

Analisis *Cluster* Kemiskinan dan Indeks Pembangunan Manusia di Indonesia

dengan Data *Outlier* Menggunakan *K-Medoids* dan Analisis Biplot

Adina Astasia^{1,a)}

¹BPS Kabupaten Ogan Komering Ulu Timur

Email: ^{a)} adinaastasia@bps.go.id

Abstrak

Kemiskinan masih menjadi permasalahan global maupun nasional. Dalam rangka percepatan pengentasan kemiskinan diperlukan strategi untuk mempermudah pemerintah dalam pengambilan kebijakan salah satunya dengan mengelompokkan wilayah sehingga dapat ditentukan wilayah prioritas dan wilayah percontohan. Tujuan penelitian ini adalah mengelompokkan provinsi di Indonesia berdasarkan variabel kemiskinan, angka harapan hidup, rata-rata lama sekolah, harapan lama sekolah, serta pengeluaran per kapita pada tahun 2020 menggunakan *cluster k-medoids*. Metode ini dipilih karena adanya indikasi *outlier* pada data. Hasil penelitian menghasilkan 3 *cluster*, dimana *cluster* 1 memiliki karakteristik tingkat kemiskinan tertinggi, sementara angka harapan hidup, rata-rata lama sekolah, serta pengeluaran per kapita terendah, *cluster* 2 memiliki karakteristik rata-rata variabel yang sedang, sementara *cluster* 3 memiliki tingkat kemiskinan terendah serta rata-rata variabel lain tertinggi. Dari penelitian ini, diberikan rekomendasi untuk memprioritaskan pembangunan sistem pendidikan dan kesehatan, serta program-program untuk pengentasan kemiskinan pada *cluster* 1. Sementara *cluster* 3 dapat dijadikan wilayah percontohan dalam pembangunan sistem pendidikan, kesehatan, maupun pengentasan kemiskinan. Untuk *Cluster* 2 membutuhkan perhatian lebih pada pembangunan sistem pendidikan.

Kata-kata kunci: *cluster*, *outlier*, *k-medoids*, kemiskinan

Abstract

Poverty is still a global and national problem. In the context of accelerating poverty alleviation, a strategy is needed to facilitate the government in making policy, one of which is by grouping areas so that priority areas and pilot areas can be determined. The purpose of this study is to classify provinces in Indonesia based on the variables of poverty, life expectancy, average length of schooling, expected length of schooling, and per capita expenditure in 2020 using the k-medoids cluster. This method was chosen because of the indication of outliers in the data. The results of the study resulted in 3 clusters, where cluster 1 has the characteristics of the highest poverty level, while the life expectancy, average length of schooling, and the lowest per capita expenditure, cluster 2 has the characteristics of a medium variable average, while cluster 3 has the lowest poverty rate and average the highest other variables. From this research, recommendations are given to prioritize the development of education and health systems, as well as programs for poverty alleviation in cluster 1. Meanwhile, cluster 3 can be used as a pilot area in the development of education, health, and poverty alleviation systems.

Keywords: cluster, outlier, k-medoids, poverty

I. PENDAHULUAN

1.1. Latar Belakang Penelitian

Target *Sustainable Development Goals* (SDGs) yang pertama adalah menghilangkan kemiskinan dan kelaparan di tahun 2030. Kemiskinan yang dimaksud dalam target tersebut adalah orang dengan pendapatan kurang dari 1,9 Dolar Amerika per hari (BPS, 2019). Sementara menurut BPS kemiskinan adalah penduduk yang memiliki rata-rata pengeluaran perkapita perbulan dibawah garis kemiskinan. Dalam pengukuran kemiskinan, BPS menggunakan konsep *basic needs approach* atau kemampuan memenuhi kebutuhan dasar, sehingga kemiskinan merupakan ketidakmampuan dari sisi ekonomi dalam pemenuhan kebutuhan dasar makanan dan bukan makanan yang diukur dari sisi pengeluaran.

