

IMPLEMENTASI METODE *LATENT CLASS CLUSTER ANALYSIS* DALAM PENGELOMPOKAN WILAYAH BERDASARKAN INDIKATOR INDEKS PEMBANGUNAN MANUSIA

Florencita Yessica, Dadan Kusnandar, Nurfitri Imro'ah

INTISARI

Analisis multivariat merupakan analisis yang digunakan untuk memahami struktur data yang melibatkan lebih dari dua variabel pada setiap objek. Salah satu analisis pada analisis multivariat ialah analisis cluster yang bertujuan untuk mengelompokkan objek-objek berdasarkan karakteristik yang dimiliki. Setiap kelompok berisi objek-objek yang mirip satu sama lain. Pada analisis cluster terdapat metode Latent Class Cluster Analysis yang mengasumsikan objek masuk ke dalam salah satu cluster dengan jumlah dan ukuran cluster yang tidak diketahui sebelumnya. Pada penelitian ini metode Latent Class Cluster Analysis digunakan untuk mengelompokkan kabupaten/kota di Provinsi Kalimantan Barat. Indikator Indeks Pembangunan Manusia pada tahun 2019 yang digunakan yakni Angka Harapan Hidup saat Lahir, Angka Kesakitan, Harapan Lama Sekolah Rata-rata Lama Sekolah, Pengeluaran per Kapita dan Jumlah Penduduk Miskin. Metode ini menggunakan pendekatan berbasis model yang didasarkan pada konsep probabilitas dengan Algoritma Expectation Maximization sebagai tahapan estimasi parameter. Pemilihan model cluster berdasarkan kriteria nilai Bayesian Information Criterion terkecil kemudian pengelompokan anggota cluster menggunakan peluang posterior. Dari hasil analisis diperoleh model dengan 2 cluster. Cluster 1 terdiri dari 12 kabupaten/kota dan cluster 2 terdiri dari 2 kabupaten/kota. Berdasarkan pengelompokan kedua cluster yang diperoleh dapat dikategorikan sebagai "IPM Tinggi" untuk cluster 1 dan "IPM Rendah" untuk cluster 1. Berdasarkan hasil tersebut maka bentuk kebijakan-kebijakan dari pemerintah dapat lebih diperhatikan dan diprioritaskan pada perkembangan indikator IPM kabupaten/kota yang terdapat pada cluster 1.

Kata Kunci: Indeks pembangunan manusia, latent class cluster analysis, peluang posterior

PENDAHULUAN

Pembangunan manusia didefinisikan sebagai upaya untuk pengembangan pilihan yang lebih kepada penduduk melalui upaya pemberdayaan yang memprioritaskan pada peningkatan kemampuan dasar dan kualitas manusia agar dapat ikut serta diseluruh bidang pembangunan [1]. Keberhasilan dalam upaya membangun kualitas hidup manusia itu dapat diukur dengan indikator Indeks Pembangunan Manusia (IPM) yang mengukur pembangunan manusia dengan tiga dimensi dasar yaitu umur panjang dan hidup sehat, pengetahuan dan standar hidup layak. Perbandingan pencapaian pembangunan antar wilayah menjadi penting sebagai dasar evaluasi pemerintah dalam kebijakan selanjutnya dalam peningkatan sumber daya manusia [2].

Pemerintah perlu mengetahui gambaran umum keadaan suatu daerah ketika memberikan kebijakan kepada daerah dengan melihat pengaruh indikator IPM terhadap tinggi rendahnya angka IPM. Salah satu cara yang dapat dilakukan ialah dengan melakukan pengelompokan terhadap suatu daerah dengan berdasarkan pada indikator IPM yang memiliki pengaruh terhadap tinggi rendahnya pembangunan manusia. Dalam hal ini analisis *cluster* dapat digunakan sebagai alat bantu dalam pengelompokan daerah-daerah tersebut.

