

**Analisis Non-Hierarchical Partitioning K-Medoid
Pada Produksi Sektor Hortikultura
Tahun 2019 Di Indonesia**

S K R I P S I



**ARISKA DEWI SUSANTI
F1C217009**

**PROGRAM STUDI MATEMATIKA
JURUSAN MATEMATIKA DAN ILMU PENGETAHUAN ALAM**

**FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS JAMBI
2021**

SURAT PERNYATAAN

Dengan ini saya menyatakan bahwa skripsi ini benar-benar karya sendiri. Sepanjang pengetahuan saya tidak terdapat karya atau pendapat yang ditulis atau diterbitkan orang lain kecuali sebagai acuan atau kutipan dengan mengikuti tata penulisan karya ilmiah yang telah lazim.

Tanda tangan yang tertera dalam halaman pengesahan adalah asli. Jika tidak asli, saya siap menerima sanksi sesuai dengan peraturan yang berlaku.

Jambi, 6 Juli 2021

Yang menyatakan



Ariska Dewi Susanti
F1C217009

RINGKASAN

Sektor hortikultura memiliki peran dalam pemenuhan gizi dan nutrisi masyarakat Indonesia. Sektor hortikultura terbagi menjadi subsektor tanaman sayur-sayuran, tanaman buah-buahan, tanaman obat dan tanaman hias. Di Indonesia masih terdapat beberapa daerah yang memiliki perbedaan yang jauh dari rata-rata produksi daerah lainnya seperti provinsi D.K.I Jakarta, Jawa Barat, dan Jawa Timur. Nilai produksi hortikultura yang jauh dari nilai produksi lainnya pada data dalam statistika dapat dikatakan sebagai *outlier*. Pertumbuhan penduduk di Indonesia setiap tahunnya mengalami peningkatan sedangkan produksi hortikultura tiap tahunnya tidak selalu mengalami kenaikan bahkan ada yang mengalami penurunan. Pertumbuhan penduduk mengakibatkan jumlah permintaan produk hortikultura meningkat. Data produksi hortikultura di Indonesia mengandung *outlier* yang menyebabkan persebaran produksi tidak merata, maka diperlukan suatu pengelompokan wilayah. Metode yang digunakan untuk mengelompokkan suatu wilayah adalah analisis *cluster*. Analisis *Cluster* merupakan teknik analisis data yang bertujuan untuk mengelompokkan objek-objek ke dalam beberapa kelompok berdasarkan kemiripan karakteristik yang dimilikinya. Analisis *cluster* yang digunakan adalah *K-Medoid*. *K-Medoid* menggunakan prinsip meminimalisir disimilitud objek, maka tiap objek *cluster* direpresentasikan oleh objek dari dalam *cluster* yang terbentuk. Algoritma *K-Medoids* memiliki kelebihan untuk mengatasi kelemahan pada algoritma *K-Means* yang sensitif terhadap *outlier* dan hasil pengelompokan pada metode ini tetap meskipun dilakukan pengacakan terhadap data. *K-Medoid* memilih objek medoid secara random untuk dijadikan pusat dari sebuah *cluster*.

Penelitian dilakukan dengan merumuskan masalah, melakukan standarisasi data, mengecek asumsi analisis *cluster*, melakukan analisis *cluster* dengan algoritma *K-Medoid* menggunakan ukuran jarak *Euclidean*, kemudian menghitung nilai *Silhouette Coefficient* sebagai penentu banyaknya *cluster* yang tepat. Hasil penelitian yang diperoleh adalah data mengalami multikolinearitas sehingga dilakukan analisis faktor dengan hasil 8 faktor yang digunakan dalam analisis *cluster K-Medoid*. Diperoleh bahwa *Cluster 1* memiliki 25 anggota yang terdiri dari Provinsi Aceh, Sumatera Barat, Riau, Bengkulu, Lampung, Kep.Bangka Belitung, Kep. Riau, DKI Jakarta, Jawa Barat, DI Yogyakarta, Bali, Nusa Tenggara Timur, Kalimantan Barat, Kalimantan Tengah, Kalimantan Selatan, Kalimantan Timur, Kalimantan Utara, Sulawesi Tengah, Sulawesi Tenggara, Gorontalo, Sulawesi Barat, Maluku, Maluku Utara, Papua Barat dan Papua. *Cluster 1* merupakan *cluster* dengan tingkat produksi tanaman hortikultura yang rendah. Variabel yang sangat mempengaruhi secara positif pada *cluster 1* adalah variabel produksi tanaman hias yang terdiri dari komoditas tanaman anggur dan tanaman *heliconia*. *Cluster 2* memiliki 9 anggota yang terdiri dari Provinsi Sumatera Utara, Jambi, Sumatera Selatan, Jawa Tengah, Jawa Timur, Banten, Nusa Tenggara Barat, Sulawesi Utara, Sulawesi Selatan. *Cluster 2* merupakan *cluster* dengan tingkat produksi tanaman hortikultura yang tinggi. Variabel yang sangat berpengaruh pada *cluster* ini adalah produksi tanaman buah yang terdiri dari produksi komoditas tanaman jeruk besar dan tanaman duku. Hasil perhitungan menggunakan software dan secara manual tidak memberikan perbedaan yang cukup besar. Berdasarkan nilai *Sillhouette Coefficient* yang diperoleh hasil *cluster* secara keseluruhan memiliki kategori struktur yang buruk karena bernilai 0,24. Hal ini dikarenakan pada *cluster 1* struktur *cluster* yang terbentuk lemah dan pada *cluster 2* struktur *cluster* yang terbentuk buruk.

SUMMARY

The horticultural sector has a role in fulfilling the nutrition of the Indonesian people. The horticultural sector is divided into sub-sectors of vegetable crops, fruit crops, medicinal plants and ornamental plants. In Indonesia, there are still some areas that have differences that are far from the average production of other regions, such as the provinces of D.K.I Jakarta, West Java, and East Java. Horticultural production values that are far from other production values in the statistical data can be said to be outliers. Population growth in Indonesia every year has increased, while horticultural production each year does not always increase and some even experience a decline. Population growth causes the demand for horticultural products to increase. Horticultural production data in Indonesia contains outliers that cause the distribution of production to be uneven, so a regional grouping is needed. The method used to classify an area is cluster analysis. Cluster analysis is a data analysis technique that aims to group objects into several groups based on the similarity of their characteristics. The cluster analysis used is K-Medoid. K-Medoid uses the principle of minimizing the dissimilarity of objects, so that each cluster object is represented by an object from within the cluster that is formed. The K-Medoids algorithm has the advantage of overcoming the weaknesses of the K-Means algorithm which is sensitive to outliers and the grouping results in this method remain even though the data is randomized. K-Medoid randomly selects a medoid object to be the center of a cluster.

The research was conducted by formulating problems, standardizing data, checking cluster analysis assumptions, performing cluster analysis with the K-Medoid algorithm using the Euclidean distance measure, then calculating the Silhouette Coefficient value as a determinant of the number of appropriate clusters. The results of the study obtained were that the data experienced multicollinearity so that a factor analysis was carried out with the results of 8 factors used in the K-Medoid cluster analysis. It was found that Cluster 1 has 25 members consisting of the Provinces of Aceh, West Sumatra, Riau, Bengkulu, Lampung, Kep. Bangka Belitung, Kep. Riau, DKI Jakarta, West Java, DI Yogyakarta, Bali, East Nusa Tenggara, West Kalimantan, Central Kalimantan, South Kalimantan, East Kalimantan, North Kalimantan, Central Sulawesi, Southeast Sulawesi, Gorontalo, West Sulawesi, Maluku, North Maluku, West Papua and Papua. Cluster 1 is a cluster with a low level of horticultural crop production. The variable that has a very positive influence on cluster 1 is the ornamental plant production variable which consists of grapes and heliconia plants. Cluster 2 has 9 members consisting of the provinces of North Sumatra, Jambi, South Sumatra, Central Java, East Java, Banten, West Nusa Tenggara, North Sulawesi, South Sulawesi. Cluster 2 is a cluster with a high level of horticultural crop production. The most influential variable in this cluster is the production of fruit crops, which consist of large citrus and duku commodities. The results of calculations using software and manually do not give a big enough difference. Based on the value of the Sillhouette Coefficient, the result of the cluster as a whole has a bad structure category because it is 0.24. This is because in cluster 1 the cluster structure formed is weak and in cluster 2 the cluster structure is poorly formed.

**Analisis Non-Hierarchical Partitioning K-Medoid
Pada Produksi Sektor Hortikultura
Tahun 2019 Di Indonesia**

S K R I P S I

Diajukan sebagai salah satu syarat untuk memperoleh Gelar
Sarjana pada Program Studi Matematika



ARISKA DEWI SUSANTI

F1C217009

**PROGRAM STUDI MATEMATIKA
JURUSAN MATEMATIKA DAN ILMU PENGETAHUAN ALAM**

FAKULTAS SAINS DAN TEKNOLOGI

UNIVERSITAS JAMBI

2021

PENGESAHAN

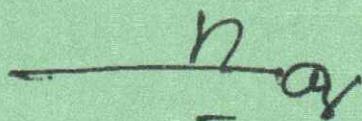
Skripsi dengan judul **Analisis Non-Hierarchical Partitioning K-Medoid Pada Produksi Sektor Hortikultura Tahun 2019 Di Indonesia** yang disusun oleh **ARISKA DEWI SUSANTI, NIM: F1C217009** telah dipertahankan didepan tim penguji pada tanggal 6 Juli 2021 dan dinyatakan lulus.

Susunan Tim Pengaji:

Ketua	:	Drs. Sufri, M.Si
Sekretaris	:	Corry Sormin, S.Si., M. Sc
Anggota	:	1. Drs. Wardi Syafmen, M.Si 2. Gusmi Kholijah, S.Si., M.Si 3. Cut Multahadah, S.Pd., M.Pd

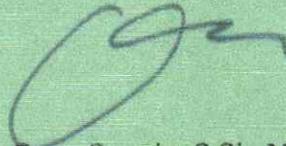
Disetujui:

Pembimbing Utama



Drs. Sufri, M.Si
NIP. 195907231985031007

Pembimbing Pendamping

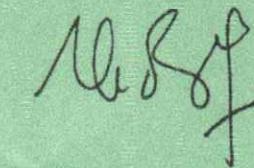


Corry Sormin, S.Si., M. Sc
NIK. 201706072011

Diketahui :



Ketua Jurusan Matematika dan
Ilmu Pengetahuan Alam



Dr. Madyawati Latief, S.P., M.Si
NIP. 197206241999032001

RIWAYAT HIDUP



Ariska Dewi Susanti lahir di Kota Klaten, pada tanggal 02 Oktober 1999. Penulis merupakan anak pertama dari dua bersaudara dari pasangan Ayahanda Suhardi dan Ibunda Surati. Jalur pendidikan formal yang pernah ditempuh oleh penulis adalah sebagai berikut:

1. SD Negeri 40 Kota Jambi tamat tahun 2005-2011
2. SMP Negeri 6 Kota Jambi tamat tahun 2011-2014
3. SMA Negeri 8 Kota Jambi tamat tahun 2014-2017

Penulis mulai menempuh pendidikan perkuliahan di program studi matematika Fakultas Sains dan Teknologi, Universitas Jambi pada tahun 2017 , lulus seleksi melalui jalur SBMPTN. Selama menempuh pendidikan di jenjang S1 , penulis cukup aktif dalam bidang akademik maupun organisasi kampus dan luar kampus. Adapun organisasi yang di ikuti penulis adalah HIMATIKA (Himpunan Mahasiswa Matematika) dan PERADAH (Perkumpulan Pemudamudi Hindu Provinsi Jambi). Penulis juga melaksanakan kegiatan Magang di Badan Pusat Statistik (BPS) Provinsi Jambi. Selain itu, Penulis juga aktif dalam kegiatan seminar-seminar baik tingkat jurusan, fakultas maupun Universitas.

PRAKATA

Om Swastiastu.

Assalamu'alaikum wr. Wb.

Puji syukur atas Asung Kerta Waranugraha Ida Sang Hyang Widhi atau Tuhan Yang Maha Esa, sehingga penulis dapat menyelesaikan Skripsi yang berjudul "**Analisis Non-Hierarchical Partitioning K-Medoid Pada Produksi Sektor Hortikultura Tahun 2019 Di Indonesia**".

Skripsi ini disusun dan diajukan sebagai syarat untuk menyelesaikan Pendidikan strata satu (S1) pada Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Jambi.

Tidak sedikit hambatan dan halangan yang penulis alami dalam menyelesaikan skripsi ini,namun dengan adanya dorongan dan dukungan dari banyak pihak akhirnya skripsi ini dapat terselesaikan. Pada kesempatan ini penulis ingin mengucapkan kepada seluruh pihak yang telah memberikan dorongan dan dukungannya kepada penulis yang telah membantu dalam penyusunan Skripsi ini. Penulis mengucapkan rasa terimakasih kepada :

1. Ida Sang Hyang Widhi atas Asung Kerta Waranugraha-Nya penulis dapat menyelesaikan Skripsi ini dengan baik.
2. Ayahanda Suhardi, Ibunda Surati, Adik penulis Angga serta seluruh keluarga besar penulis yang selalu memberikan dukungan dan doanya untuk keberhasilan penulis.
3. Bapak Prof. Drs. Damris M, M.Sc., Ph. D selaku Dekan Fakultas Sains dan Teknologi Universitas Jambi.
4. Ibu Dr. Madyawati Latief, S.P., M.Si selaku Ketua Jurusan Matematika dan Ilmu Pengetahuan Alam.
5. Ibu Gusmi Kholijah, S.Si., M. Si selaku Ketua Program Studi Matematika Fakultas Sains dan Teknologi Universitas Jambi serta selaku Dosen Pembimbing Akademik penulis.
6. Bapak Drs. Sufri, M. Si selaku Dosen Pembimbing utama dan Ibu Corry Sormin, S.Si., M.Sc selaku Dosen Pembimbing pendamping, yang telah banyak membimbing, memberi motivasi dan meluangkan waktu, tenaga dan pikirannya kepada penulis dalam menyelesaikan Skripsi ini.
7. Bapak Drs. Wardi Syafmen, M. Si, Ibu Gusmi Kholijah, S.Si., M.Si dan Ibu Cut Multahadah, S.Pd., M.Pd selaku tim penguji yang telah memberikan tambahan dan masukan informasi kepada penulis demi kesempurnaan skripsi ini.

8. Seluruh Dosen Program Studi Matematika, Fakultas Sains dan Teknologi, Universitas Jambi yang telah memberikan ilmu dan berbagai pengalaman yang sangat berharga bagi penulis.
9. Bapak dan Ibu Staff Akademik Fakultas Sains dan Teknologi yang telah membantu penulis di bidang akademik dan kemahasiswaan.
10. Tiara, Dea, Arfarani, Awliana, Boby, Rifa selaku teman dekat penulis serta teman-teman seperjuangan di Program Studi Matematika Fakultas Sains dan Teknologi Universitas Jambi Angkatan 2017 yang tidak bisa penulis sebutkan satu persatu.
11. Adik-adik di Program Studi Matematika Fakultas Sains dan Teknologi Universitas Jambi Angkatan 2018 yang selalu menyemangati penulis yang tidak bisa penulis sebutkan satu persatu.
12. Nebrisa selaku teman dekat penulis yang selalu menjadi tempat bercerita dan selalu memberikan semangat dan doanya kepada penulis selama menempuh masa perkuliahan.
13. Teman-teman Grup Cidat, The Girls Makan-makan, Squad SMA dan Pemuda Hindu Jambi.
14. Semua pihak yang telah membantu dan tidak bisa disebutkan satu persatu.

Semoga Ida Sang Hyang Widhi Tuhan Yang Maha Esa membala semua kebaikan kepada pihak yang membantu. Penulis berharap, semoga skripsi ini dapat bermanfaat bagi para pembaca dimasa mendatang. Penulis menyadari skripsi ini masih jauh dari kesempurnaan. Penulis mengharapkan adanya kritik dan saran yang membangun sehingga dapat membantu penulis dalam penyempurnaan skripsi ini. Sekian dan terimakasih.

Om Santi, Santi, Santi Om.

Wassalamu'alaikum wr wb.

Jambi, 6 Juli 2021

Yang menyatakan



Ariska Dewi Susanti

NIM. F1C217009

DAFTAR ISI

PENGESAHAN	i
RIWAYAT HIDUP.....	ii
PRAKATA.....	iii
DAFTAR ISI	v
DAFTAR TABEL	vii
DAFTAR GAMBAR.....	viii
DAFTAR LAMPIRAN	ix
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Tujuan.....	4
1.4 Manfaat Penelitian.....	4
1.5 Batasan Masalah	5
II. TINJAUAN PUSTAKA.....	6
2.1 Hortikultura.....	6
2.1.1 Klasifikasi Hortikultura.....	6
2.1.2 Sifat dan Fungsi Produksi Hortikultura.....	7
2.1.3 Peran Hortikultura.....	8
2.2 Produksi Hortikultura	9
2.3 Vektor dan Matriks	9
2.3.1 Vektor Random dan Matriks Random	9
2.3.2 Vektor Means dan Matriks Kovariansi	10
2.4 Analisis Multivariat	15
2.4.1 Teknik Analisis Multivariat	17
2. 5 Analisis <i>Cluster</i>	17
2.6 <i>K-Medoid (Partitioning Around Medoids)</i>	27
2.4 <i>Silhouette Coefficient</i>	31
III. METODOLOGI PENELITIAN	33
3.1 Jenis dan Sumber Data.....	33
3.2 Objek dan Variabel Penelitian.....	33
3.3 Teknik Analisis Data.....	35
3.4 Diagram Alur Penelitian.....	38

IV. HASIL DAN PEMBAHASAN.....	39
4.1 Hasil Penelitian.....	39
4.2 Pembahasan.....	59
V. PENUTUP	63
5.1 Kesimpulan.....	63
5.2 Saran	64
DAFTAR PUSTAKA.....	65
LAMPIRAN	67

DAFTAR TABEL

Tabel	Halaman
1. Pengukuran Antar Objek	16
2. Contoh Data Jumlah Pembelian Buku	28
3. Medoid Awal	29
4. Hasil Perhitungan Algoritma <i>K-Medoid</i> Iterasi ke-1	29
5. Non- <i>Medoid</i>	29
6. Hasil Perhitungan Algoritma <i>K-Medoid</i> Terhadap Non- <i>Medoid</i>	30
7. Hasil Akhir <i>Cluster</i> Algoritma <i>K-Medoid</i>	30
8. Kriteria Penilaian <i>Clustering</i> yang Baik	32
9. Variabel Penelitian	33
10. Total <i>Variance</i>	42
11. Variabel Hasil Analisis Faktor	42
12. <i>Medoid</i> Awal	44
13. Objek Non- <i>Medoid</i>	47
14. Selisih Setiap Iterasi	47
15. Hasil Analisis <i>Cluster</i>	48
16. Anggota <i>Cluster</i> yang Terbentuk dengan Perhitungan Manual	49
17. Anggota <i>Cluster</i> yang Terbentuk dengan <i>Software R</i>	49
18. Anggota <i>Cluster</i> $k = 3$ yang Terbentuk	50
19. Anggota <i>Cluster</i> $k = 4$ yang Terbentuk	50
20. Hasil <i>Silhouette Coefficient</i>	51
21. Hasil <i>Silhouette Coefficient</i> pada $k = 3$	52
22. Hasil <i>Silhouette Coefficient</i> pada $k = 4$	53
23. Nilai Rata-rata Setiap Variabel pada <i>Cluster</i>	53
24. Perbandingan Hasil Perhitungan Manual dan <i>Output R</i>	55
25. Perbandingan Anggota <i>Cluster</i> Secara Manual dan <i>Output R</i>	57

DAFTAR GAMBAR

Gambar	Halaman
1. Skema Analisis Multivariat	16
2. Data yang Menunjukkan Keberadaan Tiga <i>Cluster</i>	18
3. Jarak pada Vektor Dimensi Dua (Johnson dan Wichern, 2007)	20
4. Jarak pada Vektor Dimensi Tiga	20
5. Jenis Teknik dalam Metode Aglomerasi	25
6. Diagram Alur Penelitian	38
7. <i>Silhouette Plot</i>	51
8. <i>Silhouette Plot</i> untuk $k = 3$	52
9. <i>Silhouette Plot</i> untuk $k = 4$	52
10. Peta Penyebaran <i>Cluster</i> Manual	58
11. Peta Penyebaran <i>Cluster</i> Ouput R	58

DAFTAR LAMPIRAN

Lampiran	Halaman
1. Data Produksi Hortikultura Tahun 2019.....	67
2. Matriks Varians Kovariansi	75
3. Data Hasil Standarisasi <i>Z-Score</i>	76
4. Matriks Korelasi R	86
5. <i>Rotated Component Matrix</i>	87
6. Data Hasil Analisis Faktor	89
7. Hasil Perhitungan Jarak Objek terhadap <i>Medoid</i> Awal	90
8. Hasil Perhitungan Jarak Objek terhadap Non- <i>Medoid</i>	91
9. Hasil Perhitungan Jarak di Setiap Iterasi	92
10. <i>Syntax R</i>	101
11. Hasil Input Data di <i>R</i>	102
12. Hasil <i>Output R K-Medoid</i>	103
13. Perhitungan Nilai Rata-Rata Tiap Variabel	104



I. PENDAHULUAN

1.1 Latar Belakang

Sektor pertanian memiliki peran penting di masyarakat dalam Pembangunan Ekonomi Indonesia. Hal ini karena sektor pertanian sebagai penyedia bahan pangan, bahan baku industri, pendapatan rumah tangga pedesaan serta penyumbang produksi domestik bruto di Indonesia. Salah satu sektor pertanian yang sangat penting adalah sektor Hortikultura. Sektor Hortikultura memiliki peran dalam pemenuhan gizi dan nutrisi masyarakat Indonesia. Namun masih terdapat beberapa kendala atau tantangan baik dari eksternal maupun internal. Berdasarkan Rencana Strategis Direktoral Jenderal Hortikultura Tahun 2015-2019 bahwa potensi yang dapat mendukung perkembangan sektor hortikultura antara lain ketersediaannya payung hukum, keanekaragaman hayati, ketersediaan lahan pertanian, agroklimat (iklim yang sesuai), dukungan teknologi, ketersediaan tenaga kerja, ketersediaan pasar, penetapan komoditas prioritas hortikultura, sistem perbenihan, serta sistem perlindungan hortikultura.

Sektor hortikultura terbagi menjadi subsektor tanaman sayur-sayuran, subsektor tanaman buah-buahan, subsektor tanaman hias, dan subsektor tanaman obat-obatan. Berdasarkan data Badan Pusat Statistik tahun 2019 subsektor tanaman buah-buahan terdiri dari 26 komoditas, subsektor tanaman sayur-sayuran terdiri dari 25 komoditas, subsektor tanaman hias terdiri dari 12 komoditas, dan subsektor tanaman obat terdiri dari 7 komoditas. Produksi tanaman buah-buahan terbesar yang tercatat berada pada komoditas durian, pisang, jeruk siam, mangga, dan nenas. Produksi subsektor tanaman sayur-sayuran yang memiliki produksi tertinggi terdapat pada komoditas tomat, cabai rawit, cabai besar, kubis, kentang, dan bawang merah. Pada subsektor tanaman hias komoditas yang paling banyak adalah krisan, sedap malam, dan melati. Sedangkan produksi pada subsektor tanaman obat-obatan yang paling banyak terdapat pada komoditas jahe dan kunyit. Subsektor tanaman sayuran dan buah-buahan merupakan tanaman pada sektor hortikultura yang cukup strategis untuk dikembangkan karena tanaman tersebut dibutuhkan setiap saat serta tidak tergantikan kedudukannya dalam pemenuhan kebutuhan konsumsi masyarakat. Ketua Umum Himpunan Kerukunan Tani Indonesia Moeldoko menyebutkan bahwa penyusutan lahan pertanian di Indonesia terjadi secara signifikan di setiap tahunnya. Selain itu kondisi tanah pertanian yang sudah rusak, aspek permodalan, manajemen pertanian, minimnya penguasaan teknologi dan inovasi serta penanganan pasca panen.

Berdasarkan data produksi sektor hortikultura tahun 2019 di Indonesia terdapat beberapa daerah yang memiliki perbedaan yang jauh dari rata-rata produksi daerah lainnya. Pada pulau Sumatera terdapat provinsi lampung yang memiliki data outlier, yaitu pada produksi nenas sebanyak 699.243 ton dan produksi jengkol sebanyak 15.6363 ton yang nilainya cukup berbeda jauh dari provinsi lainnya di pulau Sumatera. Pada pulau Jawa terdapat beberapa daerah seperti D.K.I Jakarta, Jawa Barat, dan Jawa Timur. Daerah D.K.I Jakarta memiliki perbedaan nilai produksi hortikultura yang sangat jauh dari rata-ratanya pada banyak komoditasnya contohnya pada komoditas cabai rawit, cabai besar dan terung. D.K.I Jakarta tidak memiliki hasil produksi pada komoditas tersebut atau produksi sebesar 0 ton. Nilai ini sangat jauh lebih rendah dibandingkan dengan daerah lainnya yang rata-rata memiliki nilai produksi pada komoditas tersebut. Kemudian daerah Jawa Barat memiliki nilai produksi yang sangat tinggi pada komoditas sawo sebesar 24.878 ton dibandingkan dengan produksi komoditas sawo pada daerah lainnya. Pada daerah Jawa Timur produksi apel sebanyak 480.834 ton, sangat jauh berbeda dengan produksi apel di daerah lainnya. Pada pulau Kalimantan tidak terdapat data yang mengandung outlier. Pada pulau Sulawesi terdapat outlier pada provinsi Sulawesi Selatan yaitu pada produksi Jeruk Besar yang berjumlah 36.674 ton yang rentang nilainya cukup jauh daripada jumlah produksi diprovinsi lainnya. Sedangkan pada pulau Papua dan sekitarnya tidak terdapat adanya nilai yang jauh berbeda dari nilai lainnya. Nilai produksi yang jauh dari nilai produksi lainnya pada data dalam statistika dapat dikatakan sebagai *outlier*. *Outlier* adalah merupakan suatu nilai pengamatan yang sangat besar atau sangat kecil dibandingkan dengan observasi lainnya (Johnson dan Wichern, 2007).

Adanya nilai produksi yang sangat jauh berbeda di setiap komoditas pada masing-masing daerah menyebabkan persebaran produksi hortikultura yang kurang baik. Sehingga diperlukan adanya suatu pengelompokan yang membantu pemetaan hasil produksi hortikultura di setiap daerah, sehingga persebaran hasil produksi dari setiap komoditas sektor hortikultura dapat tersalurkan secara merata. Diperlukan suatu metode analisa untuk pengelompokan daerah-daerah untuk mengetahui pembagian kelompok berdasarkan hasil produksi sektor hortikultura serta menganalisa daerah dan komoditas apakah yang sangat berpengaruh dalam suatu daerah dalam suatu kelompok maka tersebut. Salah satu metode mengelompokkan secara matematika adalah dengan analisis *cluster*. Analisis *cluster* merupakan salah satu jenis permasalahan dalam *data mining*. Menurut Han dkk (2012) Analisis *cluster* dalam *data mining (clustering)* merupakan suatu proses mempartisi sekumpulan

objek data menjadi subset. Analisis *cluster* atau pengelompokan terbagi menjadi metode yaitu hierarki dan Non-hierarki (partisi). Teknik yang sering digunakan dalam Metode Non-Hierarki (partisi) adalah *K-Means*. *K-Means* memiliki kelemahan yaitu sensitive terhadap data yang memiliki nilai sangat jauh dari rata-ratanya atau observasi yang menyimpang jauh dari data lainnya (*outlier*). Adanya *outlier* dapat berpengaruh terhadap hasil analisis *cluster* yang akan menyebabkan hasil analisis yang diperoleh menggunakan *K-Means* terdapat *cluster* yang kurang baik atau tidak signifikan.

Berdasarkan penelitian Sangga (2018) yang berjudul perbandingan algoritma *K-Means* dan algoritma *K-Medoid* dalam pengelompokan komoditas peternakan di Jawa Tengah tahun 2015, adanya penurunan hasil ternak di Jawa Tengah diperlukan adanya pengelompokan kelompok bidang peternakan serta algoritma *K-Medoids* dan *K-means* yang memiliki kesamaan dalam meminimalkan *squared error* sehingga perlu diketahui algoritma manakah yang lebih tepat, diperoleh bahwa metode *K-medoid* lebih baik dari pada metode *K-means* karena metode *K-medoid* memiliki nilai variansi *cluster* lebih kecil khususnya pada pengelompokan komoditas peternakan di Jawa Tengah tahun 2015. Selanjutnya berdasarkan penelitian Marlina D et. al (2018) yang berjudul Implementasi Algoritma *K-Medoid* dan *K-Means* untuk Pengelompokan Wilayah Sebaran Cacat pada Anak, rendahnya fasilitas bagi penyandang cacat oleh Dinas Sosial Riau serta angka penyandang cacat yang tersebar di Riau perlu dilakukan pengelompokan sehingga dapat diketahui sebaran cacat yang tinggi, berdasarkan algoritma *K-Medoid* diperoleh *cluster* pertama tingkat penyandang cacat rendah, *cluster* kedua penyandang cacat sedang dan *cluster* ketiga penyandang cacat tinggi kemudian dengan dibandingkan menggunakan nilai validitasnya diperoleh hasil bahwa algoritma *K-Medoid* lebih baik dalam pengelompokan data sebaran cacat pada anak dibandingkan dengan algoritma *K-Means*.

Berdasarkan beberapa hasil penelitian tersebut terlihat bahwa algoritma *k-Medoid* menghasilkan hasil pengelompokan yang lebih baik. Sehingga pada data produksi sector hortikultura yang memiliki *outlier*, peneliti ingin mengelompokkan provinsi di Indonesia dalam bidang pertanian khususnya dalam sektor hortikultura dengan menggunakan algoritma *K-medoid*. Penelitian ini menggunakan data produksi seluruh komoditas sektor hortikultura se-Indonesia yang dikutip dari Badan Pusat Statistik Indonesia Tahun 2019 yang terdiri atas produksi Temuireng, Temulawak, Lempuyang, Jahe, Kencur, Kunyit, Laos, Stoberi, Anggur, Apel, Blewah, Semangka, Melon, Sukun, Sirsak, Markisa, Sawo, Salak, Nenas, Nangka, Manggis, Mangga, Jeruk Besar, Jeruk Siam, Jambu Air, Pepaya, Pisang, Rambutan, Alpukat, Belimbing, Duku, Durian, Jambu Biji,

Jengkol, Petai, Jamur, Paprika, Melinjo, Bawang Merah, Bawang Putih, Bawang Daun, Kentang, Kubis, Kembang Kol, Sawi, Wortel, Lobak, Kacang Merah, Kacang Panjang, Cabai Besar, Cabai Rawit, Tomat, Terung, Buncis, Ketimun, Labusiam, Kangkung, Bayam, Anggrek, Anthurium, Anyelir, Gerbera, Gladiol, Heliconia, Krisan, Mawar, Sedap Malam, Dracaena, Melati, dan Palem. Penelitian ini tertuang dalam skripsi penulis yang berjudul **“Analisis Non-Hierarchical Partitioning K-Medoid Pada Produksi Sektor Hortikultura Tahun 2019 Di Indonesia”**.

1.2 Rumusan Masalah

Berdasarkan latar belakang tersebut, maka rumusan masalah yang akan dikaji dalam permasalahan ini adalah sebagai berikut:

1. Bagaimana hasil pengelompokan provinsi di Indonesia berdasarkan produksi sektor hortikultura menggunakan analisis *cluster K-Medoid*?
2. Produksi apa saja yang berpengaruh dalam suatu *cluster* yang diperoleh?

1.3 Tujuan

Berdasarkan rumusan masalah yang ada maka tujuan yang akan dicapai dalam penelitian ini adalah sebagai berikut:

1. Mengetahui hasil pengelompokan provinsi di Indonesia berdasarkan produksi tanaman hortikultura tahun 2019 dengan menggunakan algoritma *K-Medoid*.
2. Mengetahui nilai produksi komoditas apa saja yang berpengaruh dalam satu *cluster*.

1.4 Manfaat Penelitian

Manfaat yang diperoleh dari penelitian ini adalah sebagai berikut:

1. Bagi penulis adalah menerapkan teori matematika dalam bidang statistika khususnya dalam pengelompokan suatu objek.
2. Bagi pembaca adalah untuk menambah wawasan dan sebagai bahan referensi untuk penelitian selanjutnya.
3. Bagi pemerintah adalah sebagai bahan informasi mengenai pengelompokan provinsi di Indonesia berdasarkan produksi hortikultura dalam mengambil kebijakan-kebijakan program bagi pembangunan perkembangan hortikultura di Indonesia. Serta sebagai sumber informasi agar persebaran produksi di Indonesia semakin merata.

1.5 Batasan Masalah

Pada penelitian ini, penulis membatasi materi dan pembahasan agar tidak meluas sehingga digunakan batasan masalah sebagai berikut:

1. Variabel yang digunakan dalam penelitian sebanyak 70 variabel produksi tanaman hortikultura yang memuat keseluruhan informasi produksi sektor hortikultura.
2. Metode analisis menggunakan algoritma *K-Medoid* dengan Jarak *Euclidean*.
3. Proses pengelompokan dilakukan secara manual dan hasilnya dibandingkan dengan output dari *software R*.



II. TINJAUAN PUSTAKA

2.1 Hortikultura

Menurut Kamus Besar Bahasa Indonesia hortikultura memiliki pengertian yaitu pengusahaan dan pemeliharaan kebun bunga, buah-buahan dan sayur-sayuran. Kata Hortikultura berasal dari Bahasa Latin ‘hortus’ yang artinya kebun dan ‘colere’ yang artinya membudidayakan. Secara harfiah, hortikultura berarti ilmu yang mempelajari pembudidayaan tanaman kebun. Akan tetapi, pada umumnya para pakar mendefinisikan hortikultura sebagai ilmu yang mempelajari budidaya tanaman sayuran, buah-buahan, bunga-bungaan, atau tanaman hias. Hortikultura merupakan cabang pertanian yang berurusan dengan budidaya intensif tanaman yang diajukan untuk bahan pangan manusia obat-obatan dan pemenuhan kepuasan (Zulkarnain, 2009).

Pada masa pemerintahan Hindia Belanda hortikultura diartikan sebagai *perkebunan rakyat* atau *tuinbouw* yaitu ilmu yang menitik beratkan perhatiannya pada ilmu berkebun tanam-tanaman yang mengandung seni, Kesehatan dan perdagangan. Hal tersebut dikarenakan pada waktu itu tanaman hortikultura seperti buah-buahan, sayuran dan obat-obatan kebanyakan ditanam oleh penduduk di sekitar perkampungan tempat tinggalnya. Hal ini berdasarkan fakta bahwa pada saat itu usaha tani hortikultura tidak memerlukan perhatian khusus, seperti jarak tanam, pemupukan ataupun pemberantasan hama dan penyakit. Hortikultura merupakan budidaya tanaman yang menguntungkan. Hal ini seiring dengan sejalannya kebutuhan masyarakat Indonesia (Sunaryono, 1981).

Tanaman hortikultura juga merupakan tanaman yang paling banyak dibudidayakan oleh petani di Indonesia, karena produksi hortikultura merupakan bahan pangan yang dibutuhkan manusia untuk kehidupan sehari-hari. Hortikultura juga berperan sebagai sumber gizi masyarakat, penyedia lapangan pekerjaan khususnya dalam bidang usaha tani, dan penunjang kegiatan agrowisata dan agroindustri di masyarakat. Hal ini menunjukkan bahwa pengembangan hortikultura terkait dengan aspek yang lebih luas yang meliputi teknologi dengan sosio-budaya petani.

2.1.1 Klasifikasi Hortikultura

Menurut Badan Pusat Statistik tanaman hortikultura termasuk dalam salah satu sub sektor pertanian yang membahas masalah budidaya tanaman yang menghasilkan buah, sayuran, tanaman hias, rempah tradisional dan bahan baku obat tradisional. Berdasarkan jenis komoditas yang diusahakan hortikultura mencakup bidang ilmu buah-buahan (*pomology*), sayuran (*olericulture*), bunga dan tanaman hias (*floriculture*), serta pertamanan (*landscape*

horticulture) yaitu bagian ilmu hortikultura yang mempelajari pemanfaatan tanaman hortikultura, terutama tanaman hias dalam penataan lingkungan (Zulkarnain, 2009).