Sejak awal tahun 2020, Indonesia dan seluruh negara di dunia terdampak pandemi *covid-19* yang menyebabkan perekonomian Indonesia belum pulih sepenuhnya hingga saat ini, begitupun dengan kemiskinan. Menurut data BPS, pada Maret 2020 atau awal ditemukannya kasus *covid-19* di Indonesia, tingkat kemiskinan nasional sebesar 9,78 persen, semakin

memburuk selama pandemi hingga mencapai 10,19 persen pada September 2020. Pada Maret 2021 tingkat kemiskinan di Indonesia nyaris tidak ada perubahan yaitu sebesar 10,14 persen. Salah satu strategi pengentasan kemiskinan di Indonesia dengan karakteristik wilayah seperti tingkat kesehatan dan pendidikan yang beragam yaitu diperlukannya arah kebijakan yang berbeda antar wilayah. Upaya yang dapat dilakukan adalah pengelompokan wilayah berdasarkan karakteristik yang sama untuk mempermudah pemerintah dalam pengambilan kebijakan. Melalui pengelompokan ini dapat terbentuk wilayah-wilayah yang merupakan daerah prioritas serta wilayah-wilayah yang dapat dijadikan percontohan dalam pengentasan kemiskinan. Salah satu metode pengelompokan wilayah adalah menggunakan analisis *cluster*.

Analisis *cluster* berdasarkan karakteristik kemiskinan pada penelitian sebelumnya menggunakan kriteria kesehatan, pendidikan, dan ekonomi, dimana hal tersebut merupakan komponen yang dapat dijelaskan oleh Indeks Pembangunan Manusia (IPM). Hal ini sejalan dengan penelitian Hajar (2020) bahwa IPM, Jumlah Penduduk, dan Konsumsi berpengaruh signifikan terhadap kemiskinan.

1.2 Tujuan Penelitian

Berdasarkan pembahasan di atas, maka penelitian ini bertujuan untuk melakukan pengelompokan wilayah di Indonesia menggunakan analisis *cluster* dengan algoritma *k-medoids*.

II. TINJAUAN PUSTAKA

Beberapa penelitian yang menggunakan analisis *cluster* untuk pengelompokan wilayah diantaranya:

1. Riyanti (2018) melakukan *cluster* wilayah di Sulawesi Utara menggunakan variabel IPM, tingkat pengangguran terbuka, pertumbuhan ekonomi, persentase penduduk miskin. Analisis diawali dengan analisis biplot lalu dilanjutkan dengan analisis *cluster*.
2. Wahyuni & Jatmiko (2018) mengelompokkan wilayah di Pulau Jawa menggunakan kriteria Persentase rumah tangga yang bekerja di pertanian, rata-rata lama sekolah, pengeluaran rumah tangga per kapita, dan tingkat pengangguran terbuka. *Clustering* dilakukan dengan metode *average linkage cluster*.
3. Widyadhana, dkk. (2021) membuat *cluster* kemiskinan di Provinsi Jawa Tengah menggunakan garis kemiskinan, jumlah penduduk miskin, jumlah keluarga pra sejahtera, dan pengeluaran per kapita. *Clustering* dilakukan dengan metode *k-means* dan *average linkage*.
4. Bahauddin, dkk. (2021) melakukan analisis *cluster* provinsi di Indonesia berdasarkan persentase penduduk miskin menggunakan algoritma *k-means*. Variabel yang digunakan adalah persentase penduduk miskin, kedalaman, dan keparahan kemiskinan.

Variabel yang dipasangkan pada penelitian di atas dapat disederhanakan menjadi dimensi pendidikan, kesehatan, dan pengeluaran per kapita. Komponen tersebut dapat dijelaskan dalam komponen Indeks pembangunan Manusia (IPM). Penelitian ini akan menggunakan variabel kemiskinan dan variabel pembentuk komponen

IPM, yaitu Angka Harapan Hidup (AHH), Rata-Rata Lama Sekolah (RLS), Harapan Lama Sekolah (HLS), serta Pengeluaran Per Kapita (PPP).