Analisis *cluster* merupakan salah satu teknik multivariat yang mengelompokkan objek berdasarkan pada kemiripan objek. Di dalam analisis *cluster* terdapat metode *Latent Class Cluster Analysis* yang menggunakan konsep probabilitas dalam pengelompokan objek. *Latent Class Cluster Analysis* dapat digunakan pada variabel penelitian yang memiliki tipe skala yang berbeda seperti variabel yang bersifat kontinu, kategorik atau campuran (kontinu dan kategorik) [3]. Pada penelitian ini *Latent Class Cluster*

Analysis digunakan untuk mengelompokkan kabupaten/kota di Kalimantan Barat berdasarkan indikator IPM. Hasil dari pengelompokan dengan menggunakan *Latent Class Cluster Analysis* diharapkan mampu memberi gambaran pengaruh indikator IPM terhadap tinggi/rendahnya IPM kabupaten/kota.

Pengelompokan menggunakan *Latent Class Cluster Analysis* dimulai dengan membentuk model *Latent Class Cluster Analysis* berdasarkan fungsi kepadatan peluang dari distribusi data yang digunakan selanjutnya dilakukan estimasi parameter dengan memaksimalkan fungsi *log-likelihood* dari model dengan menggunakan algoritma *Expectation Maximization* (EM). Kemudian dilanjutkan menghitung nilai *Bayesian Information Criterion* (BIC) berdasarkan *log-likelihood* yang telah optimum dari model yang terbentuk dan melakukan pemilihan model terbaik yang memenuhi kriteria. Setelah memperoleh model untuk *cluster* yang terbaik dilanjutkan dengan menghitung peluang posterior dari masing-masing objek untuk pengklasifikasian anggota *cluster* yang terbentuk. Selanjutnya untuk *cluster* yang telah terbentuk diidentifikasi dan diinterpretasikan karakteristik dari masing-masing *cluster* terbentuk dengan menghitung nilai rata-rata pada masing-masing indikator IPM yang terdapat pada *cluster*.

ANALISIS CLUSTER

Analisis *cluster* merupakan teknik multivariat yang mempunyai tujuan untuk mengelompokkan objek-objek berdasarkan karakteristik yang dimiliki, dimana setiap kelompok berisi objek-objek yang mirip satu sama lain. Analisis *cluster* terdiri dari metode hirarki dan non hirarki. Dalam metode hirarki jumlah kelompok yang akan diperoleh belum diketahui, sedangkan dalam metode non hirarki diasumsikan ada k kelompok terlebih dahulu [4].

Pemilihan indikator yang menjadi dasar pengelompokan objek ditentukan oleh peneliti, yang tentunya memperhitungkan kaidah logis dan keilmuan yang ada. Indikator/set variabel *cluster* adalah suatu set variabel/indikator yang merepresentasikan karakteristik yang dipakai objek-objek. Solusi *cluster* secara keseluruhan bergantung pada variabel-variabel yang digunakan sebagai dasar untuk menilai kesamaan. Penambahan atau pengurangan variabel-variabel yang relevan dapat mempengaruhi substansi hasil analisis *cluster* [5].

Latent Class Cluster Analysis

Latent Class Cluster Analysis merupakan salah satu metode dalam analisis *cluster* yang mengasumsikan pengelompokan objek masuk ke dalam salah satu *cluster* dengan jumlah dan ukuran *cluster* yang tidak diketahui sebelumnya. Analisis ini pertama kali diperkenalkan oleh Lazarfeld dan Henry pada tahun 1968 untuk pengelompokan berdasarkan variabel dikotomis, kemudian diperluas untuk variabel bertipe nominal oleh Goodman [6]. Tahapan dalam pengelompokan menggunakan metode *Latent Class Cluster Analysis* terlebih dahulu membentuk model *Latent Class Cluster Analysis*. Secara umum model *Latent Class Cluster Analysis* dapat dirumuskan dengan persamaan berikut [3]:

$$f(\mathbf{x}_h | \theta) = \sum_{j=1}^c \eta_j g(\mathbf{x}_h | \theta) \quad (1)$$

dengan:

η_j = peluang prior (awal) *cluster* ke- j

$g(\mathbf{x}_h | \theta)$ = fungsi kepadatan peluang dari variabel yang digunakan.

