetris antara kasus rugi dan untung. Total estimasi *excess cost* yang teridentifikasi pada kelima CBG ini mencapai Rp 231,15 juta (*adjusted*), yang berasal dari 330 kasus rugi pada lima kluster fokus.

Mekanisme defisit yang berhasil disingkap oleh *framework* LOAF ini bersifat ganda dan saling melengkapi. Mekanisme pertama, yaitu defisit yang didorong oleh item dengan *unit-cost* tinggi, dominan pada CBG M-1-80-I (item ortopedi) dan I-4-20-I (item antikoagulan). Mekanisme kedua, yaitu defisit yang didorong oleh akumulasi frekuensi tindakan rutin, dominan pada CBG K-4-17-I, A-4-13-I, dan O-6-10-I. Karena perbandingan dilakukan dalam paket tarif yang identik dan tingkat mortalitas pada seluruh kluster fokus adalah 0%, kedua mekanisme ini dapat diatribusikan secara sah kepada perbedaan pola tindakan medis, bukan kepada perbedaan diagnosis, tarif paket, atau kompleksitas klinis terminal.

Dengan demikian, kerangka LOAF yang diusulkan dalam penelitian ini terbukti mampu mengidentifikasi karakteristik kelompok pasien dan pola tindakan yang terkait dengan defisit klaim, baik dari dimensi frekuensi, kombinasi tindakan, maupun beban biaya, sehingga menjawab rumusan masalah penelitian secara komprehensif.

4.9 Implikasi dan Kontribusi Penelitian

Hasil penelitian ini memiliki implikasi strategis pada tiga level sekaligus, yaitu klinis, manajerial, dan akademik.

Pada level klinis, *framework* LOAF yang diusulkan memberikan cara membaca baru bahwa diagnosis yang sama, bahkan paket tarif CBG yang identik tidak selalu menghasilkan profil biaya yang sama. Perbedaan intensitas tindakan, pemilihan alat atau obat, dan dinamika episode rawat terbukti berperan besar dalam membentuk defisit, bahkan pada kasus dengan *outcome* klinis yang baik sekalipun (mortalitas 0%). Konsekuensinya, evaluasi mutu-biaya perlu dilakukan mulai dari pendekatan berbasis label diagnosis sampai dengan pendekatan berbasis pola layanan aktual. Selain itu, temuan tingkat mortalitas 61% pada CBG J-1-20-III (yang sengaja dikeluarkan dari *top-5* kandidat efisiensi) mengindikasikan perlunya tinjauan klinis-aktuarial khusus pada paket-paket CBG dengan *severity level* berat, yang besar kemungkinannya merefleksikan ketidakcukupan tarif paket terhadap kasus-kasus dengan kompleksitas tinggi.

Pada level manajerial, kontribusi utama *framework* LOAF yang diusulkan dalam penelitian ini adalah kemampuan memetakan prioritas penanganan klinis secara terstruktur dan bertingkat. Pada Top-5 CBG kandidat efisiensi yang dianalisis, penanganan klinis dapat dirumuskan secara spesifik per mekanisme defisit. Untuk mekanisme defisit yang didorong oleh item dengan *unit-cost* tinggi (CBG M-1-80-I dan I-4-20-I), rekomendasi penanganan klinis meliputi penyusunan standar pemilihan alat dan obat berdasarkan formularium rumah

sakit, evaluasi *value-based* terhadap alternatif yang tersedia, serta audit pemilihan brand atau spesifikasi alat ortopedi. Untuk mekanisme defisit yang didorong oleh akumulasi frekuensi tindakan rutin (CBG K-4-17-I, A-4-13-I, dan O-6-10-I), rekomendasi penanganan klinisnya meliputi standarisasi *clinical pathway* untuk tindakan keperawatan berulang, penyusunan *order set* yang disepakati lintas-unit, serta audit utilisasi tindakan rutin pada kasus pasien dengan lama rawat inap yang panjang. Sasaran efisiensi bukan "mengurangi layanan yang diperlukan", tetapi memperkecil variasi yang tidak memberikan nilai tambah klinis yang sebanding terhadap biaya. Untuk CBG kasus berat yang tidak masuk dalam jalur analisis komparatif (J-1-20-III, N-1-12-II, N-4-10-III), rekomendasi penanganan klinisnya berbeda secara fundamental. Tinjauan ulang yang bersifat klinis-aktuarial mengenai kecukupan tarif paket lebih sesuai untuk kelompok ini, bersamaan dengan pengkajian ulang standar penanganan kasus terminal dan koordinasi dengan BPJS Kesehatan terkait penyesuaian *case-mix score* pada paket-paket dengan mortalitas tinggi.

Pada level metodologis, penelitian ini berkontribusi melalui integrasi beberapa komponen analitik dalam satu alur yang operasional. Komponen-komponen tersebut meliputi stratifikasi berbasis CBG, klastering K-Means per-kelompok, justifikasi empiris pemilihan komponen PCA, benchmark algoritma, uji robustness antar-model, uji stabilitas bootstrap, uji signifikansi statistik antar klaster dengan koreksi FDR, serta analisis komparatif kasus rugi-vs-untung pada paket tarif CBG identik. Integrasi ini menjadikan *framework* LOAF dapat diterapkan dalam siklus manajemen layanan rumah sakit. Berbeda dari pendekatan klastering global yang lazim, prinsip stratifikasi per-CBG memberikan jaminan metodologis bahwa setiap perbedaan antar klaster maupun setiap gap antara kelompok rugi dan untung dapat diatribusikan secara sah kepada perbedaan pola tindakan medis, dan bukan kepada perbedaan diagnosis atau tarif paket CBG.