Analisis *cluster* non hirarki menggunakan algoritma *k-means* banyak digunakan karena penggunaannya yang mudah, namun metode ini memiliki kelemahan yaitu tidak *robust* terhadap data *outlier*. Oleh karena itu, beberapa penelitian menggunakan *k-medoids* untuk mengatasinya, diantaranya Wahyuli, dkk. (2019) yang melakukan pengelompokan provinsi di Indonesia berdasarkan persentase kemiskinan dengan data panel dari tahun 2013-2017. Dalam penelitian ini *k-medoids* dipilih karena memiliki efisiensi yang lebih baik dibandingkan *k-means* dan memiliki performa yang lebih baik untuk dataset kecil. Penelitian lain menggunakan *k-medoids* dilakukan oleh Purwita, dkk. (2021) digunakan untuk pengelompokan indikator-indikator kemiskinan di Indonesia.

III. METODE PENELITIAN

3.1. Data Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder yang berasal dari Badan Pusat Statistik (BPS). Penelitian menggunakan data provinsi (34 provinsi di Indonesia) dengan periode waktu tahun 2020. Data yang digunakan diantaranya persentase penduduk miskin, angka harapan hidup saat lahir, rata-rata lama sekolah, harapan lama sekolah, serta pengeluaran per kapita disesuaikan.

Data diolah menggunakan *R software* dengan package *MVN* untuk pendeteksian *outlier*, serta *factoextra* dan *cluster* untuk *clustering* dan visualisasi data.

3.2. Langkah-langkah Penelitian

Analisis *cluster* merupakan teknik analisis multivariat yang bertujuan mengelompokkan objek yang mirip dalam *cluster* yang sama. Penggunaan analisis *cluster* dalam pengelompokan wilayah berdasarkan karakteristik tertentu telah banyak dilakukan diantaranya pengelompokan wilayah menggunakan data indikator pembangunan anak usia dini (Astasia, 2018) serta pengelompokan

provinsi di Indonesia berdasarkan risiko kematian ibu melahirkan (Faeni, 2020). Sementara pengelompokan wilayah menggunakan variabel kemiskinan diantaranya dilakukan oleh Riyanti (2018), Wahyuni dan Jatmiko (2018), Bahauddin, dkk. (2021), dan Widyadhana, dkk. (2021).

Karena kelemahan yang disebutkan di atas, pada penelitian ini digunakan analisis *cluster k-medoids*. Langkah-langkah analisis *cluster k-medoids* adalah sebagai berikut:

1. Deteksi *outlier* secara multivariat dengan menghitung jarak *mahalanobis*.

$$d_{mah}(x, y) = \sqrt{(x - y)^T S^{-1} (x - y)}$$

dengan:

$d_{mah}(x, y)$: jarak kuadrat Mahalanobis

x : Vektor data x

y : Vektor data y

S : Covariance Matrix

Jarak yang dihasilkan kemudian dibandingkan dengan 97,5% kuantil (Q) dari distribusi *chi-square* (χ^2_p), dimana p merupakan derajat bebas distribusi *chi-square* yang sama dengan jumlah variabel yang digunakan (Ghorbani, 2019). Jika nilai yang dihasilkan lebih dari Q maka data merupakan *outlier* (Korkmaz, 2014).

2. Standarisasi data untuk mendapatkan data yang homogen (Purwita, dkk. 2021).
3. Penentuan jumlah *cluster* optimum (k) berdasarkan *gap statistics*.
4. Pilih poin k sebagai initial centroid/nilai tengah (*medoids*) sebanyak k *cluster*.
5. Cari semua poin yang paling dekat dengan *medoids*, menggunakan jarak vektor menggunakan jarak *euclidian*.

Clustering pada data.

$$d_{euc}(x, y) = \sqrt{(x - y)^T (x - y)}$$

dengan:

$d_{euc}(x, y)$: jarak kuadrat Euclidean

x : Vektor data x


y : Vektor data y

6. Plot data hasil *cluster k-medoids* dan analisis biplot.

IV. HASIL DAN PEMBAHASAN

4.1 Identifikasi *Outlier*

Langkah awal dalam analisis *cluster k-medoids* adalah pendeteksian *outlier* untuk memastikan metode yang digunakan telah sesuai. Karena data merupakan data multivariat, maka digunakan pendeteksian *outlier* secara multivariat menggunakan jarak mahalanobis yang dibandingkan dengan χ^2 Q-Q Plot (Korkmaz, 2014).