Sayuran merupakan salah satu bahan pangan yang berfungsi sebagai salah satu sumber gizi. Kebutuhan sayuran bagi masyarakat semakin meningkat seiring dengan bertambahnya jumlah penduduk. Contoh beberapa sayuran yang paling banyak diminati oleh masyarakat Indonesia adalah bayam, kangkung, terung, sawi, dan buncis. Buah-buahan juga menjadi makanan yang sering diminati oleh masyarakat Indonesia. Buah dan sayuran memiliki peran yang sangat penting terutama sebagai sumber vitamin, mineral, dan serat makanan. Banyaknya konsumsi buah dan sayur juga dikaitkan akan dampak positifnya yang dapat mengurangi beberapa penyakit seperti jantung. Beberapa buah-buahan dan sayur-sayuran merupakan antioksidan yang kuat dan berfungsi untuk memodifikasi aktivasi metabolismik dan detoksifikasi atau disposisi karsinogen, juga mempengaruhi proses tumbuhnya sel tumor (Hanani, Z. et. al, 2016).

Tanaman hortikultura juga dibedakan berdasarkan tanaman hortikultura semusim dan tahunan. Tanaman hortikultura semusim meliputi tanaman hortikultura yang usianya relatif pendek (kurang dari satu tahun) dan panennya dilakukan satu atau beberapa kali masa panen untuk satu kali penanaman. Sedangkan tanaman hortikultura tahunan meliputi tanaman yang usianya lebih dari satu tahun dan untuk masa panennya dilakukan lebih dari satu kali penanaman

2.1.2 Sifat dan Fungsi Produksi Hortikultura

Produksi hasil hortikultura secara umum memiliki sifat atau ciri-ciri yaitu tidak dapat disimpan terlalu lama, mudah rusak bila disimpan tanpa perlakuan khusus, melimpah atau meruah pada suatu musim dan langka pada musim yang lain, dan fluktuasi harganya yang tajam sesuai dengan musim yang sedang berjalan. Produksi hortikultura yang mudah rusak adalah buah-buahan dan sayur-sayuran. Hal ini sering terjadi pada proses pengangkutan. Sehingga diperlukan penanganan yang baik saat proses pengangkutan. Produksi hortikultura tidak dapat disimpan dalam waktu yang lama karena akan cepat membusuk dan tidak dapat dikonsumsi kembali.

Fungsi hortikultura dalam kehidupan sangatlah besar. Secara universal hortikultura mempunyai guna memperbaiki gizi masyarakat, memperbesar devisa negara, memperluas kesempatan kerja/lapangan pekerjaan, meningkatkan pemasukan petani, dan pemenuhan kebutuhan keindahan dan

kelestarian lingkungan. Menurut Zulkarnain (2009), Secara sederhana fungsi utama tanaman hortikultura dapat dikelompokkan menjadi empat, yaitu:

- a. Fungsi penyediaan pangan, yakni terutama sekali dalam kaitannya dengan penyediaan vitamin, mineral, serat, dan senyawa lain untuk memenuhi gizi.
- b. Fungsi ekonomi, di mana pada umumnya komoditas hortikultura memiliki nilai ekonomi yang tinggi, menjadi sumber pendapatan bagi petani, pedagang, kalangan industri, dan lain-lain.
- c. Fungsi kesehatan, ditunjukkan oleh manfaat komoditas biofarmaka untuk mencegah dan mengobati berbagai penyakit tidak menular.
- d. Fungsi sosial budaya, yang ditunjukkan oleh peran komoditas hortikultura sebagai salah satu unsur keindahan atau kenyamanan lingkungan, serta perannya dalam berbagai upacara, kepariwisataan, dan lain-lain.

Selain tanaman sayuran, buah-buahan dan obat-obatan. Tanaman hias memiliki fungsi yang tidak kalah penting. Walaupun fungsinya tidak sepenting tanaman hortikultura lainnya tanaman hias tetap memiliki peranan yang cukup berarti dalam kehidupan sehari-hari terutama bagi para pecinta tanaman hias. Disadari atau tidak tanaman hias memberikan pengaruh dalam kehidupan manusia sebagai penyedia udara segar, bersih dan alami terutama di daerah perkotaan. Oleh karena itu, walaupun tidak memberikan manfaat secara langsung atau jasmania, adanya tanaman hias mampu menghadirkan nilai-nilai keindahan yang dapat menimbulkan dampak positif bagi psikologis bagi orang yang memandangnya. Selain fungsi tersebut tanaman hias memiliki beberapa fungsi fisik atau jasmaniah yaitu, sebagai peneduh, sebagai pengencer polusi, sebagai peredam suara, dan sebagai pembatas (Zulkarnain, 2009).

2.1.3 Peran Hortikultura

Melihat fungsi dari produksi tanaman hortikultura maka dapat dilihat bahwa hortikultura memiliki peranan yang sangat besar dalam pembangunan ekonomi suatu negara. Dalam pembangunan nasional sektor pertanian khususnya hortikultura berperan melalui pembentukan PDB, perolehan devisa suatu negara, penyedia bahan pangan, penyedia kebutuhan vitamin dan mineral, penciptaan lapangan pekerjaan baru, serta melalui peningkatan pendapatan masyarakat.

Hal ini berkaitan dengan kegiatan ekspor dan impor produksi hortikultura dalam negeri. Peran aktif sektor hortikultura dalam pembangunan nasional inilah mengapa perlu dikembangkan dan menjadi perhatian penting bagi pemerintah. Hal ini sejalan dengan rata-rata pekerjaan dan pemenuhan kebutuhan hidup masyarakat Indonesia bergantung kepada sektor pertanian. Pertanian juga merupakan sektor yang dominan dalam ekonomi nasional dan regional. Contoh

yang dapat diambil ialah kontribusinya dalam pendapatan baik nasional maupun regional, perannya dalam pemberian lapangan kerja pada penduduk yang bertambah dengan cepat, kontribusinya dalam penghasilan devisa dan lain-lain. Pembangunan ekonomi juga perlu dipandang sebagai suatu proses kenaikan dalam pendapatan per kapita, karena kenaikan tersebut mencerminkan tambahan pendapatan dan adanya perbaikan dalam kesejahteraan ekonomi masyarakat (Arsyad, 2010).

2.2 Produksi Hortikultura

Menurut Kamus Besar Bahasa Indoensia produksi merupakan suatu proses mengeluarkan hasil atau penghasilan. Produksi dalam arti ekonomi mempunyai pengertian semua kegiatan yang meningkatkan nilai kegunaan atau faedah (*utility*) suatu benda. Produksi dalam pertanian merupakan hasil suatu hasil yang diperoleh dalam suatu lahan pertanian dalam waktu tertentu. Besar potensi komoditi pertanian diukur dengan satuan berat ton atau kilogram. Menurut badan Pusat Statistik produksi sektor hortikultura merupakan bentuk produksi dari setiap tanaman sayuran, buah-buahan, biofarmaka dan tanaman hias yang diambil berdasarkan luas yang dipanen pada bulan/triwulan laporan.

2.3 Vektor dan Matriks

Menurut Rencher (2002), Vektor dan matriks dapat didefinisikan sebagai berikut:

Definisi 1. Matriks

Matriks adalah array persegi panjang atau persegi dari bilangan real atau variabel yang disusun dalam baris dan kolom. Array random dari n baris dan p kolom ditunjukkan dengan:

$$A_{n \times p} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1p} \\ a_{21} & a_{22} & \cdots & a_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{np} \end{bmatrix} \quad (1)$$

Definisi 2. Vektor

Vektor adalah matriks dengan satu kolom atau satu baris. Vektor ditunjukkan dalam array sebagai berikut:

$$A_{n \times 1} = \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix} \quad (2)$$

2.3.1 Vektor Random dan Matriks Random

Menurut Johnson dan Wichern (2007), Vektor random adalah vektor yang elemen-elemennya berupa variabel random. Jika suatu unit eksperimen hanya memiliki satu variabel terukur maka variabel terukur disebut variabel random, sedangkan jika terdapat lebih dari satu variabel terukur, misalkan n variabel

maka variabel-variabel tersebut disebut vektor random dengan n komponen. Sedangkan matriks random adalah matriks yang mempunyai elemen variabel random. Secara khusus biarkan $X = \{X_i\}$ suatu matrik random dengan ordo $n \times p$. Maka matrik random dari nilai harapan *Mean* dinotasikan dengan $E(X)$ dengan ordo $n \times p$, yaitu:

$$E(\mathbf{X}) = \begin{bmatrix} E(X_{11}) & E(X_{12}) & \cdots & E(X_{1p}) \\ E(X_{21}) & E(X_{22}) & \cdots & E(X_{2p}) \\ \vdots & \vdots & \ddots & \vdots \\ E(X_{n1}) & E(X_{n2}) & \cdots & E(X_{np}) \end{bmatrix} \quad (3)$$

Dimana, untuk setiap elemen matriks nya apabila X_{ij} merupakan variabel random kontinu dengan *Probability Density Function* (PDF) $f_{ij}(x_{ij})$ adalah sebagai berikut:

$$E(X_{ij}) = \int_{-\infty}^{\infty} x_{ij} f_{ij}(x_{ij}) dx_{ij} \quad (4)$$

Kemudian apabila X_{ij} merupakan variabel random diskrit dengan *Probability Function* $p_{ij}(x_{ij})$ adalah sebagai berikut:

$$E(X_{ij}) = \sum_{all x_{ij}} x_{ij} p_{ij}(x_{ij}) \quad (5)$$

2.3.2 Vektor Means dan Matriks Kovariansi

Seandainya diketahui matriks $\mathbf{X}' = [X_1, X_2, \dots, X_p]$ adalah vektor random berukuran $p \times 1$. Kemudian setiap elemen \mathbf{X} adalah variabel random dengan distribusi probabilitas marginalnya sendiri. Fungsi marginal Mean μ_i dan Variansi σ_i^2 didefinisikan sebagai $\mu_i = E(X_i)$ dan $\sigma_i^2 = E(X_i - \mu_i)^2$ dimana $i = 1, 2, 3, \dots, p$. Secara khusus fungsi marginal untuk Mean untuk variabel diskrit dan kontinu pada persamaan (4) dan (5). Sedangkan Variansi pada variabel random kontinu dengan PDF $f_i(x_i)$ dan diskrit dengan $p_i(x_i)$ adalah sebagai berikut:

$$\sigma_i^2 = \int_{-\infty}^{\infty} (x_i - \mu_i)^2 f_i(x_i) dx_i \quad (6)$$

$$\sigma_i^2 = \sum_{all x_i} (x_i - \mu_i)^2 p_i(x_i) \quad (7)$$

Perilaku dari setiap pasangan variabel random seperti X_i dan X_k dijelaskan oleh fungsi probabilitas bersama, dan ukuran dari hubungan linear antara kedua variabel tersebut disediakan oleh kovarians:

$$\sigma_{ik} = E(X_i - \mu_i)(X_k - \mu_k) \quad (8)$$

Jika X_i dan X_k merupakan variabel random kontinu dengan fungsi kepadatan bersama $f_{ik}(x_i, x_k)$ adalah sebagai berikut:

$$\sigma_{ik} = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x_i - \mu_i)(x_k - \mu_k) f_{ik}(x_i, x_k) dx_i dx_k \quad (9)$$

Jika X_i dan X_k merupakan variabel random kontinu dengan fungsi probabilitas bersama $p_{ik}(x_i, x_k)$ adalah sebagai berikut:

$$\sigma_{ik} = \sum_{all x_i} \sum_{all x_k} (x_i - \mu_i)(x_k - \mu_k) p_{ik}(x_i, x_k) \quad (10)$$

Secara lebih umum, perilaku kolektif dari variabel random p dijelaskan oleh fungsi kepadatan probabilitas gabungan $f(x_1, x_2, \dots, x_p) = f(\mathbf{x})$. Fungsi

tersebut akan sering menjadi fungsi density normal multivariat. Jika probabilitas gabungan $P[X_i \leq x_i \text{ dan } X_k \leq x_k]$ dapat dituliskan sebagai produk dari probabilitas marginal yang sesuai sehingga:

$$P[X_i \leq x_i \text{ dan } X_k \leq x_k] = P[X_i \leq x_i] P[X_k \leq x_k] \quad (11)$$

Untuk semua pasangan nilai x_i dan x_k maka X_i dan X_k dikatakan independent secara statistik ketika X_i dan X_k adalah variabel random kontinu dengan kerapatan gabungan $f_{ik}(x_i, x_k)$ dan kerapatan marginal $f_i(x_i)$ dan $f_k(x_k)$, kondisi independennya menjadi:

$$f_{ik}(x_i, x_k) = f_i(x_i)f_k(x_k), \text{ untuk semua pasangan } (x_i, x_k) \quad (12)$$

Variabel random kontinu p X_1, X_2, \dots, X_p saling independent secara statistic jika kepadatannya dapat difaktorkan sebagai berikut:

$$f_{12\dots p}(x_1, x_2, \dots, x_p) = f_1(x_1), f_2(x_2), \dots, f_p(x_p) \quad (13)$$

Independensi statistic memiliki implikasi penting untuk kovariansi. Persamaan faktorisasi (13) menyiratkan bahwa $\text{Cov}(X_i, X_k) = 0$. Sehingga $\text{Cov}(X_i, X_k) = 0$ jika X_i dan X_k independen (Johnson dan Wichern, 2007).

Definisi 3. Vektor Means

Menurut Mattjik dan Sumertajaya (2011), Misalkan \mathbf{X} adalah vektor random berukuran $p \times 1$ yang berpadanan dengan populasi peubah ganda, n vektor pengamatan dinotasikan dengan X_1, X_2, \dots, X_p dimana:

$$\mathbf{X}_i = \begin{bmatrix} X_{i1} \\ X_{i2} \\ \vdots \\ X_{ip} \end{bmatrix}$$

Vektor *Mean* berisi nilai rata-rata dari setiap data pengamatan. Nilai *Mean* dapat diperoleh dengan rumusan sebagai berikut:

$$\bar{\mathbf{X}} = \frac{1}{n} \sum_{i=1}^n \mathbf{X}_i \quad (14)$$

Sehingga vektor *Mean* dapat dituliskan sebagai berikut:

$$\bar{\mathbf{X}} = \begin{bmatrix} \bar{X}_1 \\ \bar{X}_2 \\ \vdots \\ \bar{X}_p \end{bmatrix} \quad (15)$$

Maka setiap X_i adalah variabel random. Misalkan $\mu_i = E(X_i)$ dan $\sigma_{ii} = \text{Var}(X_i)$ adalah ragam populasi. Maka selanjutnya peragam populasi antara X_i dan X_j adalah $\sigma_{ij} = \text{Cov}(X_i, X_j)$. Didefinisikan vektor random *Mean* sebagai vektor dari nilai harapan setiap variabel dengan ordo $p \times 1$, yaitu:

$$E(\mathbf{X}) = \begin{bmatrix} E(X_1) \\ E(X_2) \\ \vdots \\ E(X_p) \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_p \end{bmatrix} = \boldsymbol{\mu} \quad (16)$$

Menurut Mattjik dan Sumertajaya (2011), Konsep ragam populasi atau variansi dirangkum dalam sebuah matriks yang memuat ragam dan peragam populasi yang diletakkan bersesuaian dalam matriks ragam-peragam. Jika matriks tersebut disebut dengan matriks kovariansi dan dilambangkan dengan Σ . Oleh karena itu ekspektasi suatu matriks variabel random harus dipahami komponen demi komponen.

Definisi 4. Matriks Kovariansi Populasi

Jika \mathbf{X} adalah vektor random mengambil nilai yang mungkin dalam populasi data multivariat. Kovariansi vektor random \mathbf{X} dengan ordo $p \times 1$ adalah sebagai berikut:

$$\begin{aligned} \Sigma &= E(\mathbf{X} - \boldsymbol{\mu})(\mathbf{X} - \boldsymbol{\mu})' \\ &= E \left(\begin{bmatrix} X_1 - \mu_1 \\ X_2 - \mu_2 \\ \vdots \\ X_p - \mu_p \end{bmatrix} [X_1 - \mu_1 \quad X_2 - \mu_2 \quad \cdots \quad X_p - \mu_p] \right) \\ &= E \left[\begin{array}{cccc} (X_1 - \mu_1)^2 & (X_1 - \mu_1)(X_2 - \mu_2) & \cdots & (X_1 - \mu_1)(X_p - \mu_p) \\ (X_2 - \mu_2)(X_1 - \mu_1) & (X_2 - \mu_2)^2 & & \cdots \\ \vdots & \vdots & \ddots & \vdots \\ (X_p - \mu_p)(X_1 - \mu_1) & (X_p - \mu_p)(X_2 - \mu_2) & \cdots & (X_p - \mu_p)^2 \end{array} \right] \\ &= \left[\begin{array}{cccc} E(X_1 - \mu_1)^2 & E(X_1 - \mu_1)(X_2 - \mu_2) & \cdots & E(X_1 - \mu_1)(X_p - \mu_p) \\ E(X_2 - \mu_2)(X_1 - \mu_1) & E(X_2 - \mu_2)^2 & & \cdots \\ \vdots & \vdots & \ddots & \vdots \\ E(X_p - \mu_p)(X_1 - \mu_1) & E(X_p - \mu_p)(X_2 - \mu_2) & \cdots & E(X_p - \mu_p)^2 \end{array} \right] \end{aligned} \quad (17)$$

Atau dapat dinyatakan sebagai berikut:

$$\Sigma = \text{Cov}(\mathbf{X}) = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1p} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{p1} & \sigma_{p2} & \cdots & \sigma_{pp} \end{bmatrix} \quad (18)$$

Keterangan:

σ_{ij} : Kovariansi dari X_i dan X_j , dimana $i = 1, 2, 3, \dots, p$ dan $j = 1, 2, 3, \dots, p$

Vektor $\boldsymbol{\mu}$ dan matrik Σ disebut sebagai vektor mean populasi dan matrik varians-kovariansi populasi (Johson dan Wichern, 2007).

Definisi 5. Kovariansi Sampel

Kovariansi sampel dari variabel ke- j dan ke- k didefinisikan sebagai berikut:

$$\begin{aligned} S_{jk} &= \frac{1}{n-1} \sum_{i=1}^n (X_{ij} - \bar{X}_j)(X_{ik} - \bar{X}_k) \\ &= \frac{1}{n-1} (\sum_{i=1}^n X_{ij}X_{ik} - n\bar{X}_j\bar{X}_k) \end{aligned} \quad (19)$$

Variansi sampel variabel ke- j , $S_{jj} = S_j^2$ didefinisikan sebagai berikut:

$$\begin{aligned} S_{jj} &= S_j^2 = \frac{1}{n-1} \sum_{i=1}^n (X_{ij} - \bar{X}_j)^2 \\ &= \frac{1}{n-1} (\sum_{i=1}^n X_{ij}^2 - n\bar{X}_j^2) \end{aligned} \quad (20)$$

Akar kuadrat dari variansi populasi maupun sampel disebut dengan Standar deviasi. Sedangkan matriks varians-kovariansi untuk data sampel dinyatakan sebagai berikut:

$$\mathbf{S} = \begin{bmatrix} S_{11} & S_{12} & \cdots & S_{1p} \\ S_{21} & S_{22} & \cdots & S_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ S_{p1} & S_{p2} & \cdots & S_{pp} \end{bmatrix} \quad (21)$$

Keterangan:

S_{ij} : Kovariansi dari X_i dan X_j , dimana $i = 1, 2, 3, \dots, p$ dan $j = 1, 2, 3, \dots, p$ (Rencher, 2002).

Definisi 6. Koefisien Korelasi Populasi

Koefisien korelasi populasi dua variabel random j dan k didefinisikan sebagai berikut:

$$\begin{aligned} \rho_{jk} &= \text{corr}(j, k) = \frac{\sigma_{jk}}{\sigma_j \sigma_k} \\ &= \frac{E[(y_{ij} - \mu_j)(y_{ik} - \mu_k)]}{\sqrt{E(y_{ij} - \mu_j)^2} \sqrt{E(y_{ik} - \mu_k)^2}} \end{aligned} \quad (22)$$

(Rencher, 2002).

Matriks koefisien korelasi dituliskan dalam bentuk matiks simetrik sebagai berikut:

$$\boldsymbol{\rho} = \rho_{jk} = \begin{bmatrix} \rho_{11} & \rho_{12} & \cdots & \rho_{1p} \\ \rho_{21} & \rho_{22} & \cdots & \rho_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{p1} & \rho_{p2} & \cdots & \rho_{pp} \end{bmatrix}$$

dengan $\rho_{jk} = \frac{\sigma_{jk}}{\sigma_j \sigma_k}$ dan $\sigma_i = \sqrt{\sigma_i^2}$ maka bentuk matriks koefisien korelasi secara umum dapat dituliskan sebagai berikut:

$$\begin{aligned} \boldsymbol{\rho} &= \begin{bmatrix} \frac{\sigma_{11}}{\sqrt{\sigma_1 \sqrt{\sigma_1}}} & \frac{\sigma_{12}}{\sqrt{\sigma_1 \sqrt{\sigma_2}}} & \cdots & \frac{\sigma_{1p}}{\sqrt{\sigma_1 \sqrt{\sigma_p}}} \\ \frac{\sigma_{21}}{\sqrt{\sigma_2 \sqrt{\sigma_1}}} & \frac{\sigma_{22}}{\sqrt{\sigma_2 \sqrt{\sigma_2}}} & \cdots & \frac{\sigma_{2p}}{\sqrt{\sigma_2 \sqrt{\sigma_p}}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\sigma_{p1}}{\sqrt{\sigma_p \sqrt{\sigma_1}}} & \frac{\sigma_{p2}}{\sqrt{\sigma_p \sqrt{\sigma_2}}} & \cdots & \frac{\sigma_{pp}}{\sqrt{\sigma_p \sqrt{\sigma_p}}} \end{bmatrix} \\ &= \begin{bmatrix} 1 & \rho_{12} & \cdots & \rho_{1p} \\ \rho_{21} & 1 & \cdots & \rho_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{p1} & \rho_{p2} & \cdots & 1 \end{bmatrix} \end{aligned} \quad (23)$$

(Johnson dan Wichern, 2007).

Definisi 7. Koefisien Korelasi Sampel

Koefisien korelasi sampel didefinisikan sebagai berikut:

$$\begin{aligned} r_{jk} &= \text{corr}(j, k) = \frac{s_{jk}}{s_j s_k} \\ &= \frac{\sum_{i=1}^n [(y_{ij} - \bar{y}_j)(y_{ik} - \bar{y}_k)]}{\sqrt{\sum_{i=1}^n (y_{ij} - \bar{y}_j)^2} \sqrt{\sum_{i=1}^n (y_{ik} - \bar{y}_k)^2}} \end{aligned} \quad (24)$$

Matriks koefisien korelasi sampel disimbolkan dengan r yang dapat dituliskan dalam bentuk matriks simetrik sebagai berikut:

$$\mathbf{R} = (r_{jk}) = \begin{bmatrix} 1 & \rho_{12} & \cdots & \rho_{1p} \\ \rho_{21} & 1 & \cdots & \rho_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \rho_{p1} & \rho_{p2} & \cdots & 1 \end{bmatrix} \quad (25)$$

Dimana membentuk sebuah matriks diagonal karena pada entri korelasi yang bernilai 1 berkorelasi dengan dirinya sendiri (Rencher, 2002).

Menurut Johnson dan Wichern (2007), Beberapa teorema dalam nilai ekspektasi dalam data multivariat adalah sebagai berikut:

a. Jika diketahui sebarang konstanta α maka $E(\alpha\mathbf{X}) = \alpha E(\mathbf{X})$

Bukti:

$$\begin{aligned} E(\alpha\mathbf{X}) &= E \begin{bmatrix} \alpha X_{11} & \alpha X_{12} & \cdots & \alpha X_{1p} \\ \alpha X_{21} & \alpha X_{22} & \cdots & \alpha X_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \alpha X_{n1} & \alpha X_{n2} & \cdots & \alpha X_{np} \end{bmatrix} \\ &= E\alpha \begin{bmatrix} X_{11} & X_{12} & \cdots & X_{1p} \\ X_{21} & X_{22} & \cdots & X_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ X_{n1} & X_{n2} & \cdots & X_{np} \end{bmatrix} \\ &= \alpha E \begin{bmatrix} X_{11} & X_{12} & \cdots & X_{1p} \\ X_{21} & X_{22} & \cdots & X_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ X_{n1} & X_{n2} & \cdots & X_{np} \end{bmatrix} \\ &= \alpha E(\mathbf{X}) \quad \blacksquare \end{aligned}$$

b. Jika diketahui sebuah konstanta α dan β adalah $E(\alpha\mathbf{X} + \beta\mathbf{Y}) = \alpha E(\mathbf{X}) + \beta E(\mathbf{Y})$

Bukti:

$$\begin{aligned} E(\alpha\mathbf{X} + \beta\mathbf{Y}) &= E \begin{bmatrix} \alpha X_{11} & \alpha X_{12} & \cdots & \alpha X_{1p} \\ \alpha X_{21} & \alpha X_{22} & \cdots & \alpha X_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \alpha X_{n1} & \alpha X_{n2} & \cdots & \alpha X_{np} \end{bmatrix} + E \begin{bmatrix} \beta Y_{11} & \beta Y_{12} & \cdots & \beta Y_{1p} \\ \beta Y_{21} & \beta Y_{22} & \cdots & \beta Y_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \beta Y_{n1} & \beta Y_{n2} & \cdots & \beta Y_{np} \end{bmatrix} \\ &= E\alpha \begin{bmatrix} X_{11} & X_{12} & \cdots & X_{1p} \\ X_{21} & X_{22} & \cdots & X_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ X_{n1} & X_{n2} & \cdots & X_{np} \end{bmatrix} + E\beta \begin{bmatrix} Y_{11} & Y_{12} & \cdots & Y_{1p} \\ Y_{21} & Y_{22} & \cdots & Y_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ Y_{n1} & Y_{n2} & \cdots & Y_{np} \end{bmatrix} \\ &= \alpha E \begin{bmatrix} X_{11} & X_{12} & \cdots & X_{1p} \\ X_{21} & X_{22} & \cdots & X_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ X_{n1} & X_{n2} & \cdots & X_{np} \end{bmatrix} + \beta E \begin{bmatrix} Y_{11} & Y_{12} & \cdots & Y_{1p} \\ Y_{21} & Y_{22} & \cdots & Y_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ Y_{n1} & Y_{n2} & \cdots & Y_{np} \end{bmatrix} \\ &= \alpha E(\mathbf{X}) + \beta E(\mathbf{Y}) \quad \blacksquare \end{aligned}$$

c. Misalkan X dan Y adalah matriks variabel random dengan dimensi yang sama maka $E(\mathbf{X} + \mathbf{Y}) = E(\mathbf{X}) + E(\mathbf{Y})$.

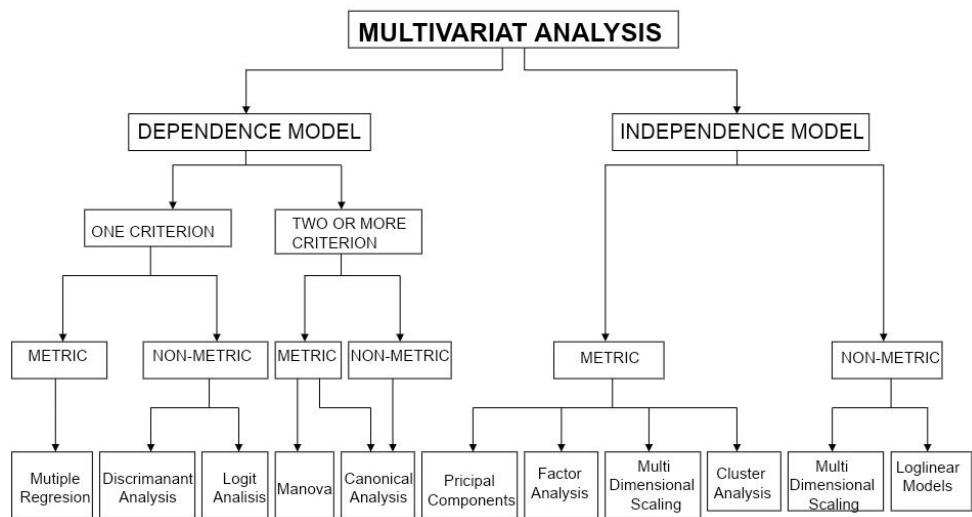
Bukti:

$$\begin{aligned}
E(\mathbf{X} + \mathbf{Y}) &= E \begin{bmatrix} X_{11} + Y_{11} & X_{12} + Y_{12} & \cdots & X_{1p} + Y_{1p} \\ X_{21} + Y_{21} & X_{22} + Y_{22} & \cdots & X_{2p} + Y_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ X_{n1} + Y_{n1} & X_{n2} + Y_{n2} & \cdots & X_{np} + Y_{np} \end{bmatrix} \\
&= E \begin{bmatrix} X_{11} & X_{12} & \cdots & X_{1p} \\ X_{21} & X_{22} & \cdots & X_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ X_{n1} & X_{n2} & \cdots & X_{np} \end{bmatrix} + E \begin{bmatrix} Y_{11} & Y_{12} & \cdots & Y_{1p} \\ Y_{21} & Y_{22} & \cdots & Y_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ Y_{n1} & Y_{n2} & \cdots & Y_{np} \end{bmatrix} \\
&= E(\mathbf{X}) + E(\mathbf{Y}) \quad \blacksquare
\end{aligned}$$

2.4 Analisis Multivariat

Informasi multivariat timbul kala periset mencatat nilai sebagian variabel random pada beberapa subjek atau objek atau mungkin salah satu dari berbagai hal lain yang mereka minati, mengarah ke vektor observasi bernilai atau multidimensi untuk masing-masing. Informasi tersebut dikumpulkan dalam bermacam disiplin ilmu. Data atau informasi multivariat tidak hanya terdiri atas satu variabel saja melainkan bisa terdiri atas lebih dari satu. Analisis multivariat merupakan analisis statistika yang melibatkan lebih dari satu variabel bebas. Analisis data multivariat melibatkan identifikasi dan pengukuran variasi dalam satu set variabel, baik diantara variabel itu sendiri atau antara variabel dependen dan satu atau lebih variabel independent (Hair et al., 2010).

Contoh data atau informasi multivariat adalah dimisalkan produksi padi dari tahun 2010 sampai 2020 yang dipengaruhi oleh keadaan tanah, luas lahan, iklim, dan banyaknya pupuk yang digunakan. Produksi padi dapat disimbolkan dengan y lalu keadaan tanah, luas lahan, iklim, dan banyaknya pupuk yang digunakan merupakan variabel-variabel yang disimbolkan secara berturut adalah sebagai x_1 , x_2 , x_3 , dan x_4 . Terlihat bahwa data atau informasi produksi padi terdiri lebih dari satu variabel. Jenis-jenis analisis dalam analisis multivariat dapat dilihat dalam skema berikut:



Sumber: Hair, dkk (2010)

Gambar 1. Skema Analisis Multivariat

Menurut Johnson dan Wichern (2007), dalam analisis multivariat terdapat p variabel, dimana $p \geq 1$ serta n objek. Observasi objek ke- j dan variabel ke- k dapat dinotasikan dengan x_{jk} , untuk $j = 1, 2, 3, \dots, n$ dan $k = 1, 2, 3, \dots, p$. Oleh karena itu pengukuran antara objek ke- j dan variabel ke- k dapat disajikan dalam tabel berikut:

Tabel 1. Tabel Pengukuran Antar Objek

	Variabel 1	Variabel 2	...	Variabel k	...	Variabel p
Objek 1	x_{11}	x_{12}	...	x_{1k}	...	x_{1p}
Objek 2	x_{21}	x_{22}	...	x_{2k}	...	x_{2p}
⋮	⋮	⋮		⋮		⋮
Objek j	x_{j1}	x_{j2}	...	x_{jk}	...	x_{jp}
⋮	⋮	⋮		⋮		⋮
Objek n	x_{n1}	x_{n2}	...	x_{nk}	...	x_{np}

Sumber: Jonhson dan Wichern (2007)

Pengukuran antar objek dalam bentuk matrik dapat dituliskan dengan matrik X adalah sebagai berikut:

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1k} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2k} & \dots & x_{2p} \\ \vdots & \vdots & & \vdots & & \vdots \\ x_{j1} & x_{j2} & \dots & x_{jk} & \dots & x_{jp} \\ \vdots & \vdots & & \vdots & & \vdots \\ x_{n1} & x_{n2} & \dots & x_{nk} & \dots & x_{np} \end{bmatrix} \quad (26)$$

Keterangan:

x_{jk} : elemen dari matrik dari observasi objek ke- j dan variabel ke- k

n : banyaknya objek

p : banyaknya variabel

2.4.1 Teknik Analisis Multivariat

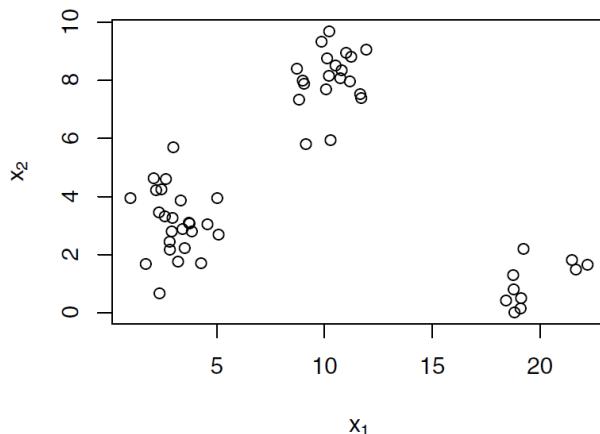
Menurut Wijaya dan Budiman (2016), Teknik dalam analisis multivariat secara umum terbagi menjadi dua, yaitu analisis dependensi dan analisis interdependensi. Analisis dependensi berfungsi untuk menerangkan atau memprediksi variabel tergantung (*dependent variable*) dengan menggunakan dua atau lebih variabel bebas. Pembagian metode dari analisis dependensi didasarkan pada jumlah variabel terikat, misalnya satu atau lebih dan skala pengukuran bersifat metrik (kuantitatif) atau non metrik (kualitatif). Analisis interdependensi berfungsi untuk memberikan makna terhadap seperangkat variabel atau membuat kelompok-kelompok secara bersama-sama. Ciri dari analisis interdependensi adalah semua variabelnya bersifat independen. Contoh membuat klasifikasi terhadap kelompok konsumen tertentu atau keperluan segmentasi misalnya preferensi konsumen berdasarkan kelompok usiaBerikut penjelasan lebih lanjut mengenai teknik dalam analisis multivariat:

2. 5 Analisis Cluster

Analisis *Cluster* merupakan salah satu metode analisis pada teknik interdepedensi dalam analisis multivariat. Data multivariat yang terdiri dari lebih dari satu variabel dan bersifat metrik dapat dilakukan pengelompokan secara statistika dengan menggunakan analisis *cluster*. Analisis *cluster* merupakan suatu teknik analisis statistik yang ditujukan untuk membuat klasifikasi individu-individu atau objek-objek kedalam kelompok-kelompok lebih kecil yang berbeda satu dengan yang lain. Dalam Analisis *Cluster* tidak ada perbedaan antara variabel terikat dan variabel bebas. Analisis *Cluster* dapat diterapkan dalam berbagai bidang ilmu seperti psikologi, biologi, dan manajemen. Analisis *Cluster* merupakan teknik analisis data yang bertujuan untuk mengelompokkan objek-objek ke dalam beberapa kelompok berdasarkan kemiripan karakteristik yang dimilikinya, sehingga objek yang terdapat dalam satu *cluster* akan memiliki karakteristik dengan tingkat kemiripan yang tinggi. Sedangkan, objek-objek antar *cluster* yang berbeda memiliki tingkat kemiripan yang sangat rendah. Hal ini menunjukkan bahwa keragaman dalam suatu *cluster* minimum dan keragaman antar *cluster* maksimum (Mattjik dan Sumertajaya, 2011).

Menurut Everitt dan Hothorn (2011), Analisis *cluster* merupakan istilah umum yang digunakan untuk berbagai metode numerik dengan tujuan untuk menemukan kelompok atau *cluster* yang homogen dan terpisah dari kelompok lainnya. Hal ini berarti bahwa objek dalam setiap *cluster* yang terbentuk cenderung mirip satu sama lain dan berbeda jauh (tidak sama) dengan objek dari

kelompok lainnya. Selain itu, setiap objek hanya masuk ke dalam satu kelompok saja, tidak terjadi tumpang tindih. Hal ini ditunjukkan pada gambar berikut:



Sumber: Everitt dan Hothorn (2011)

Gambar 2. Data yang Menunjukkan Keberadaan Tiga Cluster

Menurut Husson, dkk (2011) sebuah partisi dikatakan memiliki kualitas yang baik apabila:

- Setiap anggota dalam sebuah *cluster* homogen atau memiliki *Homogenitas* yang tinggi (variabilitas dalam *cluster* rendah).
- Setiap anggota berbeda dari satu *cluster* ke *cluster* berikutnya (*Between-cluster*) atau *Heterogenitas* yang tinggi antara *cluster* yang satu dengan yang lainnya (variabilitas antar *cluster* tinggi).