Secara teoretis, penelitian ini memperkaya literatur analitik pembiayaan kesehatan dengan menempatkan *loss concentration* sebagai unit analisis utama, dan memperkenalkan perbedaan antara dua mekanisme pembentuk defisit (kompleksitas klinis terminal vs inefisiensi operasional) sebagai kategori analitik baru yang berimplikasi pada strategi penanganan klinis yang berbeda. Pendekatan ini melengkapi studi biaya yang selama ini cenderung menekankan rerata populasi tanpa segmentasi eksplisit terhadap kelompok rugi. Dengan kata lain, kontribusi *framework* LOAF yang penelitian ini usulkan adalah mengubah data klaim dari sekadar laporan retrospektif menjadi instrumen pengambilan keputusan prospektif. Apabila diimplementasikan secara berkelanjutan, *framework* LOAF ini berpotensi menjadi pondasi *early warning system* defisit klaim rumah sakit dengan

kemampuan mendeteksi pola yang berubah, memicu audit tepat sasaran, dan mendukung perbaikan layanan yang tetap menjaga mutu klinis sambil memperbaiki keberlanjutan finansial institusi.

BAB 5

Kesimpulan dan Saran

5.1 Kesimpulan

Penelitian ini berhasil mengembangkan *framework Loss-Oriented Analytical Framework (LOAF)* yang dapat mengidentifikasi karakteristik kelompok pasien dan pola tindakan medis penyebab defisit klaim INA-CBG, melalui klastering K-Means yang distratifikasi per-CBG. Dari 9.789 episode rawat inap, 61,48% tercatat defisit dengan total kerugian Rp 15,56 miliar, yang terkonsentrasi pada sejumlah kecil CBG prioritas dan berhasil dipecah menjadi 35 klaster yang telah melalui lima lapis validasi (justifikasi PCA, *benchmark* algoritma, uji *robustness*, stabilitas *bootstrap*, dan uji *Mann-Whitney U*), dengan struktur klaster yang terbukti stabil dan diskriminatif.

Temuan utama menunjukkan bahwa defisit terbentuk dari dua mekanisme fundamental berbeda, yaitu kompleksitas klinis terminal pada CBG kasus berat, dan inefisiensi operasional pada CBG kasus ringan, dimana masing-masing mekanisme tersebut menuntut strategi penanganan klinis berbeda. Pada lima CBG kandidat efisiensi, hasil analisis komparatif (rugi-vs-untung) telah berhasil mengidentifikasi estimasi *excess cost* terkoreksi oleh *severity* sebesar Rp 231,15 juta dari 330 kasus rugi, yang terbentuk dari kombinasi perpanjangan lama rawat, eskalasi tindakan rutin, dan kemunculan item dengan *unit-cost* tinggi yang asimetris (*anomaly*). Dengan demikian, framework LOAF terbukti mampu menerjemahkan data klaim retrospektif menjadi instrumen analisis prospektif yang spesifik, terkuantifikasi, dan *actionable*, sekaligus menjawab rumusan masalah dan tujuan penelitian secara komprehensif.

5.2 Saran

Berdasarkan kesimpulan tersebut, dapat dirumuskan saran-saran bagi tiga pihak pemangku kepentingan dan untuk penelitian lanjutan sebagai berikut.

5.2.1 Saran bagi Manajemen Rumah Sakit

Bagi manajemen rumah sakit yang menjadi konteks dalam penelitian ini, terdapat beberapa rekomendasi tindak lanjut yang disusun berdasarkan dua mekanisme defisit yang teridentifikasi.

1. Pada CBG kasus ringan kandidat efisiensi, manajemen disarankan menyusun atau menyempurnakan *clinical pathway* untuk standarisasi tindakan keperawatan rutin (Balance Cairan, Injeksi per Shift, Ganti Infus) dan pemeriksaan penunjang (USG Abdomen, DL dengan Diferensial). Standarisasi ini bertujuan memperkecil variasi frekuensi tindakan antar pasien dengan paket CBG yang sama, sehingga frekuensi tindakan tetap proporsional terhadap indikasi klinis aktual.
2. Terkait mekanisme defisit yang didorong oleh item dengan *unit-cost* tinggi (terutama pada CBG M-1-80-I dan I-4-20-I), disarankan untuk menyusun standar pemilihan alat dan obat berbasis formularium rumah sakit dengan pertimbangan *value-based*. Audit pemilihan *brand* dan spesifikasi alat ortopedi serta antikoagulan perlu dilakukan secara berkala untuk memastikan keputusan klinis tetap selaras dengan mutu dan keberlanjutan finansial.
3. Pada CBG kasus berat dengan mortalitas tinggi (J-1-20-III, N-1-12-II, N-4-10-III), manajemen disarankan melakukan tinjauan klinis-aktuarial khusus terkait kecukupan tarif paket. Koordinasi dengan pihak BPJS Kesehatan untuk mempertimbangkan penyesuaian *case-mix score* atau penambahan komponen *exceptional payment* pada paket-paket dengan mortalitas tinggi dapat menjadi solusi struktural.
4. Terkait hasil analisis asimetri (*anomaly candidate*) yang ditemukan pada *top-5* CBG kandidat, sebaiknya ditindaklanjuti dalam forum audit multidisiplin yang melibatkan klinisi, tim *case-mix*, keuangan, dan unit mutu. Temuan ini adalah dasar untuk penelusuran lebih lanjut, bukan sebagai kesimpulan final.
5. Untuk implementasi yang berkelanjutan, manajemen disarankan mengoperasionalkan *framework* LOAF sebagai *early warning system* defisit klaim yang dijalankan secara periodik (bulanan atau triwulanan), sehingga pola defisit dapat dideteksi sejak dini dan tindakan korektif dapat dilakukan sebelum kerugian terakumulasi.

