

ANALISIS PERBANDINGAN ALGORITMA *K-MEANS* DAN *FUZZY C-MEANS* DALAM PENGELOMPOKAN TIPE INFLASI KOTA DI INDONESIA

Erick

Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Tarumanagara,
Jln. Letjen S. Parman No. 1, Jakarta, 11440, Indonesia
E-mail: erick.535210084@stu.untar.ac.id

ABSTRAK

Penelitian ini menganalisis perbandingan algoritma *K-Means* dan *Fuzzy C-Means* dalam mengelompokkan kota-kota di Indonesia berdasarkan tipe inflasi. Dataset yang digunakan diperoleh dari Badan Pusat Statistik (BPS), mencakup 10 jenis inflasi selama periode Januari hingga Oktober 2024 dengan total 5.371 baris data. Visualisasi heatmap digunakan untuk melakukan *Feature Selection*, menghasilkan enam kolom yang dilatih dalam model. Kedua algoritma diuji dalam dua skenario yaitu dengan dan tanpa penanganan outlier. Evaluasi dilakukan menggunakan *Silhouette Score* dan *Davies-Bouldin Index* untuk menilai kualitas *clustering*. Hasil menunjukkan bahwa *K-Means* tanpa penanganan outlier pada *n-cluster* 6 memiliki performa terbaik dengan skor *Silhouette* 0.2493 dan DBI 1.2061, menunjukkan pemisahan kluster yang baik. Sementara itu, pada model *Fuzzy C-Means*, skenario terbaik tanpa penanganan outlier ditemukan pada *n-cluster* 4. Penelitian ini mengindikasikan bahwa skenario tanpa penanganan outlier menghasilkan *clustering* yang lebih stabil pada *K-Means* dibandingkan *Fuzzy C-Means*. Temuan ini diharapkan dapat menjadi referensi dalam penerapan metode *clustering* untuk analisis inflasi di Indonesia, dalam mendukung pembuatan kebijakan ekonomi yang lebih tepat.

Kata kunci— *K-Means*, *Fuzzy C-Means*, *Davies Bouldin Index*, Inflasi, *Silhouette Score*

ABSTRACT

This study analyzes the comparison between the *K-Means* and *Fuzzy C-Means* algorithms in clustering cities in Indonesia based on types of inflation. The dataset used was obtained from the Central Bureau of Statistics (BPS), covering 10 types of inflation from January to October 2024, with a total of 5,371 data rows. A heatmap visualization was used for feature selection, resulting in six columns trained in the model. Both algorithms were tested in two scenarios: with and without outlier handling. The evaluation was conducted using the *Silhouette Score* and *Davies-Bouldin Index* to assess clustering quality. The results show that *K-Means* without outlier handling at *n-cluster* 6 achieved the best performance with a *Silhouette score* of 0.2493 and a DBI of 1.2061, indicating good cluster separation. Meanwhile, for the *Fuzzy C-Means* model, the best scenario without outlier handling was found at *n-cluster* 4. This study indicates that the scenario without outlier handling produces more stable clustering in *K-Means* compared to *Fuzzy C-Means*. These findings are expected to serve as a reference for the application of clustering methods for inflation analysis in Indonesia, supporting more precise economic policy-making.

Keywords— *K-Means*, *Fuzzy C-Means*, *Davies Bouldin Index*, Inflation, *Silhouette Score*

1. PENDAHULUAN

Inflasi merupakan fenomena ekonomi dimana harga barang dan jasa mengalami kenaikan yang berkelanjutan dan kenaikan harga tersebut dapat mempengaruhi harga barang dan jasa lainnya. Secara umum inflasi dapat berdampak negatif dan positif terhadap perekonomian. Dalam situasi inflasi tinggi dan fluktuatif, ekonomi negara dianggap sedang tidak stabil, hal tersebut dapat menyebabkan peningkatan kemiskinan dan pengangguran pada sebuah negara [1]. Inflasi di Indonesia memiliki dampak yang besar terhadap sektor ekonomi, termasuk penurunan daya beli masyarakat yang berkelanjutan apabila tidak diimbangi dengan kenaikan pendapatan, mengakibatkan menurunnya konsumsi rumah tangga dan berpengaruh signifikan terhadap Produk

Domestik Bruo (PDB). Dalam jangka panjang, kondisi tersebut dapat menyebabkan penurunan kinerja perusahaan, peningkatan pengangguran, dan ketidakstabilan ekonomi. Inflasi juga mendorong fluktuasi harga bahan pokok yang tidak kembali ke tingkat semula, sehingga memerlukan kebijakan moneter yang ketat untuk menjaga stabilitas ekonomi dan memitigasi dampak negatif yang ada [2]. Secara Umum inflasi di Indonesia dianggap baik jika berada di bawah ambang batas 5%. Pada level ini, inflasi tidak memiliki dampak negatif yang signifikan terhadap pertumbuhan ekonomi.

Sebaliknya, inflasi dianggap buruk atau berdampak negatif jika melebihi ambang batas 5%. Di atas level ini, inflasi dapat menghambat pertumbuhan ekonomi secara signifikan, menyebabkan turunnya pertumbuhan ekonomi, mengurangi efisiensi sumber daya, serta meningkatkan biaya produksi yang menghambat produksi barang dan jasa [3]. Bank Indonesia berperan penting dalam pengendalian inflasi di Indonesia melalui penerapan kebijakan moneter, seperti pengaturan suku bunga, operasi pasar terbuka, dan pengelolaan cadangan wajib bank. Kebijakan ini telah berhasil menjaga inflasi dalam kisaran target yang ditetapkan meskipun dihadapkan pada tantangan, seperti fluktuasi harga komoditas internasional dan perubahan nilai tukar [4]. Disamping itu laporan dari pemerintah berperan dalam menentukan kebijakan fiskal dengan tujuan untuk mengelola anggaran negara agar ekonomi tetap stabil, pengangguran menurun dan mengendalikan inflasi. Keputusan pemerintah dalam mengelola inflasi sangat penting, dimana kebijakan yang tidak tepat dapat memperburuk kondisi ekonomi, sedangkan inflasi yang dikelola dengan baik dapat memberikan dorongan positif bagi pertumbuhan ekonomi [5]. Pemerintah dapat melakukan penanganan inflasi berdasarkan kelompok kota-kota-kota tersebut yang dikelompokkan berdasarkan indikator inflasi. Dengan hasil pengelompokan tersebut, pemerintah dapat merancang kebijakan yang lebih tepat sasaran dan menyesuaikan langkah-langkah penanganan inflasi sesuai dengan kebutuhan spesifik dari kelompok kota yang berbeda [6].

