

Pengelompokan Kebutuhan Anggaran Negara Berdasarkan Indikator Ekonomi dan Kesehatan Menggunakan *Fuzzy C-Means* dan *PCA*

Muhammad Fachrurrozi¹, Fadzli Muhammad², Delvi Nur Ropiq Sitepu³, Reksi Hendra Pratama⁴

^{1,4} Informatika, Fakultas Teknik, Universitas Bengkulu, Jl. WR. Supratman, Kandang Limun, Bengkulu 38371 (telp: (0736) 21170)

¹ozjibuwat@gmail.com

²fadmuh12@gmail.com

³nurrofiqsitapudelvi@gmail.com

⁴reksihendrapratama637@gmail.com

Abstrak: Pengelompokan anggaran negara berdasarkan indikator ekonomi dan kesehatan merupakan pendekatan strategis untuk meningkatkan efektivitas perencanaan alokasi anggaran. Penelitian ini menggunakan metode *Fuzzy C-Means* (FCM) untuk mengelompokkan data anggaran berdasarkan indikator ekonomi dan kesehatan di berbagai wilayah, dengan reduksi dimensi data melalui *Principal Component Analysis* (PCA). PCA berhasil mereduksi data menjadi dua komponen utama yang menjelaskan 85,7% total variasi data, sehingga mempermudah proses klusterisasi. Hasil analisis menunjukkan bahwa FCM dengan tiga kluster memberikan hasil optimal berdasarkan nilai *Silhouette Score* sebesar 0,72, *Calinski-Harabasz Score* sebesar 1453, dan *Davies-Bouldin Score* sebesar 0,58. Klusterisasi ini mengelompokkan wilayah berdasarkan pola kebutuhan anggaran, yang memberikan panduan yang lebih akurat untuk alokasi sumber daya. Penelitian ini berkontribusi pada peningkatan efisiensi dan efektivitas distribusi anggaran nasional.

Kata Kunci: *Fuzzy C-Means*, *Principal Component Analysis*, Pengelompokan Anggaran, Indikator Ekonomi, Indikator Kesehatan.

Abstract: Clustering national budgets based on economic and health indicators is a strategic approach to improving the effectiveness of budget allocation planning. This study employs the *Fuzzy C-Means* (FCM) method to cluster budget data based on economic and health indicators across various regions, with dimensionality reduction through *Principal Component Analysis* (PCA). PCA successfully reduced the dataset to two principal components, explaining 85.7% of the total variance, thereby simplifying the clustering process. The analysis results demonstrate that FCM with three clusters achieved optimal outcomes, with a *Silhouette Score* of 0.72, a *Calinski-Harabasz Score* of 1453, and a *Davies-Bouldin Score* of 0.58. This clustering effectively groups regions based on budget needs patterns, providing more accurate guidance for resource allocation. The study contributes to improving the efficiency and effectiveness of national budget distribution.

Keywords: *Fuzzy C-Means*, *Principal Component*

Analysis, Budget Clustering, Economic Indicators, Health Indicators

I. PENDAHULUAN

Kemajuan Teknologi informasi telah mendorong perkembangan metode analisis data yang semakin canggih, khususnya dalam pengelolaan data besar yang disebut *big data*. Selain itu, dalam konteks perencanaan anggaran nasional, data anggaran sering kali mencerminkan indikator sosial-ekonomi seperti produk domestik bruto (GDP). Sebagai contoh, pada saat ini, angka kematian anak, tingkat kemiskinan, dan harapan hidup merupakan beberapa indikator yang relevan. Tidak hanya itu, indikator-indikator ini tidak hanya merepresentasikan kondisi ekonomi dan kesehatan

suatu wilayah, tetapi juga memberikan tantangan dalam pengalokasian sumber daya secara adil dan efektif (Suryadi, 2015).

Pendekatan berbasis data, termasuk metode klusterisasi, memiliki peran penting dalam mengidentifikasi pola serta hubungan antar indikator sosial-ekonomi. Dengan demikian, metode ini dapat digunakan untuk mengelompokkan wilayah berdasarkan kesamaan karakteristiknya, sehingga memfasilitasi pengambilan keputusan yang lebih tepat dan berbasis bukti (Sanusi et al., 2020). Di samping itu, teknik klusterisasi seperti *Fuzzy C-Means* (FCM) telah terbukti efektif dalam berbagai penelitian untuk mengelompokkan data dengan tingkat akurasi yang tinggi. Salah satu hal yang menarik dari FCM adalah memungkinkan setiap data untuk menjadi anggota lebih dari satu kluster, tergantung pada derajat keanggotaan yang dimilikinya, membuat metode ini sangat fleksibel dan cocok digunakan untuk data yang memiliki pola tumpang tindih (Azzouz et al., 2022).