Asumsi Analisis Cluster

Analisis *cluster* memiliki asumsi merupakan syarat yang harus dicukupi sebelum data diolah. Asumsi dalam analisis *cluster* adalah sebagai berikut:

- Sampel mewakili populasi yang ada (*Representatif*)

Menurut Hair, dkk (1998) penggunaan sampel yang representatif pada penelitian akan memberikan hasil yang maksimal dan sesuai dengan kondisi populasi yang ada. Namun apabila di dalam penelitian menggunakan populasi maka dapat disimpulkan bahwa asumsi representatif terpenuhi. Cara untuk mengetahui sampel telah mewakili populasi yang ada dibutuhkan nilai KMO atau nilai *Kaiser-Meyer Olkin*. Hipotesis dan kriteria keputusan dalam asumsi ini apabila data berupa sampel adalah sebagai berikut:

H_0 : Sampel mewakili tidak populasi yang ada

H_1 : Sampel mewakili populasi yang ada

Kriteria keputusan:

H_0 ditolak apabila $KMO > 0,5$, artinya sampel mewakili populasi yang ada

H_0 diterima apabila $KMO < 0,5$, artinya sampel tidak mewakili populasi yang ada

Menurut Nugroho (2008), Nilai KMO dapat dihitung dengan rumus:

$$KMO = \frac{\sum_i^n \sum_{j \neq i} r_{ij}^2}{\sum_i^n \sum_{j \neq i} r_{ij}^2 + \sum_i^n \sum_{j \neq i} a_{ij}^2}, \text{ dengan } a_{ij} = -\frac{v_{ij}}{\sqrt{v_{ii}v_{jj}}} \quad (27)$$

Keterangan:

- a_{ij} : Koefisien korelasi parsial dari variabel i dan j
- r_{ij} : Korefisien korelasi sederhana dari variabel i dan j
- v_{ij} : Invers matriks korelasi dari variabel i dan j

b. Tidak multikolinearitas

Multikolinearitas merupakan masalah yang perlu diperhatikan dalam analisis multivariat pada umumnya, karena pengaruhnya yang sangat besar dalam menghasilkan solusi, sehingga mengganggu proses analisis Analisis *cluster* sebaiknya tidak ada multikolinearitas. Multikolinearitas di tandai apabila $r > 0,5$. Apabila terjadi multikolinearitas maka harus diatasi atau menghilangkan variabel yang mengatasi multikolinearitas (Nugroho, 2008).

Menurut Hasan (2002), Perhitungan koefisien korelasi pada skala pengukuran data interval dan rasio menggunakan koefisien korelasi *pearson*. Persamaan dari koefisien korelasi *pearson* adalah sebagai berikut:

$$r_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (28)$$

Keterangan:

- r_{xy} : Korelasi antara variabel x dan variabel y
- x_i, y_i : Variabel bebas x dan y pada data ke- i
- \bar{x}, \bar{y} : Rata-rata data variabel x dan variabel y

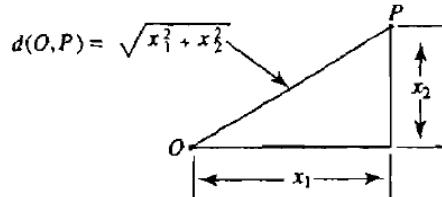
Ukuran Kesamaan Jarak

Mengukur seberapa mirip objek-objek yang akan dikelompokkan dalam analisis *cluster* diperlukan suatu ukuran pendekatan. Pendekatan yang paling biasa ialah mengukur kemiripan dinyatakan dengan jarak (*distance*) antara dua buah objek. Objek-objek dengan jarak lebih pendek antara mereka akan lebih mirip satu sama lain dibandingkan dengan pasangan dengan jarak antara dua objek. Satuan pada ukuran jarak mengikuti ukuran dari satuan variabel yang digunakan, namun apabila variabel-variabel yang digunakan memiliki satuan yang berbeda pula maka ukuran jarak mengikuti nilai *z-score* yang telah diperoleh dari proses standarisasi data. Adapun ukuran jarak yang digunakan dalam analisis *cluster* adalah jarak *Euclidean*. Jarak *Euclidean* merupakan tipe pengukuran jarak dalam analisis *cluster* yang paling umum digunakan. Menurut Johnson dan Wichern (2007), jarak *Euclidean* merupakan perhitungan jarak antara dua titik yang diturunkan berdasarkan Teorema Pythagoras. Jarak ini merupakan jarak geometris antar kedua objek. Jika kita mempertimbangkan titik $P = (x_1, x_2)$, ditarik garis lurus dengan jarak $d(O, P)$ dari titik P menuju titik asal

$O = (0,0)$. Menurut Teorema Pythagoras jarak $d(O,P)$ dapat dituliskan sebagai berikut:

$$d(O,P) = \sqrt{x_1^2 + x_2^2} \quad (29)$$

Keadaan ini dapat diilustrasikan dalam gambar berikut:



Sumber: Johnson dan Wichern (2007)

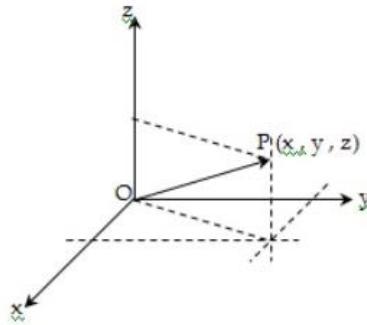
Gambar 3. Jarak pada Vektor Dimensi Dua

Jarak pada ruang berdimensi tiga dengan titik $P = (x,y,z)$ dengan titik asal $O = (0,0,0)$ pada **Gambar 4.** dimisalkan bahwa $x = x_1$, $y = x_2$, dan $z = x_3$ maka diperoleh jarak sebagai berikut:

$$d^2(O,P) = (OX)^2 + (OZ)^2 + (OY)^2 \quad (30)$$

$$d^2(O,P) = (x)^2 + (y)^2 + (z)^2 \quad (31)$$

$$d(O,P) = \sqrt{(x_1)^2 + (x_2)^2 + (x_3)^2} \quad (32)$$



Gambar 4. Jarak pada Vektor Dimensi Tiga

Secara umum jika titik P koordinat sebanyak p sehingga $P = (x_1, x_2, \dots, x_p)$, apabila ditarik garis lurus dari titik P ke titik asal $O = (0,0, \dots, 0)$. Maka jarak titik $d(O,P)$ dapat dituliskan sebagai berikut:

$$d(O,P) = \sqrt{x_1^2 + x_2^2 + \dots + x_p^2} \quad (33)$$

Berdasarkan Teorema Pythagoras dapat dihitung jarak antara dua objek P dan Q dengan koordinat titik $P = (x_1, x_2, \dots, x_p)$ dan koordinat titik $Q = (y_1, y_2, \dots, y_p)$ adalah sebagai berikut:

$$d(P,Q) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_p - y_p)^2} \quad (34)$$

Pengukuran Jarak *Euclidean* pada analisis *cluster* antara dua objek sebanyak p variabel dapat dihitung dengan rumus sebagai berikut:

$$d_{ij} = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} \quad (35)$$

Keterangan:

d_{ij} : Jarak antara objek ke- i dan objek ke- j

x_{ik} : Nilai objek ke- i pada variabel ke- k

x_{jk} : Nilai objek ke- j pada variabel ke- k

Menurut Manly (2017), Jarak *Euclidean* dapat digunakan dengan syarat variabel yang diamati tidak saling berkorelasi, memiliki skala pengukuran data yang sama, dan pengukuran pembakuan atau standarisasi memiliki rata-rata nol serta standar deviasinya satu. Jarak ini sangat sensitif terhadap besarnya sampel dan varians. Penggunaan Jarak *Euclidean* tidak akan efektif apabila terdapat korelasi antar variabelnya, sehingga dibutuhkan *principal component analysis*. Berdasarkan penelitian Nugraheny (2015) perhitungan keakuratan kesamaan atau kemiripan jarak *Euclidean* sebesar 93%, lebih tinggi dibandingkan presentase dari perhitungan menggunakan jarak *Mahattan*. Berikut contoh perhitungan jarak *Euclidean*:

Perhitungan jarak pada antar objek pada analisis *cluster* akan menghasilkan suatu matriks jarak sebagai berikut:

$$\mathbf{d}_{(i,j)} = \begin{bmatrix} d_{11} & d_{12} & \cdots & d_{1p} \\ d_{21} & d_{22} & \cdots & d_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ d_{n1} & d_{n2} & \cdots & d_{np} \end{bmatrix} \quad (36)$$

Keterangan:

d_{ij} : Jarak antara objek ke- i dan objek ke- j , dimana $i = 1, 2, \dots, n$ dan $j = 1, 2, \dots, p$

Menurut Johnson dan Wichern (2007), Ukuran jarak apapun $d(P, Q)$ diantara dua titik i dan j adalah valid asalkan memenuhi syarat berikut:

1.) $d(i, j) = d(j, i)$

Bukti:

Berdasarkan persamaan jarak *Euclidean*, kuadrat *Euclidean*, dan *Manhattan*, bahwa nilai jarak *Euclidean* diperoleh dari akar dua buah objek yang dikurangkan kemudian dikuadratkan, jarak kuadrat *Euclidean* diperoleh dari jumlah hasil dua buah objek yang dikurangkan lalu dikuadratkan. Sedangkan jarak *Manhattan* diperoleh dari penjumlahan dari nilai mutlak kedua buah objek yang dikurangkan. Dimisalkan apabila a dan $b \in R$ dimana $a \neq b$, maka untuk jarak *Euclidean* dan jarak kuadrat *Euclidean* berlaku:

$$(a - b)^2 = (b - a)^2$$

Untuk jarak *Manhattan* berlaku:

$$|a - b| = |b - a|$$

Sehingga dapat terlihat bahwa:

- a. $d_{ij} = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} = d_{ji} = \sqrt{\sum_{k=1}^p (x_{jk} - x_{ik})^2}$
b. $d_{(i,j)} = \sum_{k=1}^p (x_{ik} - x_{jk})^2 = d_{(j,i)} = \sum_{k=1}^p (x_{jk} - x_{ik})^2$
c. $d_{(i,j)} = \sum_{k=1}^p |x_{ik} - x_{jk}| = d_{(j,i)} = \sum_{k=1}^p |x_{jk} - x_{ik}|$

Dapat disimpulkan bahwa $d_{(i,j)} = d_{(j,i)}$. ■

2.) $d(i,j) > 0$, jika $i \neq j$

Bukti:

Terlihat pada persamaan jarak $d_{(i,j)}$ apabila a dan $b \in R$ dimana $a \neq b$, akan sama nilainya apabila dikurangkan dan dikuadratkan maupun dimutlakkan, $(a - b)^2 = (b - a)^2$ maupun $|a - b| = |b - a|$ akan selalu bernilai positif atau > 0 . Apabila nilai tersebut diakarkan pada jarak Euclidean dan dijumlahkan pada Jarak Kuadrat Euclidean dan jarak Manhattan maka akan selalu bernilai positif atau $d(i,j) > 0$ ■.

3.) $d(i,j) = 0$, jika $i = j$

Bukti:

Berdasarkan persamaan jarak Euclidean, jarak kuadrat Euclidean dan jarak Manhattan, apabila dimisalkan nilai a dan $b \in R$ dimana $a = b$, maka hasil pengurangan nilai a terhadap dirinya sendiri maupun nilai b terhadap dirinya sendiri maka atau $a - a = 0$ dan $b - b = 0$ atau akan bernilai 0. Apabila nilai tersebut dikuadratkan maupun diberi nilai mutlak maka akan tetap bernilai 0.■

Sehingga pada persamaan jarak berikut akan bernilai 0:

- a. $d_{ij} = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} = 0$
b. $d_{(i,j)} = \sum_{k=1}^p (x_{ik} - x_{jk})^2 = 0$
c. $d_{(i,j)} = \sum_{k=1}^p |x_{ik} - x_{jk}| = 0$

Hal ini akan menyebabkan nilai diagonal utama pada entri matriks akan bernilai 0, seperti yang terlihat pada matriks jarak berikut:

$$\begin{aligned} \mathbf{d}_{(i,j)} &= \begin{bmatrix} d_{11} & d_{12} & \cdots & d_{1p} \\ d_{21} & d_{22} & \cdots & d_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ d_{n1} & d_{n2} & \cdots & d_{np} \end{bmatrix} \\ &= \begin{bmatrix} 0 & d_{12} & \cdots & d_{1p} \\ d_{21} & 0 & \cdots & d_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ d_{n1} & d_{n2} & \cdots & 0 \end{bmatrix} \end{aligned} \tag{37}$$

Metode Analisis Cluster

Analisis cluster memiliki berbagai macam metode dalam proses pengelompokannya. Metode pengelompokan yang digunakan akan menentukan

hasil dari pengelompokan. Analisis *cluster* terbagi menjadi dua metode yaitu Metode Hierarki dan metode Non-Hierarki. Hasil pengelompokan yang diperoleh selanjutnya akan diinterpretasikan untuk menggambarkan dan menjelaskan keadaan di setiap *cluster* yang diperoleh. Pada analisis *cluster* terdapat dua jenis pengelompokan, yaitu dengan menggunakan metode Hierarki dan metode Non-Hierarki. Berikut kedua metode analisis *cluster*:

1. Metode Hierarki (*Hierarchical Methods*)

Analisis *cluster* dengan metode Hierarki belum diketahui jumlah kelompok yang akan terbentuk. Metode Hierarki dimulai dengan mengelompokkan dua atau lebih objek berdasarkan kesamaan paling dekat ke dalam satu *cluster*. Kemudian dilanjutkan kembali ke objek-objek lainnya yang memiliki kedekatan setelahnya. Proses pengelompokan dilakukan secara bertingkat. Hasil dari pengelompokan dengan metode *hierarki* secara grafik dapat ditampilkan dengan diagram pohon atau dikenal dengan dendogram. Dendogram membantu memperjelas Hierarki atau tingkatan dalam *cluster* yang terbentuk. Garis vertikal mewakili *cluster* yang terbentuk. Posisi garis pada skala menunjukkan jarak (*distance*) untuk mana *cluster* digabung. Dendogram menunjukkan bagaimana proses *cluster* terbentuk. Dimulai dengan setiap objek yang direpresentasikan sebagai *cluster* terpisah hingga bagaimana semuanya berada dalam satu *cluster* yang sama. Pada dasarnya metode *hierarki* ini dibedakan menjadi dua metode pengelompokan, yaitu (a) metode aglomerasi (*agglomerative method*); dan (b) metode pembagian (*divisive method*). Dendogram pada metode aglomerasi dibaca dari kiri ke kanan dan pada metode pembagian (*divisive*) dibaca dari kanan ke kiri (Hair, et. al, 2010).

a. Metode Aglomerasi (*agglomerative method*)

Metode Aglomerasi dimulai dengan kenyataan bahwa setiap objek membentuk *clusternya* masing-masing. Kemudian dua objek dengan jarak terdekat bergabung menjadi satu *cluster*. Selanjutnya objek ketiga akan bergabung dengan *cluster* yang ada atau bersama objek lain dan membentuk *cluster* baru. Proses akan terus berlanjut hingga akhirnya terbentuk satu *cluster* yang terdiri dari keseluruhan objek. Setiap pengelompokan akan membentuk suatu matriks jarak yang baru. Menurut Johnson dan Wichern (2007), Metode Aglomerasi memiliki beberapa teknik pengelompokan sebagai berikut:

1. *Single Linkage* (Tautan Tunggal)

Pengelompokan ini terjadi bila *cluster-cluster* digabungkan menurut jarak antara anggota-anggota yang terdekat di antara dua *cluster*. Teknik ini dimulai dengan menemukan jarak terkecil $D = \{d_{ij}\}$ dan menggabungkan objek yang sesuai, dimisalkan objek U dan V menjadi

cluster (UV). Kemudian menghitung jarak antara *cluster (UV)* terbentuk dengan objek lainnya. Jarak antara *cluster (UV)* dengan *cluster W* lainnya dihitung dengan:

$$d_{(UV)W} = \min\{d_{UW}, d_{VW}\} \quad (38)$$

Sehingga jarak antara *cluster (ij)* dengan *cluster k* lainnya secara umum dapat dihitung dengan:

$$d_{(ij)k} = \min\{d_{ik}, d_{jk}\} \quad (39)$$

2. Complete Linkage (Tautan Lengkap)

Pengelompokan ini terjadi bila *cluster-cluster* digabungkan menurut jarak antara anggota-anggota yang terjauh (*Maximum Distance*) di antara dua *cluster*. Langkah dalam Teknik ini adalah yang pertama menggabungkan dua objek dengan jarak minimum $D = \{d_{ij}\}$ dan menggabungkan objek yang sesuai, dimisalkan objek U dan V menjadi *cluster (UV)*. Kemudian menghitung jarak antara *cluster (UV)* terbentuk dengan objek lainnya. Jarak antara *cluster (UV)* dengan *cluster W* lainnya dihitung dengan:

$$d_{(UV)W} = \max\{d_{UW}, d_{VW}\} \quad (40)$$

Sehingga jarak antara *cluster (ij)* dengan *cluster k* lainnya secara umum dapat dihitung dengan:

$$d_{(ij)k} = \max\{d_{ik}, d_{jk}\} \quad (41)$$

3. Average Linkage (Tautan Rata-Rata)

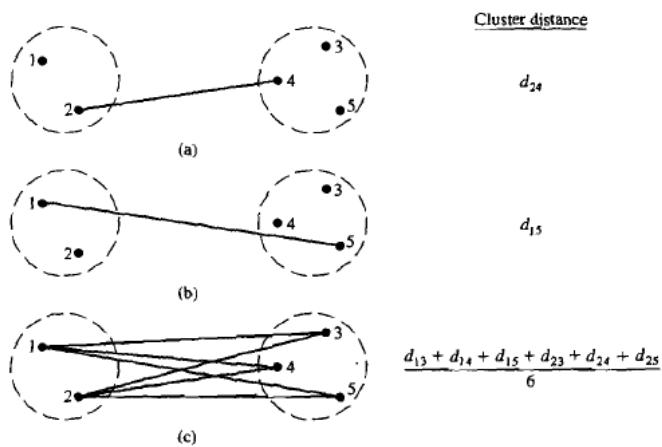
Pengelompokan ini menggabungkan objek menurut jarak rata-rata (*Average Distance*) pasangan-pasangan anggota masing-masing pada himpunan antara dua *cluster* dimana satu anggota pasangan dimiliki oleh setiap *cluster*. Langkah dalam Teknik ini adalah yang pertama menggabungkan dua objek dengan jarak minimum $D = \{d_{ij}\}$ dan menggabungkan objek yang sesuai, dimisalkan objek U dan V menjadi *cluster (UV)*. Kemudian menghitung jarak antara *cluster (UV)* terbentuk dengan objek lainnya. Jarak antara *cluster (UV)* dengan *cluster W* lainnya dihitung dengan:

$$d_{(UV)W} = \text{average}\{d_{UW}, d_{VW}\} \quad (42)$$

Sehingga jarak antara *cluster (ij)* dengan *cluster k* lainnya secara umum dapat dihitung dengan:

$$d_{(ij)k} = \text{Average}\{d_{ik}, d_{jk}\} \quad (43)$$

Menurut Johnson dan Wichern (2007), Secara umum ketiga teknik dalam Metode Aglomerasi diatas dapat digambarkan pada gambar dibawah ini:



Gambar 5. Jenis Teknik dalam Metode Aglomerasi

b. Metode Pembagian (*Divisive Method*)

Proses pengelompokan ini berlawanan dengan metode Aglomerasi, dimana metode pembagian dimulai dengan satu *cluster* besar yang mencakup seluruh objek. Objek yang memiliki ketidakmiripan yang cukup besar akan dipisahkan sehingga membentuk *cluster* yang lebih kecil. Hingga diperoleh n *cluster* yang diinginkan. Metode yang sering digunakan adalah *splinter average distance methods* dimana pada perhitungan jarak rata-rata masing-masing objek dengan objek pada grup *splinter* dan jarak rata-rata objek tersebut dengan objek lain pada grupnya.

2. Metode Non-Hierarki (*Non-Hierarchical Methods*)

Metode *Non-Hierarchical* sering disebut juga sebagai metode sekatan (*Partitioning*). Berbeda dengan metode Hierarki, prosedur metode Non-Hierarki tidak dilakukan secara bertahap melainkan dimulai dengan menentukan terlebih dahulu jumlah *cluster* yang akan dibentuk. Metode *clustering* dengan metode *Non-Hierarchical* bertujuan untuk mengelompokan objek ke dalam k kelompok dimana kelompok (k) lebih kecil dibanding jumlah data (n). Metode ini sangat sering digunakan dan menguntungkan dalam *clustering* data yang berukuran besar (Mattjik dan Sumertajaya, 2011).

Metode *Non-Hierarchical* dimulai dengan menentukan lebih dahulu jumlah *cluster* yang diinginkan bisa dua atau lebih *cluster*. Menurut Kaufman dan Rousseeuw (1990), Pada umumnya jumlah *cluster* tidak diketahui jumlahnya. Karena sebagian besar metode partisi atau *Non-Hierarchical* menyediakan jumlah k yang tetap. Peneliti harus menerapkan untuk beberapa nilai k untuk menemukan pengelompokan yang paling tepat. Setelah jumlah *cluster* ditentukan, maka proses *cluster* dilakukan tanpa mengikuti proses hierarki. Pada pemilihan nilai k tentu saja tidak semua nilai k mengarah kepengelompokan

yang alami. Sehingga disarankan untuk menjalankan algoritma beberapa kali dengan jumlah k yang berbeda dan untuk mencari karakteristik k atau grafik tertentu yang terlihat paling baik atau untuk mempertahankan pengelompokan yang menampilkan interpretasi paling berarti.

Metode ini biasa berhubungan dengan suatu metode yang disebut *K-means cluster*. Metode non-hierarki memiliki kelemahan dan keunggulan. Kelemahan dari metode ini adalah banyaknya *cluster* harus ditentukan sebelumnya dan pemilihan pusat *cluster* secara sembarang. Keunggulan *clustering* dengan menggunakan metode ini dapat diterapkan dalam himpunan data yang jauh lebih besar. Beberapa metode yang termasuk dalam metode Non-Hierarki ini adalah *K-Means*, *K-Medoid*, dan *fuzzy K-Means*.

Metode Non-Hierarki yang umum digunakan adalah *K-Means*. Hal ini dikarenakan metode ini dapat dengan mudah diterapkan, relatif lebih cepat dan diadaptasi bagi pemula. Pengclusteran *K-means* pertama kali dipopulerkan oleh Hartigan pada tahun 1975. Penggunaan pengclusteran *K-means* untuk menjelaskan algoritma dalam penentuan suatu objek ke dalam *cluster* tertentu berdasarkan rataan terdekat (Nugroho, 2008). Metode Non-Hierarki yang sering digunakan adalah *K-Means*.

Pengelompokan *K-means* pertama kali dipopulerkan oleh Hartigan pada tahun 1975. Penggunaan pengclusteran *K-means* untuk menjelaskan algoritma dalam penentuan suatu obyek ke dalam *cluster* tertentu berdasarkan rataan terdekat. Pengclusteran *K-means* sangat cocok untuk data dengan ukuran yang besar karena memiliki kecepatan yang lebih tinggi dibandingkan metode hierarki. Namun, pemilihan banyaknya cluster dan *centroid* yang harus ditentukan lebih dahulu menjadi kelemahan metode ini. Hasil pengelompokan mungkin tergantung pada urutan observasi data. Banyaknya cluster dan *centroid* yang diperoleh digunakan sebagai *input* untuk pengclusteran *K-means* (Nugroho, 2008).

Menurut Johnson dan wichern (2007), Algoritma *K-Means* terdiri dari riga proses berikut:

- 1.) Partisi data kedalam k *cluster* awal.
- 2.) Hitung jarak ke centroid, lalu menetapkan objek ke dalam cluster yang memiliki nilai jarak ke centroid (Mean) terdekat. Hitung kembali centroid untuk cluster yang menerima objek baru dan cluster yang kehilangan objek.
- 3.) Ulangi langkah kedua sampai tidak ada lagi objek yang berpindah.

2.6 K-Medoids (Partitioning Around Medoids)

K-Medoids atau *Partitioning Around Medoids* (PAM) adalah algoritma *clustering* yang mirip dengan *K-Means*. Algoritma *K-Medoids* diusulkan pada tahun 1987 dan dikembangkan oleh Leonard Kaufmann dan Peter J. Rousseeuw. Menurut Han dkk (2012), Teknik analisis *K-Medoid* merupakan salah satu teknik dari metode partisi, *K-Medoid* menggunakan prinsip meminimalisir disimilitas objek, maka tiap objek *cluster* direpresentasikan oleh objek dari dalam *cluster* yang terbentuk.

Algoritma *K-Medoid* memiliki kesamaan dengan algoritma *K-Means* dimana kedua metode ini merupakan metode analisis *cluster* partisional atau memecah data set menjadi kelompok-kelompok dan berusaha meminimalkan *squared error*, jarak antara titik berlabel yang berada dalam *cluster* dan titik yang ditunjuk sebagai pusat *cluster* itu. Hal yang membedakan kedua metode ini adalah pemilihan data *point* sebagai pusatnya. Algoritma *K-Medoids* menggunakan objek perwakilan (*medoid*) sebagai titik pusat *cluster* untuk setiap *cluster*, sedangkan *K-Means* menggunakan nilai rata-rata (*mean*) sebagai pusat *cluster*. Algoritma *K-Medoids* memiliki kelebihan untuk mengatasi kelemahan pada algoritma *K-Means* yang sensitif terhadap *outlier* dan hasil pengelompokan pada metode ini tetap meskipun dilakukan pengrandoman terhadap data. Selain hal tersebut metode ini juga lebih kuat apabila berhubungan dengan data pengukuran skala interval dan juga dengan koefisien ketidaksamaan umum (Arora et al., 2016).

Menurut Setyawati (2017), *K-Medoids* menggunakan metode pengclusteran partisi untuk mengclusterkan sekumpulan n objek menjadi sejumlah k *cluster*. Objek yang mewakili sebuah *cluster* disebut dengan *medoids*. *Cluster* dibangun dengan menghitung kedekatan yang dimiliki antara *medoids* dengan objek *non-medoids*.

Menurut Han dkk (2012), algoritma pengelompokan ini menggunakan *medoid* sebagai pusat *cluster* nya. *Medoid* merupakan objek yang letaknya terpusat di dalam suatu *cluster*. Berikut algoritma analisis *cluster* *K-medoids*, yaitu:

1. Menentukan k sebagai banyaknya *cluster* yang ingin dibentuk.
2. Membangkitkan k pusat *cluster* (*medoid*) secara random.
3. Menghitung jarak objek *non-medoid* dengan *medoid* pada tiap *cluster* dan menempatkan tiap objek *non-medoid* tersebut ke *medoid* terdekat, kemudian hitung total jaraknya.
4. Memilih secara random objek *non-medoid* pada masing-masing *cluster* sebagai kandidat *medoid* baru.

5. Menghitung jarak setiap objek *non-medoid* dengan *medoid* baru dan menempatkan tiap objek *non-medoid* tersebut ke kandidat *medoid* terdekat, kemudian hitung total jaraknya.
6. Menghitung selisih total jarak ($S_{total\ jarak}$). Selisih total jarak dapat dihitung dengan rumus berikut:

$$S_{total\ jarak} = Total\ Cost\ Baru - Total\ Cost\ Lama \quad (44)$$

Keterangan:

Total Cost Baru : Nilai total jarak pada kandidat *medoid* yang baru

Total Cost Lama : Nilai total jarak pada *medoid* yang lama

Nilai Total biaya/cost diperoleh dengan persamaan:

$$Total\ Cost = \sum_{i=1}^n d(i,j) \quad (45)$$

7. Jika diperoleh nilai $S_{total\ jarak} < 0$, maka kandidat *medoid* baru tersebut menjadi *medoid* baru dan jika diperoleh $S_{total\ jarak} > 0$ iterasi berhenti.
8. Kembali ke langkah (4) sampai (7) sampai tidak terjadi perubahan *medoid* atau $S_{total\ jarak} > 0$.

Contoh penerapan dari algoritma *K-medoid* dapat terlihat pada contoh data berikut:

Tabel 2. Contoh Data Jumlah Pembelian Buku

N	X_1	X_2
1	12	24
2	10	23
3	7	31
4	9	21
5	20	40
6	23	44
7	11	22
8	22	10
9	8	19
10	10	15

Perhitungan analisis *K-medoid* tersebut dilakukan dengan tahapan algoritma sebagai berikut:

1. Inisiasi jumlah k sebanyak 3 *cluster* dari data sampel
2. Membangkitkan k pusat *cluster* (*medoid*) secara random dari data sampel yang ada. Diasumsikan data ke-9, ke-4, dan ke-6 sebagai pusat *cluster* ke-1, ke-2, dan ke-3. Setiap *medoid* diasumsikan dengan $C1$, $C2$, dan $C3$.

Tabel 3. Medoid Awal

Medoid	Keterangan	X1	X2
C1	Data ke-9 sebagai pusat <i>cluster</i> 1	8	19
C2	Data ke-4 sebagai pusat <i>cluster</i> 2	9	21
C3	Data ke-6 sebagai pusat <i>cluster</i> 3	23	44

3. Menghitung jarak objek *non-medoid* dengan *medoid* pada tiap *cluster* dan menempatkan tiap objek *non-medoid* tersebut ke *medoid* terdekat dengan jarak *Euclidean*. Rumus menghitung jarak *Euclidean* menggunakan persamaan (35). Perhitungan jarak adalah sebagai berikut:

$$d_{(1,C1)} = \sqrt{(12 - 8)^2 + (24 - 19)^2} = 6,40$$

$$d_{(2,C1)} = \sqrt{(10 - 8)^2 + (23 - 19)^2} = 4,47$$

$$d_{(3,C1)} = \sqrt{(7 - 8)^2 + (31 - 19)^2} = 12,04$$

Hasil dari keseluruhan perhitungan jarak dapat dilihat pada **tabel 4.** berikut:

Tabel 4. Hasil Perhitungan Algoritma *K-Medoid* Iterasi ke-1

N	C1	C2	C3	Terdekat	Cluster yang diikuti
1	6,40	4,24	22,83	4,24	2
2	4,47	2,24	24,70	2,24	2
3	12,04	10,20	20,62	10,2	2
4	2,24	0,00	26,93	0	2
5	24,19	21,95	5,00	5	3
6	29,15	26,93	0,00	0	3
7	4,24	2,24	25,06	2,24	2
8	16,64	17,03	34,01	16,64	1
9	0,00	2,24	29,15	0	1
10	4,47	6,08	31,78	4,47	1
Jumlah	103,85	93,14	220,07		
		Total Cost			417,07

4. Memilih secara random objek *non-medoid* pada masing-masing *cluster* sebagai kandidat *medoid* baru. Kemudian hitung jarak *Euclidean* objek *non-medoid* dengan *medoid* baru yang telah ditentukan. Objek *non-medoid* yang dipilih menjadi *medoid* baru terlihat pada tabel berikut:

Tabel 5. Non-*Medoid*

Non-Medoid	Ket	X1	X2
D1	Data ke-10 sebagai pusat <i>cluster</i> 1	10	15
D2	Data ke-3 sebagai pusat <i>cluster</i> 2	7	31
D3	Data ke-5 sebagai pusat <i>cluster</i> 3	20	40

Hasil dari perhitungan jarak ke *Medoid* yang baru secara keseluruhan adalah sebagai berikut:

Tabel 6. Hasil Perhitungan Algoritma *K-Medoid* Terhadap Non-Medoid

N	C1	C2	C3	Terdekat	Cluster yang diikuti
1	9,22	8,60	17,89	9,22	1
2	8,00	8,54	19,72	8	1
3	16,28	0,00	15,81	0	2
4	6,08	10,20	21,95	6,08	1
5	26,93	15,81	0,00	0	3
6	31,78	20,62	5,00	5	3
7	7,07	9,85	20,12	7,07	1
8	13,00	25,81	30,07	13	1
9	4,47	12,04	24,19	4,47	1
10	0,00	16,28	26,93	0	1
Jumlah	122,83	127,75	181,68		
		Total Cost			432,26

5. Setelah diperoleh hasil perhitungan jarak terhadap *medoid* dan *non-medoid*, maka yang harus dicari adalah selisih dari nilai total cost baru dengan nilai total cost lama. Selisih total jarak ($S_{total\ jarak}$) dari kedua iterasi adalah sebagai berikut:

$$S_{total\ jarak} = \text{Nilai total cost baru} - \text{Nilai total cost lama}$$

$$S_{total\ jarak} = 432,26 - 417,07$$

$$S_{total\ jarak} = 15,19$$

6. Keputusan jika diperoleh $S_{total\ jarak} > 0$ artinya iterasi berhenti. Jika diperoleh nilai $S_{total\ jarak} < 0$ maka perlu dilakukan iterasi kembali. Diperoleh nilai selisih jarak bernilai > 0 . Sehingga diperoleh anggota tiap *cluster* dengan anggota sebagai berikut:

Tabel 7. Hasil Akhir *Cluster* Algoritma *K-Medoid*

N	X1	X2	Cluster
1	12	24	2
2	10	23	2
3	7	31	2
4	9	21	2
5	20	40	3
6	23	44	3
7	11	22	2
8	22	10	1
9	8	19	1
10	10	15	1

2.4 Silhouette Coefficient

Silhouette Coefficient merupakan suatu metode yang digunakan untuk melihat kualitas dan kekuatan dari *cluster* yang terbentuk. *Silhouette Coefficient* dapat mengukur seberapa baik atau buruknya suatu objek ditempatkan dalam suatu *cluster*. Dalam perhitungan ini terdapat dua komponen yaitu a_i^j dan b_i^j . a_i^j merupakan rata-rata jarak data ke- i terhadap data lainnya pada satu *cluster* ke- j . Sedangkan b_i^j merupakan rata-rata jarak data ke- i terhadap seluruh data lainnya yang tidak berada dalam satu *cluster* ke- j . Nilai *silhouette* berada pada interval $-1 \leq s(i) \leq 1$. Apabila nilai *silhouette* semakin mendekati 1 maka menunjukkan bahwa data tersebut berada dalam *cluster* yang tepat. Apabila nilai *silhouette* mendekati -1 maka menunjukkan bahwa data tidak berada dalam *cluster* yang tepat (Kaufman dan Rousseeuw, 1990).

Nilai *Silhouette Coefficient* data ke- i dapat dihitung dengan persamaan sebagai berikut:

$$SC_i^j = \frac{b_i^j - a_i^j}{\max \{a_i^j, b_i^j\}} \quad (46)$$

Dimana nilai a_i^j dan b_i^j diperoleh dari persamaan sebagai berikut:

$$a_i^j = \frac{1}{m_{j-1}} \sum_{\substack{r=1 \\ r \neq i}}^{m_j} d(x_i^j, x_r^j) \quad (47)$$

$$b_i^j = \frac{1}{m_n} \sum_{\substack{r=1 \\ r \neq i}}^{m_n} d(x_i^j, x_r^n) \quad (48)$$

Keterangan:

SC_i^j : Nilai *Silhouette* data ke- i dalam satu *cluster*

a_i^j : Rata-rata jarak data ke- i terhadap semua data dalam satu *cluster*

i : indeks data

j : *cluster*

m_j : Jumlah data dalam *cluster* ke- j

$d(x_i^j, x_r^j)$: Jarak data ke- i dengan data ke- r dalam *cluster* ke- j

x : Data

b_i^j : Rata-rata jarak data ke- i terhadap seluruh data yang tidak dalam satu *cluster*

m_n : Jumlah data dalam *cluster* ke- n

$d(x_i^j, x_r^n)$: Jarak data ke- i dengan data ke- r dalam *cluster* ke- n

Nilai rata-rata *Silhouette Coefficient* dari sebuah *cluster* ditentukan oleh persamaan sebagai berikut:

$$SC_j = \frac{1}{m_j} \sum_{i=1}^{m_j} SC_i^j \quad (49)$$

Keterangan:

SC_j : Nilai rata-rata *Silhouette Coefficient*

Nilai rata-rata SC_j untuk semua objek ke- i dalam sebuah *cluster* disebut dengan *Average Silhouette Width* dari *cluster* tersebut. Sedangkan nilai rata-rata *Silhouette Coefficient* dari seluruh *cluster* atau global dapat dihitung melalui persamaan berikut:

$$SC_g = \frac{1}{k} \sum_{j=1}^k SC_j \quad (50)$$

Keterangan:

SC_g : nilai rata-rata *Silhouette Coefficient* global

Nilai rata-rata *Silhouette Coefficient* untuk seluruh data disebut dengan *Average Silhouette Width for Entire Data Set*. Nilai ini yang digunakan sebagai pemilihan nilai terbaik dari k yang digunakan. Menurut Kaufman dan Rousseeuw (1990), Kriteria penilaian yang hasil *clustering* yang baik berdasarkan nilai *Silhouette Coefficient* yang didefinisikan sebagai lebar rata-rata *silhouette* maksimal untuk seluruh sekumpulan data (*Average Silhouette Width for Entire Data Set*) terlihat pada tabel berikut:

Tabel 8. Kriteria Penilaian *Clustering* yang Baik

Nilai <i>Silhouette Coefficient</i>	Keterangan
0,71 – 1,00	Struktur Kuat
0,51 – 0,71	Struktur Baik
0,26 – 0,51	Struktur Lemah
$\leq 0,25$	Struktur Buruk



III. METODOLOGI PENELITIAN

3.1 Jenis dan Sumber Data

Jenis data yang digunakan dalam penelitian ini adalah data sekunder. Menurut Siyoto dan Sidik (2015), Data sekunder adalah data yang diperoleh atau dikumpulkan peneliti secara tidak langsung atau dari berbagai sumber, baik dari objek secara individual (responden) maupun dari suatu badan (instansi) seperti Badan Pusat Statistik, buku, laporan, jurnal dan lain-lain. Data dalam penelitian ini diperoleh dari Website Badan Pusat Statistik dengan data produksi tanaman sektor hortikultura tahun 2019.

