

PERBANDINGAN *COMPELXITY INVARIANT DISTANCE* (CID) DAN *DYNAMIC TIME WARPING* (DTW) DALAM ANALISIS KLASTER DERET WAKTU PADA NILAI TUKAR PETANI DI INDONESIA

Laila Fathiyaturrahmi^{*1}, Andriano², Harista Almiatus Soleha³, Dedy Dwi Prastyo⁴

^{1,2,3,4}Institut Teknologi Sepuluh Nopember, Surabaya

Email: ¹Lailafathi64@gmail.com, ²andriano0512@gmail.com, ³harista.almiatuss@gmail.com, ⁴dedy-dp@statistika.its.ac.id

*Penulis Korespondensi

(Naskah masuk: 26 September 2024, diterima untuk diterbitkan: 17 Juni 2025)

Abstrak

Analisis klaster yang merupakan bagian dari data mining yang membagi data kedalam beberapa kelompok berdasarkan kedekatan karakteristik tertentu. Konsep utama dalam klaster adalah memaksimalkan kedekatan data di dalam klaster dan meminimalkan kesamaan data antar klaster. Analisis klaster juga bisa digunakan pada berbagai jenis data termasuk data deret waktu. Pengukuran kesamaan menjadi hal yang utama pada analisis klaster. Metode yang bisa digunakan dalam pengukuran jarak yaitu *Complexity Invariant Distance* (CID) dan *Dynamic Time Warping* (DTW). Analisis pengukuran jarak CID dan DTW dapat digunakan pada pengelompokan data deret waktu salah satunya pada data Nilai Tukar Petani (NTP). NTP dapat menggambarkan daya beli petani karena diperoleh dari perbandingan indeks harga yang diterima petani dibandingkan dengan yang harus dibayarnya, atau dapat dinyatakan sebagai kemampuan petani dalam memnuhi kebutuhan sehari-hari dari hasil pertanian. Sehingga dilakukan analisis untuk membandingkan metode pengukuran jarak CID dan DTW pada klastering data deret waktu pada nilai tukar petani pada 34 Provinsi di Indonesia. Hasil analisis yang dilakukan menunjukkan klaster terbaik adalah pengklasteran dengan banyak klaster dua ($k=2$) menggunakan ukuran jarak CID terlihat dari nilai *silhouette* 0.8776 yang lebih tinggi dibandingkan klaster lain. Dimana klaster satu terdiri dari 25 Provinsi dan klaster dua terdiri dari 9 Provinsi.

Kata kunci: Klaster deret waktu, *complexity invariant distance*, *dynamic time warping*, nilai tukar petani

COMPARISON OF *COMPLEXITY INVARIANT DISTANCE* (CID) AND *DYNAMIC TIME WARPING* (DTW) IN TIME SERIES CLUSTER ANALYSIS OF FARMER'S TERMS OF TRADE IN INDONESIA

Abstract

Cluster analysis is a part of data mining which divides data into several groups based on the proximity of certain characteristics. The main concept in clusters is to maximize data similarity within clusters and minimize data similarity between clusters. Cluster analysis can also be used on various types of data, including time series data. Measuring similarity is the main thing in cluster analysis. The methods that can be used to measure distance are *Complexity Invariant Distance* (CID) and *Dynamic Time Warping* (DTW). CID and DTW distance measurement analysis can be used to group time series data, one of which is Farmer's Terms of Trade (NTP) data. The farmer's terms of trade is a ratio between the price index received by farmers and the price index paid by farmers. In general, it can be interpreted as the farmer's ability to meet their daily needs through agricultural products. So an analysis was carried out to compare the CID and DTW distance measurement methods in clustering time series data on farmer's terms of trade according to 34 provinces in Indonesia. The results of this analysis show that the best cluster is clustering with two clusters ($k=2$) using the CID distance measure because it has the highest silhouette coefficient value, namely 0.8776. Where cluster one consists of 25 provinces and cluster two consists of 9 province.

Keywords: Cluster time series, *complexity invariant distance*, *dynamic time warping*, farmer's terms of trade.