Clustering merupakan metode pembelajaran mesin yang digunakan untuk menemukan pola serupa dengan mengelompokkan elemen-elemen yang memiliki kedekatan fitur satu sama lain. Proses ini bertujuan untuk membentuk partisi optimal yang mengelompokkan titik-titik independen ke dalam klaster dengan memaksimalkan kesamaan dalam satu klaster dan perbedaan antar klaster [7]. Clustering dibagi menjadi dua pendekatan utama, yaitu pendekatan berbasis model probabilistik dan pendekatan nonparametrik. Pendekatan berbasis model probabilistik mengasumsikan bahwa data berasal dari campuran model probabilistik, seperti model campuran Gaussian, dengan algoritma EM (*Expectation-Maximization*). Sementara itu pendekatan clustering nonparametrik umumnya menggunakan fungsi objektif untuk mengukur kesamaan atau perbedaan, yang dapat dibagi menjadi metode hierarkis dan partisional, di mana metode partisional seperti model Fuzzy-Cmeans, dan metode K-Means menjadi yang paling populer digunakan [8]. evaluasi clustering adalah proses yang digunakan untuk mengukur kualitas hasil pengelompokan data yang dihasilkan oleh metode clustering. Salah satu cara yang umum digunakan adalah dengan *Davies-Bouldin Index* (DBI), yang mengevaluasi cluster berdasarkan nilai kohesi dan separasi [9]. Metode evaluasi lain yang sering digunakan untuk melakukan evaluasi cluster adalah *Silhouette Score*, dimana evaluasi tersebut metrik evaluasi untuk menilai kualitas hasil clustering. Cara kerjanya adalah dengan menghitung nilai *Silhouette* untuk setiap data dalam cluster.

Pada penelitian ini metode nonparametrik partisional seperti K-Means dan Fuzzy C-Means dipilih untuk melakukan clustering dikarenakan metode ini mampu mengelompokkan data berdasarkan kesamaan karakteristik tanpa memerlukan asumsi distribusi data tertentu yang dimana dataset yang digunakan mencakup berbagai indikator inflasi di sejumlah kota di Indonesia, termasuk komponen pengeluaran seperti pakaian, perawatan kesehatan, pendidikan, dan transportasi. Penggunaan kedua model tersebut akan dievaluasi menggunakan *Silhouette Score* dan *Davies-Bouldin Index*, untuk menentukan metode yang memberikan hasil terbaik dalam melakukan clustering. Diharapkan, model yang menunjukkan performa paling optimal dapat menjadi acuan dalam mengelompokkan kota berdasarkan tipe inflasi, sehingga dapat mendukung kebijakan pemerintah dalam pengambilan keputusan yang lebih tepat [10].

2. METODE PENELITIAN

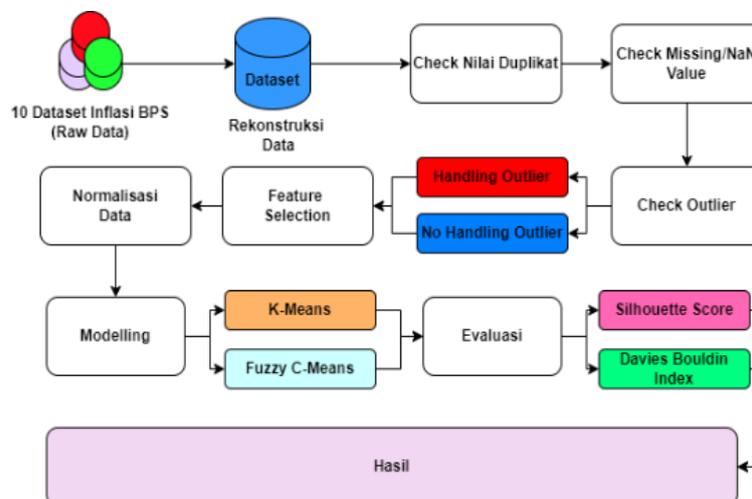
2.1 Datasets

Dataset yang digunakan dalam penelitian ini adalah data *Year-on-Year Inflation* (Y-on-Y) yang mencakup 10 tipe inflasi di Indonesia. Data ini diperoleh dari Badan Pusat Statistik (BPS) dengan periode waktu dari Januari hingga Oktober 2024. Dataset terdiri dari total 150 baris data untuk setiap kota di seluruh Indonesia, mencakup berbagai tipe inflasi. Tipe-tipe inflasi yang tercakup dalam masing-masing dataset yaitu: *Clothing and Footwear, Education, Equipments and Routine Household Maintenance, Health, Housing, Electricity, and Household Fuel, Information, Communication, and Financial Services, Personal Care and Other Services, Provision of Food and Beverages/Restaurant, Recreation, Sports, and Culture, serta Transportation.*

Seluruh dataset tersebut digabungkan menjadi satu, menghasilkan total 5.371 baris data. Data ini merupakan dataset mentah hasil penggabungan 10 dataset di atas berdasarkan tipe inflasinya yang digunakan dalam penelitian ini. Dataset tersebut mencakup rentang nilai inflasi berdasarkan tipe inflasi di Indonesia yang terdiri dari 3 jenis value (positif, negatif, 0, dan '-') apabila nilai tersebut positif, maka dianggap terjadi inflasi, apabila value bernilai negatif maka terjadi deflasi, apabila bernilai 0, berarti tidak ada perubahan dan apabila bernilai '-' maka tidak ada record data yang disimpan pada kota, tipe inflasi, dan bulan tersebut. Menurut laporan Badan Pusat Statistik (BPS), pada Februari 2024, angka inflasi di Indonesia mencapai 4,75%. Provinsi dengan inflasi tertinggi adalah Papua Selatan sebesar 4,61%, sementara kabupaten dengan inflasi tertinggi adalah Minahasa Selatan dengan tingkat inflasi mencapai 6,06% [11]. Angka inflasi ini tergolong masih stabil dan dapat di kendalikan, dimana berdasarkan penelitian, inflasi dapat dikategorikan ke dalam beberapa tingkatan. Inflasi ringan atau normal berada pada kisaran kurang dari 10% per tahun dan dianggap stabil serta dapat diterima. Inflasi sedang berkisar antara 10% hingga 30% per tahun, yang mulai menunjukkan adanya tekanan ekonomi. Inflasi berat, dengan rentang 30% hingga 100% per tahun, mencerminkan kondisi ekonomi yang lebih terganggu. Sementara itu, hiperinflasi, yang melebihi 100% per tahun, menandakan situasi ekonomi yang sangat buruk dan berpotensi menimbulkan krisis pada sebuah negara [12].

2.2 Alur Penelitian

Penelitian ini menggunakan metode clustering K-Means dan C-Means untuk mengelompokkan kota-kota di Indonesia berdasarkan tipe inflasi. Data inflasi Year-on-Year yang diperoleh dari Badan Pusat Statistik (BPS) mencakup 10 jenis data yang digabungkan menjadi dataset mentah. Selanjutnya, dataset tersebut diproses melalui tahap preprocessing dan dilatih oleh model untuk dapat kemudian di evaluasi. Untuk garis besar penelitian dapat dilihat Gambar 2.



