

# ANALISIS DATA WORLD DEVELOPMENT INDICATORS MENGUNAKAN CLUSTER DATA MINING

Sigit Kamseno<sup>1)</sup>, Barka Satya<sup>2)</sup>

<sup>1),2)</sup> Teknik Informatika STMIK AMIKOM Yogyakarta

<sup>3)</sup>Sistem Informasi STMIK AMIKOM Yogyakarta

Jl Ring road Utara, Condongcatur, Sleman, Yogyakarta 55281

Email : [sigit.k@students.amikom.com](mailto:sigit.k@students.amikom.com)<sup>1)</sup>, [barka.satya@amikom.ac.id](mailto:barka.satya@amikom.ac.id)<sup>2)</sup>

## Abstrak

*World Development Indicators* merupakan sebuah database yang berisi tentang track records indikator - indikator yang mempengaruhi perkembangan suatu negara. Ada berbagai macam data yang tercatat dalam database tersebut, seperti nama negara, kode negara, sistem perdagangan yang digunakan, kategori pendapatan, survei - survei, dan masih banyak lagi. Data tersebut dihimpun oleh World Bank sebagai salah satu organisasi internasional yang berperan untuk membantu negara berkembang menjadi negara maju, khususnya dalam mengembangkan ekonomi.

Dalam penelitian ini akan dibuat kluster yang akan membagi negara - negara di dunia ke dalam sebuah kluster (kelompok) menggunakan algoritma DBSCAN. Kluster tersebut akan mewakili suatu negara termasuk dalam kluster negara maju, negara berkembang, atau negara yang tertinggal soal perkembangannya. Klusterisasi akan dilakukan dengan melakukan perbandingan indikator - indikator dimasing - masing negara yang kemudian indikator tersebut di transformasi menjadi nilai - nilai kuantitatif. Perbandingan nilai kuantitatif ditentukan dengan nilai *eps* (kedekatan), seberapa dekat nilai kuantitatif suatu negara dengan nilai kuantitatif negara lain. Setelah perbandingan nilai *eps* ditentukan pula *minPts* (minimum points) yang akan menentukan kedekatan - kedekatan points layak menjadi sebuah kluster. Kluster yang terbentuk akan mempengaruhi penamaan kluster, ditentukan berdasarkan rata - rata nilai kuantitatif negara di kluster tersebut lebih kecil dari kluster lain atau lebih besar dari kluster disekitarnya.

Evaluasi kluster dilakukan setelah kluster terbentuk dengan metode *Sillhouette Index*. Metode ini dilakukan dengan mencari rata - rata jarak atau kemiripan kluster.

**Kata kunci:** Data mining, clustering, dbscan, sillhouette coefficient, visualisasi cluster, algoritma cluster

## 1. Pendahuluan

*Dataset world development indicators* berisi record negara didunia, record tersebut berisi *system of trade, income group, currency*, dan lain - lain. *Dataset* tersebut akan diolah dengan kluster *data mining* menggunakan algoritma DBSCAN. Algoritma DBSCAN akan

mengolah *record* negara di dalam *dataset* tersebut yang akan dikelompokkan berdasarkan nilai kedekatan atau kemiripan. Nilai kepadatan ditentukan dari masukkan nilai *minimum points* dan *epsilon* (jarak), seberapa padat dan mirip data tersebut akan dibuat menjadi kluster.

*Clustering* adalah suatu teknik dalam data mining yang digunakan untuk memasukkan data ke dalam grup yang bersesuaian tanpa pengetahuan yang mendalam tentang grup tersebut (Santosa, 2007). *Clustering* ini bertujuan untuk meminimalisasikan *objective function* yang diset dalam proses *clustering*, yang pada umumnya berusaha meminimalisasikan variasi antar kluster (Agusta, 2007). Sampai saat ini, para ilmuwan data (*data scienties*) terus melakukan berbagai usaha untuk melakukan perbaikan model kluster dan menghitung jumlah kluster yang optimal sehingga dapat di hasilkan kluster yang baik (Alfina, et al. 2012).

DBSCAN adalah algoritma *clustering* yang melihat bahwa sebuah kluster merupakan daerah yang padat obyek dan terpisah dari daerah yang memiliki tingkat kepadatan yang rendah (*noise*). DBSCAN dapat membentuk daerah dengan bentuk yang tidak beraturan di dalam ruang data. Bagian penting algoritma ini adalah kepadatan obyek dan hubungan antar obyek yang dibentuk dari obyek yang berdekatan [1]. Konsep kepadatan yang dimaksud dalam DBSCAN adalah jumlah data yang berada dalam radius *Eps* ( $\epsilon$ ) dari setiap data. Jika jumlah data dalam radius  $\epsilon$  lebih dari atau sama dengan *MinPts* (jumlah minimal data dalam radius  $\epsilon$ ), data tersebut masuk dalam kategori kepadatan yang diinginkan. Konsep kepadatan seperti ini melahirkan tiga macam status dari setiap data, yaitu inti (*core*), batas (*border*), dan *noise* (*noise*) [2]. DBSCAN menyatakan bahwa sebuah kluster dapat dibentuk jika untuk setiap titik data, pada dalam radius tertentu *Eps* dari titik data tersebut terdapat minimal *minPts* titik obyek. [1].

