

Grouping The Regencies/Cities in Indonesia Based on Expenditure Groups Inflation Value Using DBSCAN Method

Meliani Putri, Dony Permana*, Syafriandi, Zilrahmi

Departemen Statistika, Universitas Negeri Padang, Padang, Indonesia

*Corresponding author: donypermana@fmipa.unp.ac.id

Submitted : 21 Maret 2023

Revised : 09 Mei 2023

Accepted : 19 Mei 2023

ABSTRACT

The different characteristics of each regencies/cities in Indonesia can trigger differences in expenditure groups inflation value, the differences that occur will affect Indonesia's national inflation. The purpose of this research is to create groups of regencies/cities based on expenditure groups inflation value and to identify the characteristics of the resulting groups. DBSCAN is a density-based non-hierarchical cluster method that can be used in data conditions that contain noise. The data used in this study is secondary data obtained from the publication of the Badan Pusat Statistik Republic of Indonesia (BPS RI) regarding expenditure groups inflation value. The analysis includes outlier detection, grouping using the DBSCAN method, performing cluster validation with silhouette coefficient, and identifying the characteristics of the clusters formed. Based on the grouping that has been done, two clusters are produced with a silhouette coefficient value of 0.65. The resulting cluster is cluster 0 in the form of a noise cluster consisting of 3 regencies/cities with regencies/cities that have a high category expenditure groups inflation value. Cluster 1 consisting of 87 regencies/cities is a cluster with regencies/cities that have a low category expenditure groups inflation value.

Keywords: DBSCAN, Expenditure Group Inflation, Regencies/Cities in Indonesia, Silhouette Coefficient



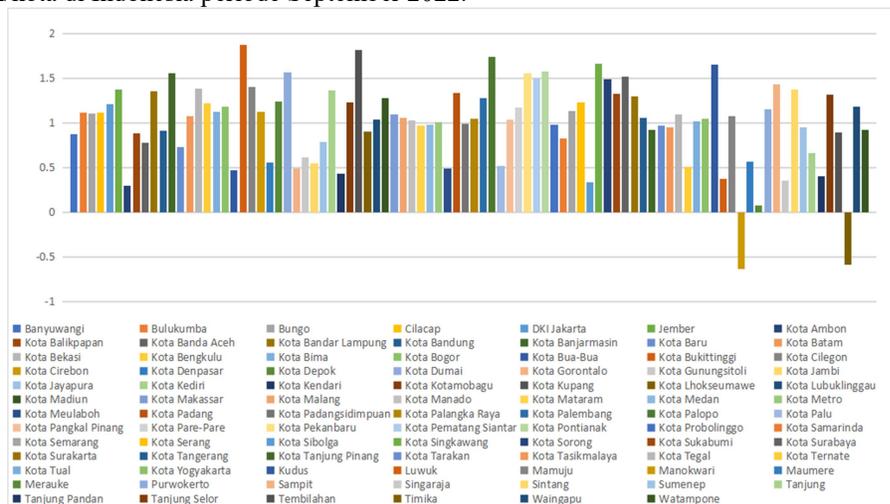
This is an open access article under the Creative Commons 4.0 Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited. ©2022 by author and Universitas Negeri Padang.

I. PENDAHULUAN

Inflasi merupakan salah satu permasalahan penting yang dihadapi oleh suatu negara dalam proses mencapai tujuan serta target perekonomian. Inflasi dikatakan sebagai permasalahan penting, karena inflasi dapat menyebabkan ketidakstabilan dalam perekonomian. Rendahnya nilai inflasi hingga berada pada level deflasi akan menekan pertumbuhan ekonomi, namun sebaliknya tingginya nilai inflasi akan membuat penurunan terhadap daya beli masyarakat yang tentunya dapat mengakibatkan roda perekonomian tidak berjalan. Inflasi diartikan sebagai suatu kondisi terjadinya kenaikan harga terhadap barang dan jasa secara umum yang berlangsung secara terus menerus dalam jangka waktu tertentu serta mengakibatkan kenaikan harga pada barang dan jasa lainnya (Santoso dkk, 2013: 7). Besarnya inflasi dapat diukur dari indikator perekonomian, menurut BPS RI (2020: 3) salah satu indikator yang dijadikan sebagai dasar pengukuran inflasi adalah Indeks Harga Konsumen (IHK). Pengukuran IHK ditujukan untuk melihat besaran perubahan harga dari barang yang dikonsumsi serta jasa yang digunakan oleh masyarakat. Inflasi berdasarkan kelompok barang dan jasa yang diperhitungkan dapat dibagi menjadi beberapa jenis, yaitu inflasi umum, inti, non-inti, kelompok pengeluaran, *administered price*, dan *volatile food*. Dari beberapa jenis inflasi tersebut, hanya inflasi kelompok pengeluaran yang menggambarkan kelompok barang dan jasa secara spesifik dan rinci. Di Indonesia, inflasi berdasarkan kelompok pengeluaran dikelompokkan menjadi 11 komoditi yang diukur pada periode bulanan.