5.2.2 Saran bagi BPJS Kesehatan dan Regulator

Bagi BPJS Kesehatan sebagai penyelenggara skema klaim INA-CBG dan *regulator* pembiayaan kesehatan, beberapa rekomendasi dapat diajukan berdasarkan temuan penelitian.

1. Temuan bahwa CBG K-1-13-I (Prosedur Apendik Ringan) mengalami defisit pada seluruh 150 kasusnya tanpa ada satu pun kasus untung mengindikasikan adanya persoalan struktural pada penetapan tarif paket. Disarankan dilakukan kajian ulang terhadap struktur tarif INA-CBG untuk paket-paket dengan *diagnosis* yang serupa.
2. Temuan mortalitas 61% pada CBG J-1-20-III mengindikasikan bahwa paket-paket *diagnosis* dengan kompleksitas terminal kemungkinan tidak sepenuhnya terakomodasi oleh tarif paket standar. Pertimbangan untuk pengenalan mekanisme *exceptional payment* atau penyesuaian *case-mix score* pada paket-paket dengan tingkat mortalitas tinggi perlu dipertimbangkan.
3. *Framework* LOAF yang dikembangkan dalam penelitian ini dapat dijadikan referensi metodologis bagi BPJS Kesehatan dalam melakukan evaluasi periodik terhadap distribusi defisit lintas rumah sakit, sehingga kebijakan penyesuaian tarif dapat didasarkan pada bukti empiris.

5.2.3 Saran bagi Penelitian Lanjutan

Bagi peneliti yang akan melanjutkan pengembangan *framework* analitik ini, ada beberapa arah penelitian lanjutan dapat ditempuh.

1. Replikasi *framework* LOAF pada data rumah sakit lain dengan karakteristik berbeda (tipe rumah sakit, lokasi geografis, profil pasien) untuk menguji generalisasi temuan. Penelitian multi-institusi akan memperkuat validitas eksternal kerangka.
2. Perluasan periode data pengamatan dari satu tahun menjadi multi-tahun untuk menguji ketegaran pola defisit terhadap variasi musiman, perubahan kebijakan tarif, dan dinamika *case-mix* secara *longitudinal*.
3. Pengintegrasian *framework* LOAF dengan analisis prediktif (misalnya *survival analysis* untuk LOS atau *gradient boosting* untuk prediksi defisit pada level pasien individu) untuk mengubah pendekatan dari retrospektif menjadi *prospective real-time monitoring*.
4. Eksplorasi metode klustering alternatif yang dapat menangani data berdimensi sangat tinggi tanpa reduksi PCA untuk menguji apakah hasil dapat ditingkatkan dengan pendekatan yang lebih modern. Meskipun *benchmark* pada penelitian ini menunjukkan K-Means unggul dengan konfigurasi PCA dua komponen, eksplorasi metode alternatif dapat memperkaya pembandingan metodologis.
5. Pengembangan model evaluasi yang menggabungkan dimensi mutu klinis (*patient safety indicators, clinical outcome*) dengan dimensi efisiensi finansial, sehingga

rekomendasi penanganan klinisnya tidak hanya berdasarkan minimisasi biaya tetapi juga peningkatan mutu pelayanan secara holistik.

6. Melakukan kajian khusus terhadap CBG dengan defisit pada seluruh kasusnya (seperti K-1-13-I pada penelitian ini) untuk menelaah lebih dalam lagi mengenai apakah persoalannya bersifat struktural pada tarif paket atau terkait dengan pola praktik klinis lokal yang dapat dikoreksi.
7. Evaluasi efektivitas implementasi rekomendasi LOAF melalui penelitian penanganan klinis (*before-after study* atau *interrupted time series*), untuk mengukur seberapa besar pengurangan defisit yang dapat dicapai setelah penerapan *clinical pathway* dan standar pemilihan alat berdasarkan temuan *framework* ini.

Daftar Pustaka

- Adha, R., Nurhaliza, N., & Soleha, U. (2021). *Perbandingan Algoritma DBSCAN dan K-Means Clustering untuk Pengelompokan Kasus Covid-19 di Dunia*. 18(2).
- Afrina, E., Cut, D., Aidha, N., Ramdhaningrum, H., Wahyudi, D., Silvia, K., Fanggidae, J., Dwi, H., Ningrum, R., Thaariq, R. M., Kartika, W., & Chrisnahutama, A. (2020). *Defisit Jaminan Kesehatan Nasional (JKN): Mengapa dan Bagaimana Mengatasinya?*
- Aggarwal, C. C., Hinneburg, A., & Keim, D. A. (2001). On the Surprising Behavior of Distance Metrics in High Dimensional Space. *8th International Conference on Database Theory (ICDT 2001)*. https://doi.org/10.1007/3-540-44503-X_27
- Ahmad, Z. G., Salsabila, L. N., Febriani, D., & Gurning, F. P. (2023). *ANALISIS DEFISIT JAMINAN KESEHATAN NASIONAL (JKN) DIKOTA MEDAN: SEBAB, DAMPAK, DAN SOLUSI*.
- Akbar, E. (2023). *Perbandingan Algoritma DBSCAN - K-Means dan K-Means untuk Pengelompokan Madrasah Aliyah Provinsi Jawa Timur* [PhD Thesis, Universitas Islam Negeri Syarif Hidayatullah].
<https://repository.uinjkt.ac.id/dspace/handle/123456789/68812>
- Akheel, S. A. (2019). Understanding Learning Styles for Adaptive Learning Systems Using K-Means Clustering. *IJFMR: International Jurnal for Multidisciplinary Research*, 1(3). <https://doi.org/10.36948/ijfmr.2019.v01i03.10061>
- Al-Hasani, L. E., Perez, G., Herndon, H. N., Park, J., Poole, J. L., Tien, I., Washburn, N. R., Cho, Y. K., Gentry, T. R., & Kurtis, K. E. (2023). Prediction of heat of hydration of cementitious systems using Gaussian process regression enables mass concrete thermal modeling. *Materials and Structures*, 56(2), 45.
<https://doi.org/10.1617/s11527-023-02134-8>