Gambar 1. Identifikasi *Outlier*

Dari Gambar 1. Dapat dilihat bahwa secara multivariat, terdapat *outlier* pada Provinsi DKI Jakarta, DI Yogyakarta, Papua, Kep. Riau, Maluku Utara, dan Kalimantan Barat. Namun karena tujuan penelitian ini untuk pengelompokan provinsi berdasarkan variabel yang ada, maka *outlier* tidak dibuang.

Tiga daerah yang merupakan *outlier* dengan jarak terjauh dari kelompoknya adalah Provinsi DKI Jakarta, DI Yogyakarta, dan Papua. Provinsi DKI Jakarta merupakan *outlier* karena tingginya PPP per kapita per tahun serta tingginya rata-rata lama sekolah. Sementara DI Yogyakarta karena tingginya angka harapan hidup dan harapan lama sekolah. Tingginya harapan lama sekolah mengindikasikan kondisi sistem pendidikan yang baik di berbagai jenjang, namun angka ini tidak selalu dibarengi dengan tingginya rata-rata lama sekolah. Provinsi Papua memiliki tingkat kemiskinan tertinggi, sementara angka harapan hidup, harapan lama sekolah, dan PPP per kapita per tahun yang paling rendah secara nasional.

4.2 Penentuan Jumlah *Cluster* Optimum

Langkah selanjutnya adalah standarisasi data dilanjutkan dengan penentuan jumlah *cluster* optimum (k).



Gambar 2. Grafik Gap Statistics

Berdasarkan Gambar 2. Terlihat bahwa terdapat penurunan yang landai cenderung mendatar pada kelompok ke-3 dan ke-4, sehingga dapat diambil kesimpulan jumlah *cluster* yang optimal adalah 3.

4.3 Analisis *Cluster K-medoids*

Selanjutnya dilakukan analisis *cluster k-medoids* menggunakan *cluster* optimal yaitu 3 *cluster*. Diperoleh hasil 3 provinsi yang menjadi centroid tiap *cluster* yaitu Provinsi Gorontalo, Jambi, dan Bali. Tiap *cluster* beranggotakan sebagai berikut:

Tabel 1. Anggota *Cluster* berdasarkan Analisis *Cluster K-medoids*

Cluster 1	Cluster 2	Cluster 3
Aceh	Sumatera Utara	Kep. Riau
Bengkulu	Sumatera Barat	DKI Jakarta
Nusa Tenggara Barat	Riau	DI Yogyakarta
Nusa Tenggara Timur	Jambi	Bali
Sulawesi Tengah	Sumatera Selatan	Kalimantan Timur
Gorontalo	Lampung	
Sulawesi Barat	Kep. Bangka Belitung	
Maluku	Jawa Barat	
Papua Barat	Jawa Tengah	
Papua	Jawa Timur	
	Banten	
	Kalimantan Barat	
	Kalimantan Tengah	
	Kalimantan Selatan	
	Kalimantan Utara	
	Sulawesi Utara	
	Sulawesi Selatan	
	Sulawesi Tenggara	
	Maluku Utara	

Berdasarkan Tabel 1 dan Tabel 2., *Cluster* 1 beranggotakan 10 provinsi merupakan *cluster* dengan tingkat kemiskinan tertinggi. Angka harapan hidup, rata-rata lama sekolah, serta pengeluaran per kapita pada *cluster* ini merupakan yang terendah dibandingkan *cluster* lain. Sementara itu, harapan lama sekolah pada *cluster* 1 lebih tinggi dibandingkan *cluster* 2. Berdasarkan karakteristik tersebut, provinsi yang terdapat pada *cluster* 1 sebaiknya diprioritaskan untuk percepatan peningkatan fasilitas kesehatan, fasilitas pendidikan, serta pengentasan kemiskinan.