j = banyaknya *cluster* yang terbentuk (1, 2, ..., c)

θ = himpunan parameter

Distribusi variabel yang digunakan dalam perhitungan disesuaikan dengan jenis indikator variabel pada data. Untuk penelitian ini, variabel indikator bersifat kontinu maka digunakan distribusi normal multivariat. Misalkan baris vektor $\mathbf{x}_h = (x_{1h}, \dots, x_{ph})$ disebut sebagai pola respon dari objek ke- h sehingga fungsi kepadatan peluang yang digunakan yaitu dirumuskan [7]:

$$g(\mathbf{x}_h | \mu_{ij}, \sigma_{ij}^2) = \frac{1}{(2\pi)^{\frac{p}{2}} [\prod_{i=1}^p \sigma_i^2]} \exp \left[-\frac{1}{2} \sum_{i=1}^p \frac{(x_{ij} - \mu_{ij})^2}{\sigma_{ij}^2} \right] \quad (2)$$

dengan

μ_{ij} = parameter lokasi variabel kontinu x_i di cluster j

σ_{ij}^2 = varians dari variabel ke- i di cluster j .

Selanjutnya untuk memperoleh model *Latent Class Cluster Analysis* untuk variabel kontinu Persamaan (2) disubstitusikan ke dalam Persamaan (1):

$$f(\mathbf{x}_h | \eta_j, \mu_{ij}, \sigma_{ij}^2) = \sum_{j=1}^c \eta_j \left[\frac{1}{(2\pi)^{\frac{p}{2}} [\prod_{i=1}^p \sigma_i^2]} \exp \left[-\frac{1}{2} \sum_{i=1}^p \frac{(x_{ij} - \mu_{ij})^2}{\sigma_{ij}^2} \right] \right] \quad (3)$$

Berdasarkan model *Latent Class Cluster Analysis* yang terbentuk selanjutnya estimasi parameter menggunakan metode *Maximum Likelihood Estimation* (MLE) Oleh karena itu model *Latent Class Cluster Analysis* diubah ke fungsi *log-likelihood*, maka diperoleh fungsi *log-likelihood* untuk *Latent Class Cluster Analysis* sebagai berikut:

$$L(\theta) = \sum_{h=1}^n \log \left[\sum_{j=1}^c \eta_j \left[\frac{1}{[(2\pi)^{\frac{p}{2}} [\prod_{i=1}^p \sigma_i^2]]} \exp \left[-\frac{1}{2} \sum_{i=1}^p \frac{(x_{ij} - \mu_{ij})^2}{\sigma_{ij}^2} \right] \right] \right] \quad (4)$$

Fungsi *log-likelihood* dari model *Latent Class Cluster Analysis* dapat dimaksimumkan dengan proses iterasi menggunakan algoritma *Expectation-Maximization* (EM). Tahapan estimasi parameter yang dilakukan dengan algoritma EM terdiri dari dua proses yaitu *E-Step* dan *M-Step* [8]. Berikut langkah-langkah dalam algoritma EM:

1. *E-Step* digunakan untuk mencari suatu fungsi yang merupakan ekspektasi dari fungsi *log-likelihood* yang dinotasikan dengan:

$$= E[\log[L(\theta)] | \mathbf{x}_h, \hat{\theta}^{(r-1)}] \\ = \sum_{j=1}^c \left[\sum_{h=1}^n \left[\log \eta_j^{(r)} - \frac{p}{2} \log 2\pi - \sum_{i=1}^p \log \sigma_{ij}^{2(r)} - \frac{1}{2} \sum_{i=1}^p \frac{(x_{ih} - \mu_{ij}^{(r)})^2}{\sigma_{ij}^{2(r)}} \right] \right] \quad (5)$$

$$P(j | \mathbf{x}_h, \hat{\eta}_j^{(r-1)}, \hat{\mu}_{ij}^{(r-1)}, \hat{\sigma}_{ij}^{2(r-1)})$$