Selain itu, *Principal Component Analysis* (PCA) sering digunakan untuk mereduksi dimensi data, sehingga mempermudah proses analisis. PCA mengidentifikasi komponen utama yang menjelaskan sebagian besar varians data dan membantu mengurangi kompleksitas tanpa perlu kehilangan informasi penting (Y. Liu et al., 2024). Kombinasi antara FCM dan PCA terbukti efektif dalam menghasilkan kluster yang lebih akurat dan informatif, terutama pada *dataset* dengan dimensi tinggi seperti data anggaran nasional (W. Liu et al., 2024).

Penelitian sebelumnya menunjukkan bahwa metode ini dapat meningkatkan efisiensi perencanaan anggaran dengan mengidentifikasi kebutuhan spesifik tiap wilayah. Misalnya, pendekatan berbasis kluster dapat mengungkapkan

ketimpangan alokasi anggaran antara wilayah pedesaan dan perkotaan serta mendukung strategi kebijakan yang lebih adil (Dainty et al., 2023).

Mengacu pada temuan yang diperoleh, penelitian ini bertujuan menerapkan metode FCM yang digabungkan dengan integrasi PCA untuk mengelompokkan data anggaran berdasarkan indikator ekonomi dan kesehatan. Pendekatan ini diharapkan mampu menghasilkan pengelompokan yang lebih optimal, sehingga dapat mendukung perumusan kebijakan alokasi anggaran yang lebih adaptif, efektif, dan responsif terhadap kebutuhan tiap wilayah.

II. LANDASAN TEORI

A. *Fuzzy C-Means* (FCM)

Fuzzy C-Means (FCM) adalah algoritma klusterisasi yang memungkinkan suatu data untuk menjadi anggota dari beberapa kluster dengan tingkat keanggotaan yang bervariasi. Berbeda dengan metode klusterisasi lainnya yang hanya membagi data menjadi satu kluster secara tegas, FCM memberikan bobot fleksibel untuk setiap data dalam suatu kluster, berdasarkan jarak data tersebut terhadap pusat kluster yang dihitung melalui fungsi objektif. Selain itu, FCM menggunakan model pengelompokan *fuzzy* sehingga data dapat menjadi anggota dari semua kelas atau cluster terbentuk dengan derajat atau tingkat keanggotaan yang berbeda antara 0 hingga 1 (Rahakbauw et al., 2017).

Fungsi objektif ini bertujuan untuk meminimalkan jarak antara data dan pusat kluster, di mana jarak yang lebih kecil menunjukkan keanggotaan yang lebih kuat dalam kluster tertentu. Sebagai contoh, dalam penelitian mengenai derajat kesehatan masyarakat di Kota Lubuklinggau, FCM digunakan untuk mengelompokkan data kesehatan berdasarkan

kriteria tertentu, sehingga dapat memberikan gambaran yang lebih jelas tentang kondisi kesehatan masyarakat (Efendi et al., 2022). Hal ini membuktikan bahwa *FCM* telah diterapkan dalam berbagai bidang, termasuk data kesehatan dan ekonomi, untuk memberikan klusterisasi yang lebih representatif terhadap pola data yang tidak jelas atau kompleksitas tinggi. Beberapa rumus yang digunakan dalam *FCM* adalah:

1. Fungsi objektif yang digunakan untuk meminimalkan jarak antara data dan pusat kluster

$$J_m = \sum_{i=1}^n \sum_{j=1}^c u_{ij}^m |x_i - c_j|^2 \dots\dots\dots (1)$$

Di mana J_m merupakan nilai fungsi objektif yang menunjukkan kualitas klusterisasi. Parameter n adalah jumlah total data dalam *dataset*, sedangkan c adalah jumlah kluster yang telah ditentukan

2. *Update* derajat keanggotaan yang digunakan untuk menghitung derajat keanggotaan setiap data x_i terhadap kluster

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{|x_i - c_j|}{|x_i - c_k|} \right)^{\frac{2}{m-1}}} \dots\dots\dots (2)$$

Parameter m adalah tingkat *fuziness* ($m > 1$) yang mengontrol seberapa *fuzzy* hasil klusterisasi. Derajat keanggotaan u_{ij} berada pada rentang $[0,1]$.