*Sillhouette Coefficient* digunakan untuk memvalidasi baik sebuah data, kluster tunggal, atau bahkan keseluruhan. Metode validasi kluster yang menggabungkan nilai kohesi dan separasi. Menghitung nilai *sillhouette coefficient* sebuah data ada dua komponen  $a_i$  dan  $b_i$ .  $a_i$  adalah rata - rata jarak data ke- $i$  terhadap semua data lainnya dalam satu kluster, sedangkan  $b_i$  didapatkan dengan menghitung rata - rata jarak data ke- $i$  terhadap semua data dari kluster yang lain tidak dalam satu kluster dengan data ke- $i$ , kemudian

diambil yang terkecil ([Tan *et al*, 2006], [Petrovic, 2003]) [3].

Berikut formula menghitung  $a_i^j$  :

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

$d = (x_i^j, x_r^j)$  adalah perhitungan (*euclidean* kuadrat) jarak data ke-i dengan data ke-r dalam satu kluster  $j$ , sedangkan  $m_j$  adalah jumlah data dalam kluster ke- $j$ .

Berikut formula untuk menghitung  $b_i^j$  :

$$b_i^j = \min_{\substack{n=1, \dots, k \\ n \neq j}} \left\{ \frac{1}{m_n} \sum_{r=1}^{m_n} d(x_i^j, x_r^n) \right\} \quad (2)$$

Untuk mendapatkan *sillhouette coefficient* data ke-i menggunakan persamaan sebagai berikut :

$$SI_i^j = \frac{b_i^j - a_i^j}{\max(a_i^j, b_i^j)} \quad (3)$$

Nilai *sillhouette coefficient* yang didapat dalam rentang [-1,+1]. Nilai *sillhouette coefficient* yang mendekati 1 menandakan bahwa data tersebut berada dalam kluster yang tepat.

Persamaan nilai *sillhouette coefficient* kluster :

$$SI_j = \frac{1}{m_j} \sum_{i=1}^{m_j} SI_i^j \quad (4)$$

Persamaan nilai *sillhouette coefficient* global :

$$SI = \frac{1}{k} \sum_{j=1}^k SI_j \quad (5)$$

$k$  adalah jumlah kluster.[4]

Berikut ini adalah representasi dari nilai *sillhouette coefficient* [5] :

**Tabel 2.Representasi Kauffman dan Rousseeuw (1990)**

	SC	Representasi
2. Pem bah an	0.71 - 1.00	Baik
	0.51 - 0.70	Sedang
	0.26 - 0.50	Buruk
	$\leq 0.25$	Berada di kluster lain

### 2.1. P engumpulan Data

*Dataset* diperoleh dari kaggle *dataset*, salah satu platform terbesar yang memiliki ratusan *dataset* apapun. Sebelum dilakukan *clustering* analisis *dataset* terlebih dahulu untuk menentukan atribut yang mempunyai relasi terkuat. *Dataset* harus melalui tahap *data selection*, *data cleaning*, *data transformation* (inisialisasi), *cluster* dan evaluasi.

*Data selection* dilakukan untuk menghapus atribut yang tidak memiliki relasi kuat dengan atribut yang lain. Setelah analisis didapat 3 atribut dari tabel *country* yaitu *country*, *income group*, dan *latest trade data*.

**Tabel 3.Data Selection**

Attribut	Keterangan
<i>Country</i>	Nama negara
<i>Income Group</i>	Kategori pendapatan
<i>Lates Trade Data</i>	Tahun survei pendapatan

*Data cleaning* menghapus atau memperbaiki atribut yang memiliki masukkan yang tidak relevan, kosong, atau tidak sesuai dengan data yang lain.

*Data transformation* untuk meng-inisialisasi data yang sudah melalui tahap *selection* dan *cleaning*.