Gambar 2 Alur Penelitian

2.2.1 Pengumpulan dan Rekonstruksi Data

10 data yang di dapat dari situs resmi Badan Pusat Statistik (BPS), selanjutnya di lakukan pivoting table. Pivot Table adalah metode untuk meringkas, menganalisis, dan menyajikan data dalam format yang mudah dipahami, di mana Pivot Table memungkinkan pengelompokan data secara akurat dan efisien [13]. dimana sebelumnya 10 dataset tersebut digabungkan menjadi satu dengan hasil total 5.371 baris dan 12 kolom, yang terdiri dari Kolom Kota, Tipe Inflasi, dan value Inflasi setiap bulan nya terhiong dari bulan Januari – Oktober 2024. Data tersebut lalu diringkas dan ditambahkan beberapa kolom dan menghasilkan 150 baris dengan total 36 kolom. Sebanyak 150 baris tersebut mewakili semua nilai unik kota di seluruh Indonesia, sementara 36 kolom terdiri dari 1 kolom kota dan 35 kolom sub-tipe inflasi yang diambil dari 10 dataset inflasi. Nilai pada 35 kolom sub-tipe inflasi tersebut diisi dengan rata-rata inflasi sepanjang bulan untuk setiap kota. Menggunakan rata-rata sebagai cara merangkum data atau membuat fitur baru tidak menghilangkan informasi penting terutama jika data memiliki tingkat ketidakpastian atau sebaran yang berbeda [14]. Hasil akhir dari proses pengolahan dataset yang akan digunakan untuk tahap preprocessing selanjutnya dapat dilihat pada Gambar 1.

City	Inf. Clothing	Inf. Footwear	Inf. Educati...	Inf. Basic E...	Inf. Middle ...	Inf. Higher ...
KAB ACEH TENGAH	4.534	4.101	0.133	0.357	0	0
MEULABOH	2.411	1.266	1.102	2.106	0	0
KAB ACEH TAMIANG	2.373	3.073	3.061	0.125	0.214	2.343
KOTA BANDA ACEH	2.808	0.544	0.416	1.734	0	0
KOTA LHOEKSEUMAWE	1.576	7.925	2.262	4.693	2.428	0
KAB LABUHANBATU	5.792	2.603	0.3	1.14	0	0
KAB KARO	4.917	7.114	0	0	0	0
KAB DELI SERDANG	3.31	0.7	0.261	0.789	0	0
KOTA SROINGA	2.598	2.523	3.121	3.988	3.62	6.593
KOTA PEMATANGSIANTAR	0.457	1.525	5.387	4.133	2.206	10.122
KOTA MEDAN	1.242	1.486	1.685	0.806	0.691	4.852
KOTA PADANGSIDIMPUAN	2.77	1.736	1.732	0.146	5.111	0
KOTA GUNUNGSITOLI	1.687	2.07	3.413	5.12	3.333	3.547
KAB DHARMASRAYA	3.318	0.449	0.812	3.446	0.16	0
KAB PASAMAN BARAT	4.362	4.292	0.366	0.67	0.018	0.582
KOTA BANANG	0.703	0.320	1.708	4.458	3.486	0.57

Gambar 2 Dataset Setelah Di Rekonstruksi

Berikut adalah penjelasan rinci mengenai kolom-kolom dalam dataset yang telah direkonstruksi dan melalui tahap preprocessing.

Tabel 1. Detail Dataset Year-on-Year Inflation Periode 2024

Nama Kolom	Deskripsi Kolom	Nama Kolom	Deskripsi Kolom
City	Nama Kota/Kabupaten di Indonesia	Inf_Health_Medicines_Products	Tingkat inflasi untuk produk obat-obatan.
Inf_Clothing	Tingkat inflasi untuk kategori pakaian.	Inf_Outpatient_Services	Tingkat inflasi untuk jasa rawat jalan.
Inf_Footwear	Tingkat inflasi untuk kategori alas kaki.	Inf_Inpatient_Services	Tingkat inflasi untuk jasa rawat inap.
Inf_Education_Services	Tingkat inflasi untuk jasa pendidikan secara umum.	Inf_Water_Electricity_Household	Tingkat inflasi untuk air dan listrik rumah tangga.
Inf_Basic_Education	Tingkat inflasi untuk pendidikan dasar.	Inf_House_Rent	Tingkat inflasi untuk sewa rumah.
Inf_Middle_Education	Tingkat inflasi untuk pendidikan menengah.	Inf_House_Maintenance	Tingkat inflasi untuk pemeliharaan rumah.
Inf_Higher_Education	Tingkat inflasi untuk pendidikan tinggi.	Inf_Water_Supply	Tingkat inflasi untuk pasokan air.
Inf_Household	Tingkat inflasi untuk kategori rumah tangga secara umum.	Inf_Electricity_Supply	Tingkat inflasi untuk pasokan listrik.

Nama Kolom	Deskripsi Kolom	Nama Kolom	Deskripsi Kolom
Inf_Clothing	Tingkat inflasi untuk kategori pakaian.	Inf_Financial_Services	Tingkat inflasi untuk layanan keuangan.
Inf_Footwear	Tingkat inflasi untuk kategori alas kaki.	Inf_Communication_Equipment	Tingkat inflasi untuk peralatan komunikasi.
Inf_Education_Services	Tingkat inflasi untuk jasa pendidikan secara umum.	Inf_Communication_Services	Tingkat inflasi untuk layanan komunikasi.
Inf_Furnitures_Equipment	Tingkat inflasi untuk perabotan dan peralatan rumah tangga.	Inf_Personal_Care	Tingkat inflasi untuk perawatan pribadi.
Inf_Household_Textiles	Tingkat inflasi untuk tekstil rumah tangga, seperti gorden dan selimut.	Inf_Food_Beverage_Services	Tingkat inflasi untuk layanan makanan dan minuman.
Inf_Household_Tools	Tingkat inflasi untuk alat-alat rumah tangga.	Inf_Recreation_Sports_Culture	Tingkat inflasi untuk rekreasi, olahraga, dan budaya.
Inf_Tableware	Tingkat inflasi untuk peralatan makan.	Inf_School_Supplies	Tingkat inflasi untuk perlengkapan sekolah.
Inf_Housing_Equipment	Tingkat inflasi untuk perlengkapan perumahan.	Inf_Recreation_Sport_Services	Tingkat inflasi untuk layanan rekreasi dan olahraga.
Inf_Household_Services	Tingkat inflasi untuk jasa rumah tangga.	Inf_Transportation	Tingkat inflasi untuk kategori transportasi.
Inf_Health	Tingkat inflasi untuk kategori kesehatan secara umum.	Inf_Vehicle_Purchase	Tingkat inflasi untuk pembelian kendaraan.

2.2.2 Preprocessing Data

Dalam melakukan *Preprocessing Data*, *Exploratory Data Analyst* (EDA) dilakukan untuk menganalisis dan merangkum karakteristik utama dataset melalui penggunaan grafik statistik dan metode visualisasi. Tujuan dari EDA adalah untuk menarik hipotesis terkait fenomena yang diamati dan menilai asumsi yang diajukan [15]. EDA terdiri dari beberapa tahap, dimulai dengan pengecekan terhadap duplikasi data, hal ini dilakukan karena Duplikasi data berdampak negatif pada pemodelan pembelajaran mesin dengan meningkatkan waktu pelatihan dan konsumsi energi. Hal ini juga dapat menyebabkan *overfitting*, sehingga mengurangi generalisasi model yang akan dibuat [16]. Mengecek Missing dan NaN value dilakukan untuk memastikan bahwa data yang digunakan pada penelitian ini tidak memiliki record yang kosong, hal tersebut perlu dilakukan karena Nilai yang hilang dapat mengganggu performa dan kemampuan interpretasi model secara signifikan, yang menyebabkan potensi bias dan wawasan yang tidak dapat diandalkan, sehingga penanganan data yang hilang perlu dilakukan dalam memodelkan machine learning [17].