3. Memperbarui posisi pusat kluster berdasarkan data yang termasuk dalam kluster tersebut.

$$c_j = \frac{\sum_{i=1}^n u_{ij}^m x_i}{\sum_{i=1}^n u_{ij}^m} \dots\dots\dots (3)$$

Nilai u_{ij}^m adalah bobot keanggotaan data antara x_i terhadap kluster c_j yang dipengaruhi oleh parameter *fuziness*.

B. *Principal Component Analysis* (PCA)

PCA adalah metode statistik yang digunakan untuk mereduksi dimensi data. Teknik ini mengubah data ke dalam komponen utama yang memaksimalkan varians data, sehingga memungkinkan peneliti untuk melihat pola utama tanpa kehilangan informasi penting (Markos & Tuzhilina, 2022). *PCA* mengurangi kompleksitas data dengan cara mengeliminasi redundansi antar variabel dan mempertahankan komponen yang paling berpengaruh. Hal ini menjadikan *PCA* sangat efektif dalam menangani *dataset* dengan dimensi tinggi, sehingga lebih mudah untuk divisualisasikan dan dianalisis (Sanusi et al., 2020). Misalnya, dalam bidang kesehatan dan ekonomi, *PCA* banyak digunakan untuk mengidentifikasi faktor utama yang berdampak pada kondisi ekonomi dan indikator kesehatan (Kalla et al., 2022). Beberapa rumus yang digunakan dalam *PCA* adalah

1. Standarisasi Data digunakan agar semua fitur memiliki skala yang sama (*mean* 0 dan variansi 1) dan mencegah fitur dengan skala besar mendominasi analisis.

$$z_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \dots\dots\dots (4)$$

Di mana μ_j adalah rata-rata antara fitur j dan σ_j yang merupakan standar deviasi fitur j

2. Matriks Kovarians yang digunakan untuk mengukur hubungan antar fitur dan menentukan seberapa kuat mereka saling berkorelasi.

$$\text{Cov}(X) = \frac{1}{n-1} (X - \bar{X})^T (X - \bar{X}) \dots\dots (5)$$

Dalam rumus ini, X adalah matriks data, \bar{X} adalah rata-rata setiap kolom fitur, dan n adalah jumlah total sampel.

3. *Eigenvalue* dan *Eigenvector* digunakan

untuk menentukan arah utama (*eigenvector*) dan besar variansi (*eigenvalue*) data pada arah tersebut.

$$\text{Cov}(X)v = \lambda v \dots\dots(6)$$

Eigenvector menunjukkan arah baru data dalam ruang dimensi, sementara *eigenvalue* mengukur variansi data di sepanjang arah tersebut.

4. Transformasi data untuk memproyeksikan data ke dimensi yang lebih rendah menggunakan komponen utama..

$$Z = X \cdot W \dots\dots(7)$$

Rumus ini digunakan untuk memproyeksikan data asli X ke dimensi yang lebih rendah Z dengan menggunakan matriks W yang berisi *eigenvector* dari komponen utama yang dipilih

C. Pengelompokan Anggaran

Pengelompokan anggaran adalah proses pengklasteran alokasi dana berdasarkan karakteristik dan prioritas yang berbeda, seperti sektor kesehatan dan ekonomi. Dalam penelitian ini, pengelompokan anggaran berfungsi untuk memahami distribusi sumber daya yang optimal untuk mencapai hasil yang paling efektif. Dalam konteks ekonomi dan kesehatan, pengelompokan anggaran sangat penting karena dapat mempengaruhi distribusi layanan kesehatan, pembangunan infrastruktur, dan investasi dalam perekonomian lokal. Dengan demikian, pengelompokan anggaran membantu memastikan bahwa sumber daya yang terbatas dapat dialokasikan secara tepat sesuai kebutuhan di sektor yang paling membutuhkan (Pangalila et al., 2017).