1. PENDAHULUAN

Analisis kluster (*Cluster Analysis*) merupakan salah satu bagian dari *data mining* yang mana membagi data kedalam beberapa kelompok berdasarkan kedekatan karakteristik tertentu. Konsep utama dalam kluster adalah memaksimalkan kesamaan data di dalam kluster dan meminimalkan kesamaan data antar kluster (Kaufman and Rousseeuw, 1990). (; Kaufman dan Rousseeuw, 2006). Pada analisis kluster biasanya digunakan pada data *cross-section*. Namun, analisis kluster juga bisa digunakan pada berbagai jenis data termasuk data deret waktu (Warren Liao, 2005b).

Analisis kluster deret waktu mempunyai konsep yang dalam prosesnya dengan analisis kluster pada data *cross-section*. Pengukuran kesamaan (*similarity measurement*) menjadi hal yang utama pada analisis kluster. Ukuran kesamaan tersebut dapat dihitung antara setiap objek yang akan dikelompokkan dengan menggunakan metode pengukuran jarak (*distance measurement*) yang telah ditentukan. Metode yang bisa digunakan dalam pengukuran jarak yaitu *Dynamic Time Warping* (DTW) dan *Complexity Invariant Distance* (CID).

CID merupakan salah satu metode pengukuran jarak pada analisis kluster deret waktu dengan memberikan faktor koreksi pada jarak *euclidean* berdasarkan perbedaan kompleksitas antara data. CID sendiri memperoleh kluster dengan nilai akurasi yang lebih baik dibandingkan jarak *euclidean* (Barista dkk., 2011). Selain CID, metode pengukuran jarak lainnya adalah DTW yang merupakan salah satu pengukuran jarak pada analisis kluster deret waktu dengan menghitung *warping path* yang terpendek (*optimal*) antara dua data deret waktu yang menghasilkan nilai – nilai *warping path* yang menghasilkan jarak kedua data tersebut. DTW dinyatakan lebih realistis dalam mengukur jarak data deret waktu jika dibandingkan beberapa metode pengukuran jarak lainnya seperti *Euclidean*, *Canberra*, dan lain – lain. Urutan waktu dalam mengukur jarak DTW sangat penting (Sakoe and Chiba, 1978). Analisis pengukuran jarak CID dan DTW dapat digunakan pada pengelompokan data deret waktu salah satunya untuk mengklusterkan NTP.

Pertanian merupakan sektor yang lamban dalam mengikuti teknologi dan juga sangat bergantung kepada iklim (Sukartini & Solihin, 2013). Oleh karena itu petani harus menyiapkan strategi tertentu agar panen mendapatkan hasil yang maksimal. Hasil yang maksimal tersebut akan berdampak kepada tingkat kesejahteraan petani. Tingkat kesejahteraan petani di Indonesia dapat diukur melalui NTP. Menurut Badan Pusat Statistik (BPS) NTP merupakan perbandingan It atau indeks harga yang diterima petani dengan Ib yang merupakan indeks harga yang harus dibayar petani. Secara umum hal ini dapat menunjukkan kemampuan petani memenuhi kebutuhan sehari hari.

Beberapa penelitian sebelumnya yang membahas metode kluster menggunakan jarak CID dan DTW antara lain dilakukan oleh (Abbasimehr, Paki and Bahrini, 2022) menggunakan metode klustering *k-means* dan *Density-Based Spatial Clustering of Applications with Noise* (DBSCAN) dengan pendekatan hirarki serta menggunakan pengukuran jarak dengan metode DTW, CID, *Correlation-based Time Series* (CORT) dan *Shape-Based Distance* (SBD) untuk melihat segmentasi pelanggan bank dalam bertransaksi. Hasil penelitian ini menunjukkan bahwa pengukuran jarak dengan metode CID memberikan hasil terbaik pada data segmentasi pelanggan bank dalam bertransaksi. Penelitian lainnya juga dilakukan oleh (Munthe, 2019) melakukan pengklusteran dengan metode *k-means* menggunakan ukuran jarak DTW pada data nilai produksi padi di Indonesia. Penelitian tersebut juga membandingkan konsep kluster hirarki dan nonhirarki. Tujuannya adalah mengelompokkan nilai produksi padi di Indonesia menggunakan konsep analisis deret waktu. Klustering deret waktu hirarki dan nonhirarki menghasilkan jumlah kluster yang sama yaitu 3 kluster yang optimal. Kluster pertama terdiri atas 8 provinsi, kluster kedua terdiri atas 15 provinsi, dan 8 provinsi lainnya termasuk kedalam kluster 3. Secara rata – rata dari 3 kluster yang terbentuk menghasilkan nilai koefisien *silhouette* 0,64 yang berarti terklasifikasi baik katas jumlah kluster tersebut.