Perkembangan inflasi nasional di Indonesia tidak terlepas dari dinamika perkembangan inflasi yang terjadi pada lingkup daerah. Sehingga dengan demikian, pengukuran inflasi tidak hanya dilakukan pada skala nasional, akan tetapi juga dilakukan pada skala daerah berupa provinsi, kabupaten, dan kota. Pengukuran inflasi skala daerah hanya dilakukan pada 90 kabupaten/kota yang terdiri dari 34 ibu kota provinsi dan 56 kabupaten/kota di Indonesia.

Pengukuran inflasi pada 90 kabupaten/kota ini didasari oleh pertimbangan kondisi Produk Domestik Regional Bruto (PDRB), pengeluaran perkapita, letak geografis, serta pertimbangan usulan BPS Provinsi, BPS kabupaten/kota, serta Walikota/Bupati setempat (BPS RI, 2020: 5). Secara umum, berikut pada Gambar 1, disajikan gambaran inflasi pada setiap kabupaten/kota di Indonesia periode September 2022.



Gambar 1. Inflasi Kabupaten/Kota di Indonesia September 2022

Berdasarkan Gambar 1, dapat diidentifikasi bahwa terjadi perbedaan inflasi yang cukup signifikan pada setiap kabupaten/kota di Indonesia. Terdapat kabupaten/kota yang memiliki nilai inflasi cukup tinggi serta sangat rendah hingga berada pada level deflasi. Adanya perbedaan karakteristik dari setiap daerah di Indonesia terkait kualitas infrastruktur logistik, kemampuan produksi pangan lokal, kebijakan *administered price*, serta perbedaan struktur pasar menjadi salah satu pemicu perbedaan nilai inflasi antar daerah di Indonesia. Kondisi ini tentu akan mempengaruhi perkembangan inflasi pada skala nasional Indonesia. Semakin, banyak daerah yang mengalami peningkatan inflasi, tentu akan mendorong inflasi pada skala nasional. Hal ini dikarenakan oleh, inflasi nasional merupakan hasil penggabungan dari inflasi masing-masing daerah di Indonesia (Utari dkk, 2015: 35). Melihat kondisi ini, maka pengendalian terhadap perbedaan nilai inflasi antar daerah perlu dilakukan. Salah satu langkah yang dapat ditempuh adalah dengan mengelompokkan kabupaten/kota berdasarkan nilai inflasi kelompok pengeluaran. Adapun metode yang dapat digunakan adalah metode *clustering*.

Penelitian ini bertujuan untuk mengelompokkan kabupaten/kota berdasarkan nilai inflasi kelompok pengeluaran serta mengidentifikasi karakteristik dari masing-masing *cluster* yang dihasilkan. Melihat kondisi inflasi dari masing-masing kabupaten/kota di Indonesia pada Gambar 1 yang menunjukkan terdapat kabupaten/kota yang memiliki nilai inflasi sangat tinggi maupun sangat rendah diduga sebagai *noise*. Sehingga dalam penelitian yang dilakukan diperlukan metode yang dapat menangani data yang memuat *noise*. Metode yang digunakan adalah metode *clustering* non hirarki berbasis kepadatan (*density*) yaitu metode *Density Based Spatial Clustering Applications with Noise* (DBSCAN) dengan pengukuran kekuatan *cluster* menggunakan koefisien *silhouette*. DBSCAN merupakan metode *cluster* berbasis *density* dengan pengelompokan berdasarkan kepada kepadatan yang saling terhubung, daerah yang memiliki kepadatan tinggi dikategorikan sebagai *cluster* sedangkan yang rendah dikategorikan sebagai *noise* (Setiyadi dkk, 2021: 88). Konsep kepadatan merujuk kepada banyaknya objek dalam radius jarak epsilon yang memenuhi ambang batas *minimum points* (Budiman dkk, 2016). DBSCAN memiliki kelebihan yaitu ketahanan terhadap data yang memuat *noise*. Sebagaimana dalam sebuah penelitian yang dilakukan oleh Mustakim dkk (2020) dengan tujuan penelitian adalah membandingkan kinerja metode *K-Medoids* dan DBSCAN dalam mengelompokkan opini publik terkait bencana alam di Indonesia. Metode terbaik yang dihasilkan dalam penelitian tersebut adalah metode DBSCAN dengan pertimbangan memiliki nilai *silhouette* yang lebih besar serta waktu komputasi yang lebih cepat dibandingkan dengan *K-Medoids*.