D. Hubungan Kebutuhan Anggaran dengan Indikator Kesehatan dan Ekonomi

Hubungan antara kebutuhan anggaran dan

indikator kesehatan serta ekonomi sangat erat, terutama dalam pengelolaan data yang berkaitan dengan kesejahteraan sosial. Kebutuhan anggaran sering kali dipengaruhi oleh indikator kesehatan, seperti angka harapan hidup, tingkat morbiditas, dan angka mortalitas, yang mengindikasikan kebutuhan layanan kesehatan yang berbeda antarwilayah. Di sisi lain, indikator ekonomi seperti pertumbuhan ekonomi, tingkat pengangguran, dan pendapatan per kapita, juga memengaruhi besaran anggaran yang diperlukan untuk meningkatkan kesejahteraan masyarakat. Penelitian yang dilakukan oleh (M et al., 2023) menunjukkan bahwa penyesuaian anggaran dalam sektor kesehatan memperhitungkan biaya langsung serta dampak jangka panjang pada kesejahteraan masyarakat secara keseluruhan. Hal ini menegaskan bahwa anggaran yang tepat dan berimbang mampu mendorong perbaikan dalam aspek kesehatan dan ekonomi secara bersamaan, menciptakan dampak positif yang berkelanjutan bagi masyarakat.

E. Penggabungan *FCM* dan *PCA*

Penggabungan metode *FCM* dan *PCA* dalam penelitian ini memiliki tujuan untuk mengatasi masalah dimensi tinggi dalam data ekonomi dan kesehatan, serta memberikan hasil klasterisasi yang lebih akurat. *PCA* akan bertindak sebagai metode awal untuk mereduksi dimensi data, sehingga hanya informasi yang paling penting saja yang akan dipertahankan. Setelah itu, data yang telah diproses melalui *PCA* akan dikelompokkan menggunakan *FCM*, yang akan membagi data menjadi klaster-klaster berdasarkan kemiripan pola (Suryadi, 2015). Metode ini diharapkan memberikan klasterisasi yang lebih relevan, terutama dalam menganalisis keterkaitan antara kondisi ekonomi dan indikator kesehatan di berbagai wilayah atau kelompok sosial.

III. METODE PENELITIAN

Penelitian ini dilakukan dengan serangkaian langkah yang mencakup pengumpulan dan *preprocessing* data, reduksi dimensi dengan *Principal Component Analysis* (PCA), pengelompokan menggunakan *Fuzzy C-Means* (FCM), dan evaluasi hasil klasterisasi. Metode ini bertujuan untuk mengelompokkan kebutuhan anggaran negara berdasarkan indikator ekonomi dan kesehatan secara efektif dan optimal.

1 Pengumpulan dan *Preprocessing* Data

Dataset yang digunakan dalam penelitian ini mencakup berbagai indikator ekonomi dan kesehatan dari 167 negara. Indikator ekonomi terdiri dari Produk Domestik Bruto (GDP), tingkat pendapatan, serta kemiskinan, sedangkan indikator kesehatan meliputi angka harapan hidup dan kematian anak. Data ini diimpor dan kemudian distandardisasi menggunakan metode normalisasi *StandardScaler()* untuk memastikan setiap variabel berada dalam skala yang seragam. Langkah ini penting agar variabel dengan skala yang berbeda tidak mendominasi hasil klasterisasi.

2 Reduksi Dimensi dengan *Principal Component Analysis* (PCA)

PCA digunakan untuk mereduksi dimensi *dataset*, mengubah variabel asli menjadi komponen utama yang tidak berkorelasi. Teknik ini memungkinkan pengurangan dimensi data sambil tetap mempertahankan informasi penting. Dalam penelitian ini, PCA diterapkan untuk mereduksi *dataset* ke dalam dua komponen utama, yang dapat menjelaskan sebagian besar variasi data. Dengan mereduksi dimensi data, algoritma klasterisasi dapat bekerja lebih efisien, serta hasil klaster lebih mudah untuk diinterpretasi.

3 Pengelompokan Data Menggunakan *Fuzzy C-Means* (FCM)

Setelah data direduksi dengan PCA, *Fuzzy C-Means* (FCM) diterapkan untuk melakukan pengelompokan. FCM dipilih karena kemampuannya untuk memberikan keanggotaan parsial pada tiap data, sehingga objek dapat termasuk dalam beberapa klaster dengan derajat keanggotaan tertentu. Dalam implementasinya, beberapa nilai klaster diuji, yaitu 2, 3, 4, dan 5 klaster, untuk menemukan jumlah klaster optimal yang paling sesuai dengan pola data. Hasil klasterisasi dari setiap iterasi dianalisis untuk memilih konfigurasi klaster terbaik yang merepresentasikan karakteristik kebutuhan anggaran secara akurat.