3.2 Objek dan Variabel Penelitian

1. Objek

Objek yang digunakan dalam penelitian ini adalah seluruh Provinsi di Indonesia yang berjumlah sebanyak 34 Provinsi.

2. Variabel

Variabel yang digunakan dalam penelitian ini merupakan variabel yang dapat menggambarkan produksi tanaman pada sektor hortikultura secara umum. Variabel penelitian awalnya berjumlah sebanyak 70 variabel yang diperoleh melalui Website Badan Pusat Statistik Tahun 2019, disebutkan pada tabel berikut:

Tabel 9. Variabel Penelitian

Variabel	Keterangan	Satuan
X1	Produksi Temuireng	Kg
X2	Produksi Temulawak	Kg
X3	Produksi Lempuyang	Kg
X4	Produksi Jahe	Kg
X5	Produksi Laos/Lengkuas	Kg
X6	Produksi Kencur	Kg
X7	Produksi Kunyit	Kg
X8	Produksi Stoberi	Ton
X9	Produksi Anggur	Ton
X10	Produksi Apel	Ton
X11	Produksi Blewah	Ton
X12	Produksi Semangka	Ton
X13	Produksi Melon	Ton
X14	Produksi Sukun	Ton
X15	Produksi Sirsak	Ton
X16	Produksi Markisa	Ton

Variabel	Keterangan	Satuan
X17	Produksi Sawo	Ton
X18	Produksi Salak	Ton
X19	Produksi Nenas	Ton
X20	Produksi Nangka	Ton
X21	Produksi Manggis	Ton
X22	Produksi Mangga	Ton
X23	Produksi Jeruk Besar	Ton
X24	Produksi Jeruk Siam	Ton
X25	Produksi Jambu Air	Ton
X26	Produksi Pepaya	Ton
X27	Produksi Pisang	Ton
X28	Produksi rambutan	Ton
X29	Produksi Alpukat	Ton
X30	Produksi Belimbing	Ton
X31	Produksi Duku	Ton
X32	Produksi Durian	Ton
X33	Produksi Jambu Biji	Ton
X34	Produksi Jengkol	Ton
X35	Produksi Petai	Ton
X36	Produksi Jamur	Kg
X37	Produksi Paprika	Ton
X38	Produksi Melinjo	Ton
X39	Produksi Bawang Merah	Ton
X40	Produksi Bawang Putih	Ton
X41	Produksi Bawang Daun	Ton
X42	Produksi Kentang	Ton
X43	Produksi Kubis	Ton
X44	Produksi Kembang Kol	Ton
X45	Produksi Petsai/sawi	Ton
X46	Produksi Wortel	Ton
X47	Produksi Lobak	Ton
X48	Produksi Kacang Merah	Ton
X49	Produksi Kacang Panjang	Ton
X50	Produksi Cabai Besar	Ton
X51	Produksi Cabai Rawit	Ton
X52	Produksi Tomat	Ton
X53	Produksi Terung	Ton

Variabel	Keterangan	Satuan
X54	Produksi Buncis	Ton
X55	Produksi Ketimun	Ton
X56	Produksi Labusiam	Ton
X57	Produksi Kangkung	Ton
X58	Produksi Bayam	Ton
X59	Produksi Anggrek	Tangkai
X60	Produksi Anthurium	Tangkai
X61	Produksi Anyelir	Tangkai
X62	Produksi Gerbera	Tangkai
X63	Produksi Gladiol	Tangkai
X64	Produksi Heliconia	Tangkai
X65	Produksi Krisan	Tangkai
X66	Produksi Mawar	Tangkai
X67	Produksi Sedap Malam	Tangkai
X68	Produksi Dracaena	Pohon
X69	Produksi Melati	Pohon
X70	Produksi Palem	Pohon

3.3 Teknik Analisis Data

Metode analisis *cluster* yang digunakan pada penelitian ini adalah metode K-Medoid dengan ukuran jarak *Euclidean*. Langkah-langkah yang dilakukan pada penelitian ini adalah:

1. Merumuskan masalah

Perumusan masalah merupakan proses yang sangat mendasar dalam analisis *cluster*. Identifikasi objek dan variabel yang digunakan pada penelitian harus jelas. Penggunaan variabel harus dikaji dengan baik serta relevan terhadap masalah yang ada. Dilanjutkan dengan pengumpulan dan penginputan data.

2. Melakukan Standarisasi data

Proses standarisasi dilakukan apabila di antara variabel-variabel yang diteliti terdapat perbedaan ukuran satuan nilai yang besar. Apabila perbedaan tersebut tidak disamakan maka dapat mengakibatkan perhitungan pada analisis *cluster* menjadi tidak valid. Menurut Nugroho (2008) transformasi dapat dilakukan terhadap variabel yang relevan ke dalam bentuk *z-score*, yaitu transformasi data dalam bentuk normal baku $N(0,1)$ yang dirumuskan sebagai berikut:

$$z_i = \frac{x_i - \bar{x}}{s} \quad (51)$$

Keterangan:

- x_i : Data ke- i , untuk $i = 1, 2, 3, \dots, n$
- \bar{x} : Rata-rata data
- s : Simpangan Baku (Standar Deviasi)

3. Mendeteksi adanya Multikolinearitas

Data yang telah di standarisasi dilakukan pengujian Multikolinearitas dengan melihat nilai korelasi antar variabel. Multikolinearitas di tandai apabila nilai korelasi melebihi 0,5. Perhitungan koefisien korelasi yang dapat digunakan untuk data dengan skala pengukuran interval dan rasio adalah koefisien korelasi *pearson*. Hipotesis dan kriteria pengujian yang digunakan adalah sebagai berikut:

Hipotesis:

H_0 : Tidak terdapat multikolinearitas

H_1 : Terdapat multikolinearitas

Kriteria pengujian:

H_0 ditolak apabila $r_{xy} > 0,5$, artinya terdapat multikolinearitas

H_1 ditolak apabila $r_{xy} < 0,5$, artinya tidak terdapat multikolinearitas

Persamaan dari koefisien korelasi *pearson* yang digunakan tertuang dalam persamaan (28).

4. Melakukan analisis faktor untuk mengatasi Multikolinearitas

Apabila data mengalami multikolinearitas, maka untuk mengatasi masalah ini perlu dilakukan analisis faktor. Melakukan analisis faktor dengan metode *Principal Component Analysis* (PCA) berfungsi untuk merangkum variabel-variabel yang memiliki korelasi yang tinggi. Menurut Mattjik dan Sumertajaya (2011), Model analisis faktor yang digunakan adalah sebagai berikut:

$$X = \mu + lF + \varepsilon \quad (52)$$

$$\begin{bmatrix} X_1 \\ X_2 \\ \vdots \\ X_p \end{bmatrix} = \begin{bmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_p \end{bmatrix} + \begin{bmatrix} l_{11} & l_{12} & \cdots & l_{1m} \\ l_{21} & l_{22} & \cdots & l_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ l_{p1} & l_{p2} & \cdots & l_{pm} \end{bmatrix} \begin{bmatrix} F_1 \\ F_2 \\ \vdots \\ F_m \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_p \end{bmatrix}$$

Keterangan:

- μ : vektor rata-rata
- F : vektor random yang disebut dengan *common factors* (faktor bersama)
- l : matriks konstanta yang tidak diketahui nilainya berukuran $p \times k$
- ε_p : vektor faktor khusus ke- p

5. Menentukan ukuran jarak kesamaan antar objek

Jarak yang digunakan pada penelitian ini merupakan jarak *Euclidean*. Hal ini dikarenakan variabel yang diamati tidak saling berkorelasi, memiliki skala pengukuran data yang sama atau telah distandarisasi, dan pengukuran pembakuan atau standarisasi memiliki rata-rata nol serta standar deviasinya satu. Ukuran jarak ditentukan menggunakan rumus jarak *Euclidean* pada persamaan (35).

6. Melakukan pengelompokan *K-Medoid* dengan bantuan *software R*

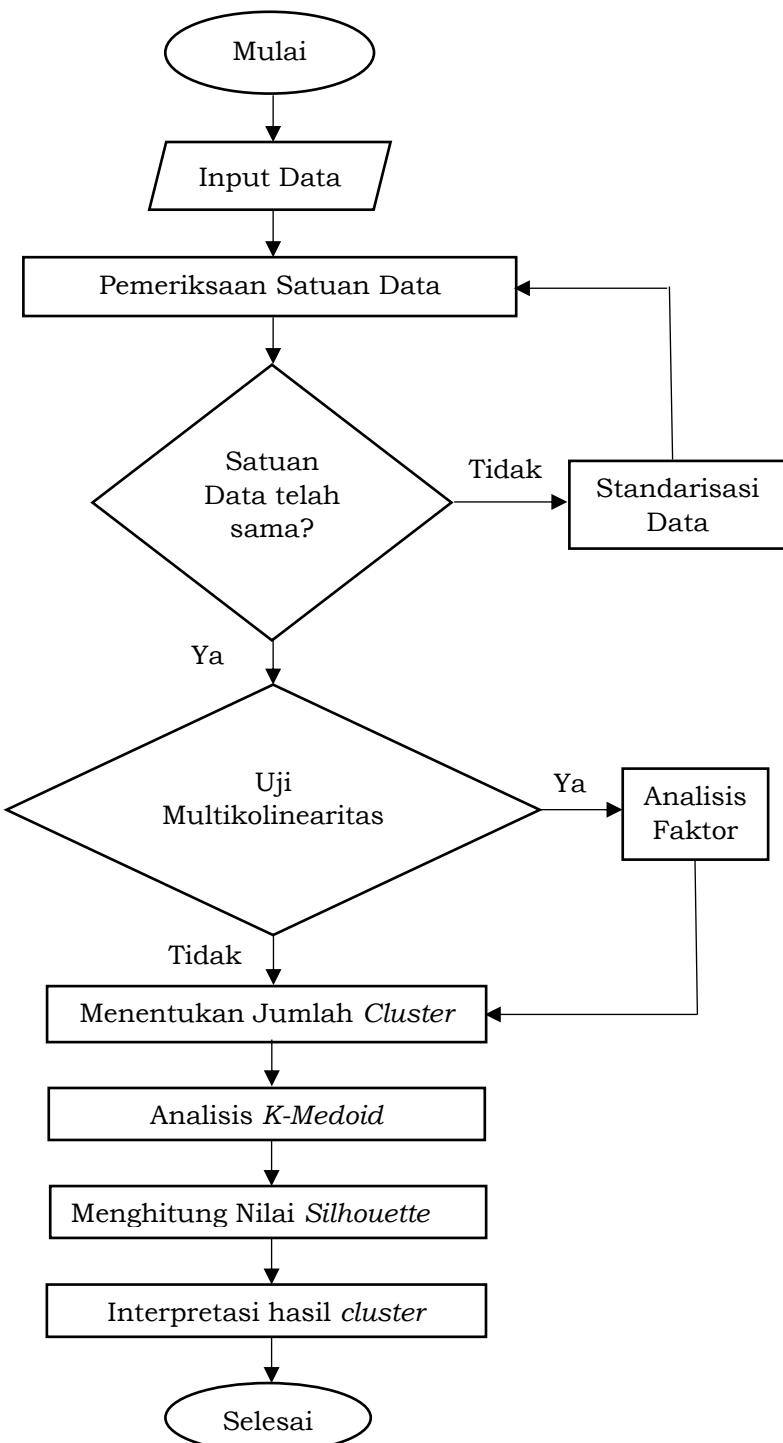
Proses pengelompokan menggunakan metode *K-Medoid*. Jarak yang digunakan adalah jarak *Euclidean* dengan mengambil jumlah *cluster* sebanyak $k = 2$, $k = 3$ dan $k = 4$. Pada $k = 2$ terbagi menjadi tingkat produksi hortikultura rendah dan tinggi. Pada $k = 3$ terbagi menjadi tingkat produksi hortikultura rendah, sedang dan tinggi. Sedangkan pada $k = 4$ terbagi menjadi kategori rendah, sedang, tinggi dan sangat tinggi. Prosedur analisis *cluster K-Medoid* tercantum pada halaman 27. Proses pengelompokan dilakukan secara manual kemudian dibandingkan dengan menggunakan *software R*.

7. Menghitung nilai *Silhouette Coefficient*

Nilai *Silhouette Coefficient* digunakan untuk menganalisis jumlah k pada *cluster* yang memiliki struktur yang baik. Nilai *Silhouette Coefficient* diperoleh menggunakan rumus pada persamaan (50).

8. Melakukan interpretasi hasil pengelompokan yang telah diperoleh.

3.4 Diagram Alur Penelitian



Gambar 6. Diagram Alur Penelitian



IV. HASIL DAN PEMBAHASAN

4.1 Hasil Penelitian

1. Data Penelitian

Data diperoleh melalui website Badan Pusat Statistik. Data yang digunakan merupakan data produksi tanaman hortikultura tahun 2019. Adapun data yang digunakan pada penelitian ini terdapat pada **Lampiran 1**.

2. Standarisasi Data

Standarisasi sangat penting dilakukan apabila dalam data terdapat satuan data yang berbeda. Apabila data yang memiliki perbedaan satuan data maka akan mempengaruhi hasil *cluster* yang terbentuk. Data produksi hortikultura pada lampiran 1 memiliki satuan yang berbeda-beda mulai dari ton, kg, tangkai dan pohon. Perbedaan satuan data ini diatasi dengan menghitung nilai *z-score*. Proses perhitungan *z-score* pada beberapa nilai data terhadap variabel x_1 dapat diperoleh dengan perhitungan menggunakan persamaan (51) dan untuk menghitung standar deviasi menggunakan akar kuadrat dari persamaan (19) sebagai berikut:

$$\begin{aligned} S_{11} &= \frac{1}{34-1} \sum_{i=1}^n (X_{i1} - \bar{X}_1)(X_{i1} - \bar{X}_1) \\ &= \frac{1}{33} (1,746 \times 10^{13}) \\ &= 5,29 \times 10^{11} \end{aligned}$$

Hasil perhitungan dari nilai variansi dan kovariansi data yang disajikan dalam bentuk matriks varians kovariansi S yang dapat dilihat pada **lampiran 2**. Berdasarkan nilai variansi dapat dihitung nilai standar deviasinya yang diperoleh untuk variabel x_1 (produksi temuireng) berdasarkan akar kuadrat dari variansi S_{11} yaitu:

$$\begin{aligned} s &= \sqrt{S_{11}} \\ &= \sqrt{5,290 \times 10^{11}} \\ &= 7,274 \times 10^5 \\ z_{1,1} &= \frac{x_{11}-\bar{x}_1}{s} \\ &= \frac{1141-204986.94}{7,274 \times 10^5} \\ &= -0,280 \\ z_{2,1} &= \frac{x_{21}-\bar{x}_1}{s} \\ &= \frac{18436-204986.94}{7,274 \times 10^5} \\ &= -0,256 \\ z_{3,1} &= \frac{x_{31}-\bar{x}_1}{s} \end{aligned}$$

$$\begin{aligned}
&= \frac{3022 - 204986.94}{7,274 \times 10^5} \\
&= -0,278 \\
z_{4,1} &= \frac{x_{41} - \bar{x}_1}{s} \\
&= \frac{28672 - 204986.94}{7,274 \times 10^5} \\
&= -0,242 \\
z_{5,1} &= \frac{x_{51} - \bar{x}_1}{s} \\
&= \frac{12346 - 204986.94}{7,274 \times 10^5} \\
&= -0,265 \\
&\vdots \\
z_{34,1} &= \frac{x_{341} - \bar{x}_1}{s} \\
&= \frac{1786 - 204986.94}{7,274 \times 10^5} \\
&= -0,279
\end{aligned}$$

Proses standarisasi data dilanjutkan ke variabel-variabel selanjutnya dengan menggunakan rumusan yang sama sehingga diperoleh hasil transformasi data ke nilai *z-score* yang baru. Data yang telah ditransformasikan ke dalam nilai *z-score* inilah yang akan digunakan pada analisis *cluster*. Data yang telah distandarisasi dalam nilai *z-score* terlampir pada **lampiran 3**.

3. Asumsi Analisis *Cluster*

Data yang telah distandarisasi kemudian diperiksa apakah memenuhi asumsi-asumsi analisis *cluster*. Asumsi-asumsi yang diperiksa adalah sebagai berikut:

a. Sampel mewakili populasi yang ada

Dalam tinjauan pustaka disebutkan bahwa apabila data yang digunakan merupakan populasi maka dianggap bahwa asumsi ini telah dipenuhi. Data dalam penelitian ini merupakan populasi sehingga dapat disimpulkan bahwa data hortikultura Tahun 2019 telah memenuhi asumsi.

b. Uji Multikolinearitas

Multikolinearitas dilihat dari nilai korelasi pada data. Perhitungan korelasi menggunakan persamaan (28) secara manual pada beberapa variabel data produksi hortikultura Tahun 2019 di Indonesia adalah sebagai berikut:

$$\begin{aligned}
r_{11} &= \frac{\sum_{i=1}^n (x_{i1} - \bar{x}_1)(x_{i1} - \bar{x}_1)}{\sqrt{\sum_{i=1}^n (x_{i1} - \bar{x}_1)^2} \sqrt{\sum_{i=1}^n (x_{i1} - \bar{x}_1)^2}} \\
&= \frac{32,999951}{\sqrt{32,999951} \sqrt{32,999951}} \\
&= \frac{32,999951}{32,999951} \\
&= 1,00
\end{aligned}$$

$$r_{12} = \frac{\sum_{i=1}^n (x_{i1} - \bar{x}_1)(x_{i2} - \bar{x}_2)}{\sqrt{\sum_{i=1}^n (x_{i1} - \bar{x}_1)^2} \sqrt{\sum_{i=1}^n (x_{i2} - \bar{x}_2)^2}}$$

$$= \frac{32,659}{\sqrt{32,999} \sqrt{32,999}}$$

$$= \frac{32,659}{32,999}$$

$$= 0,990$$

$$r_{13} = \frac{\sum_{i=1}^n (x_{i1} - \bar{x}_1)(x_{i3} - \bar{x}_3)}{\sqrt{\sum_{i=1}^n (x_{i1} - \bar{x}_1)^2} \sqrt{\sum_{i=1}^n (x_{i3} - \bar{x}_3)^2}}$$

$$= \frac{32,812}{\sqrt{32,999951} \sqrt{32,999982}}$$

$$= \frac{32,812}{32,99997}$$

$$= 0,994$$

$$r_{14} = \frac{\sum_{i=1}^n (x_{i1} - \bar{x}_1)(x_{i4} - \bar{x}_4)}{\sqrt{\sum_{i=1}^n (x_{i1} - \bar{x}_1)^2} \sqrt{\sum_{i=1}^n (x_{i4} - \bar{x}_4)^2}}$$

$$= \frac{26,190}{\sqrt{32,999951} \sqrt{32,99999}}$$

$$= \frac{26,190}{32,99998}$$

$$= 0,794$$

:

$$r_{7070} = \frac{\sum_{i=1}^n (x_{i70} - \bar{x}_{70})(x_{i70} - \bar{x}_{70})}{\sqrt{\sum_{i=1}^n (x_{i70} - \bar{x}_{70})^2} \sqrt{\sum_{i=1}^n (x_{i70} - \bar{x}_{70})^2}}$$

$$= \frac{32,00002}{\sqrt{32,00002} \sqrt{32,00002}}$$

$$= \frac{32,00002}{32,00002}$$

$$= 1,00$$

Perhitungan tersebut dilanjutkan dengan perhitungan yang sama sehingga diperoleh nilai korelasi antara seluruh variabel dengan variabel yang lainnya. Nilai korelasi dari seluruh variabel tersebut dapat disajikan dalam bentuk matriks **R** yang dapat dilihat pada **lampiran 4**. Dilakukan uji multikolinearitas untuk mengetahui ada atau tidaknya multikolinearitas seperti berikut:

Hipotesis:

H_0 : Tidak terdapat multikolinearitas

H_1 : Terdapat multikolinearitas

Kriteria pengujian:

H_0 ditolak apabila $r_{xy} > 0,5$, artinya terdapat multikolinearitas

H_1 ditolak apabila $r_{xy} < 0,5$, artinya tidak terdapat multikolinearitas

Berdasarkan hasil perhitungan korelasi dalam matriks **R** tersebut terdapat banyak nilai korelasi $r > 0,5$. Sehingga hipotesis H_0 ditolak, artinya terdapat multikolinearitas pada data. Multikolinearitas dalam data diatasi dengan menggunakan analisis faktor.

4. Mengatasi adanya Multikolinearitas

Analisis faktor dengan metode ekstraksi komponen utama (PCA) dilakukan untuk mengatasi multikolinearitas. Rotasi yang digunakan menggunakan *Varimax* dengan iterasi sebanyak 7 iterasi. Hasil dari analisis faktor menghasilkan sebanyak 8 faktor. Penentuan ini berdasarkan pada tabel *Total Variance* berikut:

Tabel 10. *Total Variance*

Faktor	Initial Eigen Values			Extraction sum of Squared Loadings			Rotation Sum of Squared Loadings		
	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %	Total	% of Variance	Cumulative %
1	41,088	58,697	58,697	41,088	58,697	58,697	23,008	32,868	32,868
2	12,031	17,187	75,884	12,031	17,187	75,884	22,206	31,723	64,591
3	4,852	6,893	82,777	4,852	6,893	82,777	10,559	15,141	79,732
4	2,471	3,53	86,307	2,471	3,53	86,307	2,71	3,871	83,603
5	2,28	3,257	89,565	2,28	3,257	89,565	2,323	3,319	86,922
6	1,79	2,557	92,121	1,79	2,557	92,121	2,277	3,253	90,175
7	1,41	2,014	94,135	1,41	2,014	94,135	2,246	3,209	93,384
8	1,116	1,594	95,73	1,116	1,594	95,73	1,642	2,346	95,73
9	0,846	1,208	96,938						
10	0,564	0,806	97,744						
11	0,417	0,596	98,339						
12	0,242	0,346	98,686						
13	0,223	0,319	99,004						
14	0,165	0,236	99,24						
15	0,119	0,171	99,41						

Berdasarkan tabel diatas diperoleh bahwa nilai eigen yang lebih dari 1 adalah pada faktor 1, faktor 2, faktor 3, faktor 4, faktor 5, faktor 6, faktor 7, dan faktor 8. Sehingga data produksi tanaman hortikultura terbagi menjadi 8 faktor. 8 faktor inilah yang akan digunakan sebagai data untuk analisis selanjutnya. Untuk menentukan variabel mana saja yang masuk kedalam suatu faktor dilihat dari hasil *Rotated Component Matrix* yang terlihat pada **lampiran 5**. Data hasil dari analisis faktor ini dapat terlihat pada **lampiran 6**. Variabel hasil analisis faktor yang memuat keseluruhan informasi dari 70 variabel yang ada dapat ditunjukkan dalam tabel berikut:

Tabel 11. Variabel Hasil Analisis Faktor

Variabel	Komponen
V1	Produksi Jamur
	Produksi Bawang Daun
	Produksi Kubis
	Produksi Sawi
	Produksi Wortel
	Produksi Lobak

Produksi Kacang Merah
Produksi Kacang Panjang
Produksi Cabai Besar
Produksi Tomat
Produksi Terung
Produksi Buncis
Produksi Ketimun
Produksi Labusiam
Produksi Kangkung
Produksi Bayam
Produksi Stoberi
Produksi Sawo
Produksi Manggis
Produksi Rambutan
Produksi Alpukat
Produksi Anthurium
Produksi Anyelir
Produksi Gerbera
Produksi Gladiol
Produksi Krisan
Produksi Dracaena

V2

Produksi Paprika
Produksi Kentang
Produksi Cabai Rawit
Produksi Blewah
Produksi Semangka
Produksi Melon
Produksi Apel
Produksi Sirsak
Produksi Nangka
Produksi Mangga
Produksi Jeruk Siam
Produksi Pepaya
Produksi Pisang
Produksi Belimbing
Produksi Durian
Produksi Temuireng
Produksi Temulawak
Produksi Tempuyang
Produksi Jahe
Produksi Kunyit
Produksi Anggrek
Produksi Mawar
Produksi Sedap Malam

V3	Produksi Petai Produksi Melinjo Produksi Bawang Putih Produksi Bawang Merah Produksi Sukun Produksi Salak Produksi Jambu Air Produksi Jambu Biji Produksi Laos Produksi Kencur Produksi Melati Produksi Palem
V4	Produksi Jengkol Produksi Nenas
V5	Produksi Anggur Produksi Heliconia
V6	Produksi Kembang kol
V7	Produksi Markisa
V8	Produksi Jeruk Besar Produksi Duku

5. Hasil Pengelompokkan *K-Medoid*

a. Jumlah *Cluster* yang akan dibentuk

Jumlah *cluster* yang diambil dalam penelitian sebanyak 2 *cluster*. *Cluster* akan terbagi menjadi 2 kriteria yaitu, *cluster* dengan tingkat produksi tanaman hortikultura yang rendah dan *cluster* dengan tingkat produksi tanaman hortikultura yang tinggi.

b. Medoid Awal

Penentuan centroid awal sebagai medoids awal dilakukan sebanyak jumlah k yang diambil. Jumlah k yang diambil sebanyak 2 maka jumlah centroid yang akan diambil sebagai *medoids* awal juga sebanyak 2. Tabel berikut merupakan tabel *medoid* awal pada perhitungan secara manual yaitu sebagai berikut:

Tabel 12. Medoid Awal

Medoid	V1	V2	V3	V4	V5	V6	V7	V8
C1	-0,36	0,06	0,30	-0,24	-0,32	-0,43	-0,37	-0,87
C2	0,28	-0,31	-0,41	0,52	-0,17	5,34	-0,32	0,45

Berdasarkan **Tabel 12**. C1 merupakan *medoid* pertama dengan mengambil objek ke-14 sebagai pusat *clusternya*. Sedangkan C2 merupakan *medoid* kedua dengan mengambil objek ke-2 sebagai pusat *clusternya*.

c. Ukuran Jarak antara objek *medoid* dan objek data

Ukuran jarak antara objek *medoid* awal yang disimbolkan $C1$ dan $C2$ dengan objek data menggunakan ukuran jarak *euklidean*. Perhitungan manual jarak objek data terhadap *medoid* $C1$ adalah sebagai berikut:

$$\begin{aligned}
 d_{ij} &= \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2} \\
 d_{1,c1} &= \sqrt{\sum_{k=1}^8 (x_{1k} - c_{1k})^2} \\
 &= \sqrt{(x_{11} - c_{11})^2 + (x_{12} - c_{12})^2 + (x_{13} - c_{13})^2 + \dots + (x_{18} - c_{18})^2} \\
 &= \sqrt{((-0,13) - (-0,36))^2 + ((-0,14) - (0,06))^2 + ((-0,19) - (0,30))^2 + \dots + (0,14 - (-0,87))^2} \\
 &= \sqrt{0,23^2 + (-0,2)^2 + (-0,49)^2 + \dots + (1,01)^2} \\
 &= 1,25 \\
 d_{2,c1} &= \sqrt{\sum_{k=1}^8 (x_{2k} - c_{1k})^2} \\
 &= \sqrt{(x_{21} - c_{11})^2 + (x_{22} - c_{12})^2 + (x_{23} - c_{13})^2 + \dots + (x_{28} - c_{18})^2} \\
 &= \sqrt{((0,28) - (-0,36))^2 + ((-0,31) - (0,06))^2 + ((-0,41) - (0,30))^2 + \dots + (0,45 - (-0,87))^2} \\
 &= \sqrt{0,64^2 + (-0,37)^2 + (-0,71)^2 + \dots + (1,32)^2} \\
 &= 6,05 \\
 d_{3,c1} &= \sqrt{\sum_{k=1}^8 (x_{3k} - c_{1k})^2} \\
 &= \sqrt{(x_{31} - c_{11})^2 + (x_{32} - c_{12})^2 + (x_{33} - c_{13})^2 + \dots + (x_{38} - c_{18})^2} \\
 &= \sqrt{(0,12 - (-0,36))^2 + ((-0,23) - (0,06))^2 + ((-0,12) - (0,30))^2 + \dots + ((-0,60) - (-0,87))^2} \\
 &= \sqrt{0,48^2 + (-0,29)^2 + (-0,42)^2 + \dots + (0,27)^2} \\
 &= 5,97 \\
 &\vdots \\
 d_{14,c1} &= \sqrt{\sum_{k=1}^8 (x_{14k} - c_{1k})^2} \\
 &= \sqrt{(x_{141} - c_{11})^2 + (x_{142} - c_{12})^2 + (x_{143} - c_{13})^2 + \dots + (x_{148} - c_{18})^2} \\
 &= \sqrt{(-0,36 - (-0,36))^2 + ((0,06) - (0,06))^2 + ((0,30) - (0,30))^2 + \dots + ((-0,87) - (-0,87))^2} \\
 &= \sqrt{0^2 + 0^2 + 0^2 + \dots + 0^2} \\
 &= 0 \\
 &\vdots \\
 d_{34,c1} &= \sqrt{\sum_{k=1}^8 (x_{34k} - c_{1k})^2} \\
 &= \sqrt{(x_{341} - c_{11})^2 + (x_{342} - c_{12})^2 + (x_{343} - c_{13})^2 + \dots + (x_{348} - c_{18})^2} \\
 &= \sqrt{(-0,20 - (-0,36))^2 + (-0,18 - (0,06))^2 + ((-0,26) - (0,30))^2 + \dots + ((-0,58) - (-0,87))^2} \\
 &= \sqrt{0,16^2 + (-0,24)^2 + (-0,56)^2 + \dots + (0,29)^2} \\
 &= 0,89
 \end{aligned}$$

Perhitungan manual jarak objek data terhadap *medoid* $C2$ adalah sebagai berikut:

$$d_{1,c2} = \sqrt{\sum_{k=1}^8 (x_{1k} - c_{2k})^2}$$

$$\begin{aligned}
&= \sqrt{(x_{11} - c_{21})^2 + (x_{12} - c_{22})^2 + (x_{13} - c_{23})^2 + \dots + (x_{18} - c_{28})^2} \\
&= \sqrt{((-0,13) - 0,28)^2 + ((-0,14) - (-0,31))^2 + ((-0,19) - (-0,41))^2 + \dots + (0,14 - (0,45))^2} \\
&= \sqrt{-0,41^2 + (0,17)^2 + (0,22)^2 + \dots + (-0,31)^2} \\
&= 5,57
\end{aligned}$$

$$\begin{aligned}
d_{2,c2} &= \sqrt{\sum_{k=1}^8 (x_{2k} - c_{2k})^2} \\
&= \sqrt{(x_{21} - c_{21})^2 + (x_{22} - c_{22})^2 + (x_{23} - c_{23})^2 + \dots + (x_{28} - c_{28})^2} \\
&= \sqrt{((0,28) - (0,28))^2 + ((-0,31) - (-0,31))^2 + ((-0,41) - (-0,41))^2 + \dots + (0,45 - 0,45)^2} \\
&= \sqrt{0^2 + 0^2 + 0^2 + \dots + 0^2} \\
&= 0
\end{aligned}$$

$$\begin{aligned}
d_{3,c2} &= \sqrt{\sum_{k=1}^8 (x_{3k} - c_{2k})^2} \\
&= \sqrt{(x_{31} - c_{21})^2 + (x_{32} - c_{22})^2 + (x_{33} - c_{23})^2 + \dots + (x_{38} - c_{28})^2} \\
&= \sqrt{(0,12 - (0,28))^2 + ((-0,23) - (-0,31))^2 + ((-0,12) - (-0,41))^2 + \dots + ((-0,60) - (0,45))^2} \\
&= \sqrt{-0,16^2 + (0,08)^2 + (0,29)^2 + \dots + (-1,05)^2} \\
&= 7,92
\end{aligned}$$

:

$$\begin{aligned}
d_{34,c2} &= \sqrt{\sum_{k=1}^8 (x_{34k} - c_{2k})^2} \\
&= \sqrt{(x_{341} - c_{21})^2 + (x_{342} - c_{22})^2 + (x_{343} - c_{23})^2 + \dots + (x_{348} - c_{28})^2} \\
&= \sqrt{(-0,20 - (0,28))^2 + (-0,18 - (-0,31))^2 + ((-0,26) - (-0,41))^2 + \dots + ((-0,58) - (0,45))^2} \\
&= \sqrt{-0,48^2 + (0,13)^2 + (-0,67)^2 + \dots + (-1,03)^2} \\
&= 5,52
\end{aligned}$$

Berdasarkan perhitungan jarak tersebut terlihat bahwa pada jarak objek data ke-14 terhadap *medoid* $C1$ dan objek data ke-2 terhadap *medoid* $C2$ bernilai 0. Hal ini dikarenakan *medoid* $C1$ dan $C2$ merupakan objek ke-14 dan ke-2 sebelum dipilih menjadi *medoid*. Sehingga jarak antara keduanya bernilai 0. Dimana objek ke-14 merupakan provinsi D.I Yogyakarta dan objek ke-2 merupakan provinsi Sumatera Utara yang kemudian dihitung jarak terhadap objek itu sendiri tidak mungkin bernilai lebih dari 0, atau dalam arti bahwa tidak memiliki jarak. Disimpulkan bahwa sifat jarak $d(i,j) = 0$, jika $i = j$ terbukti pada perhitungan jarak ini.

Apabila perhitungan ini dimulai dari sebaliknya akan diperoleh hasil yang sama pula. Diambil contoh pada perhitungan jarak *medoid* $C1$ terhadap objek data ke-2 adalah sebagai berikut:

$$\begin{aligned}
d_{c1,2} &= \sqrt{\sum_{k=1}^8 (c_{1k} - x_{2k})^2} \\
&= \sqrt{(c_{11} - x_{21})^2 + (c_{12} - x_{22})^2 + (c_{13} - x_{23})^2 + \dots + (c_{18} - x_{28})^2} \\
&= \sqrt{((-0,36) - 0,28)^2 + ((0,06) - (-0,31))^2 + ((0,30) - (-0,41))^2 + \dots + (-0,87 - (0,45))^2} \\
&= \sqrt{-0,64^2 + (0,37)^2 + (0,71)^2 + \dots + (-1,32)^2}
\end{aligned}$$

$$= 6,05$$

Berdasarkan perhitungan diatas diperoleh bahwa nilai jarak antara *medoid* C_1 terhadap objek data ke-2 dan jarak antara objek data ke-2 dan *medoid* C_1 bernilai sama. Hal ini sesuai dengan sifat jarak yaitu $d(i,j) = d(j,i)$. Serta nilai yang diperoleh juga lebih besar dari nol. Sehingga perhitungan tersebut juga sesuai dengan sifat jarak yaitu $d(i,j) > 0$, jika $i \neq j$. Dari keseluruhan perhitungan jarak ke setiap *medoid* diperoleh Total cost sebesar 278,47. Hasil perhitungan jarak ke setiap *medoid* beserta jarak minimum dan *cluster* yang dikuti dapat terlihat pada **Lampiran 7**.