Dari beberapa penelitian tersebut, maka diperoleh beberapa metode pengukuran jarak yang dapat digunakan, CID dan DTW dapat dipilih sebagai pengukuran jarak pada analisis kluster deret waktu karena memperoleh hasil yang baik dibandingkan beberapa metode pengukuran jarak lainnya. Data yang digunakan pada penelitian ini adalah NTP dengan tahun dasar 2010 pada 34 provinsi di Indonesia. Maka tujuan penelitian ini yaitu untuk membandingkan metode pengukuran jarak CID dan DTW pada klustering dengan data deret waktu pada data nilai tukar petani menurut 34 Provinsi di Indonesia.

2. TINJAUAN PUSTAKA

2.1 Analisis Kluster

Analisis kluster merupakan metode statistika yang digunakan untuk mengklusterkan objek berdasarkan kesamaan karakteristik objek tersebut. Kluster yang terbentuk memiliki ciri utama yaitu objek dalam kluster yang sama (*within cluster*) memiliki kesamaan tertinggi sebaliknya antar kluster (*between cluster*) memiliki kesamaan terendah (Hair, Black and Babin, 2010). sehingga pengukuran kesamaan menjadi langkah utama dalam analisis kluster. Adapun ukuran kesamaan dalam analisis kluster dapat direpresentasikan dengan jarak yang merupakan ukuran numerik untuk menunjukkan

seberapa jauh suatu objek terhadap objek (Kaufman and Rousseeuw, 2006; Hair, Black and Babin, 2010).

2.2 Analisis Klaster Deret Waktu

Analisis klaster dapat digunakan dalam berbagai jenis data termasuk data deret waktu hal tersebut dinyatakan oleh Warren Liao (2005), bahwa analisis klaster juga dapat digunakan pada data deret waktu yaitu data yang dikumpulkan berdasarkan urutan waktu tertentu sehingga urutan amatan menjadi hal yang penting dalam data deret waktu. Hal tersebut menyebabkan diperlukan penyesuaian pada analisis klaster deret waktu jika dibanding analisis klaster pada data *cross-section*. Berbagai pendekatan dapat digunakan dalam analisis klaster deret waktu, salah satunya *raw - data based* yang menitik beratkan pada penyesuaian ukuran jarak yang akan digunakan (Warren Liao, 2005a; Aghabozorgi, Seyed Shirkorshidi and Ying Wah, 2015; Paparrizos and Gravano, 2017; Riyadi et al., 2017; Shang, Shang, and Liu, 2019; Adnyani and Sihombing, 2021). Adapun analisis klaster deret waktu dengan pendekatan *raw - data based* dapat dilakukan menggunakan ukuran jarak *CID* dan *DTW*

2.3 Complexity-Invariance Distance (CID)

CID dikembangkan oleh Batista et al. (2011) didasari atas kesadaran akan adanya perbedaan kompleksitas data deret waktu dengan memberikan faktor koreksi bagi jarak *Euclidean*. Jarak *euclidean* adalah ukuran jarak yang sering digunakan dalam analisis klaster karena kemudahan implementasi dan hasilnya yang tidak jarang lebih baik dibanding ukuran jarak lain yang lebih kompleks (Ding et al., 2008). *CID* diperoleh dengan mengalikan jarak *euclidean* dengan faktor koreksi. Jika diasumsikan terdapat data deret waktu $P = p_1, p_2, \dots, p_T$ dan $Q = q_1, q_2, \dots, q_T$. Maka jarak *euclidean* ($ED [P, Q]$) dapat diperoleh dengan menggunakan persamaan 1.