Penelitian dengan mengelompokkan kabupaten/kota berdasarkan nilai inflasi sebelumnya telah dilakukan oleh Haryanto dan Yanuar (2022) dengan tujuan penelitian yang dilakukan adalah untuk mengelompokkan kabupaten/kota di Pulau Jawa dan Sumatera berdasarkan tingkat inflasi menggunakan metode *K-Means clustering*. Dari proses

pengklasteran, diperoleh 3 *cluster* dengan kategori ringan, menengah, dan tinggi. Namun, metode *K-Means clustering* tidak dapat berjalan dengan baik pada penelitian tersebut karena kondisi data yang memuat *noise*.

II. METODE PENELITIAN

Penelitian yang dilakukan merupakan penelitian terapan, dengan data yang digunakan adalah data sekunder yang diperoleh dari publikasi Badan Pusat Statistik Republik Indonesia (BPS, 2022) terkait inflasi kelompok pengeluaran. Penelitian ini menggunakan data inflasi berdasarkan 11 kelompok pengeluaran pada 90 kabupaten/kota di Indonesia. Adapun variabel yang digunakan dalam penelitian ini adalah kelompok makanan, minuman, dan tembakau (X_1), kelompok pakaian dan alas kaki (X_2), kelompok perumahan, air, listrik, dan bahan bakar rumah tangga (X_3), kelompok perlengkapan, peralatan, dan pemeliharaan rutin rumah tangga (X_4), kelompok kesehatan (X_5), kelompok transportasi (X_6), kelompok informasi, komunikasi, dan jasa keuangan (X_7), kelompok rekreasi, olahraga, dan budaya (X_8), kelompok pendidikan (X_9), kelompok penyediaan makanan dan minuman/restoran (X_{10}), dan kelompok perawatan pribadi dan jasa lainnya (X_{11}). Seluruh variabel yang digunakan dalam penelitian ini merupakan data numerik yang memiliki satuan persen (%). Analisis dilakukan dengan bantuan *software R Studio* versi 4.2.2.

Tahapan awal yang dilakukan dalam analisis penelitian ini adalah eksplorasi terhadap data yang akan digunakan, eksplorasi data yang dilakukan terkait dengan pendeteksian *outlier* atau pencilan yang termuat dalam data. Pendeteksian *outlier* dilakukan secara visual dengan memanfaatkan visualisasi *boxplot*. Menurut Kolbasi (2019) pendeteksian secara visual akan memperlihatkan secara langsung posisi *outlier* yang termuat di dalam data. Posisi *outlier* pada *boxplot* dapat diidentifikasi secara langsung dengan mengamati data yang berada diluar batas maksimum dan minimum *boxplot*. Pendeteksian *outlier* ditujukan sebagai dasar pertimbangan dalam menentukan metode *cluster* yang akan dilakukan. Hal ini dikarenakan oleh, data yang memuat *outlier* akan berdampak pada keakuratan hasil pengklasteran (Kolbasi, 2019). Data yang memuat *outlier*, hanya dapat dianalisis menggunakan metode *cluster* yang memiliki ketahanan terhadap *outlier*. Salah satu metode *cluster* yang memiliki ketahanan terhadap *outlier* adalah DBSCAN.

Menurut Apeltsin (2021: 185) tahapan pengelompokan menggunakan metode DBSCAN diawali dengan penetapan 2 parameter yang akan digunakan sebagai ambang batas terbentuknya *cluster*. Parameter yang dimaksud adalah *minimum points (minpts)* dan *epsilon*. *Minpts* merupakan ambang batas minimal dari objek yang diperlukan dalam membentuk *cluster* (Tu dkk, 2022). Penetapan *minpts* mengikuti aturan yang dikeluarkan oleh Ester dkk (1996) yang menyatakan bahwa untuk data yang berukuran lebih dari dua dimensi *minpts* yang dapat digunakan adalah dua kali dari dimensi data. *Epsilon* merupakan ambang batas maksimum jarak yang diperbolehkan antar dua objek (Tu dkk, 2022). Nilai *epsilon* ditentukan dari kelengkungan maksimum pada grafik *k-dist* atau grafik jarak k tetangga terdekat.