Setelah diperoleh nilai jarak terhadap *medoid*, maka selanjutnya untuk menentukan objek yang dijadikan sebagai non-*medoid*. Objek yang dipilih sebagai Non-*Medoid* dapat terlihat pada **Tabel 13.** berikut:

Tabel 13. Objek Non-*medoid*

Non-Medoid	V1	V2	V3	V4	V5	V6	V7	V8
D1	-0,27	-0,19	-0,23	-0,54	-0,21	-0,15	-0,28	-0,55
D2	0,12	5,63	-0,40	0,03	-0,06	0,16	0,05	0,06

Perhitungan dilakukan kembali untuk mengukur jarak antara objek ke setiap non-*medoid*. Diperoleh *total cost* sebesar 276,27. Hasil perhitungan jarak ke setiap objek non-medoid dapat terlihat pada **lampiran 8**. Berdasarkan iterasi pertama ini diperoleh bahwa selisih antara *total cost* baru dan *total cost* yang lama sebesar -2,20. Karena hasil S bernilai negatif maka iterasi dilanjutkan kembali. Proses perhitungan pada setiap iterasi dapat terlihat pada **lampiran 9**. Sehingga diperoleh selisih untuk setiap iterasi dapat terlihat pada tabel berikut:

Tabel 14. Selisih Setiap Iterasi

No.	Iterasi	Selisih	Keterangan
1	ke-1	-2,20	Next
2	ke-2	-11,93	Next
3	ke-3	-59,00	Next
4	ke-4	-47,32	Next
5	ke-5	-0,24	Next
6	ke-6	-13,73	Next
7	ke-7	-3,39	Next
8	ke-8	9,65	Stop

Berdasarkan **Tabel 14.** proses iterasi dihentikan ketika nilai selisih antara *Total Cost Baru* dan *Total Cost Lama* bernilai positif. Pada iterasi ke-8 diperoleh bahwa nilai selisih sebesar 11,13 , sehingga dapat disimpulkan bahwa iterasi dihentikan.

d. Hasil Analisis *Cluster K-Medoid*

Melalui perhitungan manual yang dapat dilihat pada **lampiran 7.**, **lampiran 8.**, dan **lampiran 9.**, diperoleh bahwa hasil analisis *cluster* nya adalah sebagai berikut:

Tabel 15. Hasil Analisis *Cluster*

N	Provinsi	Cluster yang diikuti
1	Aceh	1
2	Sumatera Utara	2
3	Sumatera Barat	1
4	Riau	2
5	Jambi	2
6	Sumatera Selatan	2
7	Bengkulu	1
8	Lampung	2
9	Kep.Bangka Belitung	1
10	Kep.Riau	1
11	DKI Jakarta	1
12	Jawa Barat	2
13	Jawa Tengah	2
14	DI Yogyakarta	1
15	Jawa Timur	2
16	Banten	2
17	Bali	1
18	Nusa Tenggara Barat	1
19	Nusa Tenggara Timur	1
20	Kalimantan Barat	2
21	Kalimantan Tengah	1
22	Kalimantan selatan	2
23	Kalimantan Timur	1
24	Kalimantan Utara	1
25	Sulwesi Utara	1
26	Sulwesi Tengah	1
27	Sulawesi Selatan	2
28	Sulwesi Tenggara	1
29	Gorontalo	1
30	Sulawesi Barat	1
31	Maluku	1
32	Maluku Utara	1
33	Papua Barat	1
34	Papua	1

Berdasarkan hasil pengelompokan pada **tabel 15.** maka dapat disimpulkan bahwa dari 34 objek penelitian terbentuk 2 *cluster* dengan anggota untuk masing-masing *cluster* disajikan dalam **Tabel 16.** berikut:

Tabel 16. Anggota *Cluster* yang Terbentuk dengan Perhitungan Manual

Cluster	Jumlah Anggota	Provinsi
1	22	Aceh, Sumatera Barat, Bengkulu Kep.Bangka Belitung, Kep.Riau, DKI Jakarta, DI Yogyakarta, Bali, Nusa Tenggara Barat, Nusa Tenggara Timur, Kalimantan Tengah, Kalimantan Timur, Kalimantan Utara, Sulawesi Utara, Sulawesi Tengah, Sulawesi Tenggara, Gorontalo, Sulawesi Barat, Maluku, Maluku Utara, Papua Barat, dan Papua
2	12	Sumatera Utara, Riau, Jambi, Sumatera Selatan, Lampung, Jawa Barat, Jawa Tengah, Jawa Timur, Banten, Kalimantan Barat, Kalimantan Selatan, dan Sulawesi Selatan

Hasil pengelompokan algoritma *K-Medoid* dengan menggunakan *software R* diperoleh dengan hasil sebagai berikut:

Clustering vector:

```
[1] 1 2 1 1 2 2 1 1 1 1 1 2 1 2 2 1 2 1 1 1 1 1 2 1 2 1 1 1 1 1 1 1
```

Hasil *output* pengelompokan menggunakan *software R* dapat terlihat pad **Lampiran 12.** Berdasarkan hasil pengelompokan diatas maka dapat disimpulkan bahwa dari 34 objek penelitian terbentuk 2 *cluster* dengan anggota untuk masing-masing *cluster* disajikan dalam **Tabel 17.** berikut:

Tabel 17. Anggota *Cluster* yang Terbentuk dengan *Software R*

Cluster	Jumlah Anggota	Provinsi
1	25	Aceh, Sumatera Barat, Riau, Bengkulu, Lampung, Kep.Bangka Belitung, Kep.Riau, DKI Jakarta, Jawa Barat, DI Yogyakarta, Bali, Nusa Tenggara Timur, Kalimantan Barat, Kalimantan Tengah, Kalimantan Selatan, Kalimantan Timur, Kalimantan Utara, Sulawesi Tengah, Sulawesi Tenggara, Gorontalo, Sulawesi Barat, Maluku, Maluku Utara, Papua Barat, dan Papua
2	9	Sumatera Utara, Jambi, Sumatera Selatan, Jawa Tengah, Jawa Timur, Banten, Nusa Tenggara Barat, Sulawesi Utara dan Sulawesi Selatan

Pada Tabel diatas dapat diketahui bahwa pengelompokan menggunakan algoritma *K-Medoid* dengan jarak *Euclidean* menghasilkan *cluster* 1 yang berjumlah 25 anggota dan *cluster* 2 yang berjumlah 9 anggota. Selain pengelompokan dengan jumlah *cluster* sebanyak 2, dilakukan pengelompokan dengan menggunakan *software R* untuk jumlah *cluster* sebanyak 3 dan 4. *Output*

R yang terbentuk dapat terlihat pada **Lampiran 12.** Berdasarkan pengelompokan menggunakan *software R* untuk $k = 3$ diperoleh hasil seperti pada gambar berikut:

Clustering vector:

```
[1] 1 2 3 3 2 1 3 3 3 3 2 1 2 2 3 2 3 3 3 1 3 3 2 3 1 1 3 1 1 3 3 3
```

Berdasarkan hasil pengelompokan diatas maka dapat disimpulkan bahwa dari 34 objek penelitian terbentuk 3 *cluster* dengan anggota untuk masing-masing *cluster* disajikan dalam **Tabel 18.** berikut:

Tabel 18. Anggota *Cluster k = 3* yang Terbentuk

Cluster	Jumlah Anggota	Nama Provinsi
1	8	Aceh, Sumatera Selatan, Yogyakarta, Kalimantan Selatan, Sulawesi Selatan, Sulawesi Tenggara, Sulawesi Barat, dan Maluku
2	7	Sumatera Utara, Jambi, Jawa Tengah, Jawa Timur, Banten, Nusa Tenggara Barat, dan Sulawesi Utara
3	19	Sumatera Barat, Riau, Bengkulu, Lampung, Kep. Bangka Belitung, Kep. Riau, DKI Jakarta, Jawa Barat, Bali, Nusa Tenggara Timur, Kalimantan Barat, Kalimantan Tengah, Kalimantan Timur, Kalimantan Utara, Sulawesi Tengah, Gorontalo, Maluku Utara, Papua Barat, dan Papua

Kemudian untuk $k = 4$ hasil pengelompokan menggunakan *software R* untuk $k = 4$ diperoleh hasil seperti pada gambar berikut:

Clustering vector:

```
[1] 1 2 2 3 4 2 3 3 3 3 2 4 1 2 4 3 4 3 3 3 1 3 3 4 3 1 1 3 1 1 3 3 3
```

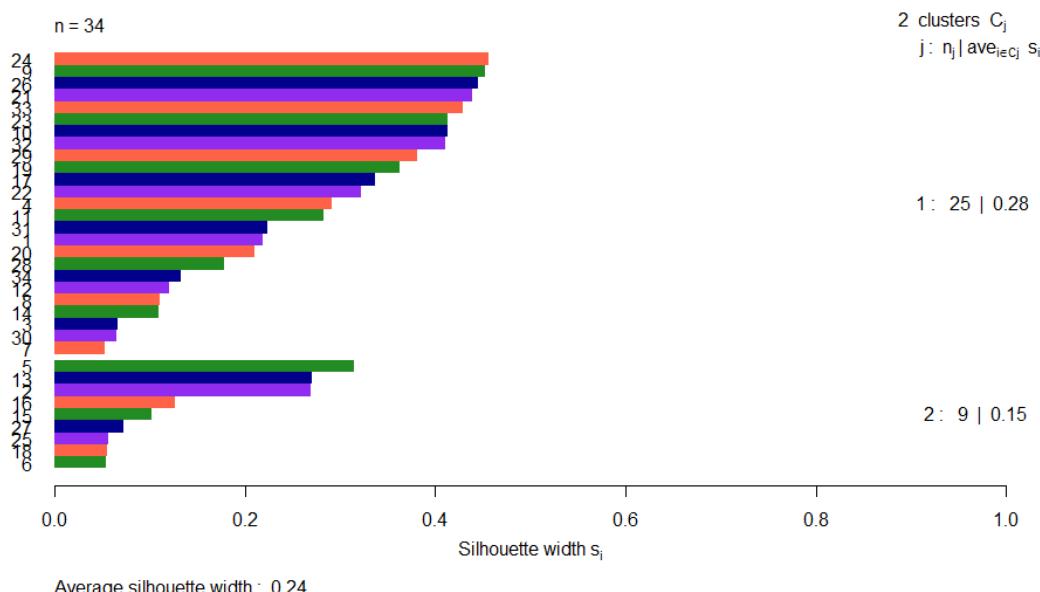
Berdasarkan hasil pengelompokan diatas maka dapat diperoleh bahwa dari 34 objek penelitian yang ada terbentuk 4 *cluster* dengan anggota untuk masing-masing *cluster* disajikan dalam **Tabel 19.** berikut:

Tabel 19. Anggota *Cluster k = 4* yang Terbentuk

Cluster	Jumlah Anggota	Nama Provinsi
1	7	Aceh, Yogyakarta, Kalimantan Selatan, Sulawesi Selatan, Sulawesi Tenggara, Sulawesi Barat, dan Maluku
2	5	Sumatera Utara, Sumatera barat, Sumatera Selatan, Jawa Barat, dan Jawa Timur
3	19	Riau, Bengkulu, Lampung, Kep.Bangka Belitung, Kep.Riau, DKI Jakarta, Bali, Nusa Tenggara Timur, Kalimantan Barat, Kalimantan Tengah, Kalimantan Timur, Kalimantan Utara, Sulawesi Tengah, Gorontalo, Maluku Utara, Papua Barat dan Papua

6. Sillhouette Coefficient

Setelah hasil pengelompokan diperoleh maka selanjutnya adalah menghitung nilai *Sillhouette* untuk menentukan apakah kelompok yang terbentuk sudah baik. Nilai *Sillhouette* ditunjukkan oleh gambar berikut:



Gambar 7. *Silhouette Plot*

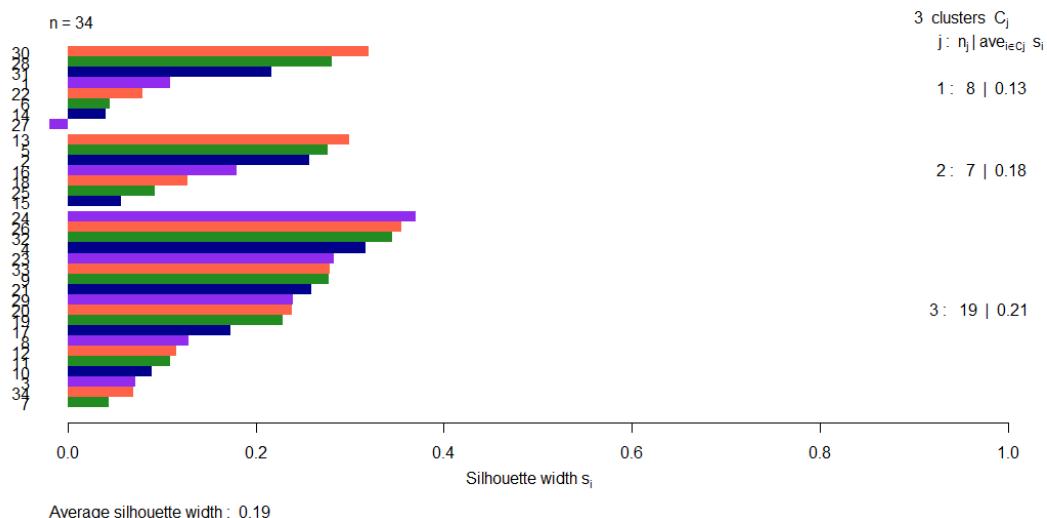
Berdasarkan gambar diatas terlihat bahwa data terbagi menjadi dua *cluster*. Nilai *Silhouette* pada setiap *cluster* dapat terlihat dalam plot *output R* tersebut. Dimana nilai nilai *Silhouette* tersebut dapat dibuat dalam tabel berikut:

Tabel 20. Hasil *Silhouette Coefficient*

Cluster	Anggota Cluster	Silhouette Coefficient	Kategori Struktur
1	25	0,28	Lemah
2	9	0,15	Buruk
Silhouette Coefficient Global		0,24	Buruk

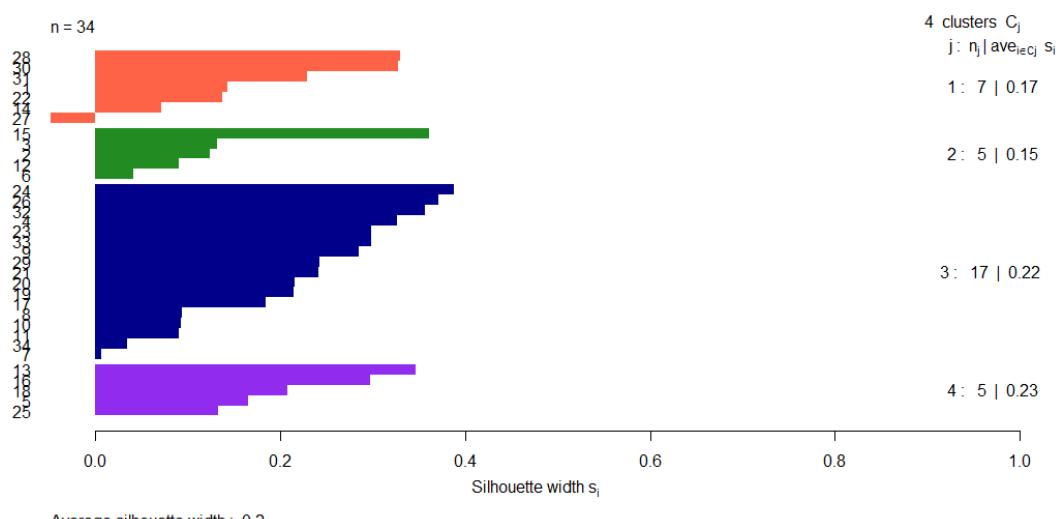
Berdasarkan **Tabel 20.** tersebut diperoleh bahwa nilai *Silhouette* untuk *cluster* 1 adalah sebesar 0,28 dan untuk *cluster* 2 sebesar 0,15. Berdasarkan katetgori struktur *cluster*, pada *cluster* 1 memiliki struktur yang lemah dan pada *cluster* 2 struktur nya buruk. Secara keseluruhan hasil *cluster* yang terbentuk bernilai 0,24, dimana dapat diartikan bahwa struktur *cluster* yang terbentuk buruk.

Perhitungan nilai *Silhouette Coefficient* juga dilakukan pada hasil pengelompokan dengan jumlah *cluster* sebanyak $k = 3$ dan $k = 4$. Nilai *Silhouette* ditunjukkan oleh gambar berikut:



Gambar 8. Silhouette plot untuk $k = 3$

Sedangkan untuk $k = 4$ nilai Silhouette dapat ditunjukkan oleh gambar plot berikut:



Gambar 9. Silhouette plot untuk $k = 4$

Berdasarkan kedua hasil menunjukkan pada $k = 3$ dan $k = 4$ diperoleh nilai Silhouette yang rendah. Berdasarkan **Gambar 8.** diatas pada $k = 3$ dapat terlihat bahwa data terbagi menjadi tiga cluster. Nilai Silhouette pada setiap cluster dapat terlihat dalam plot output R tersebut. Dimana nilai nilai Silhouette tersebut dapat dibuat dalam tabel berikut:

Tabel 21. Hasil Silhouette Coefficient pada $k = 3$

Cluster	Anggota Cluster	Silhouette Coefficient	Kategori Struktur
1	8	0,13	Buruk
2	7	0,18	Buruk
3	19	0,21	Buruk
Silhouette Coefficient Global		0,19	Buruk

Berdasarkan **Tabel 21**, diatas terlihat bahwa untuk $k = 3$ hasil *silhouette coefficient* yang diperoleh nilainya lebih buruk daripada nilai *Silhouette Coefficient* pada $k = 2$. Sehingga untuk pengelompokan dengan $k = 3$ hasilnya tidak begitu baik untuk dijadikan hasil akhir dari pengelompokan. Selanjutnya pada $k = 4$ diperoleh hasil nilai *Silhouette Coefficient* sebagai berikut:

Tabel 22. Hasil *Silhouette Coefficient* pada $k = 4$

Cluster	Anggota Cluster	Silhouette Coefficient	Kategori Struktur
1	7	0,17	Buruk
2	5	0,15	Buruk
3	17	0,22	Buruk
4	4	0,23	Buruk
Silhouette Coefficient Global		0,2	Buruk

Berdasarkan hasil tersebut dapat terlihat bahwa nilai *Silhouette Coefficient* untuk $k = 4$ juga menghasilkan struktur yang buruk. Pada masing-masing *cluster* juga memiliki struktur yang buruk. Hal ini menandakan bahwa semakin banyaknya jumlah k yang diambil maka hasil struktur *cluster* yang diperoleh juga semakin buruk. Sehingga diambil $k = 2$ untuk hasil pengelompokan yang akan diinterpretasikan.

7. Interpretasi Hasil *Cluster*

Setelah diperoleh hasil pengelompokan maka diperlukan sebuah interpretasi dan memberikan karakteristik di setiap *cluster* yang terbentuk untuk menggambarkan isi dari masing-masing *cluster* yang diperoleh. Adapun untuk meggambarkan isi dari masing-masing *cluster* tersebut dilakukan perhitungan rata-rata disetiap variabel pada *cluster* yang terbentuk. Perhitungan nilai rata-rata dapat dilihat pada **Lampiran 13**. Nilai rata-rata untuk masing-masing variabel pada setiap *cluster* ditunjukkan oleh tabel berikut:

Tabel 23. Nilai Rata-rata Setiap Variabel pada *Cluster*

Variabel	Cluster 1	Cluster 2
V1	0,025	-0,071
V2	-0,180	0,499
V3	-0,178	0,493
V4	-0,043	0,120
V5	0,038	-0,105
V6	-0,147	0,407
V7	0,013	-0,037
V8	-0,249	0,691

Berdasarkan nilai rata-rata setiap variabel pada masing-masing *cluster* diperoleh karakteristik pada setiap *cluster* adalah sebagai berikut:

1.) Cluster 1

Karakteristik pada *cluster 1* memiliki 3 variabel yang nilainya diatas rata-rata (Mean). Ketiga variabel tersebut adalah *V1*, *V5*, dan *V7*. Nilai pada ketiga variabel tersebut adalah sebesar 0,025, 0,038, dan 0,013. Hal ini ditunjukkan oleh nilai positif pada perhitungan rata-ratanya. Dimana sebelumnya data yang digunakan merupakan nilai standarisasi *z-score*, apabila bernilai positif maka dikatakan bahwa nilai tersebut berada diatas rata-rata. Berdasarkan hasil tersebut diketahui bahwa variabel tersebut memiliki kategori yang cukup tinggi, karena nilainya positif walaupun tidak besar namun nilainya sudah diatas rata-rata. Kelima variabel lainnya bernilai negatif, yang artinya nilainya dibawah rata-rata. Variabel tersebut adalah *V2*, *V3*, *V4*, *V6*, dan *V8*. Nilai kelima variabel tersebut berturut-turut adalah -0,180, -0,178, -0,043, -0,147, dan -0,249. Berdasarkan hasil kelima variabel tersebut diketahui bahwa nilainya cukup rendah.

2.) Cluster 2

Karakteristik pada *cluster 2* memiliki banyak nilai variabel yang diatas rata-rata. Pada *cluster* ini diperoleh 5 variabel yang nilainya positif atau diatas rata-rata. Kelima variabel tersebut adalah *V2*, *V3*, *V4*, *V6*, dan *V8*. Dengan nilai berturut-turut adalah 0,499, 0,493, 0,120, 0,407, dan 0,691. Nilai-nilai ini termasuk karakteristik yang sangat tinggi dibandingkan dengan *cluster 1* kecuali pada *V4* yang termasuk karakteristik cukup tinggi. Ketiga variabel lainnya yaitu *V1*, *V5*, dan *V7* dengan nilai berturut-turut adalah -0,071, -0,105, dan -0,037. Ketiga variabel tersebut memiliki nilai negatif yang artinya ketiga variabel tersebut memiliki nilai dibawah rata-rata. Ketiga variabel tersebut memiliki karakteristik tingkat produksi yang cukup rendah.

Apabila diperhatikan kembali nilai-nilai variabel pada *cluster 1* dan *cluster 2* berbanding terbalik. Pada *cluster 1*, 3 variabel yang memiliki karakteristik tingkat produksi cukup tinggi merupakan 3 variabel yang memiliki karakteristik tingkat produksi yang cukup rendah pada *cluster 2*. Begitu pula 5 variabel yang memiliki karakteristik tingkat produksi yang cukup rendah pada *cluster 1*, sebaliknya pada *cluster 2* merupakan 5 variabel dengan karakteristik tingkat produksi yang sangat tinggi. Berdasarkan analisis karakteristik dan pertimbangan dari masing-masing *cluster* yang telah diperoleh maka dapat disimpulkan bahwa:

- 1.) *Cluster 1* merupakan *cluster* dengan tingkat produksi yang dikategorikan "rendah". Sehingga anggota-anggota atau provinsi yang termasuk dalam *cluster 1* merupakan provinsi-provinsi dengan tingkat produksi tanaman Hortikultura yang rendah.

2.) Cluster 2 merupakan *cluster* dengan tingkat produksi yang dikategorikan “tinggi”. Sehingga anggota-anggota atau provinsi yang termasuk dalam *cluster* 2 merupakan provinsi-provinsi dengan tingkat produksi tanaman Hortikultura yang tinggi.

f. Perbandingan hasil pengelompokan Secara Manual dan *Output R*

Berdasarkan hasil analisis *cluster* yang telah diperoleh secara manual dan *output software R* dapat terlihat pada tabel berikut:

Tabel 24. Perbandingan Hasil Perhitungan Manual dan *Output R*

N	Provinsi	Manual	Output R
1	Aceh	1	1
2	Sumatera Utara	2	2
3	Sumatera Barat	1	1
4	Riau	2	1
5	Jambi	2	2
6	Sumatera Selatan	2	2
7	Bengkulu	1	1
8	Lampung	2	1
9	Kep.Bangka Belitung	1	1
10	Kep.Riau	1	1
11	DKI Jakarta	1	1
12	Jawa Barat	2	1
13	Jawa Tengah	2	2
14	DI Yogyakarta	1	1
15	Jawa Timur	2	2
16	Banten	2	2
17	Bali	1	1
18	Nusa Tenggara Barat	1	2
19	Nusa Tenggara Timur	1	1
20	Kalimantan Barat	2	1
21	Kalimantan Tengah	1	1
22	Kalimantan selatan	2	1
23	Kalimantan Timur	1	1
24	Kalimantan Utara	1	1
25	Sulwesi Utara	1	2
26	Sulwesi Tengah	1	1
27	Sulawesi Selatan	2	2
28	Sulwesi Tenggara	1	1
29	Gorontalo	1	1
30	Sulawesi Barat	1	1
31	Maluku	1	1
32	Maluku Utara	1	1
33	Papua Barat	1	1
34	Papua	1	1

Berdasarkan tabel tersebut terlihat bahwa hasil pengelompokan secara manual dan menggunakan *software R* tidak terlalu memiliki perbedaan yang signifikan. Perbedaan hasil yang diperoleh dikarenakan pada pengambilan *medoid* pada proses pengelompokan diambil secara *random/random*. Sehingga memungkinkan terjadinya perbedaan antara hasil yang diperoleh melalui perhitungan manual dengan hasil pengelompokan melalui *output R*. Pada Pengelompokan secara manual *Cluster 1* memiliki 22 anggota sedangkan *Cluster 1* pada output software R memiliki 25 anggota. Anggota yang memiliki perbedaan *cluster* setelah dilakukan perhitungan manual dan software R adalah provinsi Riau, Lampung, Jawa Barat, Kalimantan Barat, Kalimantan Selatan, Nusa Tenggara Barat, dan Sulawesi Utara. Perbedaan anggota *cluster* berdasarkan **Tabel 24**. Dapat dilihat dalam **Tabel 25** berikut:

Tabel 25. Perbandingan Anggota Cluster secara Manual dan *output R*

Cluster	Perhitungan Manual		Output R	
	Jumlah Anggota	Provinsi	Jumlah Anggota	Provinsi
1	22	Aceh, Sumatera Barat, Bengkulu, Kep.Bangka Belitung, Kep.Riau, DKI Jakarta, DI Yogyakarta, Bali, Nusa Tenggara Barat, Nusa Tenggara Timur, Kalimantan Tengah, Kalimantan Timur, Kalimantan Utara, Sulawesi Utara, Sulawesi Tengah, Sulawesi Tenggara, Gorontalo, Sulawesi Barat, Maluku, Maluku Barat, Papua Barat, dan Papua	25	Aceh, Sumatera Barat, Riau, Bengkulu, Lampung, Kep.Bangka Belitung, Kep.Riau, DKI Jakarta, Jawa Barat, DI Yogyakarta, Bali, Nusa Tenggara Timur, Kalimantan Barat, Sulawesi Tengah, Sulawesi Selatan, Kalimantan Timur, Kalimantan Utara, Sulawesi Tengah, Sulawesi Tenggara, Gorontalo, Sulawesi Barat, Maluku, Maluku Barat, Papua Barat, dan Papua
2	12	Sumatera Utara, Riau, Jambi, Sumatera Selatan, Lampung, Jawa Barat, Jawa Tengah, Jawa Timur, Banten, Kalimantan Barat, Kalimantan Selatan, dan Sulawesi Selatan	9	Sumatera Utara, Jambi, Sumatera Selatan, Jawa Tengah, Jawa Timur, Banten, Nusa Tenggara Barat, Sulawesi Utara dan Sulawesi Selatan

g. Peta penyebaran Cluster

Berdasarkan perhitungan manual peta penyebaran hasil pengelompokan dengan algoritma *K-Medoid* dapat terlihat pada gambar berikut:

Berdasarkan hasil *output software R* peta penyebaran hasil pengelompokan dengan algoritma *K-Medoid* dapat terlihat pada gambar berikut:



Gambar 10. Peta Penyebaran *Cluster* Manual

Berdasarkan peta penyebaran tersebut dapat terlihat bahwa provinsi yang termasuk kedalam *cluster* 1 ditunjukkan oleh warna kuning yang menunjukkan tingkat produksi rendah dan provinsi yang termasuk dalam *cluster* 2 ditunjukkan oleh warna hijau yang menunjukkan tingkat produksi yang tinggi. Provinsi yang termasuk dalam *cluster* 1 sebanyak 22 provinsi dan provinsi yang termasuk dalam *cluster* 2 sebanyak 12 provinsi.



Gambar 11. Peta Penyebaran *Cluster* Output *R*

Berdasarkan peta penyebaran tersebut dapat terlihat bahwa provinsi yang termasuk kedalam *cluster* 1 ditunjukkan oleh warna kuning yang menunjukkan bahwa tingkat produksi rendah dan provinsi yang termasuk dalam *cluster* 2 ditunjukkan oleh warna hijau yang menunjukkan tingkat produksi tinggi. Provinsi yang termasuk dalam *cluster* 1 sebanyak 25 provinsi dan provinsi yang termasuk dalam *cluster* 2 sebanyak 9 provinsi.

4.2 Pembahasan

Berdasarkan penelitian yang telah dilakukan diperoleh hasil bahwa pengelompokan tingkat produksi tanaman hortikultura di Indonesia terbagi menjadi 2 *cluster*. Di setiap *cluster* memiliki karakteristik yang berbeda, ada yang lebih tinggi dan adapula yang lebih rendah. Setiap *cluster* memiliki jumlah anggota yang berbeda. Anggota-anggota dari kedua *cluster* ini dapat terlihat dalam **Tabel 17**. Karakteristik dari masing-masing *cluster* memiliki kelemahan dan keunggulannya masing-masing sebagai berikut:

a. Keunggulan dan kelemahan *cluster* 1

Pada *cluster* 1 terdapat 25 anggota *cluster* atau sebanyak 25 provinsi di Indonesia. *Cluster* 1 merupakan kelompok provinsi di Indonesia dengan tingkat produksi hortikultura yang rendah. Hal ini dikarenakan pada *cluster* ini sebanyak 5 variabel yang terlibat memiliki nilai dibawah rata-rata, sedangkan 3 variabel lainnya memiliki nilai diatas rata-rata namun tidak terlalu tinggi (Lihat **Tabel 23**).

Provinsi-provinsi yang terdapat pada *cluster* 1 memiliki 5 variabel di bawah rata-rata yaitu yang pertama variabel V_2 seperti paprika, kentang, cabai rawit dan blewah. Yang kedua adalah variabel V_3 seperti jambu biji, jambu air dan laos. Ketiga adalah variabel V_4 seperti jengkol dan nenas. Keempat adalah variabel V_6 yaitu produksi tanaman kembang kol dan yang kelima adalah variabel V_8 yaitu produksi Jeruk Besar dan produksi Duku, dimana keseluruhan tanaman yang terdapat pada masing-masing variabel dapat terlihat pada **Tabel 11**. Kelima variabel ini nilainya berada di bawah rata-rata. Hal ini berarti bahwa provinsi-provinsi yang termasuk dalam *cluster* ini memiliki tingkat produksi tanaman-tanaman hortikultura dalam kelima variabel tersebut yang rendah serta memerlukan adanya perbaikan dan solusi untuk mengatasi rendahnya tingkat produksi tersebut.

Selain kelima variabel tersebut provinsi-provinsi pada *cluster* 1 memiliki 3 variabel yang memiliki nilai yang bernilai cukup baik yaitu pada variabel V_1 seperti Kubis, Sawi, dan Wortel. Kedua adalah variabel V_5 seperti anggur dan heliconia. Kemudian yang terakhir adalah variabel V_7 yaitu produksi Markisa (lihat **Tabel 11**). Walaupun nilai dari ketiga variabel ini tidak terlalu tinggi namun nilai tersebut menunjukkan bahwa provinsi-provinsi tersebut memiliki tingkat produksi tanaman-tanaman hortikultura pada ketiga variabel tersebut yang cukup baik.

Keunggulan dari *cluster* 1 ini adalah pada ketiga variabel yang bernilai diatas rata-rata. Dimana nilai ketiga variabel ini lebih tinggi daripada di *cluster* 2. Hal ini berarti pada produksi-produksi tanaman yang tercakup dalam ketiga variabel ini, provinsi-provinsi yang berada dalam *cluster* 1 dapat menjadi

distributor yang baik untuk tanaman-tanaman hortikultura tersebut. Kelemahan dari *cluster* 1 adalah tingkat produksi yang rendah pada kelima variabel. Rendahnya tingkat produksi ini masih dibawah rata-rata. Rendahnya tingkat produksi tanaman-tanaman tersebut bisa disebabkan oleh banyak faktor salah satunya luas lahan yang sedikit, khususnya pada provinsi-provinsi dengan jumlah penduduk yang padat seperti DKI Jakarta, kemudian dari segi kondisi tanah dan pengelolaan yang kurang baik juga dapat memicu turunnya tingkat produksi. Provinsi yang termasuk dalam *cluster* ini memungkinkan kurangnya jumlah produksi untuk pemenuhan permintaan pasar pada provinsi itu sendiri sehingga memerlukan pemasukan produksi dari provinsi lainnya, terutama provinsi yang berada pada *cluster* 2. Variabel yang sangat kecil pengaruhnya pada *cluster* 1 adalah pada variabel V_8 yaitu produksi jeruk besar dan produksi duku. Kemudian variabel yang memberikan pengaruh yang sangat besar pada *cluster* ini adalah variabel V_5 yaitu tanaman anggur dan tanaman *heliconia*.

b. Keunggulan dan kelemahan *Cluster* 2

Cluster 2 memiliki 9 anggota yang terlihat pada **Tabel 17** atau sebanyak 9 provinsi di Indonesia. *Cluster* 2 merupakan *cluster* provinsi di Indonesia dengan tingkat produksi hortikultura yang tinggi. Hal ini dikarenakan pada *cluster* ini sebanyak 5 variabel yang terlibat memiliki nilai diatas rata-rata, sedangkan 3 variabel lainnya memiliki nilai di bawah rata-rata (Lihat **Tabel 23**). Pada *cluster* 2 ini nilainya berbanding terbalik dengan hasil pada *cluster* 1.

Provinsi-provinsi yang terdapat pada *cluster* 2 memiliki 5 variabel diatas rata-rata yaitu yang pertama pada variabel V_2 seperti paprika, kentang, cabai rawit dan blewah. Yang kedua adalah variabel V_3 seperti jambu biji, jambu air dan laos. Ketiga adalah variabel V_4 seperti jengkol dan nenas. Keempat adalah variabel V_6 yaitu produksi Kembang Kol dan yang kelima adalah variabel V_8 yaitu produksi Jeruk besar dan produksi Duku, dimana keseluruhan tanaman yang terdapat pada masing-masing variabel dapat terlihat pada **Tabel 11**. Kelima variabel ini nilainya berada di atas rata-rata. Hal ini menunjukkan bahwa provinsi-provinsi yang termasuk dalam *cluster* ini memiliki tingkat produksi tanaman-tanaman hortikultura dalam komoditas kelima variabel tersebut yang tinggi sehingga dapat memenuhi kebutuhan permintaan pasar dengan cukup baik.

Provinsi-provinsi pada *cluster* 2 memiliki 3 variabel yang memiliki nilai yang bernilai rendah yaitu pada variabel V_1 seperti Kubis, Sawi, dan Wortel. Kedua adalah variabel V_5 seperti anggur dan heliconia. Kemudian yang terakhir adalah variabel V_7 yaitu produksi Markisa (lihat **Tabel 11**). Walaupun nilai dari ketiga variabel tidak begitu jauh dibawah rata-rata namun nilai tersebut menunjukkan bahwa provinsi-provinsi tersebut memiliki tingkat produksi tanaman-tanaman

hortikultura pada ketiga variabel tersebut yang rendah. Ketiga variabel di *cluster* 2 ini justru memiliki nilai produksi di atas rata-rata pada *cluster* 1.

Keunggulan dari *cluster* 2 ini adalah pada kelima variabel yang bernilai di atas rata-rata. Dimana nilai kelima variabel ini lebih tinggi daripada di *cluster* 1. Hal ini berarti pada produksi-produksi tanaman yang tercakup dalam kelima variabel ini, provinsi-provinsi yang berada dalam *cluster* 2 dapat menjadi distributor yang baik untuk tanaman-tanaman hortikultura tersebut. Sehingga dapat menjadi solusi pada *cluster* 1 dimana di lima variabel ini provinsi-provinsi tersebut memiliki tingkat produksi yang rendah. Kelemahan dari *cluster* 1 adalah tingkat produksi yang rendah pada ketiga variabel yang telah disebutkan. Tingkat produksi ketiga variabel ini masih di bawah rata-rata. Rendahnya tingkat produksi tanaman-tanaman tersebut bisa disebabkan oleh banyak faktor salah satunya luas lahan yang sedikit dan pengelolaan yang kurang baik juga dapat memicu turunnya tingkat produksi. Nilai produksi pada *cluster* 2 ini tidak begitu jauh di bawah rata-rata karena nilai negatifnya tidak begitu besar. Provinsi yang termasuk dalam *cluster* ini memungkinkan kurangnya jumlah produksi untuk pemenuhan permintaan pasar pada provinsi itu sendiri sehingga memerlukan pemasukan produksi dari provinsi lainnya. Variabel yang sangat besar pengaruhnya pada *cluster* 2 adalah pada variabel V_8 yaitu produksi jeruk besar dan produksi duku. Kemudian variabel yang memberikan pengaruh yang sangat kecil pada *cluster* ini adalah variabel V_5 yaitu tanaman anggur dan tanaman *heliconia*. Keduanya berbanding terbalik dengan *cluster* 1 terlihat pada **Tabel 23**.