Dengan $P(j | \mathbf{x}_h, \hat{\eta}_j^{(r-1)}, \hat{\mu}_{ij}^{(r-1)}, \hat{\sigma}_{ij}^{2(r-1)})$ merupakan peluang posterior dari masing-masing objek yang dinyatakan dengan rumus,

$$P(j | \mathbf{x}_h, \hat{\eta}_j^{(r-1)}, \hat{\mu}_{ij}^{(r-1)}, \hat{\sigma}_{ij}^{2(r-1)}) = \frac{\hat{\eta}_j^{(r-1)} g(\mathbf{x}_h | \hat{\mu}_{ij}^{(r-1)}, \hat{\sigma}_{ij}^{2(r-1)})}{\sum_{j=1}^c \hat{\eta}_j^{(r-1)} g(\mathbf{x}_h | \hat{\mu}_{ij}^{(r-1)}, \hat{\sigma}_{ij}^{2(r-1)})} \quad (6)$$

2. *M-Step* digunakan untuk mencari nilai estimator yang dapat memaksimumkan fungsi *log-likelihood* berdasarkan ekspektasi dari Persamaan (5). Nilai taksiran dari $\eta_j^{(r)}, \mu_{ij}^{(r)}, \sigma_{ij}^{2(r)}$ diperoleh dengan menurunkan hasil Persamaan (5) terhadap masing-masing parameter. Diperoleh nilai taksiran untuk masing-masing parameter sebagai berikut:

$$\hat{\eta}_j^{(r)} = \frac{\sum_{h=1}^n P(j|\mathbf{x}_h, \hat{\eta}_j^{(r-1)}, \hat{\mu}_{ij}^{(r-1)}, \hat{\sigma}_{ij}^{2(r-1)})}{n}$$

$$\hat{\mu}_{ij}^{(r)} = \frac{\sum_{h=1}^n x_{ih} P(j|\mathbf{x}_h, \hat{\eta}_j^{(r-1)}, \hat{\mu}_{ij}^{(r-1)}, \hat{\sigma}_{ij}^{2(r-1)})}{n\hat{\eta}_j^{(r)}}$$

$$\hat{\sigma}_{ij}^{2(r)} = \frac{\sum_{h=1}^n \sum_{j=1}^c (x_{ih} - \hat{\mu}_{ij}^{(r)})^2 P(j|\mathbf{x}_h, \hat{\eta}_j^{(r-1)}, \hat{\mu}_{ij}^{(r-1)}, \hat{\sigma}_{ij}^{2(r-1)})}{\sum_{h=1}^n \sum_{j=1}^c P(j|\mathbf{x}_h, \hat{\eta}_j^{(r-1)}, \hat{\mu}_{ij}^{(r-1)}, \hat{\sigma}_{ij}^{2(r-1)})}$$

Proses *E-Step* dan *M-Step* dilakukan secara berulang hingga mencapai estimasi parameter yang konvergen yaitu $\left| \frac{\theta^{(r+1)} - \theta^{(r)}}{\theta^{(r)}} \right| \leq \varepsilon$. Setelah didapatkan nilai estimasi parameter selanjutnya menentukan jumlah *cluster* dengan pemilihan model terbaik menggunakan nilai *Bayesian Information Criterion* (BIC). Model terbaik merupakan model dengan nilai BIC terkecil. Nilai BIC dapat dihitung menggunakan rumus [9]:

$$BIC_{LL} = -2LL + \ln(n)k$$

dengan:

n = banyaknya data pengamatan

k = jumlah parameter model

LL = nilai *log-likelihood* yang telah optimum.

Ketika melakukan klasifikasi ke dalam suatu *cluster* menggunakan aturan penetapan model, diperlukan pula kriteria untuk menilai kualitas model klasifikasi, yang memperhatikan kesalahan objek h masuk ke dalam kelas j . Kesalahan tersebut disebut sebagai taksiran proporsi kesalahan klasifikasi atau *classification error* (*Error*) yang dapat didefinisikan dengan rumus:

$$Error = \sum_{j=1}^c \frac{n_j}{n} [1 - \max(P(j|\mathbf{x}_h)]$$

dengan n_j menyatakan banyaknya data pada *cluster* ke- j .