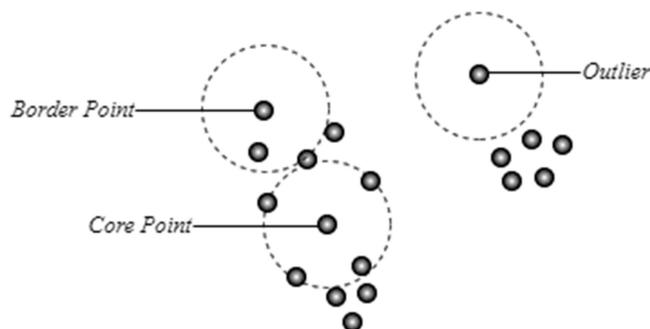
Penentuan objek awal atau objek p dilakukan secara *random* oleh *software R Studio* yang dilanjutkan dengan menghitung jarak setiap objek ke objek awal (p) menggunakan pengukuran jarak *Euclidean*, adapun pengukuran jarak *Euclidean* ditunjukkan pada persamaan (1).

$$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (1)$$

Dimana i merupakan observasi, untuk $i = 1, 2, \dots, n$; p_i merupakan objek pertama; q_i merupakan objek kedua; dan n merupakan jumlah objek. Setelah perhitungan jarak seluruh objek dilakukan, berikutnya menentukan objek yang memenuhi kondisi *density-reachable* terhadap objek p . Menurut Backlund dkk (2011) kondisi *density-reachable* dibangun oleh kondisi *directly density-reachable* dan kondisi *directly density-reachable* dibangun oleh sekumpulan tetangga terdekat (*eps-neighborhood*). *Eps-neighborhood* terbentuk jika memenuhi kondisi berikut.

$$N_{eps(p)} = \{q \in D | d(p, q) < eps\}$$

Dimana $N_{eps(p)}$ merupakan jumlah tetangga dari objek pertama (p), q merupakan objek data kedua, D merupakan seluruh data observasi, $d(p, q)$ merupakan jarak objek p dan q , serta *eps* merupakan jarak maksimal antar dua objek. Sebuah *cluster* dibangun oleh satu objek serta terdapat minimal satu objek lain dengan ketentuan memiliki jarak $< eps$. Metode DBSCAN memiliki dua jenis titik yaitu titik yang terletak di pinggir *cluster (border points)* serta titik yang berada pada pusat *cluster (core points)*. Adapun posisi dari kedua titik ini dapat dilihat pada Gambar 2.



Gambar 2. Border Point dan Core Point

Terjadinya hubungan secara langsung antara *border point* dan *core point* dikenal dengan istilah *directly density-reachable* (Backlund dkk, 2011). Kondisi objek p dan objek q yang melewati rantai objek-objek p_1, \dots, p_n , $p_1 = q$, $p_n = p$, akan mengakibatkan terjadinya hubungan secara tidak langsung antara p dan q atau dikenal dengan istilah *density-reachable*. Berikut pada Gambar 3, disajikan kondisi *density-reachable*

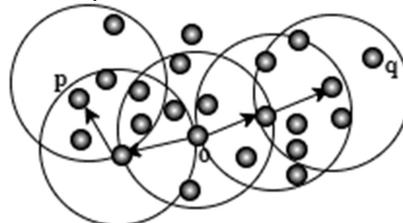


Gambar 3. Density-reachable

Gambar 3 menunjukkan kondisi *Density-reachable* dari dua objek yang mengalami hubungan tidak langsung dikarenakan adanya hubungan secara langsung dari titik p_{i+1} dan p_i . Tahapan berikutnya memisahkan objek yang memenuhi ambang batas epsilon, serta menghitung objek dengan pertimbangan *minpts*, jika objek memenuhi ambang batas epsilon dan *minpts* maka objek pusat dan *cluster* akan terbentuk. *Core point* atau pusat dapat terbentuk jika memenuhi kondisi berikut.

$$\|N_{eps(p)}\| \geq Minpts$$

Core point dapat terbentuk jika memiliki jumlah objek dalam *eps-neighborhood* lebih atau sama dengan *minpts*. Menurut Backlund dkk (2011) sekumpulan objek yang memenuhi jarak epsilon namun jumlah objek kurang dari *minpts*, maka objek tersebut akan terkategori sebagai *noise*. Disamping itu, jika sebuah objek merupakan *border point* dan tidak ada objek yang *density-reachable* terhadap objek tersebut, maka proses dilanjutkan ke objek lain. Proses berlangsung secara iteratif hingga semua objek terproses, namun berikutnya dilakukan pemeriksaan *density-connected*. Kondisi *density connected* dapat dilihat pada Gambar 4.