Pengecekan outlier di lakukan pada EDA menggunakan visualisasi barplot untuk kemudian di analisis dan di handling apabila diperlukan, outlier sendiri merupakan data atau titik yang memiliki nilai yang jauh berbeda atau menyimpang dari sebagian besar data lainnya dalam suatu dataset [18]. Menangani outlier dalam pembuatan model Machine Learning sangat penting karena dapat secara signifikan memengaruhi performa model dan pengambilan keputusan. Deteksi outlier yang efektif dapat meningkatkan kualitas data, sehingga menghasilkan prediksi yang lebih akurat dan analisis yang lebih baik [19]. Feature selection dilakukan untuk mengurangi dimensi dari dataset yang digunakan dengan cara mengeliminasi atribut-atribut yang kurang relevan [20], pemilihan fitur berdampak signifikan terhadap pembelajaran mesin dengan meningkatkan performa model, mengurangi overfitting, dan mengoptimalkan sumber daya komputasi sehingga menghasilkan peningkatan akurasi model [21]. Pada penelitian ini, Feature Selection di lakukan menggunakan matriks korelasi dengan visualisasi Heatmap. Heatmap sendiri merupakan visualisasi data dua dimensi yang memanfaatkan skala warna untuk merepresentasikan nilai dalam bentuk grid. Visualisasi ini sering digunakan untuk menampilkan korelasi antara dua variabel atau

mengidentifikasi pola dalam data yang kompleks secara lebih rinci [22]. Terakhir sebelum dilatih pada model normalisasi dilakukan menggunakan *MinmaxScaler* pada fitur yang dipilih menggunakan Heatmap, normalisasi nilai diperlukan untuk memastikan stabilitas nilai numerik dalam model memproses data [23]. *MinmaxScaler* adalah teknik normalisasi data yang mengubah fitur kedalam rentang 0 sampai 1 dimana teknik ini menyesuaikan skala data tanpa mengubah perbedaan dalam rentang, sehingga meningkatkan performa algoritma model [24].

2.2.3 Modelling dan Evaluasi

Pemodelan K-Means dan Fuzzy C-Means dilakukan dengan 10 kali percobaan menggunakan jumlah cluster yang bervariasi, mulai dari 2 hingga 10 cluster. Proses ini dilakukan dalam dua kondisi yaitu modelling dengan data yang outlier nya di tangani dan dengan data tanpa penanganan outlier. Hasil evaluasi setiap percobaan diukur kinerja cluster nya menggunakan evaluasi *Silhouette Score* dan *Davies-Bouldin Index*, dimana hasil evaluasi kemudian dicatat untuk menentukan jumlah *cluster* dan kondisi terbaik yang menghasilkan performa optimal.

2.3 K-Means

K-Means adalah algoritma clustering berbasis partisi yang secara luas digunakan untuk mengelompokkan data ke dalam sejumlah cluster yang telah ditentukan sebelumnya. Proses kerja K-Means dimulai dengan inialisasi *centroid* secara acak sesuai dengan jumlah cluster K yang diinginkan. Setiap data dalam dataset kemudian diukur jaraknya ke *centroid* dan dikelompokkan ke dalam cluster terdekat. Setelah semua data dikelompokkan, *centroid* diperbarui dengan menghitung rata-rata posisi dari data yang termasuk dalam masing-masing cluster. Proses ini diulang hingga perubahan pada posisi *centroid* tidak signifikan atau jumlah iterasi yang ditentukan tercapai [25]. K-Means bekerja dengan rumus sebagai berikut

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

Dimana x dan y masing-masing merepresentasikan dua titik dalam ruang n -dimensi, dengan x sebagai data yang di analisis dan y sebagai *centroid* atau titik tengah dari cluster. Variable n menunjukkan jumlah dimensi atau fitur dalam data, sedangkan x_i dan y_i adalah koordinat dari dimensi ke- i untuk titik x dan y . Persamaan ini menghitung jarak linear antara data dan *centroid* dengan mengkuadratkan selisih tiap koordinat, menjumlahkan hasilnya, dan mengambil akar kuadrat dari total tersebut. Perhitungan ini membantu algoritma menentukan keanggotaan data dalam cluster berdasarkan jarak terdekatnya ke *centroid*. Algoritma Kmeans dikenal karena kesederhanaannya dan kecepatan prosesnya dalam menyelesaikan masalah clustering, terutama untuk data numerik. K-Means juga sangat fleksibel dan efisien, sehingga mampu menangani data dalam skala besar dan bervariasi. Kelebihan lain dari K-Means adalah kemampuannya dalam mengenali pola dan hubungan dalam data, yang dapat mendukung proses pengambilan keputusan yang lebih baik [26].

2.4 Fuzzy C-Means

FCM adalah algoritma clustering yang membagi data ke dalam beberapa cluster berdasarkan derajat keanggotaan fuzzy, yang memungkinkan setiap data dapat menjadi anggota lebih dari satu cluster dengan derajat keanggotaan tertentu. Algoritma ini sering digunakan untuk pengolahan data yang memerlukan pengelompokan fleksibel. Cara kerja Fuzzy C-Means dapat di interpretasikan pada persamaan berikut.

$$J(U, V) = \sum_{i=1}^c \sum_{j=1}^K u_{ij}^m ||x_j - v_i||^2 \quad (2)$$

Pada Rumus 2 U merupakan matriks partisi dengan elemen u_{ij} nya menunjukkan derajat keanggotaan data j terhadap cluster i . dan V mewakili himpunan pusat cluster v_i ; sementara m adalah eksponen fuzzy yang mengatur tingkat keburaman dalam keanggotaan cluster, di mana nilai m lebih besar 1. Jarak antara x_j dan pusat cluster V_i diukur dengan menggunakan jarak euclidean yang

dinyatakan sebagai $\|x_j - v_i\|$. Algoritma Fuzzy C-Means berhenti ketika ada perubahan dalam matriks U diantara iterasi berturut turut kurang dari ambang batas yang telah di tentukan dan menandakan bahwa konvergensi telah tercapai dan hasil clustering stabil. *Algoritma Fuzzy C-Means* (FCM) memiliki beberapa kelebihan signifikan dalam proses clustering. Algoritma ini memungkinkan fleksibilitas dalam pengelompokan, di mana setiap data dapat memiliki derajat keanggotaan di lebih dari satu cluster, membuatnya sangat berguna untuk data yang memiliki batasan antar kelompok yang tidak tegas, selain itu FCM memiliki kemampuan dalam menangkap ketidakpastian dan memberikan hasil yang lebih halus dalam analisis data dibandingkan dengan algoritma clustering lainnya yang bersifat tegas. Hal ini menjadikannya ideal untuk digunakan dalam situasi di mana data memiliki tumpang tindih antar cluster atau ketika ketelitian tinggi dalam pengelompokan diperlukan[27].