$$d_{ED}(P, Q) = \sqrt{\sum_{i=1}^T (p_i - q_i)^2} \tag{1}$$

Selanjutnya faktor koreksi dapat diperoleh dengan langkah pertama menghitung estimasi kompleksitas (CE) setiap data deret waktu menggunakan persamaan 2 dan 3, dengan persamaan tersebut dapat diidentifikasi perbedaan kompleksitas antar data deret waktu. Menggunakan perbandingan kedua estimasi kompleksitas tersebut kemudian diperoleh faktor koreksi (CF) pada persamaan 4.

$$CE(P) = \sqrt{\sum_{i=1}^{T-1} (p_i - p_{i+1})^2} \tag{2}$$

$$CE(Q) = \sqrt{\sum_{i=1}^{T-1} (q_i - q_{i+1})^2} \tag{3}$$

$$CF(P, Q) = \frac{\max(CE(P), CE(Q))}{\min(CE(P), CE(Q))} \tag{4}$$

Persamaan 4 menunjukkan bahwa faktor koreksi yang diberikan akan semakin besar jika jarak antara kompleksitas deret waktu semakin jauh atau selisih antara nilai maksimum dan minimum kompleksitas jauh. Sehingga sesuai dengan pengembangan yang diterapkan *CID* diperoleh nilai $CID(P, Q)$ seperti pada persamaan 5.

$$d_{CID}(P, Q) = ED(P, Q) \times CF(P, Q) \tag{5}$$

2.4 Dynamic Time Warping (DTW)

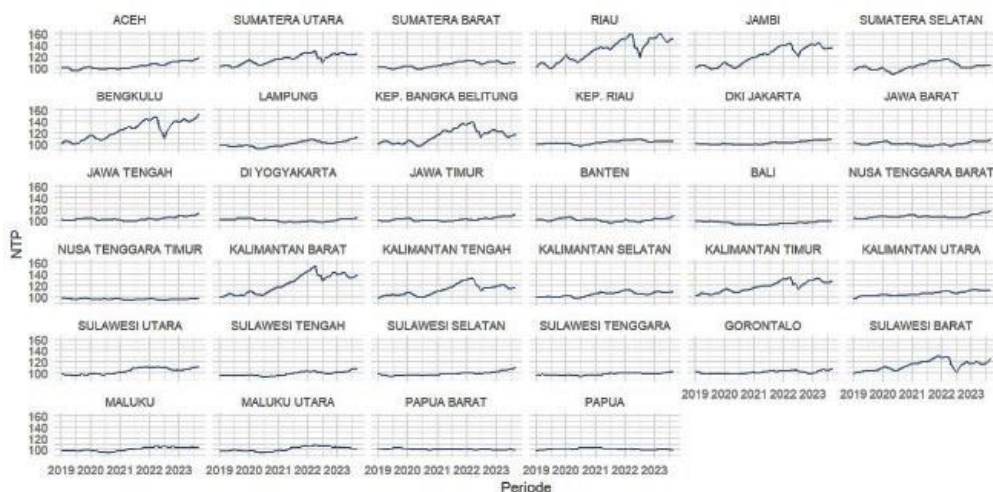
DTW merupakan algoritma untuk mengukur kedekatan dua data deret waktu dengan mencari lintasan *warping* optimum kedua data tersebut. Misalkan terdapat data deret waktu $P = p_1, p_2, \dots, p_n$ dan $Q = q_1, q_2, \dots, q_m$ *DTW* akan mengukur jarak keduanya sehingga diperoleh jarak minimum. Adapun proses perhitungan jarak *DTW* dilakukan dengan membentuk matriks berukuran $m \times n$ yang mengandung jarak elemen P dan Q ($d[P_i, Q_j]$). Selanjutnya dilakukan perhitungan lintasan *warping*, $W = w_1, w_2, \dots, w_K$ dengan $\max(m, n) \leq K \leq m+n-1$ yang memenuhi tiga kondisi yaitu, *boundary condition* yang mengharuskan lintasan dimulai dari sudut berlawanan ($w_1 = (1,1)$ dan $w_T = (m, n)$), *continuous condition* yang membatasi langkah pada sel berdekatan (tidak terjadi lompatan), dan *monotonicity* yang memaksa kan setiap poin dalam lintasan mengikuti urutan. Dengan demikian, diperoleh jarak *DTW* yang merupakan lintasan *warping* optimum (jarak terdekat) seperti pada persamaan 6.