Ali, A., Masyfufah, L., DrSoetomo, S. Y. R. S., & Kunci, K. (2021). *KLASTERISASI PASIEN BPJS DENGAN METODE K-MEANS CLUSTERING GUNA MENUNJANG PROGRAM JAMINAN KESEHATAN NASIONAL DI RUMAH SAKIT ANWAR MEDIKA BALONG BENDO SIDOARJO CLUSTERING BPJS'S INPATIENTS BY USING K-MEANS CLUSTERING METHOD TO SUPPORT THE NATIONAL HEALTH INSURANCE PROGRAM AT ANWAR MEDIKA HOSPITAL BALONG BENDO SIDOARJO.*

Aljohani, A. (2024). Optimizing Patient Stratification in Healthcare: A Comparative Analysis of Clustering Algorithms for EHR Data. *International Journal of Computational Intelligence Systems*, 17(1). <https://doi.org/10.1007/s44196-024-00568-8>

Almaripat, M., Faqih, A., & Rinaldy, A. R. (2025). Sales Data Classterization Analysis Using K-Means Method for Marketing Strategy Development. *JAIEA: Jurnal of Artificial and Engineering Application*, 4(2). <https://doi.org/10.59934/jaiea.v4i2.792>

Amalia, R., Lestari, S., Ferdianto, A., Akbar, P. S., & Fardilan, N. (2023). Determinan Pengembalian Berkas Klaim Berdasarkan Akurasi Kode Diagnosis Pasien Rawat Inap BPJS Kesehatan di RSI Sultan Agung Semarang). *Jurnal Rekam Medis Dan Informasi Kesehatan*, 6(2). <https://doi.org/10.31983/jrmik.v6i2.10633>

An, Q., Rahman, S., Zhou, J., & Kang, J. J. (2023a). A Comprehensive Review on Machine Learning in Healthcare Industry: Classification, Restrictions, Opportunities and Challenges. *Sensors*, 23(9), 4178. <https://doi.org/10.3390/s23094178>

An, Q., Rahman, S., Zhou, J., & Kang, J. J. (2023b, May). A Comprehensive Review on Machine Learning in Healthcare Industry: Classification, Restrictions,

- Opportunities and Challenges. In *Sensors* (Vol. 23, Issue 9). MDPI.
<https://doi.org/10.3390/s23094178>
- Ananda, M. D., Malik, K. N., & Masruriyah, A. F. N. (2025a). Studi Komparatif Algoritma K-Means dan K-Medoids untuk Segmentasi Informasi Kesehatan. In *Computer Science (CO-SCIENCE)* (Vol. 5, Issue 2).
<http://jurnal.bsi.ac.id/index.php/co-science>
- Ananda, M. D., Malik, K. N., & Masruriyah, A. F. N. (2025b). Studi Komparatif Algoritma K-Means dan K-Medoids untuk Segmentasi Informasi Kesehatan. *Computer Science (CO-SCIENCE)*, 5(2).
<https://doi.org/10.31294/coscience.v5i2.9207>
- Andirasdini, I. G., Saputra, D., Rivai, M., Eka, S., & Putra, M. (2025). Analysis of the Health Social Security Administration (BPJS Kesehatan) Claim Amount using Random Forest Regression. In *IAJ Indonesian Actuarial Journal Persatuan Aktuaris Indonesia (PAI)* (Vol. 01, Issue 01).
- Andirasdini, I. G., Saputra, D., Rivai, M., & Putra, S. E. M. (2025). Analysis of the Health Social Security Administration (BPJS Kesehatan) Claim Amount using Random Forest Regression. *IAJ Indonesian Actuarial Journal Persatuan Aktuaris Indonesia (PAI)*, 01(01). <https://doi.org/https://doi.org/10.65689/iajvol01no1pp001-008>
- Ardiansyah, F., Hamdan, F., Sugiyanto, S., & Siadi, I. W. (2022). Klasifikasi Customer Relationship Management Menggunakan Dataset KDD Cup 2009 dengan Teknik Reduksi Dimensi. *Komputika : Jurnal Sistem Komputer*, 11(2), 193–202.
<https://doi.org/10.34010/komputika.v11i2.6498>
- Arfiani, M., Fahlevi, H., & Zuraida, . (2020). Cost Recovery Rate dan Pengendalian Biaya di Rumah Sakit: Studi kasus pada Rumah Sakit Pemerintah. *Jurnal ASET (Akuntansi Riset)*, 12(2), 372–383. <https://doi.org/10.17509/jaset.v12i2.26317>