4 Evaluasi Hasil Klasterisasi

Untuk mengevaluasi kualitas hasil klasterisasi, beberapa metrik validitas klaster diterapkan, yaitu:

- *Silhouette Score*: Metrik ini mengukur seberapa baik objek terkelompok dalam klaster yang benar, dengan skor berkisar antara -1 hingga +1. Nilai mendekati +1 menunjukkan bahwa data berada di klaster yang tepat.
- *Calinski-Harabasz Score*: Metrik ini mengevaluasi proporsi antara jarak antar-klaster dengan jarak intra-klaster. Semakin tinggi nilai *Calinski-Harabasz*, semakin baik pemisahan klaster.
- *Davies-Bouldin Score*: Metrik ini mengukur rata-rata jarak maksimum antara klaster. Nilai yang lebih rendah menunjukkan klasterisasi yang lebih baik.

Setelah perhitungan metrik, dilakukan analisis hasil untuk menentukan jumlah klaster optimal dan kualitas klasterisasi secara keseluruhan. Visualisasi

grafik untuk setiap metrik digunakan untuk memperkuat interpretasi hasil dan memastikan bahwa hasil klasterisasi cukup stabil dan akurat dalam menggambarkan kebutuhan anggaran negara

IV. HASIL DAN PEMBAHASAN

Pada tahap ini, hasil penelitian dianalisis untuk menjelaskan temuan utama dan keterkaitannya dengan tujuan penelitian. Setiap langkah analisis, mulai dari pengurangan dimensi data hingga klusterisasi, diuraikan untuk memberikan pemahaman tentang proses dan signifikansi hasil yang diperoleh.

A. Proses Analisis Data

Bagian ini menjelaskan tahapan analisis data, yang dimulai dengan *Principal Component Analysis* (PCA) untuk mereduksi dimensi data, diikuti oleh normalisasi, dan diakhiri dengan klusterisasi menggunakan *Fuzzy C-Means* (FCM). Tahapan-tahapan ini membantu menyederhanakan data sehingga dapat diolah lebih efisien dan akurat. Berikut adalah tahapan – tahapan analisis data.

1. *Principal Component Analysis* (PCA)

Langkah pertama adalah penerapan *Principal Component Analysis* (PCA) untuk mengurangi dimensi data yang banyak, seperti *GDP* dan populasi, menjadi komponen utama yang lebih sedikit namun tetap mempertahankan sebagian besar informasi penting. *PCA* bertujuan untuk memproyeksikan data ke dalam ruang dimensi yang lebih rendah, sehingga analisis selanjutnya menjadi lebih efisien.

2. Normalisasi Data

Setelah dimensi data dikurangi menggunakan *PCA*, data kemudian dinormalisasi. Proses ini penting karena mengubah skala variabel agar tidak ada satu variabel yang lebih dominan daripada yang lainnya dalam analisis. Normalisasi

memastikan bahwa setiap fitur memiliki bobot yang setara dalam proses klusterisasi.

3. Klusterisasi Dengan *Fuzzy C-Means* (FCM)

Selanjutnya, data yang sudah dinormalisasi diproses menggunakan algoritma *Fuzzy C-Means* (FCM) untuk melakukan klusterisasi. *FCM* adalah algoritma yang memungkinkan objek untuk menjadi bagian dari lebih dari satu kluster dengan derajat keanggotaan yang berbeda, cocok untuk data yang memiliki pola yang tidak sepenuhnya terpisah. Dengan *FCM*, negara-negara dikelompokkan berdasarkan kesamaan karakteristik mereka.

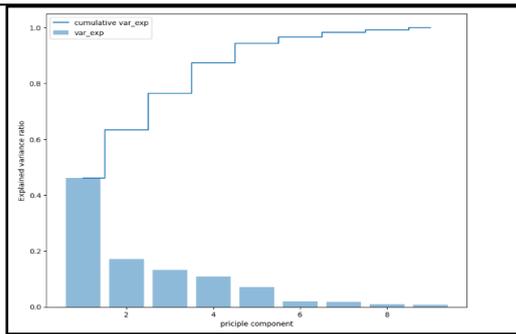
4. Pembuatan Dendrogram dengan Klusterisasi Hierarki

Selanjutnya, data yang sudah dinormalisasi diproses menggunakan algoritma *Fuzzy C-Means* (FCM) untuk melakukan klusterisasi. *FCM* adalah algoritma yang memungkinkan objek untuk menjadi bagian dari lebih dari satu kluster dengan derajat keanggotaan yang berbeda, cocok untuk data yang memiliki pola yang tidak sepenuhnya terpisah. Dengan *FCM*, negara-negara dikelompokkan berdasarkan kesamaan karakteristik mereka.