Gambar 4. Density connected

Berdasarkan Gambar 4, dapat dilihat bahwa *Density connected* merupakan kondisi dimana terjadi penggabungan dari beberapa *cluster* yang terbentuk dimana didalamnya terdapat kondisi *directly density-reachable* dan *density-reachable*. Setelah proses pembentukan *cluster* selesai dilakukan, maka tahapan berikutnya adalah melakukan validasi *cluster* menggunakan koefisien *silhouette*. Nilai Koefisien *silhouette* dapat diperoleh menggunakan persamaan (2).

$$SC = \frac{1}{n} \sum_{i=1}^n \frac{b_i - a_i}{\text{Max}(a_i, b_i)} \quad (2)$$

Dimana n merupakan jumlah objek, a_i merupakan rata-rata jarak objek ke- i atas semua objek pada kelompok yang sama dan b_i merupakan jarak terkecil objek ke- i antar semua objek pada kelompok yang berbeda. Menurut Fhadli dan Tempola (2020: 149) semakin kecil nilai a_i yang dihasilkan merepresentasikan suatu objek berada pada *cluster* yang tepat, sedangkan semakin besar nilai b_i merepresentasikan objek yang berada pada *cluster* berbeda semakin heterogen. Menurut Fransiska dkk (2022) ukuran koefisien *silhouette* dapat dilihat pada Tabel 1.

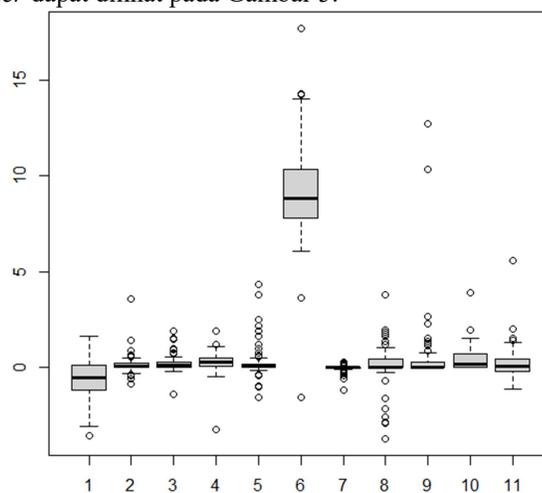
Tabel 1. Koefisien *Silhouette*

Koefisien <i>Silhouette</i>	Kategori
$0,7 < SC \leq 1$	Sangat baik
$0,5 < SC \leq 0,7$	Cukup baik
$0,25 < SC \leq 0,5$	Lemah
$SC \leq 0,25$	Tidak terdapat ikatan

Berdasarkan Tabel 1, dapat dilihat bahwa semakin besar nilai koefisien *silhouette* yang dihasilkan, maka semakin baik *cluster* yang dihasilkan dan begitupun sebaliknya.

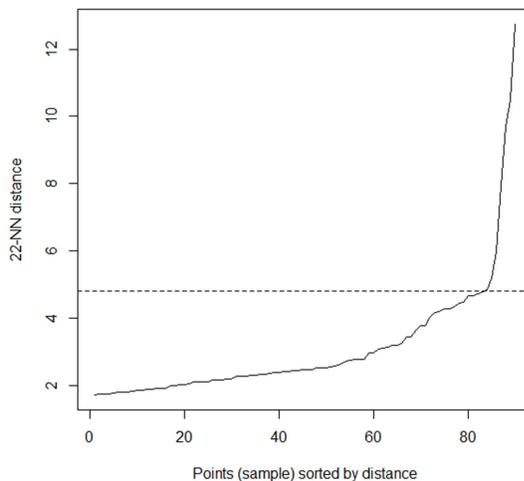
III. HASIL DAN PEMBAHASAN

Eksplorasi data yang berkaitan dengan pendeteksian *outlier* merupakan tahapan awal yang dilakukan sebelum analisis. Hasil pendeteksian *outlier* dapat dilihat pada Gambar 5.



Gambar 5. *Boxplot*

Berdasarkan Gambar 5, dapat dilihat bahwa seluruh variabel yang akan dianalisis memuat *outlier* yang ditandai oleh terdapat nilai yang berada diluar batas kuartil *boxplot*. Sehingga dengan demikian diperlukan metode *cluster* yang cocok digunakan dalam kondisi data yang memuat *outlier*. Adapun metode *cluster* yang digunakan adalah metode DBSCAN. Pengelompokan yang dilakukan menggunakan metode DBSCAN diawali dengan menetapkan jumlah *minimum points* sebesar 22, kemudian diperoleh epsilon sebagaimana disajikan pada Gambar 6.