- Arifuddin, D., Kusrini, K., & Kusnawi, K. (2025). Perbandingan Performansi Algoritma Multiple Linear Regression dan Multi Layer Perceptron Neural Network dalam Memprediksi Penjualan Obat. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 5(2). <https://doi.org/10.57152/malcom.v5i2.1952>
- Aspland, E., Harper, P. R., Gartner, D., Webb, P., & Barrett-Lee, P. (2021). Modified Needleman–Wunsch algorithm for clinical pathway clustering. *Journal of Biomedical Informatics*, 115. <https://doi.org/10.1016/j.jbi.2020.103668>
- Aulia, W., Siahaan, A. P. U., Marlina, L., & Iqbal, M. (2025). Analisis Algoritma K-Means Clustering dalam Identifikasi Tingkat Risiko Penyakit Berdasarkan Data Rekam Medis Pasien. *Journal of Science and Social Research*, 8(3). <https://garuda.kemdiktisaintek.go.id/documents/detail/5310778>
- Bolikulov, F., Nasimov, R., Rashidov, A., Akhmedov, F., & Cho, Y. I. (2024). Effective Methods of Categorical Data Encoding for Artificial Intelligence Algorithms. *Mathematics*, 12(16). <https://doi.org/10.3390/math12162553>
- Chaudhry, M., Shafi, I., Mahnoor, M., Vargas, D. L. R., Thompson, E. B., & Ashraf, I. (2023, September). A Systematic Literature Review on Identifying Patterns Using Unsupervised Clustering Algorithms: A Data Mining Perspective. In *Symmetry* (Vol. 15, Issue 9). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/sym15091679>
- Chicco, D., Campagner, A., Spagnolo, A., Ciucci, D., & Jurman, G. (2025). The Silhouette Coefficient and the Davies-Bouldin Index are more Informative than Dunn Index, Calinski-Harabasz Index, Shannon Entropy, and Gap Statistic for Unsupervised Clustering Internal Evaluation of Two Convex Clusters. *PeerJ Computer Science*, 11. <https://doi.org/10.7717/peerj-cs.3309>

- Farissa, R. A., Mayasari, R., & Umaidah, Y. (2021). *Perbandingan Algoritma K-Means dan K-Medoids Untuk Pengelompokan Data Obat dengan Silhouette Coefficient*. 5(2).
- Firmansyah, Y., Widjaja, G., & Firmansyah, A.-K. (2022). *Pemberlakuan Clinical Pathway dalam Pemberian Layanan Kesehatan dan Akibat Hukumnya (The Application of Clinical Pathway in Health Care and Its Legal Consequences)*.
- Firmanto, Y. (2021). Early Warning System: Solusi Klaim Negatif Rumah Sakit Program Jaminan Kesehatan Nasional. *JEAM: Jurnal Ekonomi Akutansi Manajemen*, 20(1).
<https://doi.org/https://doi.org/10.19184/jeam.v20i1.19303>
- Fitria, A., Armani, A. S., Rochmah, T. N., Purwaka, B. T., & Pudjirahardjo, W. J. (2021). Penerapan Clinical Pathways sebagai Instrumen Pengendalian Biaya Pelayanan: Studi Penelitian Tindakan Penderita BPJS yang Menjalani Operasi Caesar dengan Sistem Pembayaran INA-CBG. *Jurnal Keperawatan Silampari*, 4(2), 593–599.
<https://doi.org/10.31539/jks.v4i2.1546>
- Galih, A., & Amanda, P. R. (2025). Penerapan K-Means Clustering untuk Pengelompokan Pasien Rumah Sakit berdasarkan Penerapan K-Means Clustering untuk Pengelompokan Pasien Rumah Sakit berdasarkan Tingkat Keparahan Penyakit. *Jatilima: Jurnal Multimedia Dan Teknologi Informasi*, 07(3).
<https://doi.org/10.54209/jatilima.v7i03.1598>
- Guntari, P. S., Jofilla, S., Valentina, M. F., Gani, A., Ramadon, E. T., & Albarra, M. A. (2025). Penerapan Algoritma K-Means Clustering untuk Analisis Pola Penjualan Toko Kue dengan Rapidminer. *Jurnal Mahasiswa Ilmu Komputer*, 6(1), 24–34.
<https://doi.org/10.24127/ilmukomputer.v6i1.7768>
- Hasugian, P. M., Mathelinea, D., Simamora, S., & Simangunsong, P. B. N. (2025). Comparative Evaluation of Data Clustering Accuracy through Integration of

- Dimensionality Reduction and Distance Metric. *MATRIK : Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 24(3).
<https://doi.org/10.30812/matrik.v24i3.5057>
- He, Y. (2024). *Imbalanced Data Clustering using Equilibrium K-Means*.
<https://doi.org/10.48550/arXiv.2402.14490>
- Hennig, C. (2007). Cluster-wise assessment of cluster stability. *Computational Statistics & Data Analysis*, 52(1), 258–271.
<https://doi.org/https://doi.org/10.1016/j.csda.2006.11.025>
- Herdiaman, E. A. (2024). KLASERISASI PASIEN PADA RSUD CIAMIS MENGGUNAKAN METODE K-MEANS. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(3S1). <https://doi.org/10.23960/jitet.v12i3s1.5124>
- Hofmann, O.-A., Offergeld, C., & Ramackers, W. (2026). A comparative study examining the perspectives of both students and clinical teachers during practical teaching sessions in otorhinolaryngology. *BMC Research Notes*, 19(1), 185.
<https://doi.org/10.1186/s13104-026-07802-w>
- Hubert, L. J., & Arabie, P. (1985). Comparing partitions. *Journal of Classification*, 2, 193–218.
- Irwandu, I., & Sjaaf, A. C. (2018). Dampak Kebijakan Jaminan Kesehatan Nasional terhadap Efisiensi Rumah Sakit: Studi Kasus di Provinsi Sulawesi Selatan. *Media Kesehatan Masyarakat Indonesia*, 14, 360.
<https://doi.org/10.30597/mkmi.v14i4.5144>
- Izzah, L. ‘, & Jananto, A. (2022). Penerapan Algoritma K-Means Clustering Untuk Perencanaan Kebutuhan Obat Di Klinik Citra Medika. *Progresif: Jurnal Ilmiah Komputer*, 18(1), 69. <https://doi.org/10.35889/progresif.v18i1.769>