Model *Latent Class Cluster Analysis* memiliki asumsi bahwa setiap variabel yang berada dalam suatu *cluster* haruslah saling bebas. Uji asumsi kebebasan lokal dilakukan dengan melihat nilai *Bivariate Residual* (BVR) antar variabel yang terbentuk pada model *cluster* yang didefinisikan dengan [6]:

$$BVR = \frac{X^2}{db} = \frac{\sum_{i=1}^b \sum_{j=1}^k \frac{(O_{ij} - E_{ij})^2}{E_{ij}}}{db}$$

dengan:

O_{ij} = frekuensi observasi baris ke- i kolom ke- j

$E_{ij} = \frac{n_i m_j}{N}$ = frekuensi harapan baris ke- i kolom ke- j .

Asumsi terpenuhi apabila nilai BVR lebih kecil dari nilai $\chi^2_{(\alpha=0,05; db=1)} = 3,84$. Ketika asumsi tidak terpenuhi terdapat beberapa solusi yang dapat dilakukan untuk memodifikasi variabel agar nilai BVR

memenuhi kriteria. Pertama, yaitu dengan *direct effect* atau penggabungan variabel yang tidak saling bebas. Kedua, menghapus salah satu variabel dari model. Ketiga, menambah jumlah kategori pada variabel laten [10].

Setelah diperoleh model terbaik dan telah memenuhi asumsi yang diberikan dilakukan pengelompokan objek ke dalam *cluster* yang dilakukan dengan menghitung peluang posterior dari masing-masing objek dengan Persamaan (6). Pemilihan anggota dari suatu *cluster* dilakukan dengan melihat peluang posterior tertinggi dari suatu objek untuk setiap *cluster*.

STUDI KASUS

Data penelitian yang digunakan adalah data sekunder yang diperoleh dari publikasi Badan Pusat Statistik Kalimantan Barat yaitu data indikator IPM pada 14 kabupaten/kota di Kalimantan Barat tahun 2019. Indikator IPM kabupaten/kota yang digunakan sebagai variabel pengelompokan dalam penelitian ini merupakan data yang berskala rasio. Variabel-variabel Indikator IPM pada kabupaten/kota Provinsi Kalimantan Barat yang digunakan dapat dilihat pada Tabel 1.

Tabel 1 Variabel Data Indikator IPM Pada Kabupaten/Kota di Provinsi Kalimantan Barat Tahun 2019

Variabel	Keterangan	Kode Variabel
X_1	Angka Harapan Hidup saat Lahir	AHH
X_2	Angka Kesakitan	AKs
X_3	Harapan Lama Sekolah	HLS
X_4	Rata-rata Lama Sekolah	RLS
X_5	Pengeluaran per Kapita	PPK
X_6	Jumlah Penduduk Miskin	PM

Pengelompokan dengan menggunakan *Latent Class Cluster Analysis* dimulai dengan menentukan model dari *Latent Class Cluster Analysis*, untuk data indikator IPM yang berdistribusi normal multivariat diperoleh model *Latent Class Cluster Analysis* yaitu pada Persamaan (3). Estimasi parameter dari model dengan memaksimumkan fungsi *log-likelihood* menggunakan algoritma EM memperoleh nilai *log-likelihood* optimum (LL) dan nilai BIC untuk setiap *cluster* dapat dilihat pada Tabel 2.

Tabel 2 Model Latent Class Cluster

Jumlah Cluster	LL	BIC(LL)	Jumlah Parameter	Class. Error
1	-284,530	600,729	12	0,000
2	-258,932	583,840	25	0,000
3	-248,261	596,807	38	0,005
4	-241,305	617,202	51	0,042
5	-230,407	629,714	64	0,003

Pemilihan model *Latent Class Cluster Analysis* dilihat berdasarkan model yang memiliki nilai BIC terkecil. Selain itu, model yang terbaik merupakan model yang memiliki kesalahan klasifikasi (*classification error*) yang kecil. Berdasarkan Tabel 2 dapat dilihat bahwa model 2 *cluster* memiliki nilai BIC terkecil diantara model yang lainnya yaitu sebesar 583,840 dengan nilai *classification error* 0,000 dan jumlah parameternya sebanyak 25 maka model *cluster* yang digunakan yaitu *cluster* 2.