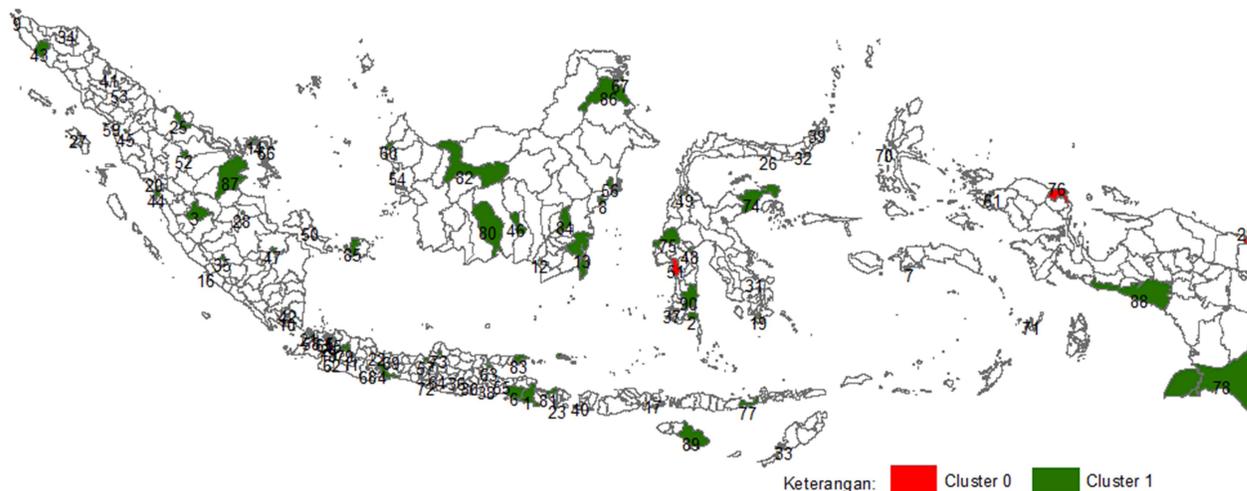
Gambar 6. Grafik k Tetangga Terdekat

Berdasarkan Gambar 6, dapat dilihat kelengkungan terbesar terjadi pada titik 4,8, ini artinya epsilon yang akan digunakan adalah 4,8. Berikutnya dilakukan penentuan objek awal serta menghitung jarak objek lain ke objek awal menggunakan persamaan (1). Proses pengelompokan berlangsung secara iteratif, dimana pengelompokan akan berhenti apabila seluruh objek telah diproses dan menempati *cluster* tertentu. Berikut pada Tabel 2 disajikan hasil *clustering* menggunakan metode DBSCAN.

Tabel 2. Hasil *Cluster*

<i>Cluster</i>	Jumlah Kabupaten/Kota
<i>Cluster</i> 0	3
<i>Cluster</i> 1	87

Berdasarkan Tabel 2, dapat dilihat bahwa dihasilkan sebanyak dua *cluster* pada metode DBSCAN yaitu *cluster* 0 dan *cluster* 1. *Cluster* 0 merupakan *cluster* dengan kategori *noise* yang terbentuk karena, objek tidak memenuhi *minimum points* yang telah ditetapkan. Secara visual berikut disajikan persebaran kabupaten/kota menurut masing-masing *cluster* pada Gambar 7.



Gambar 7. Peta Sebaran *Cluster*

Berdasarkan Gambar 7 dapat dilihat bahwa, kabupaten/kota yang termuat dalam *cluster* 0 adalah Kota Jayapura, Kota Pare-Pare, dan Manokwari. Kabupaten/kota yang termuat dalam *cluster* 1 adalah Banyuwangi, DKI Jakarta,

Jember, Kota Banda Aceh, Kota Bandar Lampung, Kota Banjarmasin, Kotabaru, Kota Batam, Kota Bengkulu, Kota Bima, Kota Bau-Bau, Kota Depok, Kota Dumai, Kota Gunungsitoli, Kota Jambi, Kota Lhokseumawe, Kota Mataram, Kota Metro, Kota Padang, Kota Palangkaraya, Kota Palu, Kota Pangkal Pinang, Kota Pontianak, Kota Probolinggo, Kota Samarinda, Kota Semarang, Kota Sorong, Kota Tanjung Pinang, Kota Tarakan, Kota Ternate, Kota Yogyakarta, Mamuju, Merauke, Sintang, Sumenep, Tanjung, Tanjung Pandan, Tembilahan, Timika, Waingapu, Bulukumba, Bungo, Cilacap, Kota Ambon, Kota Balikpapan, Kota Bandung, Kota Bekasi, Kota Bogor, Kota Bukittinggi, Kota Cilegon, Kota Cirebon, Kota Denpasar, Kota Gorontalo, Kota Kediri, Kota Kendari, Kota Kotamobagu, Kota Kupang, Kota Lubuklinggau, Kota Madiun, Kota Makassar, Kota Malang, Kota Manado, Kota Mataram, Kota Medan, Kota Metro, Kota Meulaboh, Kota Padangsidempuan, Kota Palembang, Kota Palopo, Kota Pekanbaru, Kota Pematang Siantar, Kota Serang, Kota Sibolga, Kota Singkawang, Kota Sukabumi, Kota Surabaya, Kota Surakarta, Kota Tangerang, Kota Tasikmalaya, Kota Tegal, Kota Tual, Kudus, Luwuk, Maumere, Purwokerto, Sampit, Singaraja, Tanjung Selor, dan Watampone. Berdasarkan sebarannya, dapat dilihat bahwa untuk *cluster* 0, hanya memuat tiga kabupaten/kota yang terdapat di Pulau Sulawesi dan Papua. Sedangkan *cluster* 1 didominasi oleh daerah kabupaten/kota yang tersebar di Pulau Jawa, Kalimantan, dan Sumatera.