2.5 Silhouette Score

Silhouette Score adalah metrik evaluasi yang digunakan untuk menilai kualitas hasil clustering. Nilai ini mengukur seberapa mirip suatu data dengan data dalam cluster yang sama dibandingkan dengan data di cluster lain. Skor ini berkisar antara -1 hingga 1, di mana nilai yang lebih tinggi menunjukkan cluster yang lebih baik [10]. Untuk setiap data, *Silhouette Score* dihitung dengan membandingkan jarak rata-rata data tersebut ke semua data lain di cluster yang sama (disebut $a(i)$) dengan jarak rata-rata data tersebut ke semua data di cluster terdekat (disebut $b(i)$). Skor *Silhouette* dihitung untuk semua data, dan nilai rata-rata dari semua skor digunakan sebagai evaluasi keseluruhan sebagaimana di rumuskan pada persamaan berikut.

$$s(i) = \frac{b(i) - a(i)}{\max\{a(i), b(i)\}} \quad (3)$$

Pada Rumus 3 $s(i)$ merupakan Silhouette score untuk data i , $a(i)$ adalah rata-rata jarak data ke i ke data lain dalam cluster yang sama (*within cluster similarity*), dan $b(i)$ merupakan jarak rata-rata data i ke data di cluster terdekat (*between cluster dissimilarity*), apabila skor Silhouette Score bernilai $a(i) < b(i)$ atau bernilai positif menandakan bahwa data lebih dekat dengan cluster sendiri daripada cluster lain. Skor mendekati 1 menunjukkan bahwa data terkelompok dengan baik. Sedangkan skor negatif menunjukkan kemungkinan bahwa data berada pada cluster yang salah. *Silhouette Score* unggul dalam mengevaluasi clustering secara objektif tanpa memerlukan data pelatihan, menjadikannya ideal untuk metode *unsupervised*. Skor ini membantu menentukan jumlah cluster optimal dengan menilai seberapa baik data terkelompok dibandingkan dengan cluster terdekat. Nilai positif menunjukkan clustering yang baik, sedangkan nilai mendekati nol atau negatif menandakan kemungkinan data berada dalam cluster yang salah. Hal ini menjadikan *Silhouette Score* alat yang efektif untuk memvalidasi hasil clustering [28].

2.6 Davies - Bouldin Index (DBI)

Davies-Bouldin Index (DBI) adalah metrik evaluasi yang digunakan untuk menilai kualitas hasil clustering dengan mengukur seberapa baik cluster-cluster dipisahkan dan seberapa padat data dalam cluster tersebut. Semakin rendah nilai DBI, semakin baik hasil clustering karena menunjukkan bahwa cluster lebih kompak dan terpisah dengan baik [29]. Bagaimana *Davies - Bouldin Index* bekerja dapat dilihat pada persamaan berikut.

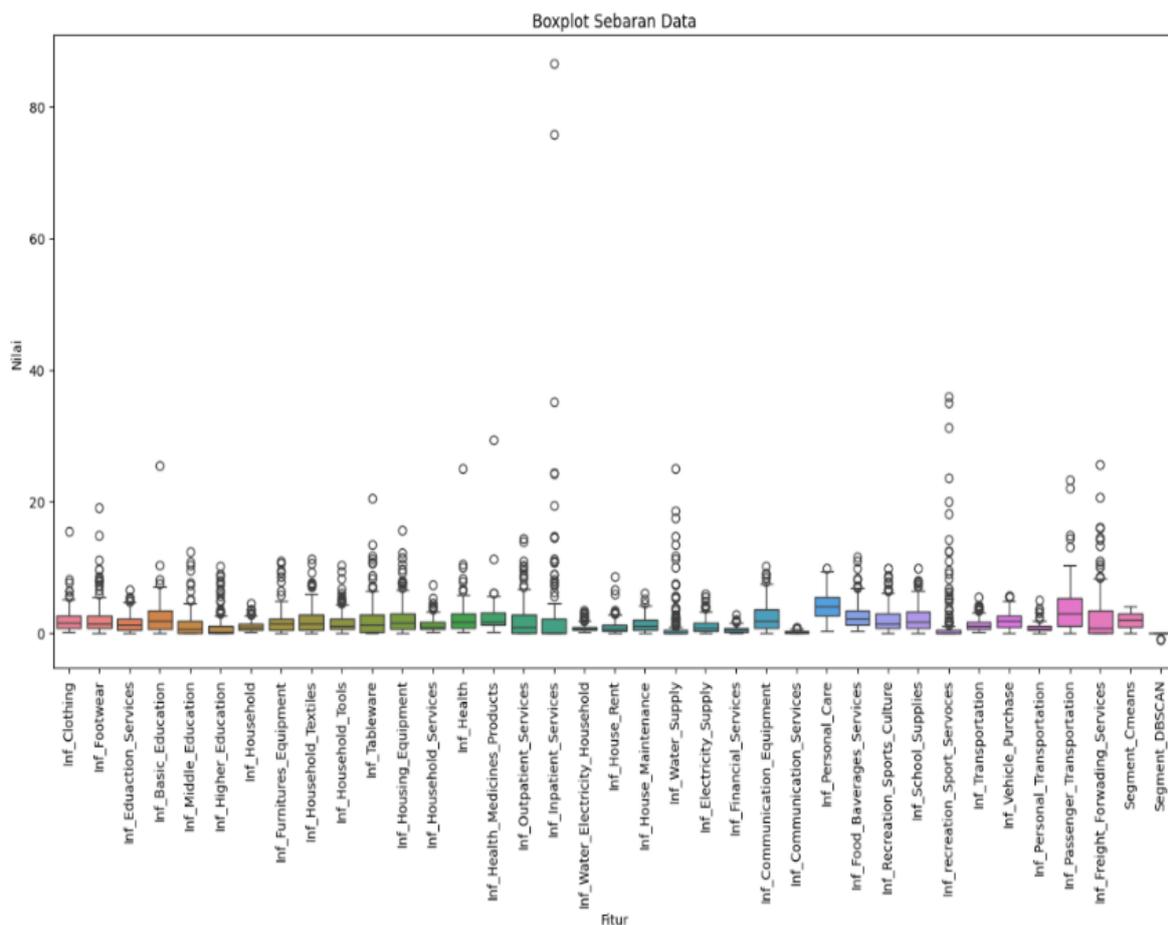
$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{(i \neq j)} \left(\frac{S_i + S_j}{d(\bar{x}_i, \bar{x}_j)} \right) \quad (4)$$

Rumus 4 menunjukkan bahwa DBI dihitung sebagai rata-rata dari nilai maksimum rasio antara jumlah rata-rata jarak intracluster S_i dan S_j serta jarak antar pusat cluster $d(\bar{x}_i \text{ dan } \bar{x}_j)$ untuk semua pasangan cluster i dan j . Dimana S_i adalah rata-rata jarak antara elemen dalam cluster i ke pusatnya yang mengukur kepadatan cluster, lalu $d(\bar{x}_i \text{ dan } \bar{x}_j)$ adalah jarak antara pusat cluster i dan j yang mengukur seberapa jauh cluster-cluster tersebut di pisah. *Davies-Bouldin Index* (DBI) efektif untuk mengevaluasi clustering dengan mempertimbangkan kepadatan dan keterpisahan cluster. DBI mengukur rasio antara jarak intracluster rata-rata dan jarak antarcentroid, di mana nilai DBI yang

lebih rendah menunjukkan clustering yang lebih baik karena cluster lebih kompak dan terpisah jelas. Hal ini membuat DBI menjadi alat evaluasi yang objektif dan tidak memerlukan data pelatihan[30].