Salah satu syarat yang harus dipenuhi untuk menyatakan bahwa model tersebut sudah cukup akurat adalah terpenuhinya asumsi kebebasan lokal, yaitu dengan nilai BVR antar dua variabel dari seluruh variabel yang ada dalam *cluster* terpilih. Berdasarkan uji asumsi kebebasan lokal nilai BVR antar

variabel yang digunakan pada data indikator IPM diperoleh nilai statistik BVR antara 0,033 sampai dengan 2,467 yang masih lebih kecil dari nilai $\chi^2_{(\alpha=0,05;db=1)} = 3,84$. Maka indikator IPM telah memenuhi asumsi kebebasan lokal untuk setiap pasangan variabel indikator pada model 2 *cluster*.

Banyaknya kabupaten/kota pada setiap *cluster* yang terbentuk diperoleh dari nilai probabilitas masing-masing *cluster* dikalikan dengan jumlah kabupaten/kota keseluruhan yang hasilnya dapat dilihat pada Tabel 3.

Tabel 3 Pengklasifikasian *Cluster* Terbentuk

Cluster	Probabilitas	Banyaknya Kabupaten/kota
1	0,833	12
2	0,167	2

Sumber: Hasil Analisis XLSTAT 2019

Nilai probabilitas untuk *cluster* 1 ialah 0,833 sehingga diperoleh 12 kabupaten/kota yang menjadi anggota *cluster* 1 dan nilai probabilitas untuk *cluster* 2 ialah 0,167 sehingga diperoleh 2 kabupaten/kota anggota *cluster* 2.

Pengelompokan kabupaten/kota masuk sebagai anggota dari masing-masing *cluster* didasarkan pada nilai probabilitas posterior yang maksimum dari *cluster* yang terbentuk. Hasil pengelompokan anggota kabupaten/kota dalam *cluster* dapat dilihat pada Tabel 4.

Tabel 4 Klasifikasi Anggota *Cluster*

Kabupaten/Kota	Cluster
Kab. Sambas	1
Kab. Bengkayang	1
Kab. Landak	1
Kab. Mempawah	1
Kab. Sanggau	1
Kab. Ketapang	1
Kab. Sintang	1
Kab. Kapuas Hulu	1
Kab. Sekadau	1
Kab. Melawi	1
Kab. Kayong Utara	1
Kab. Kubu Raya	1
Kota Pontianak	2
Kota Singkawang	2

Berdasarkan Tabel 4 diperoleh anggota kabupaten/kota masing-masing *cluster* yaitu Kabupaten Sambas, Kabupaten Bengkayang, Kabupaten Landak, Kabupaten Mempawah, Kabupaten Sanggau, Kabupaten Ketapang, Kabupaten Sintang, Kabupaten Kapuas Hulu, Kabupaten Sekadau, Kabupaten Melawi, Kabupaten Kayong Utara dan Kabupaten Kubu Raya merupakan anggota *cluster* 1. Sementara itu untuk Kota Pontianak dan Kota Singkawang merupakan anggota *cluster* 2.

Setelah mendapatkan model dan anggota masing-masing *cluster* yang sesuai selanjutnya yaitu membentuk karakteristik dari ke-2 *cluster* terbentuk. Karakteristik dari setiap *cluster* yang terbentuk dapat dilihat pada Tabel 5.

Tabel 5 Nilai Rata-Rata Variabel Setiap *Cluster*

Variabel	Kategori	Rata-rata	
		Cluster1	Cluster2
X_1	AHH	71,299	72,325
X_2	AKs	14,423	9,645

X_3	HLS	12,082	13,940
X_4	RLS	6,818	8,930
X_5	PPK	8408,645	13151,928
X_6	PM	27,981	21,182

Berdasarkan Tabel 5 karakteristik yang terdapat pada masing-masing *cluster* dapat dijabarkan sebagai berikut.