Pengelompokan dengan metode DBSCAN menghasilkan nilai koefisien *silhouette* yang cukup tinggi, yaitu sebesar 0.65. Ini artinya, *cluster* yang dihasilkan memiliki kualitas yang cukup baik, dengan kata lain terdapat ikatan cukup baik antara objek dan *cluster* yang terbentuk. Setiap *cluster* yang dihasilkan memiliki karakteristik yang berbeda, berikut pada Tabel 3 disajikan karakteristik dari masing-masing *cluster*.

Tabel 3. Karakteristik *Cluster*

No	Variabel	<i>Cluster</i> 0 (%)	<i>Cluster</i> 1 (%)
1	Kelompok Makanan, minuman, dan tembakau	-1,18	-0,56
2	Kelompok pakaian dan alas kaki	0,15	0,15
3	Kelompok perumahan, air, listrik, dan bahan bakar rumah tangga	0,22	0,22
4	Kelompok perlengkapan, peralatan, dan pemeliharaan rutin rumah tangga	0,42	0,29
5	Kelompok kesehatan	0,06	0,29
6	Kelompok transportasi	4,53	9,23
7	Kelompok informasi, komunikasi, dan jasa keuangan	0,03	-0,04
8	Kelompok rekreasi, olahraga, dan budaya	0,14	0,17
9	Kelompok pendidikan	7,88	0,22
10	Kelompok penyediaan makanan dan minuman/restoran	0,33	0,45
11	Kelompok perawatan pribadi dan jasa lainnya	-0,13	0,24
	Total	12,45	10,66

Berdasarkan Tabel 3, dapat dilihat bahwa *cluster* 0 memiliki total nilai inflasi kelompok pengeluaran yang lebih tinggi dibandingkan dengan *cluster* 1. Secara spesifik terdapat beberapa kelompok pengeluaran yang memiliki nilai inflasi lebih tinggi dibandingkan dengan *cluster* 1 yaitu kelompok perlengkapan, peralatan, dan pemeliharaan rutin rumah tangga (4), kelompok informasi, komunikasi, dan jasa keuangan (7), serta kelompok pendidikan (9). Terdapat kelompok pengeluaran yang memiliki nilai inflasi lebih rendah dibandingkan dengan *cluster* 1 yaitu kelompok makanan, minuman, dan tembakau (1), kelompok kesehatan (5), kelompok transportasi (6), kelompok rekreasi, olahraga, dan budaya (8), kelompok penyediaan makanan dan minuman/restoran (10), serta kelompok perawatan pribadi dan jasa lainnya (11). Sehingga dapat diidentifikasi bahwa *cluster* 0 merupakan *cluster* dengan daerah kabupaten/kota yang memiliki nilai inflasi kelompok pengeluaran dengan kategori tinggi. *Cluster* 1 memiliki total nilai inflasi kelompok pengeluaran yang lebih rendah dibandingkan dengan *cluster* 0. Secara spesifik terdapat kelompok pengeluaran yang memiliki nilai inflasi lebih rendah dibandingkan dengan *cluster* 0 yaitu kelompok perlengkapan, peralatan, dan pemeliharaan rutin rumah tangga (4), kelompok informasi, komunikasi, dan jasa keuangan (7), serta kelompok pendidikan (9). Terdapat kelompok pengeluaran yang memiliki nilai inflasi lebih tinggi dibandingkan dengan *cluster* 0 yaitu kelompok makanan, minuman, dan tembakau (1), kelompok kesehatan (5), kelompok transportasi (6), kelompok rekreasi, olahraga, dan budaya (8), kelompok penyediaan makanan dan minuman/restoran (10), serta kelompok perawatan pribadi dan jasa lainnya (11). Sehingga dengan demikian dapat diidentifikasi bahwa *cluster* 1 merupakan *cluster* dengan daerah kabupaten/kota yang memiliki nilai inflasi kelompok pengeluaran dengan kategori rendah.