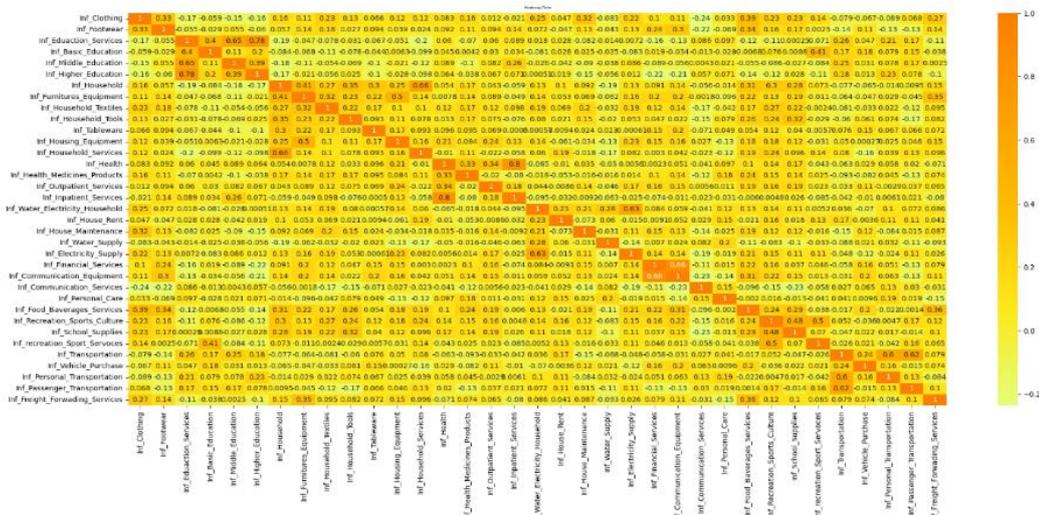
3. HASIL DAN PEMBAHASAN

Dari dataset yang dikumpulkan dan di rekonstruksi dari BPS, ditemukan beberapa baris data yang memiliki nilai '-'. Nilai ini menunjukkan bahwa tidak terdapat data yang direkam untuk kota tertentu, tipe inflasi, dan bulan tertentu. Hal ini bisa disebabkan oleh ketiadaan data yang dilaporkan, kekosongan data, atau karena pemerintah tidak memiliki data tersebut. Oleh karena itu, diputuskan untuk mengganti nilai '-' tersebut dengan angka 0. Dalam konteks nilai inflasi, angka 0 menunjukkan bahwa tidak terjadi inflasi maupun deflasi di kota tersebut pada tipe dan bulan tersebut. Dari hasil analisis yang di lakukan duplikasi data tidak di temukan, dan tidak ada baris data yang di hapus pada dataset. Hasil analisis pengecekan Outlier menggunakan boxplot terlihat bahwa banyak sekali outlier yang terdapat pada tiap fitur seperti yang terlihat pada Gambar 3.



Gambar 3 Boxplot Sebaran Outlier

Gambar 3 menunjukkan bahwa hampir di semua kolom tipe inflasi terdapat outlier, dengan nilai tertinggi berada pada kolom Inf_Inpatient_Services, di mana nilai outlier mencapai 86.5. Nilai ini sangat tinggi dan berpotensi merusak kualitas data. Namun, mengingat data ini berasal dari BPS yang sudah terverifikasi, maka pada penelitian ini dibuat dua skenario yaitu skenario dengan penanganan outlier dan satu skenario tanpa penanganan outlier. Kedua skenario tersebut kemudian dimasukkan ke dalam model clustering untuk analisis lebih lanjut terkait hasil clustering yang dibuat. Visualisasi pemilihan fitur dengan metode Heatmap dapat dilihat pada Gambar 4.



Gambar 4 Visualisi Heatmap Correlation

Dari hasil analisis visualisasi pada Gambar 4 maka di ambil 6 kolom sebagai kolom yang akan di latih pada model. Kolom-kolom yang dipilih untuk analisis clustering dalam penelitian ini meliputi *Inf_Clothing*, *Inf_Health*, *Inf_Personal_Care*, *Inf_Food_Beverages_Services*, *Inf_Housing_Equipment*, dan *Inf_Transportation*. Pemilihan kolom-kolom tersebut didasarkan pada karakteristik korelasi tiap fitur yang memberikan variasi informasi penting. Kolom *Inf_Clothing* dipilih karena memiliki korelasi rendah dengan sebagian besar kolom lainnya, sehingga memberikan informasi unik yang tidak berlebihan. Kolom *Inf_Health* juga dipilih karena korelasi rendahnya, yang menambah informasi baru tanpa tumpang tindih dengan variabel lain. Kolom *Inf_Personal_Care* dipilih karena meskipun memiliki korelasi moderat (memiliki tingkat hubungan yang cukup kuat dengan variabel lain) dengan beberapa kolom seperti *Inf_Food_Beverages_Services*, tetap cukup independen untuk menyumbang variasi dalam analisis. Sementara itu, *Inf_Food_Beverages_Services* dipilih karena memiliki korelasi rendah dengan sebagian besar kolom lain, membuatnya relevan untuk mempelajari pola konsumsi. Kolom *Inf_Housing_Equipment* dipilih karena korelasi rendahnya yang menambah dimensi baru dalam analisis, dan terakhir, *Inf_Transportation* dipilih meskipun memiliki korelasi moderat, karena mewakili kategori pengeluaran mobilitas yang signifikan.

Penerapan random state sebesar 42 ditetapkan pada kedua model, baik K-Means maupun C-Means. Hal ini dilakukan untuk memastikan hasil yang dihasilkan konsisten setiap kali model dijalankan, sehingga hasil analisis tidak berubah karena variasi acak dalam proses pengelompokan data. Berikut adalah hasil dari setiap model dengan 2 skenario yang telah ditetapkan sebelumnya.