- Johnson, T., Liu, A. J., Raza, S., & McGuire, A. (2023). A Comparison of Modeling Preprocessing Techniques. *arXiv Preprint arXiv:2302.12042*.
<https://doi.org/10.48550/arXiv.2302.12042>
- Kenzia, N. A. (2021). Analisis Kompetensi Auditor Internal terhadap Kemampuan Mencegah dan Mendeteksi Fraud dalam Program Jaminan Kesehatan Nasional (Studi Kasus di Rumah Sakit Bethesda Yogyakarta). *Accounting and Business Information Systems Journal*. <https://doi.org/10.22146/abis.v9i2.65895>
- Koladiya, V. R. (2024). *Comparative Analysis of Selected Clustering Algorithms for Weakly Supervised Data*.
- Kustiwa, D. R., Azizi, M. S. H., Purwadhi, & Widjadja, Y. R. (2026). Respon Strategis Rumah Sakit terhadap Dinamika Sistem Pembayaran INA-CBG dalam Era BPJS Kesehatan: Literature Review. *Jurnal Ilmiah Manajemen Dan Kewirausahaan*, 5(2), 523–538. <https://doi.org/10.55606/jimak.v5i2.6802>
- Laksono, B., Syahidin, Y., & Yunengsih, Y. (2024). Implementasi Data Mining Klasterisasi Data Pasien Rawat Inap dengan Algoritma K-Means Clustering. *Jurnal Teknologi Sistem Informasi Dan Aplikasi*, 7(2), 621–627.
<https://doi.org/10.32493/jtsi.v7i2.39354>
- Leisch, F., & Dolnicar, S. (2010). Evaluation of structure and reproducibility of cluster solutions using the bootstrap. *Faculty of Commerce - Papers*, 21.
<https://doi.org/10.1007/s11002-009-9083-4>
- Lippitt, W. L., Bedrick, E. J., & Carlson, N. E. (2026). *Adjusted Similarity Measures and a Violation of Expectations* (arXiv:2601.10641). arXiv.
<https://doi.org/10.48550/arXiv.2601.10641>

- Manopo, W. L. M., & Susanti, N. (2025). Prediksi Kebangkrutan Rumah Sakit Akibat Ketidaksesuaian Sistem Tarif INA-CBGS. *JAFM: Journal of Accounting and Finance Management*, 6(2). <https://doi.org/10.38035/jafm.v6i2>
- Mayeem, S., Partey, B. T., Dawuni, G. R., & Augustine, O.-W. (2026). *Soft-Aspect ABSA: A Probabilistic Framework with Cluster Stability and Class-Imbalance Diagnostics*. Computer Science and Mathematics. <https://doi.org/10.20944/preprints202605.1878.v1>
- Milenovic, Z. M. (2011). *Application of Mann-Whitney U Test in Research of Professional Training of Primary School Teacher*. 6(1). <https://doi.org/10.32728/mo.06.1.2011.06>
- Monica, R. D., Firdaus, F. M., Lestari, I. P., Suryati, Y., Rohmayani, D., & Hendrati, A. (2021). Analisis Perbedaan Tarif Riil Rumah Sakit dengan Tarif Ina-CBG's Berdasarkan Kelengkapan Medis Pasien Rawat Inap pada Kasus Persalinan Sectio Caesarea guna Pengendalian Biaya Rumah Sakit TNI AU Dr. M. Salamun Bandung. *Jurnal Manajemen Informasi Kesehatan Indonesia*, 9(1). <https://doi.org/10.33560/jmiki.v9i1.289>
- Nabyla, F. (2021). Data Mining Pengelompokan Biaya Pengeluaran Rumah Sakit Oleh BPJS Kesehatan Menggunakan Algoritma K-Means. *Smart Comp: Jurnalnya Orang Pintar Komputer*, 10(2), 79–83. <https://doi.org/10.30591/smartcomp.v10i2.2128>
- Naeem, S., Ali, A., Anam, S., & Ahmed, M. M. (2023). An Unsupervised Machine Learning Algorithms: Comprehensive Review. *International Journal of Computing and Digital Systems*, 13(1), 911–921. <https://doi.org/10.12785/ijcds/130172>