$$d_{DTW}(P, Q) = \min \left\{ \frac{\sum_{k=1}^K w_k}{K} \right\} \tag{6}$$

2.5 K-Means

Analisis klaster *k-means* termasuk dalam salah satu algoritma klaster non-hirarki yaitu metode klaster dengan menentukan banyak klaster terlebih dahulu. Adapun *k-means* membentuk klaster dengan memasukkan objek kedalam klaster dengan *centroid* terdekat. Secara umum langkah analisis klaster dimulai dengan memasukkan objek kedalam k inisial klaster tertentu, kemudian dihitung pusat klaster menggunakan persamaan 7 yang menghitung *centroid* klaster i yang terdiri dari n objek pada observasi ke-1. Perhitungan tersebut diulang pada seluruh observasi. Kemudian diukur kedekatan antara objek dengan *centroid* dan memasukkan objek kedalam klaster dengan *centroid* terdekat. Terakhir dilakukan perulangan perhitungan pusat klaster dan pengukuran jarak antara objek dengan klaster hingga tidak terjadi perubahan klaster (Johnson and Wichern, 2007).

$$C_{i,1} = \frac{\sum_{j=1}^n x_{ij}}{n} \tag{7}$$



Gambar 1. Grafik NTP 34 Provinsi di Indonesia

2.6 Koefisien *Silhouette*

Kluster yang baik merupakan kluster yang memiliki objek dengan jarak terdekat antar objek di dalam kluster yang sama dan jauh dengan objek di luar kluster. Hal tersebut dapat dievaluasi menggunakan koefisien *silhouette*. Nilai koefisien *silhouette* ($s(c)$) diukur dengan menghitung rata-rata jarak objek c dengan kluster lain ($b(c)$) dikurangi rata-rata jarak objek c dengan objek lain di luar kluster ($a(c)$). Terakhir hasil tersebut dibagi dengan nilai maksimum $a(c)$ dan $b(c)$. Secara matematis dapat dituliskan dalam persamaan 8. Selanjutnya berdasarkan nilai *silhouette* dapat diperoleh rata-rata nilai koefisien *silhouette* dengan persamaan 9. Adapun interpretasi kluster dapat dilihat pada tabel 2.

$$s(c) = \frac{b(c) - a(c)}{\max\{a(c), b(c)\}} \quad (8)$$

$$SC = \frac{\sum_{c=1}^n s(c)}{n} \quad (9)$$

Kluster kuat adalah kluster yang menunjukkan kesamaan tinggi antar objek dalam kluster yang sama dan rendah antara objek dengan kluster berbeda. Selanjutnya kategori layak digunakan berarti kesamaan objek dalam kluster masih lebih tinggi dibandingkan dengan kesamaan objek dengan kluster berbeda meskipun tidak berbeda jauh. Sedangkan, kluster buruk dan tidak layak digunakan menunjukkan bahwa kesamaan objek antar kluster berbeda lebih tinggi dibandingkan objek dalam kluster yang sama.