1. Karakteristik *Cluster* 1

Pada *cluster* 1 diperoleh nilai rata-rata variabel AHH sebesar 71,299, HLS 12,423, RLS 6,818 dan PPK 8408,645 lebih rendah dibandingkan nilai rata-rata variabel tersebut pada *cluster* 2. Sedangkan untuk nilai rata-rata variabel AKs sebesar 14,423 dan PM sebesar 27,981 lebih tinggi dibandingkan dengan rata-rata nilai variabel tersebut pada *cluster* 2. Dengan demikian karakteristik dari *cluster* 1 menunjukkan bahwa anggota pada *cluster* memiliki nilai presentase AKs yang lebih besar dan jumlah PM yang lebih banyak.

2. Karakteristik *Cluster* 2

Pada *cluster* 2 diperoleh nilai rata-rata variabel AKs sebesar 9,645 dan PM sebesar 21,182 lebih rendah dibandingkan nilai rata-rata variabel tersebut pada *cluster* 1. Sedangkan untuk nilai rata-rata AHH sebesar 72,325, HLS 13,940, RLS 8,930 dan PPK 13151,928 lebih tinggi dibandingkan dengan rata-rata nilai variabel tersebut pada *cluster* 1. Dengan demikian dari karakteristik dari *cluster* 2 menunjukkan bahwa anggota pada *cluster* memiliki nilai AHH dan HLS yang lebih tinggi, RLS yang lebih lama dan jumlah PPK yang lebih besar.

Berdasarkan karakteristik kedua *cluster* yang terbentuk, untuk kriteria penamaan atau kategori *cluster* tidak ada kriteria khusus yang harus terpenuhi karena hanya terdapat 2 *cluster* maka kedua *cluster* tersebut dibagi menjadi *cluster* IPM tinggi dan *cluster* IPM rendah dengan pembagian sesuai dengan karakteristik variabel yang terdapat pada masing-masing *cluster*.

KESIMPULAN

Hasil pengelompokan kabupaten/kota di Provinsi Kalimantan Barat dengan metode *Latent Class Cluster Analysis* menggunakan 6 variabel indikator IPM tahun 2019 menghasilkan model dengan 2 *cluster*. *Cluster* 1 terdiri dari 12 kabupaten yaitu terdapat Kabupaten Sambas, Kabupaten Bengkayang, Kabupaten Landak, Kabupaten Mempawah, Kabupaten Sanggau, Kabupaten Ketapang, Kabupaten Sintang, Kabupaten Kapuas Hulu, Kabupaten Sekadau, Kabupaten Melawi, Kabupaten Kayong Utara dan Kabupaten Kubu Raya dengan ciri khas karakteristik indikator IPM yang terdapat pada *cluster* yakni Angka Kesakitan dan Jumlah Penduduk Miskin yang memiliki rata-rata lebih tinggi dibandingkan aspek indikator empat lainnya. *Cluster* 2 terdiri dari 2 kota yaitu terdapat Kota Pontianak dan Kota Singkawang dengan ciri khas karakteristik indikator IPM yang terdapat pada *cluster* yakni Angka Harapan Hidup saat Lahir, Harapan Lama Sekolah, Rata-rata Lama Sekolah dan Pengeluaran Perkapita yang memiliki rata-rata lebih tinggi dibandingkan aspek indikator dua lainnya.

Berdasarkan pengelompokan kedua *cluster* yang terbentuk dapat dikategorikan sebagai “IPM Tinggi” untuk *cluster* 2 karena karakteristik *cluster* terdiri dari lebih banyak indikator IPM yakni Angka Harapan Hidup dan Harapan Lama Sekolah yang lebih tinggi, Rata-rata Lama Sekolah yang lebih lama dan Pengeluaran Perkapita yang besar, sementara itu untuk *cluster* 1 dikategorikan sebagai “IPM Rendah” karena karakteristik *cluster* hanya terdiri dari dua indikator IPM yakni presentase Angka Kesakitan yang lebih tinggi dan jumlah Penduduk Miskin yang lebih banyak.