Berdasarkan pembahasan keunggulan dan kelemahan pada setiap *cluster*. Terlihat bahwa untuk kategori struktur masing-masing *cluster* berbeda-beda. Pada *cluster* 1 memiliki nilai *Silhouette* yang lebih besar daripada nilai *Silhouette* pada *cluster* 2. Walaupun *cluster* 1 merupakan *cluster* dengan kategori tingkat produksi yang rendah, namun apabila dilihat dari kategori strukturnya lebih baik dibandingkan dengan *cluster* 2. Namun hal tersebut tidak berarti bahwa pada *cluster* 2 memiliki nilai-nilai yang tidak bagus. Pada *cluster* 2 nilai produksi pada anggota-anggotanya cukup tinggi. Terdapat beberapa provinsi yang dilihat secara sekilas memiliki produksi yang tinggi seperti Lampung dan Jawa Barat. Namun justru kedua provinsi ini masuk kedalam *cluster* 1. Hal ini disebabkan oleh nilai produksi tanaman hortikultura di beberapa komoditasnya rendah dibandingkan provinsi-provinsi di *cluster* 2. Perhitungan jarak juga mempengaruhi masuknya provinsi tersebut dalam *cluster* 1. Karena analisis *cluster* sendiri menggunakan perhitungan jarak dimana hal tersebut digunakan untuk mendapatkan jarak terdekat antara satu sama lain dan menempatkannya dalam satu *cluster* yang sama.

Berdasarkan keunggulan dan kelemahan masing-masing cluster solusi yang menjadi bahan pertimbangan adalah pada *cluster* 1 khususnya pada komoditas-komoditas yang tingkat produksinya dibawah rata-rata (lihat **Tabel 23**). Pada pulau Sumatera Provinsi Aceh, Sumatera Barat, Riau, Bengkulu, Lampung, Kep.Bangka Belitung, Kep. Riau dan yang lainnya (lihat pada **Tabel 17.**) dapat memperoleh distribusi dari Provinsi di *cluster* 2 yaitu Jambi, Sumatera Utara dan Sumatera Selatan. Khususnya pada produksi tanaman jeruk besar dan tanaman duku. Sebaliknya pula pada Provinsi Jambi, Sumatera Utara dan Sumatera Selatan yang termasuk dalam *cluster* 2 ini membutuhkan distribusi produksi tanaman hortikultura dalam ketiga variabel yang tingkat produksinya di bawah rata-rata oleh provinsi-provinsi yang berada di *cluster* 1. Pada pulau Jawa provinsi-provinsi pada *cluster* 1 seperti provinsi DKI Jakarta dapat memperoleh distribusi pada produksi yang nilainya di bawah rata-rata dari Provinsi yang berada di *cluster* 2 yaitu provinsi Jawa Tengah, Jawa Timur, dan Banten, begitu pula sebaliknya pda provinsi di *cluster* 2. Pada pulau Kalimantan seluruh provinsi masuk kedalam *cluster* 1 sehingga provinsi yang memungkinkan untuk mendistribusikan produksi hasil nya adalah provinsi Sulawesi Selatan yang memiliki produksi cukup tinggi. Provinsi Nusa Tenggara Barat dapat mendistribusikan hasil produksinya ke provinsi Nusa Tenggara Timur. Pada pulau Sulawesi sendiri provinsi Sulawesi Utara dan Sulawesi Selatan dapat mendistribusikan hasil produksinya kepada provinsi dengan tingkat produksi rendah di pulau tersebut dan juga dapat ke provinsi Gorontalo, Maluku, Maluku Utara, Papua Barat dan Papua.

Nilai Silhouette secara global bernilai 0,24 termasuk dalam kategori struktur yang buruk. Hal ini dikarenakan *cluster* 1 memilik struktur yang lemah dan *cluster* 2 memiliki struktur yang buruk. Sehingga secara global struktur *cluster* buruk. Apabila dilakukan untuk jumlah *k* yang lebih besar nilai *Silhouette* semakin menurun dan tidak menunjukkan adanya nilai yang baik.



V. PENUTUP

5.1 Kesimpulan

Berdasarkan hasil yang telah diperoleh sebelumnya maka dari hasil penelitian ini dapat disimpulkan bahwa:

1. *Cluster* provinsi di Indonesia berdasarkan produksi hortikultura terbentuk sebanyak 2 *cluster* sebagai berikut:
 - a.) *Cluster* 1 memiliki 25 anggota yang beranggotakan Provinsi Aceh, Sumatera Barat, Riau, Bengkulu, Lampung, Kep.Bangka Belitung, Kep. Riau, DKI Jakarta, Jawa Barat, DI Yogyakarta, Bali, Nusa Tenggara Timur, Kalimantan Barat, Kalimantan Tengah, Kalimantan Selatan, Kalimanta Timur, Kalimantan Utara, Sulawesi Tengah, Sulawesi Tenggara, Gorontalo, Sulawesi Barat, Maluku, Maluku Utara, Papua Barat dan Papua. *Cluster* 1 memiliki karakteristik 5 variabel yang termasuk kategori produksi cukup rendah dan 3 variabel yang termasuk kategori produksi cukup tinggi. Sehingga *cluster* 1 merupakan *cluster* dengan tingkat produksi tanaman hortikultura yang rendah.
 - b.) *Cluster* 2 memiliki 9 anggota yang beranggotakan Provinsi Sumatera Utara, Jambi, Sumatera Selatan, Jawa Tengah, Jawa Timur, Banten, Nusa Tenggara Barat, Sulawesi Utara, Sulawesi Selatan. *Cluster* 2 memiliki karakteristik 5 variabel yang termasuk kategori produksi yang tinggi dan 3 variabel yang termasuk kategori produksi yang rendah. Sehingga *cluster* 2 merupakan *cluster* dengan tingkat produksi tanaman hortikultura yang tinggi.
2. Berdasarkan nilai *Sillhouette Coefficient* yang diperoleh hasil *cluster* secara keseluruhan memiliki kategori struktur yang buruk karena bernilai 0,24. Hal ini diarenakan pada *cluster* 1 struktur *cluster* yang terbentuk lemah dan pada *cluster* 2 struktur *cluster* yang terbentuk buruk.
2. Variabel yang sangat mempengaruhi secara positif pada *cluster* 1 adalah variabel V_5 yang terdiri dari komoditas tanaman anggur dan tanaman *heliconia*. Sedangkan variabel yang mempengaruhi secara negatif adalah variabel V_8 yang terdiri dari produksi komoditas tanaman jeruk besar dan tanaman duku. Sebaliknya, variabel yang sangat berpengaruh secara positif pada *cluster* 2 ini adalah variabel V_8 yang terdiri dari produksi komoditas tanaman jeruk besar dan tanaman duku. Variabel yang berpengaruh secara negatif adalah variabel variabel V_5 yang terdiri dari produksi komoditas tanaman anggur dan tanaman *heliconia*.

5.2 Saran

Pada skripsi ini penulis hanya menggunakan metode Non-Hierarki yaitu metode *K-Medoid* dan penerapannya pada bidang produksi tanaman hortikultura. Variabel yang digunakan hanya sebanyak 70 variabel yang tercakup dalam 8 variabel hasil analisis faktor karena data mengalami *multikolinearitas*. Penulis menyarankan agar pada peneliti yang tertarik meneliti menggunakan analisis *cluster* dapat menggunakan metode-metode analisis *cluster* lainnya baik secara hierarki seperti algoritma *Single Linkage*, *Complete Linkage*, dan *Average Linkage* maupun non-hierarki seperti algoritma *Fuzzy K-Means*, supaya dapat diperoleh hasil yang lebih baik lagi. Variabel yang digunakan untuk selanjutnya dapat dipertimbangkan kembali supaya hasil analisis *cluster* lebih optimal. Selain dalam bidang produksi tanaman hortikultura metode analisis *cluster* juga dapat diterapkan dalam berbagai bidang lainnya.

Berdasarkan hasil penelitian penulis menyarankan agar setiap daerah dapat memaksimalkan komoditas unggulan yang ada sehingga produksinya semakin lebih tinggi. Kemudian penulis berharap pemerintah dapat mengorganisir kembali provinsi-provinsi dengan tingkat produksi yang lebih tinggi untuk mendistribusikan sebagian produksi hasilnya kepada provinsi-provinsi dengan tingkat produksi yang rendah. Seperti pada pulau Sumatera provinsi Aceh, Sumatera Barat, Bengkulu, Lampung, Kep.Bangka Belitung, dan Kep. Riau mendapatkan distribusi dari provinsi Sumatera Utara, Jambi, dan Sumatera Selatan saja, tanpa memerlukan distribusi dari luar pulau Sumatera. Begitu pula dengan provinsi-provinsi lainnya.



DAFTAR PUSTAKA

- Arora, P., Deepali, and S. Varshney. 2016. *Analysis of K-Means and K-Medoids Algorithm for Big Data*. Procedia Computer Science No 78.
- Arsyad, L. 2010. *Ekonomi Pembangunan*. UPP STIM YKPN, Yogyakarta.
- Badan Pusat Statistik. 2019. *Data Pertanian dan Pertambangan*. <https://www.bps.go.id/subject/55/hortikultura.html#subjekViewTab3>. Diakses pada 20 November 2020.
- Direktorat jenderal Hortikultura. 2015. *Rencana Strategis Direktorat Jenderal Hortikultura Tahun 2015-2019*. Kementerian Pertanian. Jakarta.
- Everitt, B and T. Hothorn. 2011. *An Introduction to Applied Multivariate Analysis with R*. Springer, New York.
- Hair, J. F., W. C Black, B. J Babin and R. E Anderson. 2010. *Multivariate Data Analysis Seventh Edition*. Prentice Hall, New Jersey.
- Hair, J.F., R. E Anderson, R. L Tatham and W. C Black. 1998. *Multivariate Data Analysis Fifth Edition*. Prentice-Hall, New Jersey.
- Han, J., M. Kamber and J. Pei. 2012. *Data Mining: Concept and Techniques Third Editioin*. Morgan Kauffman Publisher, Waltham.
- Hanani, Z., Suyatno dan S. Fatimah. 2016. *FAKTOR-FAKTOR YANG MEMPENGARUHI KONSUMSI SAYUR DAN BUAH PADA IBU HAMIL DI INDONESIA (BERDASARKAN DATA RISKESDAS 2013) THE AFFECTING FAKTORS OF VEGETABLES AND FRUIT CONSUMPTION ON INDONESIAN PREGNANT WOMEN (Based on Indonesia Basic Health Research 2013)*. Jurnal Kesehatan Masyarakat Vol 4, No 1.
- Hasan, M. I. 2002. *Pokok-Pokok Materi Statistika 2 (Statistik Inferensif)*. Bumi Aksara, Jakarta.
- Husson, F., S. Le and J. Pages. 2011. *Exploratory Multivariate Analysis by Example Using R*. CRC Press, New York.
- Johnson, R. A. and D. W. Wichern. 2007. *Applied Multivariate Statistical Analysis Sixth Edition*. Prentice Hall International, New Jersey.
- Kaufman, L. and P. J. Rousseeuw. 1990. *Finding Group in Data An Introduction to Cluster Analysis*. Wiley Interscience, New Jersey.
- Kusuma dan Agani. 2015. *Prototipe Komparasi Model Clustering Menggunakan Metode K-Means dan FCM untuk Menentukan Strategi Promosi: Studi Kasus Sekolah Tinggi Teknik -PLN Jakarta*. Jurnal TICOM Vol 3, No 3.
- Manly, B. F. and J. A. N. Alberto. 2017. *Multivariate Statistical Methods A Primer Fourth edition*. CRC Press, New York.
- Marlina, D., N. F Putri, A. Fernando dan A. Ramadhan. 2018. *Implementasi Algoritma K-Medoids dan K-Means untuk Pengelompokkan Wilayah Sebaran Cacat pada Anak*. Jurnal CoreIT: Jurnal Hasil Penelitian Ilmu Komputer dan Teknologi Informasi Vol 4, No 2.
- Mattjik, A.A dan I.M Sumertajaya. 2011. *Sidik Peubah Ganda dengan Menggunakan SAS Edisi Pertama*. IPB Press, Bogor.
- Nugraheny, D. 2015. *METODE NILAI JARAK GUNA KESAMAAN ATAU KEMIRIPAN CIRI SUATU CITRA (KASUS DETEKSI AWAN CUMULONIMBUS MENGGUNAKAN PRINCIPAL COMPONENT ANALYSIS)*. Jurnal ANGKASA Vol 7, No 2.

- Nugroho, S. 2008. *Statistika Multivariat terapan Edisi pertama*. UNIB Press, Universitas Bengkulu.
- Rencher, A. C. 2002. *Methods of Multivariate Analysis Second Edition*. Wiley Interscience, New York.
- Sangga, V. A. P. 2018. *PERBANDINGAN ALGORITMA K MEANS DAN ALGORITMA K MEDOID DALAM PENGELOMPOKKAN KOMODITAS PETERNAKAN DI PROVINSI JAWA TENGAH TAHUN 2015*. Skripsi. Universitas Islam Indonesia Yogyakarta.
- Setyawati, A. W. 2017. *Implementasi Algoritma Partitioning Around Medoid (PAM) untuk Pengelompokan Sekolah Menengah Atas di DIY Berdasarkan Nilai Daya Serap Ujian Nasional*. Skripsi. Universitas Sanata Dharma Yogyakarta.
- Siyoto, S dan M. A. Sodik. 2015. *Dasar Metodologi Penelitian*. Literasi Media Publishing, Yogyakarta.
- Sunaryono, H. 1981. *Pengantar Pengetahuan Dasar Hortikultura*. Sinar Baru, Bandung.
- Wijaya, T dan S. Budiman. 2016. *ANALISIS MULTIVARIAT UNTUK PENELITIAN MANAJEMEN*. Pohon Cahaya, Yogyakarta.
- Zulkarnain. 2009. *Dasar-Dasar Hortikultura*. PT. Bumi Aksara, Jakarta.

LAMPIRAN

Lampiran 1. Data Produksi Hortikultura Tahun 2019

n		X1	X2	X3	X4	X5	X6	X7	X8	X9
1	Aceh	1141	32139	2755	2155952	875778	484980	4526650	12	0
2	Sumatera Utara	18436	50285	20200	2815186	750202	106589	1126773	102	0
3	Sumatera Barat	3022	255836	8184	4508462	2984947	801357	2504711	65	0
4	Riau	28672	157584	224703	1091840	1147484	598622	850780	0	0
5	Jambi	12346	26953	12556	813915	535314	120070	421173	0	0
6	Sumatera Selatan	27930	108304	9920	1348625	1532785	604691	2003190	5	1
7	Bengkulu	2062	14668	38454	1402513 6	2283478	488374	4108019	27	0
8	Lampung	254350	292244	286913	1363150	860202	535683 5	763742	0	1
9	Kep.Bangka Belitung	88	1970	139	236517	422316	296437	352863	0	0
10	Kep.Riau	120	211	200	19212	116371	13125	30766	0	0
11	DKI Jakarta	365	3467	1413	8893	8808	2522	7880	0	2
12	Jawa Barat	15868	326978	259362	3407752 7	1756889 4	685664 8	2119605 7	4758	1
13	Jawa Tengah	130635 3	6613863	133309 5	2707114 9	1868196 8	885436 9	2345713 6	303	14
14	Di Yogyakarta	825724	1464761	614267	4549794	1197304	186866 3	3102219	1	4
15	Jawa Timur	404539 5	1945728 7	356294 5	4909174 1	1356048 5	380206 2	9193993 5	573	539
16	Banten	5724	3975	9281	847959	1708473	538215	1004713	0	0
17	Bali	0	26800	0	886146	489320	479222	1233542 4	594	13088
18	Nusa Tenggara Barat	143	29629	39926	698065	684613	30076	836045	659	13
19	Nusa Tenggara Timur	11261	61591	2914	1159878	2933639	488075	3708139	0	18

20	Kalimantan Barat	34688	26192	10364	1987529	576011	277892	742218	0	0
21	Kalimantan Tengah	54029	31567	16458	464583	270826	122947	161577	0	0
22	Kalimantan selatan	0	172122	110	2666594	468871	2361547	2117711	0	0
23	Kalimantan Timur	17664	22529	1976	1161737	142861	62457	211041	0	0
24	Kalimantan Utara	4468	26546	1393	607937	580243	43727	196075	0	0
25	Sulwesi Utara	55	26369	1022	623681	219398	6391	899755	0	0
26	Sulwesi Tengah	2064	44314	6755	299138	272802	96173	273941	2	38
27	Sulawesi Selatan	243321	88067	134585	13473810	3133000	110394	9552180	400	0
28	Sulwesi Tenggara	52467	65063	5477	1301275	378398	79790	638107	0	5
29	Gorontalo	0	0	0	46064	140	0	15081	0	0
30	Sulawesi Barat	0	181812	1001	1788081	499000	62675	326243	0	0
31	Maluku	14	271	0	89721	160521	33955	167723	0	0
32	Maluku Utara	0	20275	0	3083435	319293	238089	1306879	0	0
33	Papua Barat	0	449	187	11031	11671	4587	14531	0	0
34	Papua	1786	2998	2501	6357	9494	4657	9927	0	0

X10	X11	X12	X13	X14	X14	X16	X17	X18	X19	X20	X21	X22
29	0	9472	318	1117	573	71	3785	314	1143	8475	892	21533
0	0	41170	2604	571	1635	932	14040	235506	138286	11394	13110	31980
3	0	21402	785	1948	3779	38753	5600	1136	265	10493	28833	13540
0	28	17841	1616	1680	795	11	4589	2159	132583	21703	7265	17908
0	274	5762	1001	1780	822	39	2598	1771	137622	14391	3690	5436
0	252	20799	200	1682	796	27	4916	1341	179845	12985	1734	23760
1	11	1074	256	493	422	12	1671	1694	236	4860	3625	7195
0	2	18362	494	6214	1745	56	19475	5153	699243	41628	15249	25547

0	0	2453	301	593	104	0	520	731	2567	2623	2376	3111
0	0	4362	3	424	255	0	1020	517	2242	3666	132	3269
0	0	0	0	562	57	2	323	314	0	653	9	4721
0	875	11944	243	21853	10824	127	24878	15285	228601	79697	74975	418522
3	4982	73038	27148	28159	9581	123	12926	482949	173605	148432	16068	485041
0	0	8909	24016	6388	1929	110	3989	41200	496	12172	2939	58130
480834	25866	148803	49131	15466	19194	1161	13697	102283	250292	158124	21483	1148121
0	0	1360	368	6231	3137	27	1694	400	506	4852	10269	38571
0	0	19719	552	408	303	129	3113	25640	1104	18286	10857	65693
493	1501	29646	3340	391	4011	12	14415	20	74452	68855	11558	141794
9	28	4230	832	2785	2665	165	807	1047	7809	21050	4	51845
0	123	4523	163	1592	1067	60	3755	1122	76400	12595	8134	10082
0	11	9516	522	854	547	1	1482	559	6579	20206	636	4348
0	0	19612	341	1232	1221	0	1942	496	12358	21968	1577	10408
0	60	11570	589	1546	787	0	1772	12867	20965	16340	483	5331
0	3	1056	310	767	218	0	149	1669	525	8204	104	3470
0	0	71	37	371	702	23	1	3651	600	2935	1564	14188
0	0	3532	2282	670	332	6	297	401	40635	5030	1850	14650
0	5	19232	698	11944	1234	2996	1023	6397	2898	25136	4379	129432
0	1	1987	247	1747	1201	28	191	1179	2566	6183	412	19396
0	0	10	19	4	17	0	0	0	348	1315	3	2204
0	0	270	5	575	164	92	208	150	368	5421	1497	13718
0	0	1747	191	1186	161	0	2	1106	458	4248	576	8394
0	0	1321	37	486	206	0	3	4038	353	2185	161	2843
0	32	405	196	647	129	5	64	2600	437	3033	17	3427
0	24	8135	3260	116	116	7	21	73	71	721	15	1331

X23	X24	X25	X26	X27	X28	X29	X30	X31	X32	X33	X34	X35
8529	6774	2165	13791	59081	22648	11576	1134	4114	23953	1360	1209	453
1300	296934	16555	30421	114050	17849	18525	4910	16716	90105	8456	4239	8767
230	107668	2586	39213	116379	11940	54204	783	1043	62564	3497	10799	9895
1243	40398	4026	13604	43436	28910	965	1468	7055	23010	6586	3620	1886
600	37252	1449	11071	61069	8185	4892	1151	18054	20780	1402	4177	1603
351	30376	3317	17817	143110	14296	38266	1131	42791	42048	3713	6557	3788
155	14070	497	4518	22215	5421	6470	387	356	11395	752	4432	1907
2019	23107	5073	105598	1209545	21946	18502	3776	6183	16218	7580	15363	18003
54	979	905	1311	3641	2704	491	142	1402	7247	306	152	734
255	517	374	1838	3049	2990	114	157	111	2584	327	547	648
21	143	1451	488	2432	2892	998	1658	55	68	1652	0	11
5535	38516	17934	97727	1220174	145581	104084	8756	9715	94183	50887	16110	68060
17951	34699	26908	117409	621536	108004	60145	15607	14565	172939	62417	11127	92999
416	2588	2588	8376	47554	9547	2385	825	1763	6265	2754	209	3710
29642	985455	20400	284485	2116974	131209	101310	52900	14734	289334	48561	1124	75990
119	600	2806	13745	257342	17218	2047	1563	1856	46436	4068	6357	10741
1019	348756	779	6888	231794	21445	2452	549	688	21915	2136	0	7
1451	4685	2297	12906	102116	10916	4189	499	841	17179	9331	0	2
3710	26018	1001	67879	227461	3754	11682	756	16	1574	3876	0	317
1281	139312	2150	18045	46979	25142	504	1410	6647	27209	2438	7405	4922
622	7203	846	2835	26679	16150	194	701	3942	12149	1712	2099	1092
561	141232	804	4757	62813	23210	42	1236	9113	27422	1966	537	1736
385	14050	1033	24969	103888	16392	1719	1001	7427	13994	1398	381	644
372	6206	357	12078	27095	13562	105	207	3914	10017	273	14	437
371	694	316	7901	46353	7455	4017	757	7447	11635	477	0	0
483	3924	772	4314	24488	6695	2945	299	7428	25288	421	92	119
36674	9713	1033	36910	142492	38101	5159	383	35715	45729	7618	164	966

1940	27267	1319	9231	43971	12985	760	893	12283	10265	1525	128	552
94	14819	6	1087	7701	593	21	13	1312	6026	12	0	1
283	27915	219	4987	66574	9916	637	115	19182	11580	490	5	6
402	15967	443	6094	33319	1165	806	345	9254	13369	244	10	75
396	5088	158	1533	8627	1898	931	254	2035	2383	264	1	9
324	1291	320	2403	31676	3627	339	142	1516	2813	692	57	8
184	30302	60	763	5045	240	137	162	65	128	216	11	15

X36	X37	X38	X39	X40	X41	X42	X43	X44	X45	X46	X47	X48
26738	0	10630	8840	288	994	26529	10457	450	3324	1005	0	672
37119	0	2615	18072	975	13259	118778	219537	53278	78728	95821	981	1410
98066	0	7448	122399	1866	43342	50730	131052	15917	35994	41078	619	76
49952	0	1404	507	0	3	0	0	0	1339	0	0	0
16514	0	3342	9686	395	3231	111812	33434	1362	7098	3892	17	1625
205732	0	1481	1390	157	2296	672	6847	124	4141	3669	0	74
14003	0	627	523	137	16884	4093	66021	10761	29270	35444	0	1047
175623	1	14108	3634	49	3227	297	7725	299	9095	6155	0	514
2119	0	300	170	0	172	0	0	0	1521	0	193	0
2052	0	258	95	0	396	0	0	0	3843	0	0	0
0	0	646	0	0	0	0	0	0	2786	0	0	0
17404562	9064	27418	173463	6698	140800	245418	275419	26108	179925	155312	15188	46785
4798053	0	50865	481890	36179	132141	294015	274478	43680	98325	160278	3611	4668
296508	0	16350	16999	0	141	0	0	261	3094	0	0	0
8605789	9726	40823	407877	6935	133669	320209	225819	22653	74395	91012	149	505
163258	0	54529	1545	0	414	13	21	1	7403	300	0	0
442384	38	185	19687	1563	825	208	17576	846	28320	1898	334	6
28291	340	1476	188255	30453	1076	1503	10344	1701	2788	3141	12	1103

0	157	59	8254	868	851	530	4251	883	12988	3420	45	408
17457	0	1038	53	0	848	0	77	25	4451	0	510	6
7027	0	503	396	0	768	0	5	21	1324	0	0	0
708794	0	171	1143	1	1713	0	80	150	1357	0	0	0
19951	0	953	173	0	210	0	0	131	6648	0	0	0
0	0	237	139	0	922	0	20	0	4726	0	0	0
0	0	208	3139	1896	59682	87543	61318	2016	16968	31724	0	839
355	0	45	6508	55	3877	1294	13064	744	7736	5542	2123	333
41713	0	96	101762	282	27327	50629	50453	1644	11834	34820	449	1292
736	0	151	390	0	333	5	71	28	1001	2	0	51
0	0	0	629	0	4	0	0	0	20	0	0	0
0	0	0	507	0	80	289	0	0	479	0	0	5
12	2	143	736	0	143	1	473	44	2705	7	2	3
0	0	16	624	0	162	0	55	6	606	0	0	22
355	22	41	184	0	74	18	312	51	1586	24	0	1
25	8	253	578	19	732	71	4151	632	6909	90	15	75

X49	X50	X51	X52	X53	X54	X55	X56	X57	X58	X59	X60	X61
10819	63595	61887	20821	9207	1243	15740	5266	7790	3914	73	13	0
29313	154008	49246	118583	60244	28674	22430	21243	13652	16610	67761	9928	204955
20822	139994	31782	146829	81306	51504	34103	27844	7810	4434	19598	81069	5600
9210	17513	8120	117	10225	52	16462	157	9942	8554	1220	87	80
7959	42698	9880	12348	10003	4480	5589	1609	5014	3834	786	160	0
9755	40479	11014	12487	16538	6955	10877	5804	6729	3627	2886	393	82
4919	37812	11118	18485	53267	24033	9988	8133	3009	670	2163	569	30
12465	40101	12796	18669	18312	6140	10330	5153	12211	7489	35812	21932	6578
1817	2468	2002	473	2872	367	3688	271	2024	1225	126	0	0

4550	4351	2339	285	2575	692	5559	0	5214	4198	2675	367	0
0	0	0	0	0	0	0	0	4381	2963	368533	41511	0
80943	263949	128494	284948	89738	79816	128065	120516	56229	28987	5697821	2942626	1237376
24311	164906	148750	81710	43331	31514	30743	69553	27467	10982	504108	140523	55281
2325	32933	10040	1372	2615	651	1041	179	2953	1258	62417	11710	10628
45015	104677	536098	74558	67957	23703	41371	21673	25706	14601	6134048	525924	341983
11948	7104	5019	830	5042	100	13712	91	10701	8018	4487962	300	0
1386	10189	28656	15171	2651	7733	6584	62946	6683	956	149285	607364	0
7136	17679	164773	29215	10194	869	5771	1870	5274	625	8941	2557	413
3747	2920	8816	9950	12076	3798	5262	17418	13424	3724	424	861	0
5706	1613	5731	2088	6250	1118	7444	14	5088	2731	853212	24585	0
4380	1283	5864	2410	4981	1450	4713	212	2027	1308	1173	840	160
3897	11392	13768	7399	6141	1850	4680	0	1327	1418	1371	0	0
8649	4614	8029	7430	11789	5780	12823	101	13028	5065	85259	16571	8027
3057	2120	3821	2688	3476	1288	5406	141	5173	2638	3460	0	0
2613	5537	14760	42392	4891	2060	4490	12741	3721	1031	11905	22360	315
2408	5342	22632	16516	5031	592	2272	2900	1369	876	56237	875	22
13093	21055	26115	58513	11008	6337	8477	15215	14937	7148	30575	3327	210
4661	1408	3669	5608	5534	401	1839	708	3576	2194	15328	6426	999
95	262	20580	3543	410	4	289	3	162	38	0	0	0
1658	2198	2663	1662	2250	20	1457	37	1099	656	0	0	0
2647	1470	3440	3324	4086	1543	3142	2136	4725	1604	3	4	0
3054	4548	4650	7548	5214	557	4264	464	2153	526	0	0	0
2665	1168	3277	2511	1678	1201	2598	1320	4588	3051	0	0	0
5677	3033	4388	9850	4501	2786	4766	2245	6370	3353	3495	590	0

X62	X63	X64	X65	X66	X67	X68	X69	X70
0	0	12	0	15	0	0	6	3
326532	372737	4085	7775742	558347	575480	194	2386	10215
165	2427	1622	78557	44066	1882	652	4852	31146
0	85	25	169	1310	283	261	865	58302
0	321	0	0	520	0	0	360	165
143	353	487	188	2423	1369	15	11451	834
925	0	507	0	2686	65	12	481	599
20914	7240	6696	19275	34711	36569	5789	9537	4435
0	0	43	0	0	0	0	0	35
0	0	3956	46	3676	18	3297	4009	15285
0	4877	24145	0	34509	0	1365	34840	60767
30182938	1278595	221310	179629271	25658550	6443065	7831380	38680	54579
2184591	22707	76446	132427249	20126227	25948135	113812	21782288	214247
8923	13560	13799	1196514	20170	2628	64	17299	26784
256824	182252	114685	138061336	166324899	90128385	32175	3062098	135110
0	0	6087	0	2073	314200	17943	3560	18855
1440	0	910596	186476	6385	2929	800	0	200
265	100	59172	4271	12724	10957	0	1680	18877
0	0	850	2227	2123	186	30	25	228
50	0	8405	8323	28636	33672	25	46919	3857
0	0	96	15	1127	27	415	308	12248
0	0	0	0	297484	0	0	756160	0
0	2900	1668	21	614869	2409	18	62848	19866
0	0	351	0	31926	0	0	857	3156
18778	108100	92492	5485678	92448	7684	6800	168	4225
215	0	8237	10469	9491	1190	0	1351	5610
14	663	4295	471556	9799	1059	1900	1657	3221

460	259	3614	554	4081	7656	401	2029	8653
0	0	0	0	0	0	0	0	385
0	0	0	0	0	0	0	0	0
0	13	0	8	20	0	0	0	69
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0
0	30	1056	2007	1843	1014	0	346	1498

Lampiran 2. Matriks Varians Kovariansi

$$S = \begin{bmatrix} 5,3 \times 10^{11} & 1,0 \times 10^{13} & 2,0 \times 10^{12} & 4,5 \times 10^{13} & 2,2 \times 10^{13} & 8,4 \times 10^{12} & 5,2 \times 10^{13} & 2,5 \times 10^9 & 5,0 \times 10^8 & 1,7 \times 10^{11} & 1,2 \times 10^{10} & \dots & 1,7 \times 10^{11} \\ 1,0 \times 10^{13} & 1,2 \times 10^{13} & 2,2 \times 10^{12} & 3,0 \times 10^{13} & 1,0 \times 10^{13} & 3,3 \times 10^{12} & 5,4 \times 10^{13} & 2,5 \times 10^8 & 3,1 \times 10^7 & 2,7 \times 10^{11} & 1,5 \times 10^{10} & \dots & 1,1 \times 10^{11} \\ 2,0 \times 10^{12} & 2,2 \times 10^{12} & 4,2 \times 10^{11} & 5,8 \times 10^{12} & 2,0 \times 10^{12} & 7,0 \times 10^{11} & 1,0 \times 10^{13} & 7,0 \times 10^7 & -2,2 \times 10^7 & 4,9 \times 10^{10} & 2,8 \times 10^9 & \dots & 2,0 \times 10^{10} \\ 4,5 \times 10^{13} & 3,0 \times 10^{13} & 5,8 \times 10^{12} & 1,2 \times 10^{14} & 4,5 \times 10^{13} & 1,6 \times 10^{13} & 1,6 \times 10^{14} & 5,1 \times 10^9 & -9,7 \times 10^8 & 6,4 \times 10^{11} & 3,8 \times 10^{10} & \dots & 3,4 \times 10^{11} \\ 2,2 \times 10^{13} & 1,0 \times 10^{13} & 2,0 \times 10^{12} & 4,5 \times 10^{13} & 2,2 \times 10^{13} & 8,4 \times 10^{12} & 5,2 \times 10^{13} & 2,5 \times 10^9 & -5,0 \times 10^8 & 1,7 \times 10^{11} & 1,2 \times 10^{10} & \dots & 1,7 \times 10^{11} \\ 8,4 \times 10^{12} & 3,3 \times 10^{12} & 7,0 \times 10^{11} & 1,6 \times 10^{13} & 8,4 \times 10^{12} & 4,3 \times 10^{12} & 1,6 \times 10^{13} & 9,1 \times 10^8 & -1,7 \times 10^8 & 4,0 \times 10^{10} & 3,4 \times 10^9 & \dots & 6,7 \times 10^{10} \\ 5,2 \times 10^{13} & 5,4 \times 10^{13} & 1,0 \times 10^{13} & 1,6 \times 10^{14} & 5,2 \times 10^{13} & 1,6 \times 10^{13} & 2,6 \times 10^{14} & 4,0 \times 10^9 & 4,1 \times 10^9 & 1,3 \times 10^{12} & 7,0 \times 10^{10} & \dots & 4,5 \times 10^{11} \\ 2,5 \times 10^9 & 2,5 \times 10^8 & 7,0 \times 10^7 & 5,1 \times 10^9 & 2,5 \times 10^9 & 9,1 \times 10^8 & 4,0 \times 10^9 & 6,8 \times 10^5 & 1,5 \times 10^5 & 5,1 \times 10^6 & 4,2 \times 10^5 & \dots & 7,9 \times 10^6 \\ 5,0 \times 10^8 & 3,1 \times 10^7 & -2,2 \times 10^7 & -9,7 \times 10^8 & -5,0 \times 10^8 & -1,7 \times 10^8 & 4,1 \times 10^9 & 1,5 \times 10^5 & 5,0 \times 10^6 & 2,0 \times 10^6 & 8,4 \times 10^3 & \dots & -6,3 \times 10^6 \\ 1,7 \times 10^{11} & 2,7 \times 10^{11} & 4,9 \times 10^{10} & 6,4 \times 10^{11} & 1,7 \times 10^{11} & 4,0 \times 10^{10} & 1,3 \times 10^{12} & 5,1 \times 10^6 & 2,0 \times 10^6 & 6,8 \times 10^9 & 3,6 \times 10^8 & \dots & 1,7 \times 10^9 \\ 1,2 \times 10^{10} & 1,5 \times 10^{10} & 2,8 \times 10^9 & 3,8 \times 10^{10} & 1,2 \times 10^{10} & 3,4 \times 10^9 & 7,0 \times 10^{10} & 4,2 \times 10^5 & 8,4 \times 10^3 & 3,6 \times 10^8 & 2,0 \times 10^7 & \dots & 1,2 \times 10^8 \\ \vdots & \ddots & \vdots \\ 1,7 \times 10^{11} & 1,1 \times 10^{11} & 2,0 \times 10^{10} & 3,4 \times 10^{11} & 1,7 \times 10^{11} & 6,7 \times 10^{10} & 4,5 \times 10^{11} & 7,9 \times 10^6 & -6,3 \times 10^6 & 1,7 \times 10^9 & 1,2 \times 10^8 & \dots & 1,9 \times 10^9 \end{bmatrix}$$

Lampiran 3. Data hasil standarisasi Z-score

n	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10
1	-0,28026	-0,24143	-0,29647	-0,27422	-0,28721	-0,26490	-0,06700	-0,25340	-0,17995	-0,17134
2	-0,25648	-0,23622	-0,26948	-0,21342	-0,31409	-0,44611	-0,27630	-0,14408	-0,17995	-0,17170
3	-0,27767	-0,17710	-0,28807	-0,05722	0,16438	-0,11339	-0,19147	-0,18902	-0,17995	-0,17166
4	-0,24241	-0,20536	0,04691	-0,37238	-0,22903	-0,21047	-0,29329	-0,26798	-0,17995	-0,17170
5	-0,26485	-0,24293	-0,28131	-0,39802	-0,36010	-0,43965	-0,31973	-0,26798	-0,17995	-0,17170
6	-0,24343	-0,21953	-0,28539	-0,34869	-0,14654	-0,20757	-0,22234	-0,26190	-0,17950	-0,17170
7	-0,27899	-0,24646	-0,24124	0,82062	0,01419	-0,26327	-0,09277	-0,23518	-0,17995	-0,17168
8	0,06787	-0,16663	0,14315	-0,34735	-0,29054	2,06820	-0,29864	-0,26798	-0,17950	-0,17170
9	-0,28170	-0,25011	-0,30052	-0,45128	-0,38430	-0,35519	-0,32394	-0,26798	-0,17995	-0,17170
10	-0,28166	-0,25062	-0,30043	-0,47132	-0,44980	-0,49087	-0,34377	-0,26798	-0,17995	-0,17170
11	-0,28132	-0,24968	-0,29855	-0,47227	-0,47283	-0,49594	-0,34518	-0,26798	-0,17905	-0,17170
12	-0,26001	-0,15664	0,10053	2,67029	3,28690	2,78645	0,95918	5,51142	-0,17950	-0,17170
13	1,51420	1,65133	1,76172	2,02401	3,52521	3,74315	1,09837	0,10007	-0,17370	-0,17166
14	0,85342	0,17056	0,64961	-0,05341	-0,21837	0,39774	-0,15469	-0,26676	-0,17816	-0,17170
15	5,27995	5,34482	5,21156	4,05524	2,42867	1,32363	5,31421	0,42803	0,06034	5,65945
16	-0,27395	-0,24953	-0,28638	-0,39488	-0,10892	-0,23940	-0,28381	-0,26798	-0,17995	-0,17170
17	-0,28182	-0,24297	-0,30073	-0,39135	-0,36995	-0,26765	0,41371	0,45354	5,65467	-0,17170
18	-0,28163	-0,24216	-0,23896	-0,40870	-0,32814	-0,48275	-0,29419	0,53249	-0,17415	-0,16572
19	-0,26634	-0,23296	-0,29623	-0,36610	0,15339	-0,26341	-0,11739	-0,26798	-0,17192	-0,17159
20	-0,23413	-0,24314	-0,28470	-0,28976	-0,35139	-0,36407	-0,29997	-0,26798	-0,17995	-0,17170
21	-0,20754	-0,24160	-0,27527	-0,43024	-0,41673	-0,43827	-0,33571	-0,26798	-0,17995	-0,17170
22	-0,28182	-0,20118	-0,30056	-0,22712	-0,37433	0,63378	-0,21529	-0,26798	-0,17995	-0,17170
23	-0,25754	-0,24420	-0,29768	-0,36593	-0,44413	-0,46724	-0,33267	-0,26798	-0,17995	-0,17170
24	-0,27568	-0,24304	-0,29858	-0,41702	-0,35048	-0,47621	-0,33359	-0,26798	-0,17995	-0,17170