Tabel 1. Keباikan Kluster Berdasarkan Koefisien *Silhouette*

Koefisien <i>silhouette</i>	Keterangan
0,71 – 1,00	Kluster kuat
0,51 – 0,70	Kluster layak digunakan
0,26 – 0,50	Kluster buruk
≤ 0,25	Kluster tidak layak digunakan

3. METODE PENELITIAN

3.1. Data

Data yang digunakan yaitu data sekunder Nilai Tukar Petani (NTP) pada 34 Provinsi di Indonesia pada Januari 2019 – September 2023 dan diperoleh dari publikasi Badan Pusat Statistik (BPS) Indonesia.

3.2. Langkah – Langkah Analisis

Metode yang digunakan dalam pengklustersan NTP 34 provinsi di Indonesia sejak Januari 2019 – September 2023 adalah kluster K-Means dengan membandingkan dua pengukuran jarak yaitu CID dan DTW. Dengan menggunakan koefisien *silhouette* sebagai ukuran kebaikan kluster. Adapun langkah-langkah analisis sebagai berikut:

1. Melakukan melakukan eksplorasi data nilai tukar petani pada Januari 2019 – September 2023 untuk mengetahui gambaran umum mengenai data tersebut.
2. Melakukan analisis kluster menggunakan pengukuran jarak CID dan DTW
3. Jumlah kelompok yang digunakan yaitu 2, 3, 4 dan 5
4. Melakukan validasi dengan menggunakan *silhouette* untuk melihat seberapa baik pengelompokan yang dilakukan.
5. Melakukan pemilihan jumlah kluster dan pengukuran jarak terbaik berdasarkan nilai koefisien *silhouette* tertinggi.

4. HASIL DAN PEMBAHASAN

4.1 Analisis Deskriptif

Gambar 1 menunjukkan bahwa Provinsi yang memiliki NTP cenderung mengalami perubahan yang cukup signifikan atau mengalami fluktuasi dari tahun ke tahun antara lain adalah Provinsi, Aceh, Sumatera Barat, Riau, Jambi, Sumatera Selatan, Bengkulu, Lampung, Kepulauan Bangka Belitung, Kalimantan Barat, Kalimantan Tengah, Kalimantan Timur, dan Sulawesi Barat. Sedangkan provinsi dengan NTP

yang cenderung konstan atau tidak terdapat perubahan yang signifikan antara lain Provinsi Kepulauan Riau, DKI Jakarta, Jawa Barat, Jawa Tengah, DI Yogyakarta, Jawa Timur, Banten, Bali, Nusa Tenggara Barat, Nusa Tenggara Timur, Kalimantan Utara, Sulawesi Utara, Sulawesi Tengah, Sulawesi Selatan, Sulawesi Tenggara, Gorontalo, Maluku, Maluku Utara, Papua Barat, dan Papua.

4.2 Hasil Pengklasteran

Berikut merupakan perbandingan jumlah anggota klaster pada hasil pengklasteran menggunakan pengukuran jarak CID dan DTW dengan banyak klaster (*k*) 2, 3, 4 dan 5 dapat dilihat pada tabel 2.

Tabel 2. Jumlah Anggota Cluster

k	Klaster	Anggota	
		CID	DTW
2	1	25	25
	2	9	9
3	1	10	24
	2	9	4
	3	15	6
4	1	8	15
	2	9	4
	3	14	5
	4	3	10
5	1	9	7
	2	9	4
	3	12	5
	4	2	10
	5	2	8

Dari beberapa hasil pengelompokan menunjukkan bahwa terdapat kelompok Provinsi yang selalu berada pada klaster yang sama seperti Provinsi Aceh, Sumatera Barat, Kalimantan Selatan, Kalimantan Utara, dan Sulawesi Utara serta Riau, Jambi, Bengkulu, dan Kalimantan Barat. Hal tersebut menunjukkan kelompok Provinsi tersebut memiliki kedekatan pola yang sangat kuat baik menggunakan jarak DTW maupun CID, hal tersebut dapat dilihat pada Gambar 2.

Kedua kelompok Provinsi pada Gambar 2 sekilas memiliki pola pertumbuhan yang hampir sama yaitu sama-sama terjadi peningkatan.