- Nanda, W. S., Pardede, A. M. H., & Simanjuntak, M. (2023). *ANALISIS DATA MINING UNTUK KLASTERISASI DATA REKAM MEDIS MENGGUNAKAN ALGORITMA K-MEANS PADA RUMAH SAKIT SYLVANI BINJAI. 1(3).*
- Oktafiandi, H., Winarnie, W., & Nur, W. (2025a). Analisis Klaster Pasien Menggunakan K-Means untuk Mendukung Perawatan Medis Terpersonalisasi. *Jurnal Pustaka Data (Pusat Akses Kajian Database, Analisa Teknologi, dan Arsitektur Komputer)*, 5(1), 33–38. <https://doi.org/10.55382/jurnalpustakadata.v5i1.1001>
- Oktafiandi, H., Winarnie, W., & Nur, W. (2025b). Analisis Klaster Pasien Menggunakan K-Means untuk Mendukung Perawatan Medis Terpersonalisasi. *Jurnal Pustaka Data (Pusat Akses Kajian Database, Analisa Teknologi, Dan Arsitektur Komputer)*, 5(1), 33–38. <https://doi.org/10.55382/jurnalpustakadata.v5i1.1001>
- Pinheiro, J. M. H., Oliveira, S. V. B. de, Silva, T. H. S., Saraiva, P. A. R., Souza, E. F. de, Godoy, R. V., Ambrosio, L. A., & Becker, M. (2025). The Impact of Feature Scaling in Machine Learning: Effects on Regression and Classification Tasks. *IEEE Access*, 13. <https://doi.org/10.1109/ACCESS.2025.3635541>
- Prabujaya, I., Rahman, Ibrahim, F., Muin, A. A., & Wahyuni, S. (2025). Sistem Klasterisasi Data Rekam Medis pada Puskesmas Kampili Menggunakan Algoritma K-Means. *SYNTECH: System Information and Computer Technology*, 1(2).
- Priwibowo, A. (2025). *Pembuatan Model Klasifikasi Teks Dengan BERT dan GRU untuk Pengkodean ICD-10 Diagnosis Utama Penyakit pada Proses Klaim BPJS di RSUP Persahabatan*. Universitas Islam Indonesia.
- Purwadhi, Restiani, Y., Adrian, W. I., & Harianto, M. I. F. (2024). Strategi Pengelolaan Sumber Daya untuk Keberlanjutan Operasional Rumah Sakit. *INNOVATIVE: Journal of Social Science Research*. <https://doi.org/10.31004/innovative.v4i6.16356>

- R, T., Hutapea, F., & Adhikara, M. F. A. (2022). Implementation Analysis of INA-CBG's Claims Implementation of Quality Control and Cost Control at Tarumajaya Hospital Bekasi. *Jurnal Health Sains*, 3(8), 1320–1335.
<https://doi.org/10.46799/jhs.v3i8.563>
- Rabiulyati, M., & Nurwahyuni, A. (2023). Strategi Efisiensi Rumah Sakit di Era JKN: Literature Review. *Jurnal Kesehatan Tambusai*.
<https://doi.org/10.31004/jkt.v4i2.15562>
- Rahma, F. (2025). Clustering Students Based on Academic Performance and Social Factors: An Unsupervised Learning Approach to Identify Student Patterns. *International Journal for Applied Information Management*, 5(3), 139–154.
<https://doi.org/10.47738/ijaim.v5i3.109>
- Rinaldi, I., & Sulistiadi, W. (2025). Optimalisasi Rekam Medis Elektronik Berbasis Artificial Intelligence. *Jurnal Penyakit Dalam Indonesia*, 12(4).
<https://doi.org/10.7454/jpdi.v12i4.1891>
- Rochayani, M. Y., & Utami, I. T. (2025). A Gaussian Mixture Model Approach to Profiling Stunting Risk Across Indonesian Provinces. *International Journal of Engineering and Computer Science Applications (IJECSA)*, 4(2), 135–143.
<https://doi.org/10.30812/ijeCSA.v4i2.5395>
- Rostami, M., & Saarela, O. (2023). A Feature Selection Method that Controls the False Discovery Rate. *arXiv Preprint arXiv:2208.02948*.
<https://doi.org/10.48550/arXiv.2208.02948>
- Salman, M. D., Rahmadden, R., Pratama, N. R., A, M. N. F., Setiawan, A. A., Zalianti, F., & Huda, I. B. (2025). Perbandingan Kinerja Algoritma Clustering K-Means dan K-Medoids dalam Pengelompokan Sekolah di Provinsi Riau Berdasarkan Ketersediaan Sarana dan Prasarana. *MALCOM: Indonesian Journal of Machine*

Learning and Computer Science, 5(3), 797–806.

<https://doi.org/10.57152/malcom.v5i3.1950>

Sari, P. O. C., & Suharjito, S. (2022). Outlier Detection in Inpatient Claims Using

DBSCAN and K-Means. *JURNAL TEKNIK INFORMATIKA*, 15(1), 1–10.

<https://doi.org/10.15408/jti.v15i1.25682>

Satriatama, A. E., Wibowo, A. P., Arnold, I. G. N., Pratama, R. B., Masyhuda, T. A.,

Agusti, Y. A., Purwanti, E., & Werdiningsih, I. (2023a). Analisis Klaster Data

Pasien Diabetes untuk Identifikasi Pola dan Karakteristik Pasien. *Jurnal Teknologi*

Dan Sistem Informasi Bisnis, 5(3), 172–182.

<https://doi.org/10.47233/jteksis.v5i3.828>

Satriatama, A. E., Wibowo, A. P., Arnold, I. G. N., Pratama, R. B., Masyhuda, T. A.,

Agusti, Y. A., Purwanti, E., & Werdiningsih, I. (2023b). Analisis Klaster Data

Pasien Diabetes untuk Identifikasi Pola dan Karakteristik Pasien. *Jurnal Teknologi*

Dan Sistem Informasi Bisnis, 5(3), 172–182.

<https://doi.org/10.47233/jteksis.v5i3.828>

Savander, J., & Lehtomäki, S. Ds. T. A. A. R. (2023). *Clustering of radiotherapy patients based on the usage patterns in the Kaiku Health application and electronic patient-reported outcomes*. www.aalto.fi

Schubert, E. (2023). Stop Using the Elbow Criterion for K-Means. *Association for*

Computing Machinery, 25(2023). <https://doi.org/10.1145/3606274.3606278>

Sethi, S. (2020). Feature Engineering for Healthcare Big Data: Approaches to Missing

Data Imputation, Dimensionality Reduction, and Time-Series Analysis.

International Journal of Multidisciplinary Research and Growth Evaluation., 1(1).