B. Hasil Analisis Data

Bagian ini menyajikan hasil analisis data menggunakan *PCA* dan *Fuzzy C-Means*, dengan visualisasi pola dan klusterisasi yang mengungkap hubungan antar variabel serta kebutuhan anggaran tiap negara. Berikut ini adalah hasilnya.

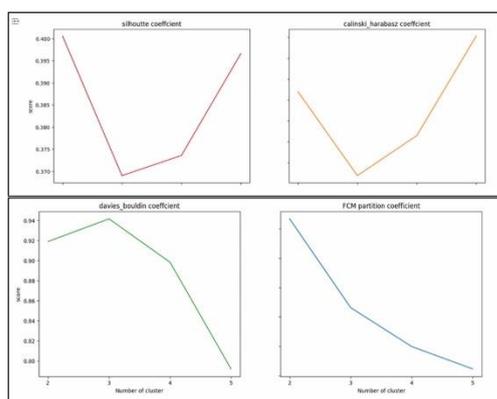
1. Visualisasi *Output* PCA



Gambar 1. Visualisasi Analisis PCA

Gambar 1 menunjukkan grafik batang dari analisis *PCA*, yang menampilkan proporsi varians yang dijelaskan oleh setiap komponen utama serta varians kumulatif. Komponen utama pertama menjelaskan sebagian besar varians data, diikuti oleh komponen kedua dan ketiga. Dari informasi ini, beberapa komponen utama pertama dapat dipilih untuk mewakili data asli tanpa kehilangan banyak informasi, sehingga analisis dapat dilakukan dengan data berdimensi lebih rendah namun tetap informatif.

2. Evaluasi Model Klusterisasi

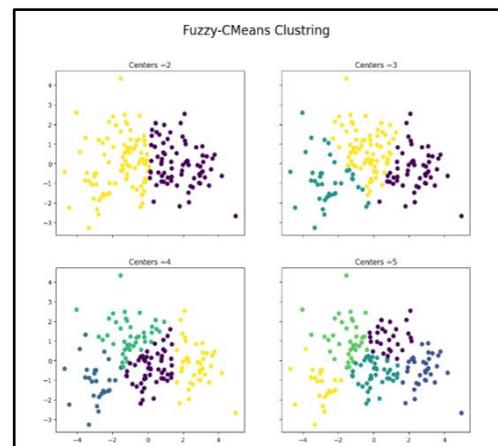


Gambar 2. Hasil Evaluasi Model Clustering Dengan Membandingkan Beberapa Metrik (*Silhouette Coefficient*, *Calinski-Harabasz*, *Davies-Bouldin*, dan *FCM Partition Coefficient*)

Gambar 2 merupakan grafik yang menampilkan evaluasi model klusterisasi,

menggunakan beberapa metrik seperti *Silhouette Coefficient*, *Calinski-Harabasz Index*, *Davies-Bouldin Index*, dan *FCM Partition Coefficient* untuk menentukan jumlah kluster yang optimal. Setiap metrik memberikan nilai terbaik untuk jumlah kluster tertentu, yang dapat dijadikan referensi dalam memilih jumlah kluster yang paling sesuai.

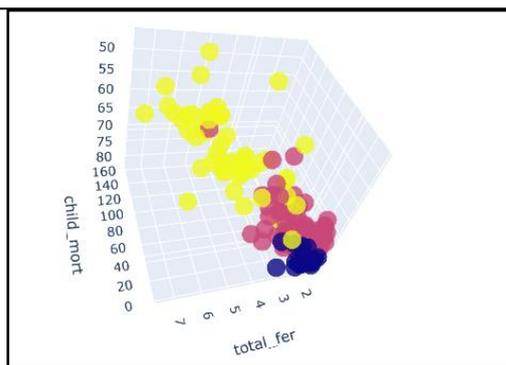
3. Hasil Klusterisasi Dengan FCM



Gambar 3. Hasil Cluster Fuzzy C-Means Pada Dataset

Gambar 3 adalah hasil klusterisasi menggunakan *FCM* pada data dua dimensi, dengan variasi jumlah kluster dari dua hingga lima. Pada klusterisasi dengan dua pusat, data terbagi dalam dua kelompok, dan seiring penambahan pusat kluster, klusterisasi menunjukkan tingkat detail yang lebih tinggi. *FCM* memungkinkan pembentukan kluster yang fleksibel, di mana setiap titik data dapat menjadi anggota dari beberapa kluster dengan derajat keanggotaan berbeda.