Akan tetapi jika dilihat dari nilai NTP terlihat bahwa kelompok kedua memiliki nilai NTP di atas 100 sejak tahun 2019 yang menunjukkan nilai jual petani lebih tinggi dibanding nilai jual yang dikeluarkan dan terus meningkat.

Hal tersebut berbeda dengan kelompok pertama yang menunjukkan nilai tukar masih dibawah 100 pada beberapa periode seperti pada tahun 2019

hingga 2020, meski demikian pada kelompok 1 masih terjadi peningkatan NTP dari waktu ke waktu.



Gambar 2. Perbandingan Pengklasteran



Gambar 3. Klaster Terbaik

4.3 Perbandingan Ukuran Jarak

Perbandingan kebaikan klaster yang terbentuk dengan menggunakan CID dan DTW dilakukan dengan menggunakan koefisien *silhouette* yang terdapat pada tabel 3.

Tabel 3. Perbandingan Nilai Koefisien *Silhouette*

k	Anggota	
	CID	DTW
2	0.8776	0.7096
3	0,4830	0,6301
4	0.3665	0.3926
5	0.3817	0.3026

Tabel 3 menunjukkan bahwa klaster terbaik adalah pengklasteran dengan banyak klaster 2 ($k = 2$) menggunakan ukuran jarak CID ditunjukkan oleh nilai koefisien *silhouette* tertinggi dibandingkan klaster lainnya yaitu sebesar 0.8776.

4.4 Klaster Terbaik

Klaster terbaik yang diperoleh adalah klaster yang menggunakan jarak CID dengan jumlah klaster yang terbentuk yaitu $k = 2$ yang dapat dilihat pada gambar 3 berikut bahwa antar anggota kelompok memiliki pola deret waktu yang sama sedangkan antar kelompoknya memiliki pola deret waktu yang berbeda, dengan anggota klaster terlihat pada tabel 4.

Tabel 4. Anggota Klaster Terbaik

Klaster	Anggota
1	Aceh, Sumatera Barat, Sumatera Selatan, Lampung, Kepulauan Riau, DKI Jakarta, Jawa Barat, Jawa Tengah, DI Yogyakarta, Jawa Timur, Banten, Bali, Nusa Tenggara Barat, Nusa Tenggara Timur, Kalimantan Selatan, Kalimantan Utara, Sulawesi Utara, Sulawesi Tengah, Sulawesi Selatan, Sulawesi Tenggara, Gorontalo, Maluku, Maluku Utara, Papua Barat, Papua
2	Sumatera Utara, Riau, Jambi, Bengkulu, Kepulauan Bangka Belitung, Kalimantan Barat, Kalimantan Tengah, Kalimantan Timur, Sulawesi Barat.

5. KESIMPULAN

Analisis klaster deret waktu pada Nilai Tukar Petani pada Januari 2019 hingga September 2023 di 34 Provinsi di Indonesia menghasilkan kesimpulan berikut:

1. Jarak *Complexity Invariance Distance* (CID) lebih baik dibandingkan dengan *Dynamic Time Warping* (DTW) karena memiliki nilai koefisien *silhouette* tertinggi.
2. Jumlah klaster optimal yang terbentuk yaitu 2 klaster dengan pengukuran jarak CID dilihat dari nilai koefisien *silhouette* tertinggi yaitu sebesar 0.8776.
3. Klaster yang terbentuk tersebut terdiri dari 25 Provinsi pada klaster satu dan 9 Provinsi pada klaster dua. Pada cluster pertama Aceh, Sumatera Barat, Sumatera Selatan, Lampung, Kepulauan Riau, DKI Jakarta, Jawa Barat, Jawa Tengah, DI Yogyakarta, Jawa Timur, Banten, Bali, Nusa Tenggara Barat, Nusa Tenggara Timur, Kalimantan Selatan, Kalimantan Utara, Sulawesi Utara, Sulawesi Tengah, Sulawesi Selatan, Sulawesi Tenggara, Gorontalo, Maluku, Maluku Utara, Papua Barat, dan Papua. Anggota klaster kedua adalah Sumatera Utara, Riau, Jambi, Bengkulu, Kepulauan Bangka Belitung, Kalimantan Barat,

Kalimantan Tengah, Kalimantan Timur, dan Sulawesi Barat.