IV. KESIMPULAN

Pengelompokan kabupaten/kota di Indonesia berdasarkan nilai inflasi kelompok pengeluaran menggunakan metode DBSCAN menghasilkan 2 *cluster*, yaitu *cluster* 0 dan 1. *Cluster* 0 terdiri dari 3 kabupaten/kota yang terdapat di Pulau Sulawesi dan Papua, sedangkan *cluster* 1 terdiri dari 87 kabupaten/kota yang didominasi oleh kabupaten/kota yang tersebar di Pulau Jawa, Kalimantan, dan Sumatera. *Cluster* 0 merupakan *cluster* yang memiliki nilai inflasi kelompok pengeluaran dengan kategori tinggi, sedangkan *cluster* 1 memiliki nilai inflasi kelompok pengeluaran dengan kategori rendah. Pengelompokan menggunakan metode DBSCAN menghasilkan koefisien *silhouette* sebesar 0.65, yang artinya *cluster* yang dihasilkan memiliki kualitas yang cukup baik. Diharapkan pada penelitian berikutnya dapat menggunakan beberapa kombinasi parameter *minpts* dan epsilon dalam membangun *cluster* pada metode DBSCAN.

DAFTAR PUSTAKA

- Apeltsin, L. (2021). *Data Science Bookcamp Five Real-world Python Projects*. Shelter Island: Manning Publications.
- Backlund, H., Hedblom, A., dan Neijman, N. (2011). *A Density-Based Spatial Clustering of Application with Noise*. Linköpings University.
- Badan Pusat Statistik RI. (2020). *Survei Biaya Hidup 2018*. Jakarta: BPS RI.
- _____ (2022). *Berita Resmi Statistik 3 Oktober 2022*. Jakarta: BPS RI.
- Budiman, S.A.D., Safitri, D., dan Ispriyanti, D. (2016). Perbandingan Metode K-Means dan Metode DBSCAN pada Pengelompokan Rumah Kost Mahasiswa di Kelurahan Tembalang Semarang. *Jurnal Gaussian*, Vol.5, No. 4, 757-762.
- Ester, M., Kriegel, H.P., Sander, J., dan Xu, X. (1996). A density-based algorithm for discovering clusters in large spatial database with noise. *KDD-96 Proceedings*. 226-231.
- Fhadli, M., dan Tempola, F. (2020). *Data Mining dengan Python untuk Pemula*. Ternate: Guepedia.
- Fransiska, N.N.R., Anggraeni, D.S., dan Enri, U. (2022). West Java Province Poverty Data Grouping Using K-Means Algorithm with Silhouette Coefficient. *Jurnal Teknologi Informasi Komunikasi*, Vol. 9, No. 1, 29-35.
- Haryanto, A.E.P., dan Yanuar, M.U. (2022). Metode K-Means Clustering untuk Pengelompokan Kabupaten/Kota dalam Upaya Pengendalian Tingkat Inflasi di Pulau Jawa dan Sumatera. *Govstat*. 1(1), 29-42.
- Kolbasi, A., dan Unsal, A. (2019). A Comparison of the Outlier Detecting Methods: An Applications on Turkish Foreign Trade Data. *Journal of Mathematics and Statistical Science*, Vol. 5, 213-234.
- Mustakim., Fauzi, M.Z., Mustafa., Abdullah, A., dan Rohayati. (2020). Clustering of Public Opinion on Natural Disasters in Indonesia Using DBSCAN and K-Medoids Algorithms. *Journal of Physics: Conference Series*.
- Santoso, W., Suselo, S.L, Nurhemi., dan Guruh, S.R. (2013). *Pengaruh Hari Besar pada Komoditi Utama Inflasi di Indonesia*. Working Paper. Bank Indonesia.
- Setiyadi, A.N., Darnoto, S., dan Arozak, M. (2021). *Sistem Informasi (SIG) Kesehatan Masyarakat*. Surakarta: Muhammadiyah University Press.
- Tu, X., Fu, C., Huang, A., Chen, H., dan Ding, X. (2022). DBSCAN Spatial Clustering Analysis of Urban "Production-Living-Ecological" Space Based on POI Data: A Case Study of Central Urban Wuhan, China. *International Journal of Environmental Research and Public Health* , 19, 55153.
- Utari, G.A.D., Cristina, R., dan Pambudi, S. (2016). *Inflasi di Indonesia: Karakteristik dan Pengendaliannya*. Jakarta: BI Institute.