Cluster 2 beranggotakan 19 provinsi merupakan *cluster* dengan tingkat kemiskinan sedang serta variabel lain, yaitu Angka harapan hidup, rata-rata lama sekolah, serta pengeluaran per kapita bernilai sedang dibandingkan *cluster* lain. Berdasarkan karakteristik tersebut, maka *cluster* 2 sebaiknya menjadi prioritas kedua dalam upaya percepatan pengentasan kemiskinan. Hal yang perlu diperhatikan adalah masih rendahnya harapan lama sekolah sehingga sistem pendidikan perlu lebih ditingkatkan pada *cluster* ini karena harapan lama sekolah pada *cluster* ini merupakan yang terendah.

Cluster 3 beranggotakan 5 provinsi merupakan *cluster* dengan tingkat kemiskinan terendah serta rata-rata variabel lain merupakan yang tertinggi. *Cluster* ini dapat dijadikan wilayah percontohan dalam pembangunan sistem pendidikan, kesehatan, maupun pengentasan kemiskinan. Pada *Cluster* ini terdapat DI Yogyakarta yang memiliki tingkat kemiskinan cukup tinggi secara nasional, namun karena komponen lainnya, seperti kesehatan dan pendidikan yang tinggi maka provinsi ini masuk ke dalam *cluster* 1 yang memiliki sistem pendidikan dan kesehatan yang sudah baik.

Tabel 2. Rata-Rata Tiap *Cluster*

Variabel	Cluster		
	1	2	3
Kemiskinan (%)	17,22	8,37	6,94
AHH (tahun)	67,24	70,77	72,86
RLS (tahun)	8,19	8,56	9,90
HLS (tahun)	13,18	12,97	13,70
PPP (Juta Rp)	9.011,60	10.583,84	14.421,60

Visualisasi data hasil *cluster* serta analisis biplot disajikan pada Gambar 3., dimana koordinat x dan y merupakan dua komponen utama yang dapat menjelaskan keseluruhan variabel tanpa menghilangkan banyak informasi. Melalui analisis biplot dapat dijelaskan kedekatan antar observasi, keragaman variabel, dan korelasi antar variabel (Faeni, 2020).



Gambar 3. Visualisasi data hasil *clustering* menggunakan *k-medoids*

Berdasarkan Gambar 3. Informasi keragaman variabel dapat dilihat dari panjang vektor pada analisis biplot. Variabel yang digunakan dalam penelitian ini pada umumnya memiliki keragaman yang sama terlihat dari panjang vektor yang relatif sama.

Informasi korelasi antar variabel dapat dilihat dari sudut antar vektor yang terbentuk. Terlihat bahwa angka harapan hidup (AHH) memiliki korelasi yang sangat kuat dengan pengeluaran per kapita (PPP). Sementara variabel kemiskinan memiliki korelasi negatif dengan variabel lain dalam penelitian ini.

Posisi observasi pada biplot menunjukkan kemiripan antar observasi tersebut, makin dekat jarak antar observasi maka karakteristik observasi tersebut makin mirip, begitupun sebaliknya. Dari Gambar 3. Terlihat bahwa observasi DKI Jakarta dengan Papua memiliki jarak terjauh sehingga dapat disimpulkan kedua observasi tersebut memiliki karakteristik paling berbeda. Dapat diketahui juga observasi-observasi pada *cluster* 2 memiliki jarak yang

sangat berdekatan yang berarti bahwa karakteristik wilayah di *cluster* 2 hampir sama.

Karakteristik tiap observasi juga dapat dijelaskan berdasarkan arah vektor variabel terhadap posisi observasi. Jika vektor variabel mengarah ke posisi observasi mengindikasikan observasi tersebut memiliki karakteristik pada variabel tersebut. Pada **Gambar 3**. Terlihat bahwa DI Yogyakarta memiliki HLS tertinggi serta DKI Jakarta memiliki pengeluaran per kapita tertinggi. Dari plot di atas juga dapat dilihat bahwa provinsi pada *cluster* 3 memiliki tingkat kemiskinan paling rendah dilihat dari arah vektor variabelnya yang berlawanan.