DAFTAR PUSTAKA

- ABBASIMEHR, H., PAKI, R. AND BAHRINI, A., 2022. A novel approach based on combining deep learning models with statistical methods for COVID-19 time series forecasting. *Neural Computing and Applications*, 4, pp.3135–3149.
- ADNYANI, P.W. AND SIHOMBING, L.R.P., 2021. Analisis Cluster Time Series Dalam Pengelompokan Provinsi Di Indonesia Berdasarkan Nilai PDRB. *Lppm Bina Bangsa*, [online] 1(1), pp.47–54.
- AGHABOZORGI, S., SEYED SHIRKHORSHIDI, A. AND YING WAH, T., 2015. Time-series clustering - A decade review. *Information Systems*, [online] 53, pp.16–38. <https://doi.org/10.1016/j.is.2015.04.007>.
- BATISTA, G.E.A.P.A., WANG, X. AND KEOGH, E.J., 2011. A complexity-invariant distance measure for time series. *Proceedings of the 11th SIAM International Conference on Data Mining, SDM 2011*, pp.699–710. <https://doi.org/10.1137/1.9781611972818.60>.
- DING, H., TRAJCEVSKI, G., SCHEUERMANN, P., WANG, X. AND KEOGH, E., 2008. Querying and mining of time series data. *Proceedings of the VLDB Endowment*, 1(2), pp.1542–1552. <https://doi.org/10.14778/1454159.1454226>.
- HAIR, J.F., BLACK, W.C. AND BABIN, B.J., 2010. *Multivariate Data Analysis*.
- JOHNSON, R.A., and WICHERN, D.W., 2007. *Applied Multivariate Statistical Analysis*. US Patent 3,123,114.
- KAUFMAN, L. AND ROUSSEEUW, P.J., 1990. Finding Groups in Data: An Introduction to Cluster Analysis. pp.1–67. <https://doi.org/10.1002/9780470316801.ch1>.
- KAUFMAN, L. AND ROUSSEEUW, P.J., 2006. *Finding Groups in Data: An introduction to Cluster ANalysis*. Wiley-interscience. New Jersey: John Wiley & Sons.
- MUNTHER, A.D., 2019. Penerapan clustering time series untuk menggerombolkan provinsi di Indonesia berdasarkan nilai produksi padi. *urnal Litbang Sukowati: Media Penelitian dan Pengembangan*, 2.
- PAPARRIZOS, J. AND GRAVANO, L., 2017. Fast and accurate time-series clustering. *ACM Transactions on Database Systems*, 42(2). <https://doi.org/10.1145/3044711>.
- RIYADI, M.A.A., PRATIWI, D.S., IRAWAN, A.R. AND FITHRIASARI, K., 2017. Clustering stationary and non-stationary time series based on autocorrelation distance of hierarchical and K-means algorithms. *International Journal of Advances in Intelligent Informatics*, 3(3),

- pp.154–160.
<https://doi.org/10.26555/ijain.v3i3.98>.
- SAKOE, H. AND CHIBA, S., 1978. Dynamic programming algorithm optimization for spoken word recognition. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 26(1), pp.43–49.
<https://doi.org/10.1109/TASSP.1978.1163055>.
- SHANG, D., SHANG, P. AND LIU, L., 2019. Multidimensional scaling method for complex time series feature classification based on generalized complexity-invariant distance. *Nonlinear Dynamics*, [online] 95(4), pp.2875–2892. <https://doi.org/10.1007/s11071-018-4728-6>.
- WARREN LIAO, T., 2005a. Clustering of time series data - A survey. *Pattern Recognition*, 38(11), pp.1857–1874.
<https://doi.org/10.1016/j.patcog.2005.01.025>.

Halaman ini sengaja dikosongkan