25	-0,28175	-0,24309	-0,29915	-0,41556	-0,42774	-0,49409	-0,29027	-0,26798	-0,17995	-0,17170
26	-0,27899	-0,23793	-0,29028	-0,44550	-0,41631	-0,45109	-0,32880	-0,26555	-0,16301	-0,17170
27	0,05270	-0,22535	-0,09252	0,76976	0,19608	-0,44428	0,24238	0,21789	-0,17995	-0,17170
28	-0,20969	-0,23197	-0,29226	-0,35306	-0,39370	-0,45894	-0,30638	-0,26798	-0,17772	-0,17170
29	-0,28182	-0,25068	-0,30073	-0,46885	-0,47469	-0,49715	-0,34473	-0,26798	-0,17995	-0,17170
30	-0,28182	-0,19839	-0,29919	-0,30816	-0,36788	-0,46714	-0,32558	-0,26798	-0,17995	-0,17170
31	-0,28181	-0,25060	-0,30073	-0,46482	-0,44035	-0,48089	-0,33534	-0,26798	-0,17995	-0,17170
32	-0,28182	-0,24485	-0,30073	-0,18867	-0,40635	-0,38313	-0,26521	-0,26798	-0,17995	-0,17170
33	-0,28182	-0,25055	-0,30045	-0,47208	-0,47222	-0,49495	-0,34477	-0,26798	-0,17995	-0,17170
34	-0,27937	-0,24981	-0,29687	-0,47251	-0,47268	-0,49492	-0,34505	-0,26798	-0,17995	-0,17170

X11	X12	X13	X14	X15	X16	X17	X18	X19	X20	X21
-0,22363	-0,21335	-0,32584	-0,38623	-0,38843	-0,18861	-0,07641	-0,30440	-0,47306	-0,38619	-0,45860
-0,22363	0,92898	-0,09828	-0,47108	-0,11475	-0,05888	1,56053	2,27116	0,54929	-0,30825	0,42277
-0,22363	0,21658	-0,27935	-0,25710	0,43778	5,63970	0,21330	-0,29540	-0,47960	-0,33231	1,55698
-0,21738	0,08825	-0,19663	-0,29874	-0,33122	-0,19765	0,05192	-0,28420	0,50677	-0,03295	0,00113
-0,16250	-0,34705	-0,25785	-0,28320	-0,32426	-0,19343	-0,26589	-0,28844	0,54434	-0,22821	-0,25676
-0,16740	0,19485	-0,33758	-0,29843	-0,33097	-0,19524	0,10412	-0,29315	0,85909	-0,26576	-0,39786
-0,22118	-0,51600	-0,33201	-0,48320	-0,42735	-0,19750	-0,41386	-0,28929	-0,47982	-0,48273	-0,26145
-0,22318	0,10703	-0,30832	0,40584	-0,08640	-0,19087	2,42809	-0,25141	4,73100	0,49912	0,57707
-0,22363	-0,46630	-0,32753	-0,46766	-0,50930	-0,19931	-0,59759	-0,29983	-0,46244	-0,54247	-0,35154
-0,22363	-0,39750	-0,35719	-0,49392	-0,47038	-0,19931	-0,51777	-0,30218	-0,46487	-0,51461	-0,51342
-0,22363	-0,55470	-0,35749	-0,47248	-0,52141	-0,19901	-0,62903	-0,30440	-0,48158	-0,59507	-0,52229
-0,02840	-0,12426	-0,33330	2,83614	2,25333	-0,18017	3,29054	-0,14045	1,22255	1,51572	4,88553
0,88795	2,07743	2,34491	3,81609	1,93300	-0,18078	1,38271	4,98089	0,81258	3,35122	0,63615

-0,22363	-0,23364	2,03314	0,43288	-0,03898	-0,18273	-0,04385	0,14334	-0,47788	-0,28747	-0,31093
5,54755	4,80784	4,53318	1,84360	4,41034	-0,02438	1,50578	0,81225	1,38425	3,61003	1,02678
-0,22363	-0,50569	-0,32086	0,40848	0,27233	-0,19524	-0,41019	-0,30346	-0,47781	-0,48294	0,21783
-0,22363	0,15593	-0,30254	-0,49641	-0,45802	-0,17987	-0,18368	-0,02706	-0,47335	-0,12420	0,26025
0,11127	0,51368	-0,02502	-0,49905	0,49757	-0,19750	1,62039	-0,30762	0,07343	1,22619	0,31082
-0,21738	-0,40226	-0,27467	-0,12703	0,15069	-0,17445	-0,55177	-0,29637	-0,42337	-0,05039	-0,52265
-0,19619	-0,39170	-0,34127	-0,31242	-0,26113	-0,19027	-0,08120	-0,29555	0,08795	-0,27617	0,06382
-0,22118	-0,21176	-0,30553	-0,42710	-0,39513	-0,19916	-0,44403	-0,30172	-0,43254	-0,07293	-0,47706
-0,22363	0,15207	-0,32355	-0,36836	-0,22144	-0,19931	-0,37060	-0,30241	-0,38946	-0,02588	-0,40918
-0,21024	-0,13774	-0,29886	-0,31957	-0,33328	-0,19931	-0,39774	-0,16693	-0,32529	-0,17617	-0,48810
-0,22296	-0,51664	-0,32663	-0,44062	-0,47992	-0,19931	-0,65681	-0,28956	-0,47767	-0,39343	-0,51544
-0,22363	-0,55214	-0,35381	-0,50216	-0,35519	-0,19584	-0,68043	-0,26786	-0,47711	-0,53413	-0,41012
-0,22363	-0,42741	-0,13033	-0,45570	-0,45054	-0,19840	-0,63318	-0,30345	-0,17866	-0,47819	-0,38949
-0,22251	0,13838	-0,28801	1,29628	-0,21809	0,25211	-0,51729	-0,23779	-0,45998	0,05872	-0,20705
-0,22341	-0,48309	-0,33291	-0,28833	-0,22659	-0,19509	-0,65010	-0,29493	-0,46245	-0,44740	-0,49322
-0,22363	-0,55434	-0,35560	-0,55919	-0,53172	-0,19931	-0,68059	-0,30784	-0,47899	-0,57739	-0,52273
-0,22363	-0,54497	-0,35700	-0,47046	-0,49384	-0,18545	-0,64739	-0,30620	-0,47884	-0,46775	-0,41495
-0,22363	-0,49174	-0,33848	-0,37551	-0,49461	-0,19931	-0,68027	-0,29573	-0,47817	-0,49907	-0,48139
-0,22363	-0,50709	-0,35381	-0,48429	-0,48301	-0,19931	-0,68011	-0,26362	-0,47895	-0,55416	-0,51133
-0,21649	-0,54010	-0,33798	-0,45927	-0,50286	-0,19856	-0,67037	-0,27937	-0,47832	-0,53152	-0,52172
-0,21828	-0,26153	-0,03298	-0,54179	-0,50621	-0,19825	-0,67724	-0,30704	-0,48105	-0,59326	-0,52186

X22	X23	X24	X25	X26	X27	X28	X29	X30	X31	X32
-0,28185	0,60708	-0,36207	-0,22330	-0,27980	-0,34799	0,00459	-0,07425	-0,21379	-0,38946	-0,18420
-0,23364	-0,26543	1,25116	1,99110	0,02556	-0,22462	-0,13291	0,18362	0,19275	0,89950	0,98149
-0,31873	-0,39458	0,19888	-0,15851	0,18699	-0,21940	-0,30221	1,50761	-0,25158	-0,70357	0,49618
-0,29858	-0,27231	-0,17513	0,06308	-0,28323	-0,38310	0,18400	-0,46801	-0,17783	-0,08865	-0,20081
-0,35612	-0,34992	-0,19262	-0,33348	-0,32974	-0,34353	-0,40979	-0,32228	-0,21196	1,03636	-0,24011
-0,27157	-0,37997	-0,23085	-0,04603	-0,20588	-0,15940	-0,23471	0,91618	-0,21411	3,56652	0,13466
-0,34801	-0,40363	-0,32151	-0,47998	-0,45007	-0,43073	-0,48899	-0,26372	-0,29422	-0,77384	-0,40548
-0,26333	-0,17865	-0,27127	0,22420	1,40594	2,23398	-0,01552	0,18276	0,07066	-0,17784	-0,32050
-0,36685	-0,41582	-0,39429	-0,41719	-0,50896	-0,47241	-0,56683	-0,48560	-0,32059	-0,66685	-0,47858
-0,36612	-0,39156	-0,39686	-0,49891	-0,49928	-0,47374	-0,55864	-0,49959	-0,31898	-0,79890	-0,56075
-0,35942	-0,41980	-0,39894	-0,33317	-0,52407	-0,47513	-0,56144	-0,46678	-0,15737	-0,80463	-0,60508
1,54994	0,24572	-0,18559	2,20330	1,26142	2,25783	3,52677	3,35858	0,60683	0,18342	1,05335
1,85688	1,74429	-0,20682	3,58426	1,62281	0,91432	2,45015	1,72807	1,34444	0,67949	2,44114
-0,11298	-0,37213	-0,38535	-0,15821	-0,37923	-0,37386	-0,37077	-0,41531	-0,24706	-0,62993	-0,49588
4,91647	3,15535	5,07919	2,58278	4,69063	4,27050	3,11500	3,25565	5,35958	0,69678	4,49218
-0,20323	-0,40798	-0,39640	-0,12466	-0,28065	0,09696	-0,15099	-0,42786	-0,16760	-0,62042	0,21198
-0,07809	-0,29935	1,53928	-0,43658	-0,40655	0,03963	-0,02988	-0,41283	-0,27677	-0,73988	-0,22011
0,27306	-0,24721	-0,37369	-0,20299	-0,29605	-0,25141	-0,33155	-0,34837	-0,28216	-0,72423	-0,30356
-0,14198	0,02545	-0,25508	-0,40242	0,71335	0,02990	-0,53675	-0,07032	-0,25449	-0,80862	-0,57854
-0,33469	-0,26773	0,37481	-0,22561	-0,20169	-0,37515	0,07605	-0,48511	-0,18408	-0,13038	-0,12682
-0,36114	-0,34727	-0,35969	-0,42627	-0,48097	-0,42071	-0,18159	-0,49662	-0,26041	-0,40705	-0,39220
-0,33318	-0,35463	0,38549	-0,43274	-0,44568	-0,33961	0,02069	-0,50226	-0,20281	0,12185	-0,12307
-0,35661	-0,37587	-0,32162	-0,39750	-0,07455	-0,24743	-0,17465	-0,44003	-0,22811	-0,05060	-0,35969
-0,36520	-0,37744	-0,36523	-0,50152	-0,31125	-0,41978	-0,25574	-0,49992	-0,31360	-0,40992	-0,42977
-0,31574	-0,37756	-0,39588	-0,50783	-0,38795	-0,37655	-0,43071	-0,35475	-0,25438	-0,04855	-0,40126

-0,31361	-0,36404	-0,37792	-0,43766	-0,45382	-0,42563	-0,45248	-0,39453	-0,30369	-0,05050	-0,16067
0,21602	4,00409	-0,34573	-0,39750	0,14471	-0,16079	0,44734	-0,31237	-0,29465	2,84277	0,19953
-0,29171	-0,18819	-0,24814	-0,35349	-0,36353	-0,38190	-0,27227	-0,47561	-0,23974	0,44608	-0,42540
-0,37104	-0,41099	-0,31735	-0,55554	-0,51307	-0,46330	-0,62731	-0,50304	-0,33448	-0,67606	-0,50009
-0,31791	-0,38818	-0,24453	-0,52276	-0,44146	-0,33117	-0,36020	-0,48018	-0,32350	1,15173	-0,40222
-0,34248	-0,37382	-0,31096	-0,48829	-0,42113	-0,40581	-0,61093	-0,47391	-0,29874	0,13627	-0,37070
-0,36809	-0,37454	-0,37145	-0,53215	-0,50488	-0,46122	-0,58992	-0,46927	-0,30854	-0,60211	-0,56429
-0,36539	-0,38323	-0,39256	-0,50722	-0,48891	-0,40949	-0,54039	-0,49124	-0,32059	-0,65519	-0,55671
-0,37507	-0,40013	-0,23126	-0,54723	-0,51902	-0,46926	-0,63743	-0,49873	-0,31844	-0,80360	-0,60402

X33	X34	X35	X36	X37	X38	X39	X40	X41	X42	X43
-0,37510	-0,36326	-0,38289	-0,28386	-0,25395	0,24893	-0,33469	-0,29075	-0,41417	-0,14277	-0,37969
0,09340	0,30716	-0,01562	-0,28076	-0,25395	-0,30258	-0,25260	-0,20481	-0,10398	0,94232	2,17260
-0,23401	1,75865	0,03421	-0,26252	-0,25395	0,02998	0,67513	-0,09335	0,65684	0,14190	1,09244
-0,03007	0,17020	-0,31959	-0,27692	-0,25395	-0,38591	-0,40880	-0,32677	-0,43923	-0,45482	-0,50734
-0,37232	0,29345	-0,33209	-0,28692	-0,25395	-0,25255	-0,32717	-0,27736	-0,35760	0,86038	-0,09920
-0,21975	0,82005	-0,23557	-0,23030	-0,25395	-0,38061	-0,40094	-0,30713	-0,38124	-0,44691	-0,42376
-0,41524	0,34987	-0,31866	-0,28768	-0,25395	-0,43937	-0,40865	-0,30964	-0,01230	-0,40667	0,29859
0,03556	2,76849	0,39238	-0,23931	-0,25351	0,48825	-0,38099	-0,32064	-0,35770	-0,45132	-0,41304
-0,44468	-0,59714	-0,37048	-0,29123	-0,25395	-0,46187	-0,41179	-0,32677	-0,43496	-0,45482	-0,50734
-0,44330	-0,50974	-0,37428	-0,29125	-0,25395	-0,46476	-0,41246	-0,32677	-0,42930	-0,45482	-0,50734
-0,35582	-0,63077	-0,40242	-0,29187	-0,25395	-0,43806	-0,41330	-0,32677	-0,43931	-0,45482	-0,50734
2,89478	2,93377	2,60364	4,91610	3,78892	1,40411	1,12921	0,51110	3,12161	2,43193	2,85477
3,65602	1,83122	3,70531	1,14386	-0,25395	3,01749	3,87190	4,19898	2,90262	3,00355	2,84328
-0,28306	-0,58452	-0,23902	-0,20314	-0,25395	0,64252	-0,26214	-0,32677	-0,43574	-0,45482	-0,50734

2,74122	-0,38207	2,95394	2,28324	4,08420	2,32650	3,21374	0,54075	2,94127	3,31166	2,24929
-0,19631	0,77580	0,07158	-0,24301	-0,25395	3,26960	-0,39956	-0,32677	-0,42884	-0,45466	-0,50708
-0,32386	-0,63077	-0,40260	-0,15949	-0,23700	-0,46979	-0,23824	-0,13125	-0,41845	-0,45237	-0,29279
0,15117	-0,63077	-0,40282	-0,28340	-0,10230	-0,38095	1,26075	3,48270	-0,41210	-0,43714	-0,38107
-0,20899	-0,63077	-0,38890	-0,29187	-0,18392	-0,47846	-0,33990	-0,21819	-0,41779	-0,44858	-0,45545
-0,30393	1,00768	-0,18548	-0,28664	-0,25395	-0,41109	-0,41283	-0,32677	-0,41786	-0,45482	-0,50640
-0,35186	-0,16634	-0,35467	-0,28976	-0,25395	-0,44790	-0,40978	-0,32677	-0,41989	-0,45482	-0,50728
-0,33509	-0,51195	-0,32622	-0,07977	-0,25395	-0,47075	-0,40314	-0,32665	-0,39599	-0,45482	-0,50636
-0,37259	-0,54647	-0,37446	-0,28590	-0,25395	-0,41694	-0,41177	-0,32677	-0,43400	-0,45482	-0,50734
-0,44686	-0,62767	-0,38360	-0,29187	-0,25395	-0,46621	-0,41207	-0,32677	-0,41599	-0,45482	-0,50710
-0,43340	-0,63077	-0,40290	-0,29187	-0,25395	-0,46820	-0,38539	-0,08960	1,07009	0,57491	0,24118
-0,43709	-0,61041	-0,39765	-0,29176	-0,25395	-0,47942	-0,35543	-0,31989	-0,34126	-0,43960	-0,34786
0,03807	-0,59448	-0,36023	-0,27938	-0,25395	-0,47591	0,49161	-0,29150	0,25181	0,14071	0,10855
-0,36420	-0,60245	-0,37852	-0,29164	-0,25395	-0,47213	-0,40984	-0,32677	-0,43089	-0,45476	-0,50647
-0,46410	-0,63077	-0,40286	-0,29187	-0,25395	-0,48252	-0,40771	-0,32677	-0,43921	-0,45482	-0,50734
-0,43254	-0,62966	-0,40264	-0,29187	-0,25395	-0,48252	-0,40880	-0,32677	-0,43729	-0,45142	-0,50734
-0,44878	-0,62856	-0,39959	-0,29186	-0,25306	-0,47268	-0,40676	-0,32677	-0,43569	-0,45480	-0,50157
-0,44746	-0,63055	-0,40251	-0,29187	-0,25395	-0,48141	-0,40775	-0,32677	-0,43521	-0,45482	-0,50667
-0,41920	-0,61816	-0,40255	-0,29176	-0,24414	-0,47969	-0,41167	-0,32677	-0,43744	-0,45460	-0,50353
-0,45063	-0,62833	-0,40224	-0,29186	-0,25038	-0,46511	-0,40816	-0,32440	-0,42080	-0,45398	-0,45667

X44	X45	X46	X47	X48	X49	X50	X51	X52	X53	X54
-0,38995	-0,42862	-0,44484	-0,26845	-0,14225	0,02862	0,46056	0,22195	-0,16145	-0,31649	-0,44267
3,76643	1,60740	1,79423	0,10081	-0,04995	1,21660	1,95431	0,09126	1,55630	1,77681	1,16348
0,82695	0,45352	0,50148	-0,03545	-0,21678	0,67117	1,72278	-0,08928	2,05261	2,64068	2,50024
-0,42536	-0,48222	-0,46857	-0,26845	-0,22629	-0,07474	-0,30078	-0,33390	-0,52524	-0,27473	-0,51241
-0,31820	-0,32671	-0,37666	-0,26205	-0,02306	-0,15510	0,11532	-0,31570	-0,31033	-0,28384	-0,25314
-0,41560	-0,40656	-0,38193	-0,26845	-0,21703	-0,03973	0,07865	-0,30398	-0,30789	-0,01580	-0,10822
0,42129	0,27196	0,36844	-0,26845	-0,09535	-0,35038	0,03459	-0,30291	-0,20250	1,49065	0,89174
-0,40183	-0,27279	-0,32322	-0,26845	-0,16201	0,13435	0,07241	-0,28556	-0,19927	0,05696	-0,15594
-0,42536	-0,47730	-0,46857	-0,19580	-0,22629	-0,54964	-0,54934	-0,39715	-0,51899	-0,57632	-0,49397
-0,42536	-0,41460	-0,46857	-0,26845	-0,22629	-0,37408	-0,51823	-0,39366	-0,52229	-0,58850	-0,47494
-0,42536	-0,44314	-0,46857	-0,26845	-0,22629	-0,66636	-0,59011	-0,41784	-0,52730	-0,69412	-0,51545
1,62876	4,33987	3,19911	5,44849	5,62475	4,53312	3,77069	0,91053	4,47947	2,98652	4,15798
3,01128	2,13655	3,31638	1,09078	0,35750	0,89529	2,13436	1,11994	0,90841	1,08312	1,32977
-0,40482	-0,43483	-0,46857	-0,26845	-0,22629	-0,51701	-0,04602	-0,31405	-0,50319	-0,58686	-0,47734
1,35693	1,49040	1,68067	-0,21236	-0,16313	2,22524	1,13930	5,12435	0,78275	2,09317	0,87242
-0,42528	-0,31848	-0,46149	-0,26845	-0,22629	0,10114	-0,47275	-0,36596	-0,51271	-0,48732	-0,50960
-0,35880	0,24631	-0,42375	-0,14273	-0,22554	-0,57733	-0,42178	-0,12160	-0,26073	-0,58538	-0,06267
-0,29153	-0,44309	-0,39440	-0,26393	-0,08835	-0,20797	-0,29803	1,28558	-0,01397	-0,27601	-0,46457
-0,35589	-0,16768	-0,38781	-0,25151	-0,17526	-0,42566	-0,54187	-0,32670	-0,35247	-0,19881	-0,29307
-0,42339	-0,39819	-0,46857	-0,07648	-0,22554	-0,29982	-0,56347	-0,35860	-0,49061	-0,43777	-0,44999
-0,42371	-0,48262	-0,46857	-0,26845	-0,22629	-0,38500	-0,56892	-0,35722	-0,48495	-0,48982	-0,43055
-0,41356	-0,48173	-0,46857	-0,26845	-0,22629	-0,41603	-0,40190	-0,27551	-0,39729	-0,44224	-0,40713
-0,41505	-0,33886	-0,46857	-0,26845	-0,22629	-0,11078	-0,51388	-0,33484	-0,39675	-0,21059	-0,17702
-0,42536	-0,39076	-0,46857	-0,26845	-0,22629	-0,46999	-0,55509	-0,37834	-0,48007	-0,55155	-0,44004
-0,26674	-0,06021	0,28059	-0,26845	-0,12136	-0,49851	-0,49864	-0,26525	0,21757	-0,49351	-0,39484

-0,36682	-0,30949	-0,33770	0,53067	-0,18464	-0,51168	-0,50186	-0,18387	-0,23710	-0,48777	-0,48079
-0,29601	-0,19883	0,35370	-0,09944	-0,06471	0,17469	-0,24226	-0,14787	0,50082	-0,24262	-0,14441
-0,42316	-0,49134	-0,46852	-0,26845	-0,21991	-0,36695	-0,56685	-0,37991	-0,42876	-0,46714	-0,49197
-0,42536	-0,51783	-0,46857	-0,26845	-0,22629	-0,66025	-0,58579	-0,20509	-0,46504	-0,67730	-0,51522
-0,42536	-0,50544	-0,46857	-0,26845	-0,22566	-0,55985	-0,55380	-0,39031	-0,49809	-0,60183	-0,51428
-0,42190	-0,44533	-0,46841	-0,26770	-0,22591	-0,49632	-0,56583	-0,38228	-0,46889	-0,52653	-0,42511
-0,42489	-0,50201	-0,46857	-0,26845	-0,22354	-0,47018	-0,51498	-0,36977	-0,39467	-0,48026	-0,48284
-0,42135	-0,47555	-0,46800	-0,26845	-0,22616	-0,49517	-0,57082	-0,38397	-0,48318	-0,62529	-0,44513
-0,37563	-0,33182	-0,46645	-0,26280	-0,21691	-0,30169	-0,54001	-0,37248	-0,35422	-0,50951	-0,35233

X55	X56	X57	X58	X59	X60	X61	X62	X63	X64	X65
0,12929	-0,26688	-0,08597	-0,13741	-0,34884	-0,25494	-0,25092	-0,18755	-0,25865	-0,28868	-0,31428
0,42580	0,36642	0,47224	2,04094	-0,30569	-0,23568	0,68274	-0,12446	1,38257	-0,26312	-0,13574
0,94317	0,62807	-0,08407	-0,04819	-0,33639	-0,09751	-0,22540	-0,18752	-0,24796	-0,27858	-0,31248
0,16129	-0,46939	0,11895	0,65871	-0,34811	-0,25479	-0,25055	-0,18755	-0,25827	-0,28860	-0,31428
-0,32061	-0,41184	-0,35031	-0,15114	-0,34839	-0,25465	-0,25092	-0,18755	-0,25724	-0,28875	-0,31428
-0,08624	-0,24556	-0,18700	-0,18666	-0,34705	-0,25420	-0,25054	-0,18753	-0,25709	-0,28570	-0,31428
-0,12564	-0,15324	-0,54124	-0,69401	-0,34751	-0,25386	-0,25078	-0,18738	-0,25865	-0,28557	-0,31428
-0,11048	-0,27136	0,33502	0,47598	-0,32606	-0,21237	-0,22095	-0,18351	-0,22677	-0,24674	-0,31384
-0,40487	-0,46487	-0,63504	-0,59879	-0,34881	-0,25496	-0,25092	-0,18755	-0,25865	-0,28848	-0,31428
-0,32194	-0,47562	-0,33127	-0,08869	-0,34718	-0,25425	-0,25092	-0,18755	-0,25865	-0,26393	-0,31428
-0,56832	-0,47562	-0,41059	-0,30059	-0,11396	-0,17434	-0,25092	-0,18755	-0,23717	-0,13726	-0,31428
5,10768	4,30143	4,52661	4,16457	3,28322	5,46007	5,38586	5,64437	5,37119	1,09981	3,81040
0,79425	2,28134	1,78776	1,07530	-0,02754	0,01795	0,00091	0,23455	-0,15867	0,19089	2,72654
-0,52218	-0,46852	-0,54657	-0,59313	-0,30910	-0,23222	-0,20250	-0,18583	-0,19894	-0,20217	-0,28681

1,26529	0,38346	1,62007	1,69624	3,56129	0,76646	1,30696	-0,13793	0,54383	0,43081	2,85591
0,03941	-0,47201	0,19123	0,56674	2,51199	-0,25438	-0,25092	-0,18755	-0,25865	-0,25056	-0,31428
-0,27651	2,01945	-0,19138	-0,64494	-0,25373	0,92463	-0,25092	-0,18728	-0,25865	5,42460	-0,31000
-0,31254	-0,40149	-0,32556	-0,70174	-0,34319	-0,25000	-0,24903	-0,18750	-0,25821	0,08251	-0,31419
-0,33510	0,21480	0,45052	-0,17001	-0,34862	-0,25329	-0,25092	-0,18755	-0,25865	-0,28342	-0,31423
-0,23840	-0,47506	-0,34327	-0,34039	0,19500	-0,20722	-0,25092	-0,18754	-0,25865	-0,23602	-0,31409
-0,35944	-0,46721	-0,63475	-0,58455	-0,34814	-0,25333	-0,25019	-0,18755	-0,25865	-0,28815	-0,31428
-0,36090	-0,47562	-0,70141	-0,56567	-0,34801	-0,25496	-0,25092	-0,18755	-0,25865	-0,28875	-0,31428
0,00001	-0,47161	0,41282	0,06007	-0,29454	-0,22278	-0,21435	-0,18755	-0,24588	-0,27829	-0,31428
-0,32872	-0,47003	-0,33517	-0,35635	-0,34668	-0,25496	-0,25092	-0,18755	-0,25865	-0,28655	-0,31428
-0,36932	0,02942	-0,47344	-0,63207	-0,34130	-0,21154	-0,24948	-0,18393	0,21733	0,29157	-0,18832
-0,46762	-0,36066	-0,69741	-0,65867	-0,31304	-0,25326	-0,25082	-0,18751	-0,25865	-0,23707	-0,31404
-0,19261	0,12748	0,59460	0,41747	-0,32940	-0,24850	-0,24996	-0,18755	-0,25573	-0,26181	-0,30346
-0,48682	-0,44755	-0,48725	-0,43253	-0,33912	-0,24248	-0,24636	-0,18747	-0,25751	-0,26608	-0,31427
-0,55551	-0,47550	-0,81234	-0,80245	-0,34889	-0,25496	-0,25092	-0,18755	-0,25865	-0,28875	-0,31428
-0,50375	-0,47415	-0,72312	-0,69642	-0,34889	-0,25496	-0,25092	-0,18755	-0,25865	-0,28875	-0,31428
-0,42907	-0,39095	-0,37783	-0,53376	-0,34889	-0,25496	-0,25092	-0,18755	-0,25859	-0,28875	-0,31428
-0,37934	-0,45722	-0,62275	-0,71872	-0,34889	-0,25496	-0,25092	-0,18755	-0,25865	-0,28875	-0,31428
-0,45318	-0,42329	-0,39088	-0,28549	-0,34889	-0,25496	-0,25092	-0,18755	-0,25865	-0,28875	-0,31428
-0,35709	-0,38663	-0,22119	-0,23367	-0,34666	-0,25382	-0,25092	-0,18755	-0,25852	-0,28213	-0,31424

X66	X67	X68	X69	X70
-0,21843	-0,22785	-0,17568	-0,20256	-0,48126
-0,19905	-0,19176	-0,17553	-0,20193	-0,24702
-0,21690	-0,22773	-0,17519	-0,20127	0,23310

-0,21838	-0,22783	-0,17548	-0,20234	0,85599
-0,21841	-0,22785	-0,17568	-0,20247	-0,47754
-0,21834	-0,22776	-0,17567	-0,19951	-0,46220
-0,21834	-0,22784	-0,17567	-0,20244	-0,46759
-0,21722	-0,22556	-0,17136	-0,20002	-0,37960
-0,21843	-0,22785	-0,17568	-0,20257	-0,48052
-0,21830	-0,22785	-0,17322	-0,20150	-0,13072
-0,21723	-0,22785	-0,17466	-0,19328	0,91254
0,67232	0,17624	5,65882	-0,19226	0,77060
0,48026	1,39954	-0,09089	5,60158	4,43303
-0,21773	-0,22768	-0,17563	-0,19796	0,13304
5,55562	5,42474	-0,15171	0,61337	2,61780
-0,21836	-0,20814	-0,16231	-0,20162	-0,04883
-0,21821	-0,22767	-0,17508	-0,20257	-0,47674
-0,21799	-0,22716	-0,17568	-0,20212	-0,04833
-0,21836	-0,22784	-0,17566	-0,20256	-0,47610
-0,21743	-0,22574	-0,17566	-0,19006	-0,39285
-0,21839	-0,22785	-0,17537	-0,20248	-0,20038
-0,20810	-0,22785	-0,17568	-0,00108	-0,48133
-0,19708	-0,22770	-0,17566	-0,18582	-0,02564
-0,21732	-0,22785	-0,17568	-0,20234	-0,40893
-0,21522	-0,22737	-0,17061	-0,20252	-0,38441
-0,21810	-0,22777	-0,17568	-0,20221	-0,35264
-0,21809	-0,22778	-0,17426	-0,20212	-0,40744
-0,21829	-0,22737	-0,17538	-0,20203	-0,28284
-0,21843	-0,22785	-0,17568	-0,20257	-0,47249

-0,21843	-0,22785	-0,17568	-0,20257	-0,48133
-0,21843	-0,22785	-0,17568	-0,20257	-0,47974
-0,21843	-0,22785	-0,17568	-0,20257	-0,48133
-0,21843	-0,22785	-0,17568	-0,20257	-0,48133
-0,21836	-0,22779	-0,17568	-0,20247	-0,44696

Lampiran 4. Matriks Korelasi **R**

$$R = \begin{bmatrix} 1,000 & 0,990 & 0,994 & 0,794 & 0,591 & 0,445 & 0,947 & 0,068 & -0,011 & 0,933 & 0,969 & \cdots & 0,677 \\ 0,990 & 1,000 & 0,991 & 0,808 & 0,618 & 0,456 & 0,962 & 0,087 & -0,004 & 0,944 & 0,986 & \cdots & 0,700 \\ 0,994 & 0,991 & 1,000 & 0,830 & 0,653 & 0,520 & 0,956 & 0,131 & -0,015 & 0,921 & 0,967 & \cdots & 0,727 \\ 0,794 & 0,808 & 0,830 & 1,000 & 0,896 & 0,695 & 0,886 & 0,568 & -0,040 & 0,716 & 0,787 & \cdots & 0,714 \\ 0,591 & 0,618 & 0,653 & 0,896 & 1,000 & 0,858 & 0,686 & 0,652 & -0,047 & 0,429 & 0,558 & \cdots & 0,817 \\ 0,445 & 0,456 & 0,520 & 0,695 & 0,858 & 1,000 & 0,480 & 0,531 & -0,037 & 0,234 & 0,367 & \cdots & 0,731 \\ 0,947 & 0,962 & 0,956 & 0,886 & 0,686 & 0,480 & 1,000 & 0,296 & 0,112 & 0,939 & 0,967 & \cdots & 0,638 \\ 0,068 & 0,087 & 0,131 & 0,568 & 0,652 & 0,531 & 0,296 & 1,000 & 0,083 & 0,076 & 0,115 & \cdots & 0,221 \\ -0,011 & -0,004 & -0,015 & -0,040 & -0,047 & -0,037 & 0,112 & 0,083 & 1,000 & 0,011 & 0,001 & \cdots & -0,065 \\ 0,933 & 0,944 & 0,921 & 0,716 & 0,429 & 0,234 & 0,939 & 0,076 & 0,011 & 1,000 & 0,980 & \cdots & 0,463 \\ 0,969 & 0,96 & 0,967 & 0,787 & 0,558 & 0,367 & 0,967 & 0,115 & 0,001 & 0,980 & 1,000 & \cdots & 0,609 \\ \vdots & \ddots & \vdots \\ 0,677 & 0,700 & 0,727 & 0,714 & 0,817 & 0,731 & 0,638 & 0,221 & -0,065 & 0,463 & 0,609 & \cdots & 1,000 \end{bmatrix}$$

Lampiran 5. *Rotated Component Matrix*

	Component							
	1	2	3	4	5	6	7	8
Zscore(x1)	-0,003	0,956	0,238	0,050	-0,022	0,017	-0,005	0,048
Zscore(x2)	0,021	0,963	0,252	0,022	-0,013	0,041	0,011	0,027
Zscore(x3)	0,060	0,944	0,282	0,077	-0,021	0,021	-0,009	0,032
Zscore(x4)	0,521	0,730	0,339	-0,004	-0,024	0,013	0,065	0,157
Zscore(x5)	0,614	0,459	0,615	0,050	-0,016	-0,011	0,068	0,104
Zscore(x6)	0,484	0,272	0,657	0,426	0,006	-0,064	-0,007	0,012
Zscore(x7)	0,224	0,949	0,159	0,001	0,107	0,010	0,023	0,088
Zscore(x8)	0,973	0,064	0,060	0,025	0,118	-0,083	-0,044	0,015
Zscore(x9)	-0,022	0,021	-0,040	-0,025	0,991	-0,003	-0,012	-0,043
Zscore(x10)	0,021	0,995	-0,071	0,006	-0,010	0,028	0,009	0,010
Zscore(x11)	0,045	0,988	0,120	0,015	-0,009	0,033	0,004	0,017
Zscore(x12)	0,041	0,870	0,331	0,142	0,078	0,223	0,087	0,130
Zscore(x13)	-0,024	0,843	0,409	0,002	-0,029	0,056	-0,021	-0,028
Zscore(x14)	0,522	0,370	0,682	0,137	-0,042	-0,108	0,001	0,235
Zscore(x15)	0,446	0,799	0,345	0,101	-0,034	0,006	0,108	-0,009
Zscore(x16)	0,025	-0,015	-0,024	-0,009	-0,022	0,028	0,981	-0,044
Zscore(x17)	0,595	0,270	0,273	0,586	0,035	0,214	0,042	-0,016
Zscore(x18)	0,024	0,191	0,841	0,060	0,030	0,473	-0,036	0,095
Zscore(x19)	0,195	0,236	0,109	0,914	-0,031	0,041	-0,072	0,105
Zscore(x20)	0,293	0,676	0,597	0,193	0,049	-0,011	-0,014	0,072
Zscore(x21)	0,891	0,173	0,144	0,233	0,085	0,030	0,263	-0,051
Zscore(x22)	0,320	0,887	0,312	0,027	0,033	0,003	-0,009	0,078
Zscore(x23)	0,097	0,584	0,296	-0,078	-0,001	-0,110	0,051	0,614
Zscore(x24)	0,040	0,890	-0,095	0,052	0,293	0,276	0,067	0,025
Zscore(x25)	0,444	0,480	0,602	0,207	-0,031	0,382	-0,015	0,082
Zscore(x26)	0,269	0,841	0,251	0,307	-0,020	0,021	0,081	0,099
Zscore(x27)	0,424	0,757	0,138	0,442	0,053	-0,059	-0,005	0,034
Zscore(x28)	0,656	0,569	0,420	0,116	0,044	-0,015	-0,021	0,156
Zscore(x29)	0,642	0,573	0,277	0,178	-0,022	0,076	0,290	0,103
Zscore(x30)	0,161	0,955	0,194	0,086	-0,016	0,098	-0,007	0,031
Zscore(x31)	0,054	0,109	0,038	0,120	-0,091	0,106	-0,048	0,903
Zscore(x32)	0,261	0,810	0,386	0,089	0,001	0,223	0,135	0,157
Zscore(x33)	0,542	0,516	0,640	0,121	-0,001	0,053	-0,014	0,087
Zscore(x34)	0,525	-0,068	0,309	0,662	-0,084	0,023	0,326	0,022
Zscore(x35)	0,492	0,553	0,632	0,175	-0,024	0,049	0,030	0,033
Zscore(x36)	0,883	0,401	0,207	0,046	0,011	-0,049	-0,051	0,001
Zscore(x37)	0,700	0,706	-0,051	0,027	-0,009	-0,041	-0,036	-0,015
Zscore(x38)	0,282	0,460	0,559	0,221	-0,096	-0,096	0,029	-0,123

Zscore(x39)	0,242	0,611	0,695	0,016	0,026	0,019	0,168	0,096
Zscore(x40)	0,090	0,152	0,812	0,037	0,053	0,013	0,010	-0,069
Zscore(x41)	0,601	0,535	0,500	-0,009	-0,013	0,054	0,154	0,106
Zscore(x42)	0,491	0,599	0,496	0,026	-0,026	0,239	0,057	0,155
Zscore(x43)	0,584	0,403	0,474	0,047	0,001	0,440	0,224	0,116
Zscore(x44)	0,376	0,247	0,492	0,075	-0,026	0,711	0,162	0,070
Zscore(x45)	0,821	0,264	0,366	0,070	0,087	0,304	0,093	0,038
Zscore(x46)	0,630	0,310	0,566	0,043	-0,020	0,360	0,124	0,148
Zscore(x47)	0,962	-0,044	0,213	0,030	0,008	-0,015	-0,031	0,011
Zscore(x48)	0,988	-0,043	0,092	0,041	-0,010	-0,054	-0,060	0,005
Zscore(x49)	0,851	0,382	0,154	0,173	-0,064	0,179	0,125	0,099
Zscore(x50)	0,725	0,201	0,366	0,177	-0,032	0,363	0,310	0,079
Zscore(x51)	0,211	0,917	0,195	0,032	0,030	0,066	0,029	0,001
Zscore(x52)	0,850	0,123	0,172	0,061	0,005	0,252	0,362	0,106
Zscore(x53)	0,609	0,353	0,171	0,148	-0,065	0,372	0,511	0,024
Zscore(x54)	0,793	0,142	0,229	0,087	0,027	0,243	0,458	0,019
Zscore(x55)	0,935	0,212	0,149	0,115	-0,017	0,057	0,160	0,012
Zscore(x56)	0,790	0,080	0,406	0,034	0,402	0,080	0,126	0,071
Zscore(x57)	0,833	0,293	0,321	0,175	0,008	0,035	0,001	0,140
Zscore(x58)	0,788	0,291	0,177	0,247	-0,089	0,285	-0,015	0,137
Zscore(x59)	0,620	0,629	0,011	0,071	-0,053	-0,118	-0,048	-0,111
Zscore(x60)	0,967	0,121	0,024	0,034	0,190	-0,074	-0,037	-0,032
Zscore(x61)	0,969	0,210	0,011	0,053	-0,015	0,079	-0,062	-0,006
Zscore(x62)	0,989	-0,039	0,069	0,036	-0,006	-0,069	-0,062	-0,018
Zscore(x63)	0,970	0,071	-0,015	0,051	-0,016	0,190	-0,075	0,000
Zscore(x64)	0,206	0,086	0,038	-0,023	0,967	-0,017	-0,032	-0,057
Zscore(x65)	0,701	0,521	0,470	0,036	-0,007	0,021	-0,044	0,029
Zscore(x66)	0,169	0,982	0,046	0,013	-0,011	0,026	-0,001	0,016
Zscore(x67)	0,083	0,970	0,204	0,015	-0,009	0,046	0,002	0,028
Zscore(x68)	0,990	-0,045	0,014	0,034	-0,007	-0,084	-0,061	-0,023
Zscore(x69)	-0,021	0,171	0,964	0,020	0,004	0,072	-0,007	0,072
Zscore(x70)	0,166	0,512	0,778	0,033	-0,048	0,050	0,050	-0,027

Extraction Method: Principal Component Analysis.