V. KESIMPULAN DAN SARAN

5.1 Kesimpulan

Pengelompokan provinsi di Indonesia menggunakan variabel kemiskinan, angka harapan hidup, rata-rata lama sekolah, harapan lama sekolah, serta pengeluaran per kapita pada tahun 2020 menggunakan *cluster k-medoids* menghasilkan 3 *cluster* optimum. Dari hasil *clustering* terbentuk 10 anggota pada *cluster* 1, 19 anggota pada *cluster* 2, dan 5 anggota pada *cluster* 3. *Cluster* 1 memiliki karakteristik tingkat kemiskinan tertinggi, sementara angka harapan hidup, rata-rata lama sekolah, serta pengeluaran per kapita pada *cluster* ini merupakan yang terendah. *Cluster* 2 memiliki karakteristik rata-rata variabel yang sedang. Sementara *Cluster* 3 memiliki tingkat kemiskinan terendah serta rata-rata variabel lain tertinggi.

5.2 Saran

Dari hasil penelitian di atas, dapat diberikan rekomendasi untuk memprioritaskan pembangunan sistem pendidikan dan kesehatan, serta program-program untuk pengentasan kemiskinan pada *cluster* 1. *Cluster* 2 membutuhkan perhatian lebih pada pembangunan sistem pendidikan. Sementara *cluster* 3 dapat dijadikan wilayah percontohan dalam pembangunan sistem pendidikan, kesehatan, maupun pengentasan kemiskinan.

Meskipun analisis *cluster k-medoids* telah memfasilitasi daerah-daerah *outlier*, namun tetap diperlukan perlakuan khusus untuk daerah yang terindikasi *outlier* sesuai keadaan daerah tersebut. Misalnya untuk Papua dengan indikasi sistem pendidikan dan kesehatan terendah

nasional perlu mendapat perhatian lebih dalam peningkatannya. Begitupun untuk DI Yogyakarta yang memiliki sistem pendidikan dan kesehatan telah baik namun memiliki tingkat kemiskinan cukup tinggi juga memerlukan perlakuan khusus sebagai upaya pengentasan kemiskinan.

DAFTAR PUSTAKA

- Astasia, A. (2018). Early Childhood Development di Indonesia: Pengelompokan Wilayah Menggunakan Analisis *Cluster* Hirarki. Seminar Nasional Statistika FMIPA Unpad 2018.
- Badan Pusat Statistik. (2021). Statistik Indonesia. Jakarta: Badan Pusat Statistik.
- _____. (2019). Indikator Tujuan Pembangunan Berkelanjutan (TPB) Indonesia 2019. Jakarta: Badan Pusat Statistik.
- Bahaudin, A., Fatmawati, A., & Sari FP. (2021). Analisis *Clustering* Provinsi di Indonesia Berdasarkan Tingkat Kemiskinan Menggunakan Algoritma K-means. MISI (Jurnal Manajemen informatika & Sistem Informasi), Vol.4, hlm.1-8.
- Ghorbani, H. (2019). Mahalanobis Distance and Its Application For Detecting Multivariate *Outliers*. Facta universitatis (NIS) Ser.Math.Inform, Vol.34, hlm. 583-595.
- Korkmaz, S., Gokusuk, D., & Zararsiz, G. (2014). MVN: An R Package for Assessing Multivariate Normality. R Journal, Vol.6 (2), 151-162
- Faeni, Y.A., & Astasia, A. (2020). Maternal Mortality Risk di Indonesia dengan Analisis Biplot dan *Cluster* Menggunakan Data Survei Kesehatan dan Demografi Indonesia (SDKI) Tahun 2017. Jurnal Sistem Cerdas, Vol. 3(2), hlm. 144 - 152.
- Purwita, A.L., Damayanti, A., Hasibuan, M.A., Sahasrakina, R.I., Septiani, A.V. (2021). Pengelompokan 34 Provinsi di Indonesia Berdasarkan Indikator Kemiskinan Tahun 2020. Seminar Nasional Statistika FMIPA Unpad 2021.
- Riyanti. (2018). *Clustering* Wilayah di Provinsi Sulawesi Utara Berdasarkan Karakteristik Sosial Ekonomi Tahun 2017. Jurnal Litbang Sukowati, Vol.2, hlm.118-127.
- Wahyuli, D., Handrizal, Parlina, I., Windarto, A.P., Suhendro, D., & Wanto, A. (2019). Mengelompokkan Garis Kemiskinan Menurut Provinsi Menggunakan Algoritma *K-medoids*. Prosiding Seminar Nasional Riset Information Science (SENARIS), hlm.452-461.
- Wahyuni, S. & Jatmiko, Y.A. (2018). Pengelompokan Kabupaten/Kota di Pulau Jawa Berdasarkan Faktor-Faktor Kemiskinan dengan Pendekatan Average Linkage Hierarchical *Clustering*. Jurnal Aplikasi Statistika & Komputasi Statistiki, Vol.10.I, hlm. 1-8.
- Widyadhana, D., Hastuti, R., Kharisudin, I., & Fauzi, F. (2021). Perbandingan Analisis *Cluster* K-means dan Average Linkage untuk Pengclusteran Kemiskinan di Provinsi Jawa Tengah. PRISMA, Prosiding Seminar Nasional Matematika, Vol. 4, hlm. 584-594.