Tabel 2 Hasil Eksperimen

Algoritma	n-Cluster	Silhouette Svaluation	DBI Evaluation	Silhouette Svaluation	DBI Evaluation
		No Handling Outliers		Handling Outliers	
K M E A N S	2	0.206154137	1.870448574	0.251331394	1.947975699
	3	0.217734649	1.641748733	0.239130401	1.860446158
	4	0.228115669	1.363325921	0.159975542	1.811004425
	5	0.249387821	1.206159741	0.150861696	1.636171616
	6	0.173471512	1.435620754	0.168112798	1.552693196
	7	0.199484431	1.275941325	0.174655404	1.517431156
	8	0.183372664	1.399133188	0.180103074	1.408013245
	9	0.186577531	1.411299411	0.190640571	1.33439897
	10	0.153993643	1.49248645	0.185506838	1.318554886
	11	0.157176412	1.324954691	0.175846323	1.291509674

Algoritma	n-Cluster	Silhouette Svaluation	DBI Evaluation	Silhouette Svaluation	DBI Evaluation
		No Handling Outliers		Handling Outliers	
C M E A N S	2	0.198405892	1.856082102	0.203598058	2.141995016
	3	0.202231206	1.63362449	0.131525607	2.242701049
	4	0.192827489	1.615727478	0.083855728	1.978745955
	5	0.114717006	1.616825767	0.033911333	2.324165524
	6	0.125284774	1.500821165	0.023599799	2.327228286
	7	0.091323343	1.454776125	0.014720331	3.382059242
	8	0.090922348	1.728219701	-0.040322559	3.32579683
	9	0.044108152	1.55973115	0.016640965	3.145070332
	10	0.056429167	1.842624728	-0.061091025	2.774016862
	11	0.054644126	1.874153367	0.001291933	3.536325308

Berdasarkan tabel hasil evaluasi, terlihat bahwa skor *Silhouette* dan *Davies-Bouldin Index* (DBI) digunakan untuk menilai kualitas clustering pada model K-Means dan C-Means dengan skenario tanpa penanganan outlier dan dengan penanganan outlier. Untuk model K-Means, skor *Silhouette* tertinggi tanpa penanganan outlier dicapai pada n-cluster 6 dengan nilai sekitar 0.2493, sedangkan DBI pada klaster ini adalah 1.2061, yang relatif rendah menunjukkan clustering yang terbaik. Dalam skenario dengan penanganan outlier, skor *Silhouette* terbaik didapatkan pada n-cluster 2 dengan nilai 0.2513, dan DBI relatif tinggi di 1. Hal ini menunjukkan bahwa skenario tanpa penanganan outlier menghasilkan hasil clustering yang lebih baik pada model K-Means. Untuk model C-Means sendiri, skor *Silhouette* tertinggi di dapatkan tanpa penanganan outlier terlihat pada n-cluster 4 dengan nilai sekitar 0.1928, sementara DBI pada klaster ini adalah 1.6157, yang cukup rendah. Pada skenario dengan penanganan outlier, skor *Silhouette* tertinggi tercatat pada n-cluster 2 dengan nilai 0.2035, namun DBI lebih tinggi di 1.978, menandakan bahwa penanganan outlier mungkin kurang optimal pada model C-Means.

4. KESIMPULAN

Dari hasil yang sudah dianalisis, dapat disimpulkan bahwa clustering dengan K-Means dan C-Means menunjukkan perbedaan kualitas antara skenario tanpa penanganan outlier dan dengan penanganan outlier. Dalam penelitian ini, dataset yang digunakan mencakup berbagai tipe inflasi di kota-kota di Indonesia, yang diperoleh dari Badan Pusat Statistik (BPS) dan mencakup 10 jenis inflasi. Penggantian nilai ‘-’ dengan 0 tetap menjaga integritas data tanpa menghapus baris. Model K-Means tanpa penanganan outlier memberikan hasil terbaik pada n-cluster 6 dengan skor *Silhouette* 0.2493 dan DBI 1.2061, menunjukkan pemisahan klaster yang baik. Sebaliknya, skenario dengan penanganan outlier pada K-Means memberikan skor *Silhouette* terbaik pada n-cluster 2, tetapi dengan DBI yang lebih tinggi, menandakan performa yang kurang optimal. Pada model C-Means, skenario tanpa penanganan outlier memiliki skor *Silhouette* terbaik di n-cluster 4, sedangkan skenario dengan penanganan outlier mencatat skor terbaik di n-cluster 2, namun dengan DBI yang tinggi, menunjukkan hasil yang kurang stabil. Model terbaik diharapkan dapat membantu melakukan clustering yang efektif untuk memisahkan tipe inflasi, sehingga pemerintah dapat mengambil langkah-langkah kebijakan yang lebih tepat dan efisien dalam menangani inflasi di berbagai kota.

DAFTAR PUSTAKA

- [1] A. Salim And Fadilla, “Pengaruh Inflasi Terhadap Pertumbuhan Ekonomi Indonesia Anggun Purnamasari,” *Ekon. Sharia J. Pemikir. Dan Pengemb. Ekon. Syariah*, Vol. 7, No. 1, Pp. 17–28, 2021, [Online]. Available: [Www.Bps.Go.Id](http://www.bps.go.id),