Rotation Method: Varimax with Kaiser Normalization.

a. Rotation converged in 7 iterations.

Lampiran 6. Data Hasil Analisis Faktor

n	V1	V2	V3	V4	V5	V6	V7	V8
1	-0,13	-0,14	-0,19	-0,23	-0,24	-0,14	-0,02	0,14
2	0,28	-0,31	-0,41	0,52	-0,17	5,34	-0,32	0,45
3	0,12	-0,23	-0,12	0,00	-0,13	0,12	5,52	-0,60
4	-0,22	-0,17	-0,12	0,58	-0,26	-0,05	-0,35	-0,07
5	-0,21	-0,25	-0,32	0,40	-0,23	0,17	-0,17	0,73
6	-0,26	-0,29	-0,54	1,10	-0,13	-0,05	0,04	2,41
7	-0,05	-0,24	-0,19	-0,44	-0,27	0,61	0,65	-0,57
8	-0,43	-0,21	-0,23	5,09	0,00	-0,71	-0,14	-0,12
9	-0,23	-0,21	-0,20	-0,45	-0,23	-0,15	-0,28	-0,52
10	-0,21	-0,21	-0,20	-0,40	-0,26	-0,07	-0,32	-0,58
11	-0,24	-0,20	-0,04	-0,54	-0,23	-0,17	-0,38	-0,73
12	5,60	-0,28	0,00	0,19	-0,04	-0,48	-0,34	-0,14
13	-0,13	0,18	5,54	0,11	0,03	0,39	-0,04	0,40
14	-0,36	0,06	0,30	-0,24	-0,32	-0,43	-0,37	-0,87
15	0,12	5,63	-0,40	0,03	-0,06	0,16	0,05	0,06
16	-0,03	-0,05	0,14	0,45	-0,62	-1,01	-0,13	-1,16
17	-0,13	-0,12	-0,22	-0,14	5,61	-0,02	-0,07	-0,25
18	-0,31	-0,07	0,59	0,19	0,18	-0,45	-0,12	-1,08
19	-0,14	-0,10	-0,12	-0,26	-0,11	-0,37	-0,09	-0,26
20	-0,21	-0,16	-0,30	0,52	-0,13	-0,25	-0,12	-0,13
21	-0,26	-0,19	-0,16	-0,25	-0,22	-0,21	-0,22	-0,32
22	-0,27	-0,12	-0,18	-0,10	-0,08	-0,16	-0,28	0,03
23	-0,16	-0,17	-0,25	-0,18	-0,25	-0,03	-0,27	-0,01
24	-0,21	-0,20	-0,22	-0,46	-0,24	-0,15	-0,31	-0,27
25	-0,08	-0,24	-0,10	-0,83	0,05	0,22	-0,14	0,04
26	-0,19	-0,21	-0,22	-0,42	-0,18	-0,08	-0,27	-0,08
27	-0,02	-0,12	-0,05	-0,89	0,00	-1,09	0,49	4,38
28	-0,23	-0,19	-0,25	-0,42	-0,21	-0,20	-0,30	0,35
29	-0,27	-0,19	-0,23	-0,54	-0,21	-0,15	-0,28	-0,55
30	-0,26	-0,22	-0,33	-0,41	-0,18	-0,20	-0,32	0,70
31	-0,23	-0,22	-0,27	-0,45	-0,20	-0,13	-0,28	0,07
32	-0,23	-0,20	-0,22	-0,53	-0,23	-0,17	-0,22	-0,43
33	-0,22	-0,21	-0,23	-0,47	-0,24	-0,11	-0,33	-0,45
34	-0,20	-0,18	-0,26	-0,51	-0,22	0,04	-0,27	-0,58

Lampiran 7. Hasil Perhitungan Jarak Objek terhadap *Medoid* Awal

a. Iterasi 1

Hasil perhitungan jarak setiap medoids				Cluster yang diikuti
N	C1	C2	Jarak Terdekat	
1	1,25	5,57	1,25	1
2	6,05	0,00	0,00	2
3	5,97	7,92	5,97	1
4	1,30	5,44	1,30	1
5	1,97	5,20	1,97	1
6	3,70	5,80	3,70	1
7	1,63	5,04	1,63	1
8	5,43	7,64	5,43	1
9	0,77	5,68	0,77	1
10	0,77	5,60	0,77	1
11	0,62	5,77	0,62	1
12	6,05	7,92	6,05	1
13	5,50	7,78	5,50	1
14	0,00	6,05	0,00	1
15	5,77	7,92	5,77	1
16	1,09	6,60	1,09	1
17	6,01	7,96	6,01	1
18	0,80	6,13	0,80	1
19	0,87	5,84	0,87	1
20	1,29	5,64	1,29	1
21	0,81	5,69	0,81	1
22	1,11	5,58	1,11	1
23	1,14	5,45	1,14	1
24	0,92	5,65	0,92	1
25	1,45	5,34	1,45	1
26	1,08	5,55	1,08	1
27	5,43	7,73	5,43	1
28	1,41	5,64	1,41	1
29	0,80	5,71	0,80	1
30	1,75	5,65	1,75	1
31	1,21	5,59	1,21	1
32	0,85	5,70	0,85	1
33	0,85	5,63	0,85	1
34	0,89	5,52	0,89	1
Total Cost			278,47	

Lampiran 8. Hasil Perhitungan Jarak Objek terhadap Non-Medoid

Hasil Perhitungan Jarak Setiap Non-Medoid				Cluster yang diikuti
n	D1	D2	Jarak Terdekat	
1	0,81	5,80	0,81	1
2	5,71	7,92	5,71	1
3	5,85	8,05	5,85	1
4	1,23	5,87	1,23	1
5	1,62	5,95	1,62	1
6	3,41	6,47	3,41	1
7	1,23	5,98	1,23	1
8	5,67	7,80	5,67	1
9	0,11	5,93	0,11	1
10	0,19	5,93	0,19	1
11	0,29	5,97	0,29	1
12	5,95	8,11	5,95	1
13	5,93	8,08	5,93	1
14	0,80	5,77	0,80	1
15	5,92	0,00	0,00	2
16	1,58	6,00	1,58	1
17	5,85	8,09	5,85	1
18	1,33	5,96	1,33	1
19	0,54	5,79	0,54	1
20	1,16	5,85	1,16	1
21	0,38	5,88	0,38	1
22	0,74	5,79	0,74	1
23	0,67	5,83	0,67	1
24	0,30	5,89	0,30	1
25	0,84	5,95	0,84	1
26	0,49	5,89	0,49	1
27	5,10	7,39	5,10	1
28	0,91	5,88	0,91	1
29	0,00	5,92	0,00	1
30	1,26	5,94	1,26	1
31	0,63	5,90	0,63	1
32	0,14	5,91	0,14	1
33	0,15	5,92	0,15	1
34	0,21	5,90	0,21	1
Total Cost		276,27		

$$S = \text{Total Cost baru} - \text{Total cost lama}$$

$$S = 276,27 - 278,47$$

$$S = -2,20 \quad (\text{Iterasi dilanjutkan})$$

Lampiran 9. Hasil Perhitungan Jarak Objek di Setiap Iterasi

b. Iterasi 2

- D_1 dan D_2 menjadi *Medoid* baru
- Dipilih objek Non-*Medoid* baru yaitu objek ke-11 sebagai pusat *Cluster 1* dan objek ke-8 sebagai pusat *cluster 2*.

Non-Medoid	V1	V2	V3	V4	V5	V6	V7	V8
E1	-0,24	-0,20	-0,04	-0,54	-0,23	-0,17	-0,38	-0,73
E2	-0,43	-0,21	-0,23	5,09	0,00	-0,71	-0,14	-0,12

N	Hasil Perhitungan Jarak Setiap Non-Medoids			Cluster yang diikuti
	E1	E2	Jarak Terdekat	
1	1,01	5,37	1,01	1
2	5,77	7,64	5,77	1
3	5,95	7,69	5,95	1
4	1,31	4,57	1,31	1
5	1,81	4,86	1,81	1
6	3,61	4,78	3,61	1
7	1,33	5,77	1,33	1
8	5,70	0,00	0,00	2
9	0,30	5,58	0,30	1
10	0,29	5,56	0,29	1
11	0,00	5,70	0,00	1
12	5,94	7,78	5,94	1
13	5,79	7,74	5,79	1
14	0,62	5,43	0,62	1
15	5,97	7,80	5,97	1
16	1,48	4,83	1,48	1
17	5,88	7,70	5,88	1
18	1,18	5,07	1,18	1
19	0,69	5,37	0,69	1
20	1,28	4,60	1,28	1
21	0,55	5,37	0,55	1
22	0,92	5,23	0,92	1
23	0,86	5,32	0,86	1
24	0,51	5,58	0,51	1
25	1,00	6,00	1,00	1
26	0,71	5,55	0,71	1
27	5,29	7,53	5,29	1
28	1,12	5,56	1,12	1
29	0,29	5,67	0,29	1
30	1,47	5,59	1,47	1
31	0,85	5,58	0,85	1
32	0,39	5,66	0,39	1

33	0,36	5,61	0,36	1
34	0,37	5,67	0,37	1
Total Cost		264,34		

$$S = \text{Total Cost baru} - \text{Total cost lama}$$

$$S = 264,34 - 276,27$$

$$S = -11,93 \quad (\text{Iterasi dilanjutkan})$$

c. Iterasi 3

- E_1 dan E_2 menjadi *Medoid* baru
- Dipilih objek Non-*Medoid* baru yaitu objek ke-7 sebagai pusat *Cluster 1* dan objek ke-6 sebagai pusat *cluster 2*.

Non-Medoid	V1	V2	V3	V4	V5	V6	V7	V8
F1	-0,05	-0,24	-0,19	-0,44	-0,27	0,61	0,65	-0,57
F2	-0,26	-0,29	-0,54	1,10	-0,13	-0,05	0,04	2,41

N	Hasil Perhitungan Jarak Setiap Non-Medoid			Cluster yang diikuti
	F1	F2	Jarak Terdekat	
1	1,25	2,67	1,25	1
2	5,04	5,80	5,04	1
3	4,92	6,38	4,92	1
4	1,66	2,60	1,66	1
5	1,81	1,86	1,81	1
6	3,50	0,00	0,00	2
7	0,00	3,50	0,00	1
8	5,77	4,78	4,78	2
9	1,21	3,35	1,21	1
10	1,19	3,39	1,19	1
11	1,33	3,61	1,33	1
12	5,90	6,50	5,90	1
13	5,91	6,52	5,91	1
14	1,63	3,70	1,63	1
15	5,98	6,47	5,98	1
16	2,15	3,86	2,15	1
17	5,97	6,45	5,97	1
18	1,81	3,82	1,81	1
19	1,30	3,05	1,30	1
20	1,58	2,63	1,58	1
21	1,25	3,09	1,25	1
22	1,42	2,71	1,42	1
23	1,28	2,77	1,28	1
24	1,27	3,14	1,27	1

25	1,18	3,11	1,18	1
26	1,26	2,95	1,26	1
27	5,26	3,08	3,08	2
28	1,56	2,60	1,56	1
29	1,23	3,41	1,23	1
30	1,81	2,32	1,81	1
31	1,36	2,84	1,36	1
32	1,19	3,31	1,19	1
33	1,23	3,30	1,23	1
34	1,10	3,42	1,10	1
Total Cost		205,34		

$$S = \text{Total Cost baru} - \text{Total cost lama}$$

$$S = 205,34 - 264,34$$

$$S = -59,00 \quad (\text{Iterasi dilanjutkan})$$

d. Iterasi 4

- F_1 dan F_2 menjadi *Medoid* baru
- Dipilih objek Non-*Medoid* baru yaitu objek ke-10 sebagai pusat *Cluster* 1 dan objek ke-27 sebagai pusat *cluster* 2.

Non-Medoid	V1	V2	V3	V4	V5	V6	V7	V8
G1	-0,21	-0,21	-0,20	-0,40	-0,26	-0,07	-0,32	-0,58
G2	-0,02	-0,12	-0,05	-0,89	0,00	-1,09	0,49	4,38

N	Hasil Perhitungan Jarak Setiap Non-Medoid		Jarak Terdekat	Cluster yang diikuti
	G1	G2		
1	0,81	4,44	0,81	1
2	5,60	6,67	5,60	1
3	5,87	5,29	5,29	2
4	1,11	2,02	1,11	1
5	1,57	2,10	1,57	1
6	3,39	3,37	3,37	2
7	1,19	1,89	1,19	1
8	5,56	6,04	5,56	1
9	0,12	1,44	0,12	1
10	0,00	1,56	0,00	1
11	0,29	1,54	0,29	1
12	5,88	5,82	5,82	2
13	5,89	5,92	5,89	1
14	0,77	1,65	0,77	1
15	5,93	5,99	5,93	1
16	1,52	1,99	1,52	1

17	5,89	5,79	5,79	2
18	1,28	1,91	1,28	1
19	0,57	1,16	0,57	1
20	1,08	1,79	1,08	1
21	0,36	1,38	0,36	1
22	0,72	1,47	0,72	1
23	0,62	1,53	0,62	1
24	0,33	1,38	0,33	1
25	0,89	1,46	0,89	1
26	0,51	1,39	0,51	1
27	5,17	4,38	4,38	2
28	0,95	1,38	0,95	1
29	0,19	1,43	0,19	1
30	1,30	1,53	1,30	1
31	0,66	1,36	0,66	1
32	0,24	1,35	0,24	1
33	0,16	1,46	0,16	1
34	0,17	1,57	0,17	1
Total Cost		158,03		

$$S = \text{Total Cost baru} - \text{Total cost lama}$$

$$S = 158,03 - 205,34$$

$$S = -47,32 \quad (\text{Iterasi dilanjutkan})$$

e. Iterasi 5

- G_1 dan G_2 menjadi *Medoid* baru
- Dipilih objek Non-*Medoid* baru yaitu objek ke-16 sebagai pusat *Cluster 1* dan objek ke-1 sebagai pusat *cluster 2*.

Non-Medoid	V1	V2	V3	V4	V5	V6	V7	V8
H1	-0,03	-0,05	0,14	0,45	-0,62	-1,01	-0,13	-1,16
H2	-0,13	-0,14	-0,19	-0,23	-0,24	-0,14	-0,02	0,14

N	Hasil Perhitungan Jarak Setiap Non-Medoid			Cluster yang diikuti
	H1	H2	Jarak Terdekat	
1	1,79	0,00	0,00	2
2	6,60	5,57	5,57	2
3	5,83	5,61	5,61	2
4	1,56	0,91	0,91	2
5	2,33	0,95	0,95	2
6	3,86	2,67	2,67	2
7	2,15	1,25	1,25	2
8	4,83	5,37	4,83	1

9	1,52	0,75	0,75	2
10	1,52	0,81	0,81	2
11	1,48	1,01	1,01	2
12	5,80	5,78	5,78	2
13	5,85	5,79	5,79	2
14	1,09	1,25	1,09	1
15	6,00	5,80	5,80	2
16	0,00	1,79	0,00	1
17	6,41	5,86	5,86	2
18	1,14	1,61	1,14	1
19	1,44	0,49	0,49	2
20	1,46	0,83	0,83	2
21	1,47	0,52	0,52	2
22	1,72	0,37	0,37	2
23	1,74	0,32	0,32	2
24	1,65	0,55	0,55	2
25	2,26	0,78	0,78	2
26	1,78	0,40	0,40	2
27	5,77	4,44	4,44	2
28	2,03	0,43	0,43	2
29	1,58	0,81	0,81	2
30	2,32	0,70	0,70	2
31	1,88	0,38	0,38	2
32	1,60	0,68	0,68	2
33	1,60	0,72	0,72	2
34	1,66	0,83	0,83	2
Total Cost		157,79		

$$S = \text{Total Cost baru} - \text{Total cost lama}$$

$$S = 157,79 - 158,03$$

$$S = -0,24 \quad (\text{Iterasi dilanjutkan})$$

f. Iterasi 6

- H_1 dan H_2 menjadi *Medoid* baru
- Dipilih objek Non-*Medoid* baru yaitu objek ke-24 sebagai pusat *Cluster1* dan objek ke-5 sebagai pusat *cluster 2*.

Non-Medoid	V1	V2	V3	V4	V5	V6	V7	V8
I1	-0,21	-0,20	-0,22	-0,46	-0,24	-0,15	-0,31	-0,27
I2	-0,21	-0,25	-0,32	0,40	-0,23	0,17	-0,17	0,73

Hasil Perhitungan Jarak Setiap Non-Medoid				Cluster yang diikuti
N	I1	I2	Jarak Terdekat	
1	0,55	0,95	0,55	1
2	5,65	5,20	5,20	2
3	5,8698	5,8672	5,87	2
4	1,06	0,90	0,90	2
5	1,36	0,00	0,00	2
6	3,14	1,86	1,86	2
7	1,27	1,81	1,27	1
8	5,58	4,86	4,86	2
9	0,26	1,55	0,26	1
10	0,33	1,57	0,33	1
11	0,51	1,81	0,51	1
12	5,87	5,94	5,87	1
13	5,88	5,91	5,88	1
14	0,92	1,97	0,92	1
15	5,89	5,95	5,89	1
16	1,65	2,33	1,65	1
17	5,86	5,95	5,86	1
18	1,43	2,18	1,43	1
19	0,42	1,34	0,42	1
20	1,02	0,98	0,98	2
21	0,25	1,31	0,25	1
22	0,50	0,96	0,50	1
23	0,41	0,97	0,41	1
24	0,00	1,36	0,00	1
25	0,71	1,46	0,71	1
26	0,21	1,19	0,21	1
27	4,84	4,15	4,15	2
28	0,62	0,99	0,62	1
29	0,30	1,62	0,30	1
30	0,98	0,91	0,91	2
31	0,35	1,13	0,35	1
32	0,20	1,53	0,20	1
33	0,19	1,51	0,19	1
34	0,37	1,60	0,37	1
Total Cost			144,06	

$$S = \text{Total Cost baru} - \text{Total cost lama}$$

$$S = 144,06 - 157,79$$

$S = -13,73$ (Iterasi dilanjutkan)

g. Iterasi 7

- I_1 dan I_2 menjadi *Medoid* baru
- Dipilih objek Non-*Medoid* baru yaitu objek ke-29 sebagai pusat *Cluster1* dan objek ke-4 sebagai pusat *cluster 2*.

Non-Medoid	V1	V2	V3	V4	V5	V6	V7	V8
J1	-0,27	-0,19	-0,23	-0,54	-0,21	-0,15	-0,28	-0,55
J2	-0,22	-0,17	-0,12	0,58	-0,26	-0,05	-0,35	-0,07

N	Hasil Perhitungan Jarak Setiap Non-Medoid			Cluster yang diikuti
	J1	J2	Jarak Terdekat	
1	0,81	0,91	0,81	1
2	5,71	5,44	5,44	2
3	5,85	5,94	5,85	1
4	1,23	0,00	0,00	2
5	1,62	0,90	0,90	2
6	3,41	2,60	2,60	2
7	1,23	1,66	1,23	1
8	5,67	4,57	4,57	2
9	0,11	1,13	0,11	1
10	0,19	1,11	0,19	1
11	0,29	1,31	0,29	1
12	5,95	5,86	5,86	2
13	5,93	5,75	5,75	2
14	0,80	1,30	0,80	1
15	5,92	5,87	5,87	2
16	1,58	1,56	1,56	2
17	5,85	5,92	5,85	1
18	1,33	1,45	1,33	1
19	0,54	0,98	0,54	1
20	1,16	0,39	0,39	2
21	0,38	0,90	0,38	1
22	0,74	0,73	0,73	2
23	0,67	0,78	0,67	1
24	0,30	1,06	0,30	1
25	0,84	1,49	0,84	1
26	0,49	1,01	0,49	1
27	5,10	4,89	4,89	2
28	0,91	1,11	0,91	1
29	0,00	1,23	0,00	1
30	1,26	1,29	1,26	1
31	0,63	1,06	0,63	1
32	0,14	1,18	0,14	1
33	0,15	1,13	0,15	1

34	0,21	1,21	0,21	1
Total Cost			140,67	

$$S = \text{Total Cost baru} - \text{Total cost lama}$$

$$S = 140,67 - 144,06$$

$$S = -3,39 \quad (\text{Iterasi dilanjutkan})$$

h. Iterasi 8

- J_1 dan J_2 menjadi Medoid baru
- Dipilih objek Non-Medoid baru yaitu objek ke-33 sebagai pusat *Cluster 1* dan objek ke-18 sebagai pusat *cluster 2*.

Non-Medoid	V1	V2	V3	V4	V5	V6	V7	V8
K1	-0,22	-0,21	-0,23	-0,47	-0,24	-0,11	-0,33	-0,45
K2	-0,31	-0,07	0,59	0,19	0,18	-0,45	-0,12	-1,08

N	K1	K2	Hasil perhitungan jarak setiap medoids	Cluster yang diikuti
			Jarak Terdekat	
1	0,72	1,61	0,72	1
2	5,63	6,13	5,63	1
3	5,88	5,77	5,77	2
4	1,13	1,45	1,13	1
5	1,51	2,18	1,51	1
6	3,30	3,82	3,30	1
7	1,23	1,81	1,23	1
8	5,61	5,07	5,07	2
9	0,11	1,28	0,11	1
10	0,16	1,28	0,16	1
11	0,36	1,18	0,36	1
12	5,89	6,03	5,89	1
13	5,91	5,25	5,25	2
14	0,85	0,80	0,80	2
15	5,92	5,96	5,92	1
16	1,60	1,14	1,14	2
17	5,87	5,58	5,58	2
18	1,37	0,00	0,00	2
19	0,51	1,23	0,51	1
20	1,08	1,40	1,08	1
21	0,31	1,26	0,31	1
22	0,64	1,45	0,64	1
23	0,55	1,55	0,55	1
24	0,19	1,43	0,19	1
25	0,79	1,82	0,79	1

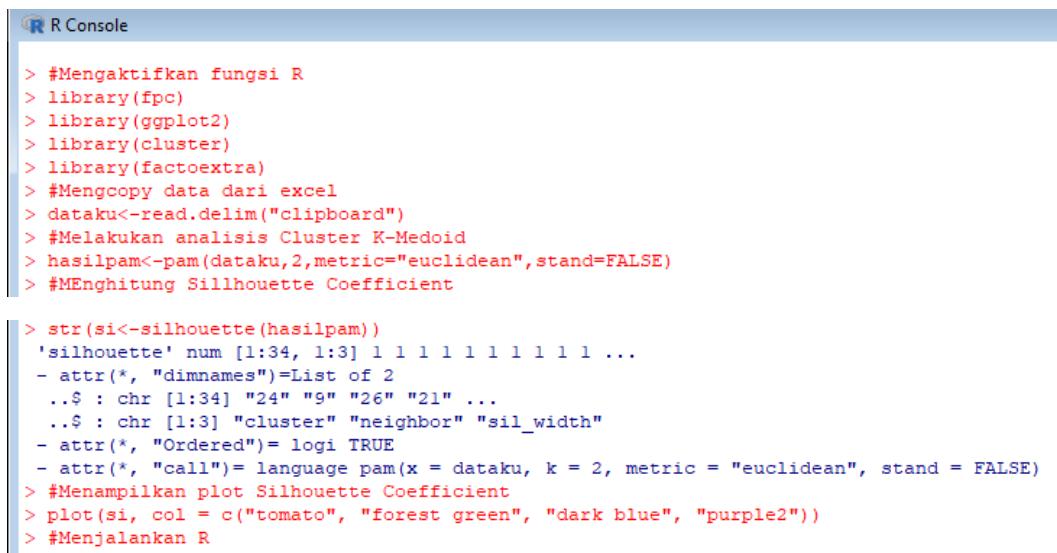
26	0,38	1,53	0,38	1
27	5,02	5,68	5,02	1
28	0,81	1,85	0,81	1
29	0,15	1,33	0,15	1
30	1,16	2,15	1,16	1
31	0,53	1,67	0,53	1
32	0,13	1,37	0,13	1
33	0,00	1,37	0,00	1
34	0,21	1,38	0,21	1
Total Cost		150,33		

$$S = \text{Total Cost baru} - \text{Total cost lama}$$

$$S = 150,33 - 140,67$$

$$S = 9,65 \quad (\text{Iterasi dihentikan})$$

Lampiran 10. Syntax R



```
R Console

> #Mengaktifkan fungsi R
> library(fpc)
> library(ggplot2)
> library(cluster)
> library(factoextra)
> #Mengcopy data dari excel
> dataku<-read.delim("clipboard")
> #Melakukan analisis Cluster K-Medoid
> hasilpam<-pam(dataku,2,metric="euclidean",stand=FALSE)
> #MEnghitung Sillhouette Coeffcient

> str(si<-silhouette(hasilpam))
'silhouette' num [1:34, 1:3] 1 1 1 1 1 1 1 1 1 1 ...
- attr(*, "dimnames")=List of 2
..$ : chr [1:34] "24" "9" "26" "21" ...
..$ : chr [1:3] "cluster" "neighbor" "sil_width"
- attr(*, "Ordered")= logi TRUE
- attr(*, "call")= language pam(x = dataku, k = 2, metric = "euclidean", stand = FALSE)
> #Menampilkan plot Silhouette Coeffcient
> plot(si, col = c("tomato", "forest green", "dark blue", "purple2"))
> #Menjalankan R
```

Lampiran 11. Hasil Input Data di R

	V1	V2	V3	V4	V5	V6	V7	V8
1	-0,13	-0,14	-0,19	-0,23	-0,24	-0,14	-0,02	0,14
2	0,28	-0,31	-0,41	0,52	-0,17	5,34	-0,32	0,45
3	0,12	-0,23	-0,12	0,00	-0,13	0,12	5,52	-0,60
4	-0,22	-0,17	-0,12	0,58	-0,26	-0,05	-0,35	-0,07
5	-0,21	-0,25	-0,32	0,40	-0,23	0,17	-0,17	0,73
6	-0,26	-0,29	-0,54	1,10	-0,13	-0,05	0,04	2,41
7	-0,05	-0,24	-0,19	-0,44	-0,27	0,61	0,65	-0,57
8	-0,43	-0,21	-0,23	5,09	0,00	-0,71	-0,14	-0,12
9	-0,23	-0,21	-0,20	-0,45	-0,23	-0,15	-0,28	-0,52
10	-0,21	-0,21	-0,20	-0,40	-0,26	-0,07	-0,32	-0,58
11	-0,24	-0,20	-0,04	-0,54	-0,23	-0,17	-0,38	-0,73
12	5,60	-0,28	0,00	0,19	-0,04	-0,48	-0,34	-0,14
13	-0,13	0,18	5,54	0,11	0,03	0,39	-0,04	0,40
14	-0,36	0,06	0,30	-0,24	-0,32	-0,43	-0,37	-0,87
15	0,12	5,63	-0,40	0,03	-0,06	0,16	0,05	0,06
16	-0,03	-0,05	0,14	0,45	-0,62	-1,01	-0,13	-1,16
17	-0,13	-0,12	-0,22	-0,14	5,61	-0,02	-0,07	-0,25
18	-0,31	-0,07	0,59	0,19	0,18	-0,45	-0,12	-1,08
19	-0,14	-0,10	-0,12	-0,26	-0,11	-0,37	-0,09	-0,26
20	-0,21	-0,16	-0,30	0,52	-0,13	-0,25	-0,12	-0,13
21	-0,26	-0,19	-0,16	-0,25	-0,22	-0,21	-0,22	-0,32
22	-0,27	-0,12	-0,18	-0,10	-0,08	-0,16	-0,28	0,03
23	-0,16	-0,17	-0,25	-0,18	-0,25	-0,03	-0,27	-0,01
24	-0,21	-0,20	-0,22	-0,46	-0,24	-0,15	-0,31	-0,27
25	-0,08	-0,24	-0,10	-0,83	0,05	0,22	-0,14	0,04
26	-0,19	-0,21	-0,22	-0,42	-0,18	-0,08	-0,27	-0,08
27	-0,02	-0,12	-0,05	-0,89	0,00	-1,09	0,49	4,38
28	-0,23	-0,19	-0,25	-0,42	-0,21	-0,20	-0,30	0,35
29	-0,27	-0,19	-0,23	-0,54	-0,21	-0,15	-0,28	-0,55
30	-0,26	-0,22	-0,33	-0,41	-0,18	-0,20	-0,32	0,70
31	-0,23	-0,22	-0,27	-0,45	-0,20	-0,13	-0,28	0,07
32	-0,23	-0,20	-0,22	-0,53	-0,23	-0,17	-0,22	-0,43
33	-0,22	-0,21	-0,23	-0,47	-0,24	-0,11	-0,33	-0,45
34	-0,20	-0,18	-0,26	-0,51	-0,22	0,04	-0,27	-0,58

Lampiran 12. Hasil Output R K-Medoid

```
> #menampilkan hasil pam
> print(hasilpam)
Medoids:
   ID V1 V2 V3 V4 V5 V6 V7 V8
[1,]  9 12 11  8 12 11  9 11 13
[2,]  5 10 15 15 24 11 25  8 31
Clustering vector:
 [1] 1 2 1 1 2 2 1 1 1 1 1 2 1 2 2 1 2 1 1 1 1 1 2 1 2 1 1 1 1 1 1 1
Objective function:
  build      swap
16.33303 16.33303

Available components:
 [1] "medoids"     "id.med"      "clustering"   "objective"    "isolation"    "clusinfo"    "silinfo"     "diss"        "call"        "data"
> |
```

Lampiran 13. Perhitungan Nilai Rata-Rata Tiap Variabel

Contoh Perhitungan:

a.) Pada *Cluster 1*

$$\begin{aligned}\bar{V}_1 &= \frac{\sum_{\text{seluruh anggota } V_1 \text{ pada } C_1} V_i}{n_{C_1}} \\ &= \frac{-0,13+0,12+(-0,22)+\cdots+(-0,20)}{25} \\ &= \frac{0,64}{25} \\ &= 0,025\end{aligned}$$

$$\begin{aligned}\bar{V}_2 &= \frac{\sum_{\text{seluruh anggota } V_2 \text{ pada } C_1} V_i}{n_{C_1}} \\ &= \frac{-0,14+(-0,23)+(-0,17)+\cdots+(-0,18)}{25} \\ &= \frac{-4,50}{25} \\ &= -0,180\end{aligned}$$

:

$$\begin{aligned}\bar{V}_8 &= \frac{\sum_{\text{seluruh anggota } V_8 \text{ pada } C_1} V_i}{n_{C_1}} \\ &= \frac{0,14+(-0,60)+(-0,07)+\cdots+(-0,58)}{25} \\ &= \frac{-6,22}{25} \\ &= -0,249\end{aligned}$$

b. a.) Pada *Cluster 2*

$$\begin{aligned}\bar{V}_1 &= \frac{\sum_{\text{seluruh anggota } V_1 \text{ pada } C_2} V_i}{n_{C_2}} \\ &= \frac{0,28+(-0,21)+(-0,26)+\cdots+(-0,02)}{9} \\ &= \frac{-0,64}{9} \\ &= -0,071\end{aligned}$$

$$\begin{aligned}\bar{V}_2 &= \frac{\sum_{\text{seluruh anggota } V_2 \text{ pada } C_2} V_i}{n_{C_2}} \\ &= \frac{-0,31+(-0,25)+(-0,29)+\cdots+0,12}{9} \\ &= \frac{4,50}{9} \\ &= 0,499\end{aligned}$$

:

$$\bar{V}_8 = \frac{\sum_{\text{seluruh anggota } V_8 \text{ pada } C_2} V_i}{n_{C_2}}$$

$$= \frac{0,45 + 0,73 + 2,41 + \dots + 4,38}{9}$$

$$= \frac{6,22}{9}$$

$$= 0,691$$