<https://doi.org/10.54660/ijmrge.2020.1.1.120-124>

- Setiawati, E., Fernanda, U. D., Agesti, S., Iqbal, M., & Herjho, M. O. A. (2024). Implementation of K-Means, K-Medoid and DBSCAN Algorithms In Obesity Data Clustering. *IJATIS: Indonesian Journal of Applied Technology and Innovation Science*, 1(1), 23–29. <https://doi.org/10.57152/ijatis.v1i1.1109>
- Shepyantoni, F., Kanedi, I., & Suryana, E. (2024). Penerapan Metode K-Means Clustering Dalam Pengelompokan Data Pasien Rawat Inap Peserta BPJS Di Rumah Sakit Umum Daerah Kabupaten Kaur. *JURNAL MEDIA INFOTAMA*, 20(2), 493–500. <https://doi.org/10.37676/jmi.v20i2.6458>
- Shickel, B., Tighe, P., Bihorac, A., & Rashidi, P. (2018). *Deep EHR: A Survey of Recent Advances in Deep Learning Techniques for Electronic Health Record (EHR) Analysis*. <https://doi.org/10.1109/JBHI.2017.2767063>
- Steinley, D. (2004). Properties of the Hubert-Arabie adjusted Rand index. *Psychological Methods*, 9(3), 386–396. <https://doi.org/10.1037/1082-989X.9.3.386>
- Sukmawati, N. D., Susilo, D. E., & Jombang, S. P. D. (2023). Pengaruh Sistem Pengendalian Manajemen dan Pengendalian Internal Terhadap Kinerja Keuangan pada Rumah Sakit Jombang. *Jurnal Ilmiah MEA (Manajemen, Ekonomi, Dan Akuntansi)*, 7(3), 2023. <https://doi.org/10.31955/mea.v7i3.3416>
- Sy, Y. S. (2022). Klasterisasi Pasien Rawat Inap Peserta BPJS Berdasarkan Jenis Penyakit Menggunakan Algoritma K-Means. *Jurnal Sistim Informasi Dan Teknologi*. <https://doi.org/10.37034/jsisfotek.v5i2.162>
- Syafiq, M., Millati, N. F., Idris, M. A., Fitrianto, A., Alifviansyah, K., & Erfiani, E. (2026). Clustering of Central Java Districts Based on Educational Indicators: A Comparison of K-Means and Hierarchical Methods. *Journal of Mathematics, Computations and Statistics*, 9(1), 192–205. <https://doi.org/10.35580/xen35m31>

- Thulasidas, M. (2022). *A Recommendation on How to Teach K-means in Introductory Analytics Course* (pp. 46–53). <https://doi.org/10.1109/TALE54877.2022.00016>
- Vardakas, G., & Likas, A. (2023). *Global K-means++: An Effective Relaxation of The Global K-means Clustering Algorithm*. <http://arxiv.org/abs/2211.12271>
- Vinh, N. X., Vinh, N. X., Epps, J., Epps, J., & Bailey, J. (2010). *Information Theoretic Measures for Clusterings Comparison: Variants, Properties, Normalization and Correction for Chance*.
- VIP, P., Hantina, J. S., Sulthoni, E. M. N., Mohamad, A., Erna, K., & Wibi, T. M. (2025). Penerapan Metode Clustering Dalam Peningkatan Pelayanan Kesehatan Di Puskesmas Binanga, Sulawesi Barat. *J-CEKI: Jurnal Cendekia Ilmiah*, 4(3). <https://doi.org/10.56799/jceki.v4i3.8021>
- Wandana, J., Defit, S., & Sumijan, S. (2020). Klasterisasi Data Rekam Medis Pasien Pengguna Layanan BPJS Kesehatan Menggunakan Metode K-Means. *Jurnal Informasi Dan Teknologi*. <https://doi.org/10.37034/jidt.v2i4.73>
- Wang, H., Donoho, D., Kuppler, C., Loftus, T. J., Jr, U. G., Copyright, frai, Shickel, B., Balch, J. A., Tighe, P. J., Abbott, K. L., Fazzone, B., Anderson, E. M., Rozowsky, J., Ozrazgat-Baslanti, T., Ren, Y., Berceli, S. A., Hogan, W. R., Efron, P. A., Moorman, J. R., ... Bihorac, A. (2022). *Phenotype clustering in health care: A narrative review for clinicians*.
- Wegmann, M., Zipperling, D., Hillenbrand, J., & Fleischer, J. (2021). *A Review of Systematic Selection of Clustering Algorithms and Their Evaluation*. <https://doi.org/10.48550/arXiv.2106.12792>
- Yeung, K. Y., & Ruzzo, W. L. (2001). *Details of the Adjusted Rand index and Clustering algorithms Supplement to the paper “An empirical study on Principal Component Analysis for clustering gene expression data” (to appear in Bioinformatics)*.

- Yu, M., & Zhang, Y. (2025). Comparative Models on Low Multiplier DRG Classification for Advanced Lung Cancer. *Frontiers in Public Health*, 13.
<https://doi.org/10.3389/fpubh.2025.1614938>
- Yunitaningtyas, K. & Herianti. (2025). Identifying Stratifications of Cancer Patient Visits: Approach of Clustering Using PCA of Mixed Data. *ICDSOS*, 2025(1).
<https://doi.org/10.34123/icdsos.v2025i1.622>
- Zeng, X., Moosavinasab, S., Lin, E.-J. D., Lin, S., Bunescu, R., & Liu, C. (2019). *Distributed Representation of Patients and Its Use for Medical Risk Adjustment*.
<http://arxiv.org/abs/1909.07157>

LAMPIRAN A