Lampiran Data Penelitian

No.	Provinsi	Kemiskinan (%)	AHH (tahun)	RLS (tahun)	HLS (tahun)	PPP (Rp/kapita/tahun)
1	Aceh	15.33	69.93	9.33	14.31	9,492
2	Sumatera Utara	9.01	69.1	9.54	13.23	10,420
3	Sumatera Barat	6.63	69.47	8.99	14.02	10,733
4	Riau	7.12	71.6	9.14	13.2	10,675
5	Jambi	8.09	71.16	8.55	12.98	10,392
6	Sumatera Selatan	12.84	69.88	8.24	12.45	10,652
7	Bengkulu	15.22	69.35	8.84	13.61	10,380
8	Lampung	12.62	70.65	8.05	12.65	9,982
9	Kep. Bangka Belitung	4.9	70.64	8.06	12.05	12,794
10	Kep. Riau	6.12	69.96	10.12	12.87	14,209
11	DKI Jakarta	4.72	72.91	11.13	12.98	18,227
12	Jawa Barat	8.4	73.04	8.55	12.5	10,845
13	Jawa Tengah	11.79	74.37	7.69	12.7	10,930
14	DI Yogyakarta	12.8	74.99	9.55	15.59	14,015
15	Jawa Timur	11.4	71.3	7.78	13.19	11,601
16	Banten	6.66	69.96	8.89	12.89	11,964
17	Bali	4.53	72.13	8.95	13.33	13,929
18	Nusa Tenggara Barat	14.14	66.51	7.31	13.7	10,351
19	Nusa Tenggara Timur	20.99	67.01	7.63	13.18	7,598
20	Kalimantan Barat	7.15	70.69	7.37	12.6	8,930
21	Kalimantan Tengah	5.16	69.74	8.59	12.66	11,154
22	Kalimantan Selatan	4.83	68.66	8.29	12.68	12,032
23	Kalimantan Timur	6.54	74.33	9.77	13.72	11,728
24	Kalimantan Utara	7.36	72.59	9	12.93	8,756
25	Sulawesi Utara	7.77	71.69	9.49	12.85	10,791
26	Sulawesi Tengah	13	68.69	8.83	13.17	9,335
27	Sulawesi Selatan	8.78	70.57	8.38	13.45	11,079
28	Sulawesi Tenggara	11.66	71.22	9.04	13.65	9,331
29	Gorontalo	15.61	68.07	7.82	13.08	10,020
30	Sulawesi Barat	11.29	65.06	7.89	12.77	9,168
31	Maluku	17.87	65.98	9.93	13.96	8,732
32	Maluku Utara	6.89	68.33	9.04	13.67	8,032
33	Papua Barat	21.84	66.02	7.6	12.91	8,086
34	Papua	26.86	65.79	6.69	11.08	6,954