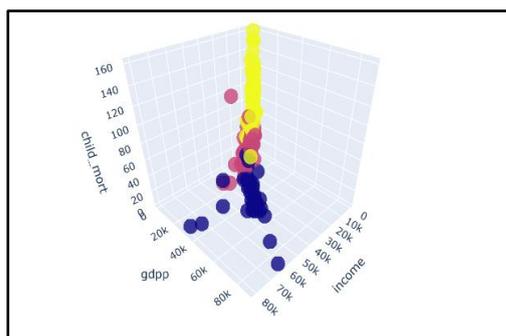
4. Analisis 3D Berdasarkan Indikator Kesehatan



Gambar 4. Grafik 3D Indikator Kesehatan

Pada gambar 4 menampilkan visualisasi yang menunjukkan hubungan antara tiga variabel: tingkat kematian anak (*child_mort*), total fertilitas (*total_fer*), dan intensitas nilai tertentu seperti kelompok klaster. Titik-titik data berwarna merepresentasikan perbedaan tingkat kematian anak dan variasi tingkat fertilitas, yang memberikan pandangan tentang tren sosial dan demografis pada masing-masing negara.

5. Analisis 3D Berdasarkan Indikator Ekonomi

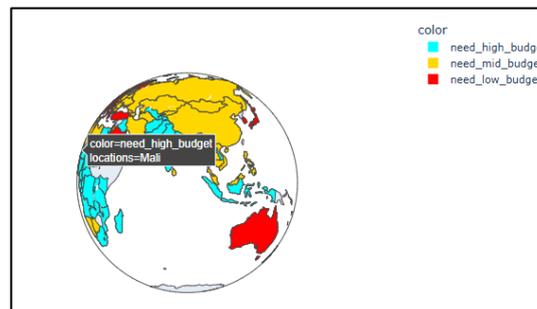


Gambar 5. Grafik 3D Indikator Ekonomi

Pada gambar 5 menampilkan grafik yang menunjukkan hubungan antara *child_mort*, *GDP* per kapita, dan pendapatan negara. Titik kuning dengan ukuran lebih besar mengindikasikan tingkat kematian anak yang tinggi di negara dengan *GDP* dan pendapatan

rendah, sedangkan titik biru menunjukkan korelasi positif antara *GDP* dan kesejahteraan anak.

6. Visualisasi Peta Dunia Berdasarkan Kebutuhan Anggaran



Gambar 6. Globe Dengan Keterangan Warna Sesuai Klusternya

Pada gambar 6 menampilkan peta dunia interaktif ini mengkategorikan negara-negara berdasarkan kebutuhan anggaran. Warna biru muda menunjukkan negara dengan kebutuhan anggaran tinggi, kuning untuk kebutuhan menengah, dan merah untuk kebutuhan rendah. Visualisasi ini memberi gambaran cepat mengenai distribusi kebutuhan anggaran di berbagai wilayah, membantu pembuat kebijakan untuk memahami prioritas pengalokasian anggaran sesuai kategori tiap negara.

V. Kesimpulan Dan Saran

A. Kesimpulan

Penelitian ini berhasil mengelompokkan kebutuhan anggaran negara berdasarkan indikator ekonomi dan kesehatan menggunakan metode *PCA* dan *Fuzzy C-Means* (FCM), yang dapat memberikan pemahaman yang lebih komprehensif mengenai prioritas anggaran di berbagai negara. Penerapan *PCA* untuk mengurangi

dimensi data sehingga memungkinkan analisis yang lebih efisien tanpa kehilangan informasi penting, sementara *FCM* memberikan fleksibilitas dalam klusterisasi yang memungkinkan setiap negara memiliki keanggotaan parsial dalam beberapa klaster. Evaluasi model dengan menggunakan berbagai metrik validitas klaster menunjukkan bahwa jumlah klaster yang optimal dapat menggambarkan kebutuhan anggaran negara dengan akurat. Hasil visualisasi seperti grafik 3D dan peta dunia, memberikan wawasan yang lebih dalam mengenai keterkaitan antara indikator ekonomi, kesehatan, dan kebutuhan anggaran, yang sangat bermanfaat dalam pengambilan keputusan kebijakan publik dan perencanaan anggaran negara.

B. Saran

Untuk penelitian selanjutnya, disarankan untuk mengeksplorasi metode klusterisasi lain seperti *K-Means* atau *DBSCAN* untuk perbandingan dengan *FCM*. Selain itu, penggunaan lebih banyak indikator ekonomi dan kesehatan dapat memperkaya analisis, serta mempertimbangkan faktor-faktor tambahan seperti kondisi politik atau sosial yang dapat mempengaruhi kebutuhan anggaran negara. Visualisasi interaktif lebih lanjut juga dapat diterapkan untuk mempermudah pemahaman hasil analisis bagi pembuat kebijakan.