- [2] E. N. Nurkhanifah, "Analisis Dampak Menurunnya Daya Beli Di Lingkungan Masyarakat Indonesia Akibat Inflasi," *Sahmiyya*, Vol. 2, No. 1, P. 241, 2023.
- [3] A. Putri And R. J. Anward, "Efek Ambang Batas Inflasi Terhadap Pertumbuhan Ekonomi Di Indonesia," *Jiep J. Ilmu Ekon. Dan Pembang.*, Vol. 6, No. 2, P. 547, 2023, Doi: 10.20527/Jiep.V6i2.11008.
- [4] S. Septiani, T. Rahmawati, V. D. Oktariani, E. Evi, And A. Fadilla, "Peran Kebijakan Moneter Di Indonesia Dalam Menghadapi Inflasi," *J. Econ. Assets, Eval.*, Vol. 1, No. 3, Pp. 1–7, 2024, Doi: 10.47134/Jeae.V1i3.204.
- [5] D. Safitri, "Pengaruh Ekspor, Pengeluaran Pemerintah Dan Inflasi Terhadap Pertumbuhan Ekonomi Di Kalimantan Tengah," *Jepp J. Ekon. Pembang. Dan Pariwisata*, Vol. 2, No. 1, Pp. 35–45, 2022, Doi: 10.52300/Jepp.V2i1.4432.
- [6] L. P. Sari, A. Fanani, And A. H. Asyhar, "Analisis Perbandingan Pengelompokan Kota di Indonesia Berdasarkan Indikator Inflasi Tahun 2021 Dengan Metode Ward Dan K-Means," *J. Sains Mat. Dan Stat.*, Vol. 9, No. 2, P. 108, 2023, Doi: 10.24014/Jsms.V9i2.21100.
- [7] D. Peng *Et Al.*, "Clustering by Measuring Local Direction Centrality for Data with Heterogeneous Density and Weak Connectivity," *Nat. Commun.*, Vol. 13, No. 1, Pp. 1–14, 2022, Doi: 10.1038/S41467-022-33136-9.
- [8] K. P. Sinaga And M. S. Yang, "Unsupervised K-Means Clustering Algorithm," *Ieee Access*, Vol. 8, Pp. 80716–80727, 2020, Doi: 10.1109/Access.2020.2988796.
- [9] Z. Nabila, A. Rahman Isnain, And Z. Abidin, "Analisis Data Mining Untuk Clustering Kasus Covid-19 Di Provinsi Lampung Dengan Algoritma K-Means," *J. Teknol. Dan Sist. Inf.*, Vol. 2, No. 2, P. 100, 2021, [Online]. Available: [Http://Jim.Teknokrat.Ac.Id/Index.Php/Jtsi](http://jim.teknokrat.ac.id/index.php/jtsi)
- [10] M. Shutaywi and N. N. Kachouie, "Silhouette Analysis for Performance Evaluation In Machine Learning With Applications to Clustering," *Entropy*, Vol. 23, No. 6, Pp. 1–17, 2021, Doi: 10.3390/E23060759.
- [11] Bps, "Inflasi Tahun-Ke-Tahun (Y-On-Y) Pada Bulan Februari 2024 Adalah 2,75 Persen," *Badan Pus. Stat.*, No. 15, Pp. 1–16, 2024, [Online]. Available: [Https://Www.Bps.Go.Id/Id/Pressrelease/2024/03/01/2301/Inflasi-Tahun-Ke-Tahun--Y-On-Y--Pada-Bulan-Februari-2024-Adalah-2-75-Persen.Html](https://www.bps.go.id/id/pressrelease/2024/03/01/2301/inflasi-tahun-ke-tahun--y-on-y--pada-bulan-februari-2024-adalah-2-75-persen.html)
- [12] S. Barat, "Hubungan Kausalitas Antara Inflasi Dan Pengangguran di Indonesia Tahun 2002-2021," Vol. Vii, No. April, Pp. 21–33, 2022.
- [13] M. Ridwan, M. F. Aponno, And J. Pelupessy, "Perhitungan Dan Penyajian Laporan Penjualan Dengan Menggunakan Pivot Table Pada Ud. Multi Tehnik," *J. Maneksi*, Vol. 9, No. 1, Pp. 304–309, 2020, Doi: 10.31959/Jm.V9i1.403.
- [14] M. Trassinelli and M. Maxton, "A Minimalistic and General Weighted Averaging Method for Inconsistent Data," 2024.
- [15] N. T. M. Sagala and F. Y. Aryatama, "Exploratory Data Analysis (Eda): A Study of Olympic Medallist," *Sistemasi*, Vol. 11, No. 3, P. 578, 2022, Doi: 10.32520/Stmsi.V11i3.1857.
- [16] A. Abadi, V. A. Dasu, And S. Sarkar, "Privacy-Preserving Data Deduplication For Enhancing Federated Learning of Language Models," 2024, [Online]. Available: [Http://Arxiv.Org/Abs/2407.08152](http://arxiv.org/abs/2407.08152)
- [17] T. L. Vo, T. Nguyen, H. L. Hammer, M. A. Riegler, And P. Halvorsen, "Explainability Of Machine Learning Models Under Missing Data," Pp. 1–44, 2024, [Online]. Available: [Http://Arxiv.Org/Abs/2407.00411](http://arxiv.org/abs/2407.00411)
- [18] P. R. Sihombing, S. Suryadiningrat, D. A. Sunarjo, And Y. P. A. C. Yuda, "Identifikasi Data Outlier (Pencilan) Dan Kenormalan Data Pada Data Univariat Serta Alternatif Penyelesaiannya," *J. Ekon. Dan Stat. Indones.*, Vol. 2, No. 3, Pp. 307–316, 2023, Doi: 10.11594/Jesi.02.03.07.
- [19] M. A. Raza, A. Mustafa, I. Ahmad, M. Gul, Shaista, And Amina, "Outlier Detection with Machine Learning in Wireless Sensor Networks," *Pakistan J. Sci. Res.*, Vol. 3, No. 1, Pp. 81–91, 2023, Doi: 10.57041/Pjoser.V3i1.964.
- [20] Julianto Indri Tri, Kurniadi Dede, Nashrulloh Muhammad Rikza, And Mulyani Asri, "Comparison of Classification Algorithm and Feature Selection In Perbandingan Algoritma Klasifikasi Dan Feature Selection," *Jutif*, Vol. 3, No. 3, Pp. 739–744, 2022, [Online]. Available: [Http://Jutif.If.Unsoed.Ac.Id/Index.Php/Jurnal/Article/View/343%0ahttps://Jutif.If.Unsoed.Ac.Id/Index.Php/Jurnal/Article/Download/343/129](http://jutif.if.unsoed.ac.id/index.php/jurnal/article/view/343%0ahttps://jutif.if.unsoed.ac.id/index.php/jurnal/article/download/343/129)
- [21] S. A. Saltykov, "On the Utility of Feature Selection in Building Two-Tier Decision Trees," Pp. 1–13, 2022, [Online]. Available: [Http://Arxiv.Org/Abs/2212.14448](http://arxiv.org/abs/2212.14448)
- [22] Andy Hermawan, Antonius Andriyanto, Ryandri Alif Pratomo Putra, William Armand Rahardjo, And Yogga Prastya Wijaya, "Optimalisasi Waktu Penjemputan Dan Lokasi Pada Data Histori Perjalanan Nyc Tlc Menggunakan Exploratory Data Analysis," *Uranus J. Ilm. Tek. Elektro, Sains Dan Inform.*,

- Vol. 2, No. 2, Pp. 121–133, 2024, Doi: 10.61132/Uranus.V1i2.175.
- [23] A. Javaloy And I. Valera, “Lipschitz Standardization for Multivariate Learning,” 2020, [Online]. Available: [Http://Arxiv.Org/Abs/2002.11369](http://Arxiv.Org/Abs/2002.11369)
- [24] Darussalam And G. Arief, “Analisis Pengaruh Data Scaling Terhadap Performa Algoritme Machine Learning Untuk Identifikasi Tanaman,” *Resti*, Vol. 1, No. 1, Pp. 19–25, 2018.
- [25] D. M. Saputra, D. Saputra, And L. D. Oswari, “Effect of Distance Metrics In Determining K-Value In K-Means Clustering Using Elbow and Silhouette Method,” Vol. 172, No. Siconian 2019, Pp. 341–346, 2020, Doi: 10.2991/Aisr.K.200424.051.
- [26] C. Kamila, “Systematic Literature Review: Penggunaan Algoritma K-Means Untuk Clustering Di Indonesia Dalam Bidang Pendidikan,” *Intech*, Vol. 2, No. 1, Pp. 19–24, 2021, Doi: 10.54895/Intech.V2i1.866.
- [27] A. Rizal, D. C. R. Novitasari, And M. Hafiyusholeh, “Pengelompokan Karyawan Berdasarkan Kesalehan Menggunakan Perbandingan Fuzzy C-Means, K-Means, Dan Probabilistic Distance Clustering,” *J. Fourier*, Vol. 11, No. 2, Pp. 69–77, 2022, Doi: 10.14421/Fourier.2022.112.69-77.
- [28] A. Z. Faridee And V. P. Janeja, “Cluster Quality Analysis Using Silhouette Score,” *Am. J. O*, Vol. 15, No. 2, Pp. 7–22, 2020.
- [29] F. Ros, R. Riad, And S. Guillaume, *Pdbi: A Partitioning Davies-Bouldin Index for Clustering Evaluation*, Vol. 528. 2023. Doi: 10.1016/J.Neucom.2023.01.043.
- [30] I. T. Utami, F. Suryaningrum, And D. Ispriyanti, “K-Means Cluster Count Optimization with Silhouette Index Validation and Davies Bouldin Index (Case Study: Coverage Of Pregnant Women, Childbirth, And Postpartum Health Services in Indonesia in 2020),” *Barekeng J. Ilmu Mat. Dan Terap.*, Vol. 17, No. 2, Pp. 0707–0716, 2023, Doi: 10.30598/Barekengvol17iss2pp0707-0716.