SARAN

Hasil pengelompokan kabupaten/kota menunjukkan bahwa mayoritas Kabupaten/Kota di Kalimantan Barat berada di *cluster* 1 yaitu *cluster* dengan IPM rendah. Dilihat dari nilai rata-rata *cluster* untuk masing-masing variabel didapatkan bahwa kabupaten/kota pada *cluster* 1 memiliki

AHH, HLS, RLS dan PPK yang lebih rendah dibandingkan kabupaten/kota di *cluster* 2. Oleh karenanya saran bagi pemerintah ialah diharapkan agar lebih memperhatikan dan memberi fokus anggaran pada perkembangan kabupaten/kota pada *cluster* 1 sehingga kebijakan-kebijakan yang diberikan pada kabupaten/kota anggota *cluster* tersebut mampu meningkatkan kualitas sumber daya manusia dan keadaan ekonomi setempat. Dengan harapan bahwa terjadi peningkatan pembangunan manusia yang lebih merata dan tepat sasaran sehingga akan berdampak pada peningkatan angka IPM pada kabupaten/kota tersebut.

DAFTAR PUSTAKA

- [1]. Ambarwati, A. N. Latent Class Cluster Analysis Untuk Pengelompokan Kabupaten/Kota Di Provinsi Jawa Tengah Berdasarkan Indikator Indeks Pembangunan Manusia 2017. *Journal of Statistics and Its Application*. 2019;1(2):46–54.
- [2]. Badan Pusat Statistik. *Indeks Pembangunan Manusia Kalimantan Barat*. Pontianak: Badan Pusat Statistik Provinsi Kalimantan Barat; 2019.
- [3]. Vermunt, J. K., dan Magidson, J. *Latent Class Cluster Analysis*. In J. Hagenars, & A. Mc Cutcheon (Eds). *Applied Latent Class Analysis*. Cambridge University Press; 2002. 89–106.
- [4]. Supranto, J. *Analisis Multivariat Arti dan Interpretasi*. Jakarta: Rineka Cipta; 2010.
- [5]. Gunawan, I. *Pengantar Statistika Inferensial*. Jakarta: Rajawali Pers; 2016.
- [6]. Budiati, S., Susanto, I., Wibowo, S., Pengelompokan Daerah Penghasil Bahan Dasar Tepung Komposit Di Indonesia Menggunakan Metode Latent Class Cluster Analysis (LCCA). *Media Statistika*. 2014;7(1):21–8.
- [7]. Gustiana, Y. Y., Suwanda, dan Zulhanif. Perbandingan Fuzzy C-Means Clustering dengan Latent Class Clustering Analysis. *Instutinal Inferensial*. 2015;1–37.
- [8]. Kusuma, T. A., dan Suparman. Algoritma Expectation-Maximization (EM) Untuk Estimasi Distribusi Mixture. *Jurnal Konvergensi*. 2014;4(2):65–83.
- [9]. Magidson, J., dan Vermunt J. K., Latent Class Models. *Statistical Innovations Inc*. 2004;175–98.
- [10]. Nurhayati, N., Mukid, M. A., dan Ispriyanti, D., Pengelompokan Pasien Demam Berdarah Rsud Dr.Soehadi Prijonegoro Dengan Metode Analisis Kelas Laten. *Jurnal Gaussian*. 2015;4:93–102.

FLORENCITA YESSICA : Jurusan Matematika FMIPA UNTAN Pontianak.
 florencitayessica@student.untan.ac.id
 DADAN KUSNANDAR : Jurusan Matematika FMIPA UNTAN Pontianak,
 dkusnand@untan.ac.id
 NURFITRI IMRO'AH : Jurusan Matematika FMIPA UNTAN Pontianak
 nurfitriimroah@math.untan.ac.id