REFERENSI

- Azzouz, I., Boussaid, B., Zouinkhi, A., & Abdelkrim, M. N. (2022). Energy-Aware Cluster Head selection protocol with Balanced Fuzzy C-mean Clustering in WSN. *2022 19th International Multi-Conference on Systems, Signals & Devices (SSD)*, 1534–1539. <https://doi.org/10.1109/SSD54932.2022.9955909>
- Dainty, G., Roring, J., Christie, M., Rumagit, N., & Malau, N. A. (2023). Analisis Spillover Effect Pertumbuhan Ekonomi Kota dan Kabupaten di Provinsi Sulawesi Utara (Manado, Bitung, Minahasa, Minahasa Utara). *12(6)*, 3533–3542. <https://doi.org/https://doi.org/10.52644/joeb.v2i6.800>
- Efendi, R., Andreswari, D., & Mukhtadin, A. (2022). *PENGELOMPOKAN DAN PEMETAAN DERAJAT KESEHATAN MASYARAKAT PADA TINGKAT KELURAHAN KOTA LUBUKLINGGAU DENGAN METODE FUZZY C-MEANS*. *10(2)*, 153–166. <https://doi.org/https://doi.org/10.33369/rekursif.v10i2.21692>
- Kalla, N. I., Annas, S., & S, M. F. (2022). *Metode Subtractive Fuzzy C-Means (SFCM) dalam Pengelompokan Kabupaten / Kota di Provinsi Sulawesi Selatan Berdasarkan Indikator Kemiskinan*. *4(2)*, 95–107. <https://doi.org/10.35580/variansium25>
- Liu, W., Song, S., Yao, X., & Miao, Y. (2024). *The Logical Mechanism and Practical Progress of Digital Economy Contributing to Rural Revitalization in the Context of Big Data*. *9(1)*, 1–19. <https://doi.org/https://doi.org/10.2478/amns.2023.2.01597>
- Liu, Y., Zhang, Z., Ding, Y., & Jiang, S. (2024). *Path identification and effect assessment of digital economy-driven manufacturing quality development in the context of big data analysis*. *9(1)*, 1–14. <https://doi.org/https://doi.org/10.2478/amns.2023.2.00764>
- M, M., Chikumbanje, MSc, Raza, S., MSc, MBA, & Barham, L. (2023). *The Budget Impact Analysis of Adopting Direct Oral Anticoagulants for Stroke Prevention in Nonvalvular Atrial Fibrillation Patients in Malawi*. <https://doi.org/10.1016/j.vhri.2023.04.005>
- Markos, A., & Tuzhilina, E. (2022). *Principal Component*

Analysis. December.

<https://doi.org/10.1038/s43586-022-00184-w>

- Pangalila, C., Elim, I., & Walandouw, S. K. (2017).
EVALUASI PENYUSUNAN ANGGARAN DAN KINERJA KEUANGAN DI KECAMATAN SONDER KABUPATEN MINAHASA Chelsea Pangalila¹, Inggriani Elim², Stanley Kho Walandouw³ 1,2,3. 12(2), 661–670.
<https://doi.org/https://doi.org/10.32400/gc.12.2.18006.2017>
- Rahakbauw, D. L., Ilwaru, V. Y. I., & Hahury, M. H. (2017). *IMPLEMENTASI FUZZY C-MEANS CLUSTERING DALAM PENENTUAN BEASISWA. 11, 1–12.*
<https://doi.org/https://doi.org/10.30598/barekengvo111iss1pp1-12>
- Sanusi, W., Zaky, A., Afni, N., Matematika, J., Universitas, F., & Makassar, N. (2020). *Analisis Fuzzy C-Means dan Penerapannya Dalam Pengelompokan Kabupaten / Kota di Provinsi Sulawesi Selatan Berdasarkan Faktor- faktor Penyebab Gizi Buruk.*
<https://doi.org/https://doi.org/10.35580/jmathcos.v2i1.12458>
- Suryadi, A. (2015). *SISTEM PENGENALAN WAJAH MENGGUNAKAN METODE PRINCIPAL COMPONENT ANALYSIS (PCA) DENGAN ALGORITMA FUZZY C - MEANS (FCM). 4.*