**Tabel 4. Inisialisasi Country**

Country	Inisialisasi
Afganistan	1
Albania	2
Algeria	3
dst...	dst...
Zimbabwe	247

**Tabel 5. Inisialisasi Income Group**

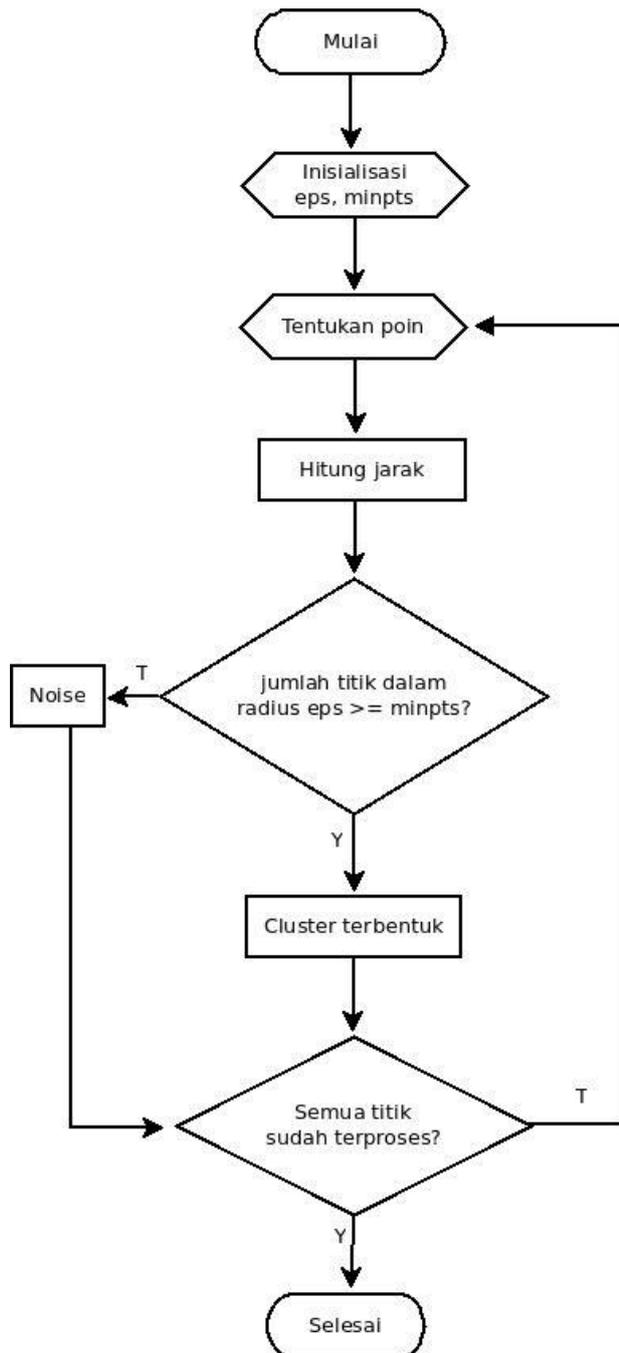
Income Group	Frekuensi
<i>High income : OECD</i>	25
<i>High income : non OECD</i>	34
<i>Upper middle income</i>	31
<i>Lower middle income</i>	32
<i>Low income</i>	15
<i>none</i>	110

**Tabel 6.Inisialisasi Latest Trade Data**

Latest Trade Data	Frekuensi
2012 - 2015	97
2008 - 2011	13
2004 - 2007	3
2000 - 2003	2
<i>none</i>	132

### 2.2. Alur Pengujian

Langkah - langkah *clustering* algoritma DBSCAN yaitu memasukkan data yang sudah melalui tahap analisis dan transformasi data, selanjutnya akan dilakukan proses. Berikut alurnya :



Gambar 1. Alur Pengujian

### 2.3. Implementasi Algoritma DBSCAN

Pengujian dilakukan dengan 10 data sampel yang diambil secara acak.

Tabel 7. Sampel Data

Income Group	Latest Trade Data	Country
1	1	1
4	5	2
4	5	3
4	1	4
5	3	5
1	1	6
1	1	7
1	1	8
5	5	9
5	5	10

Selanjutnya nilai - nilai sampel data akan dipadatkan dengan standard deviasi. Berikut hasil pemadatan data :

Tabel 8. Pemadatan Nilai Data Sampel

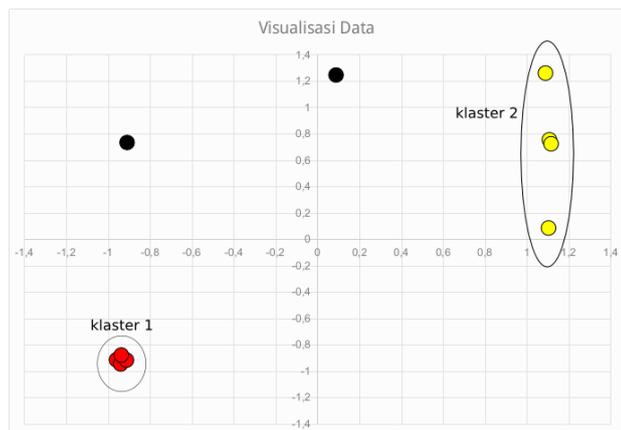
Income Group	Latest Trade Data	Country
-0.955	-0.914	-1.725
0.679	1.162	-1.711
0.679	1.162	-1.697
0.679	-0.914	-1.683
1.224	0.123	-1.669
-0.955	-0.914	-1.655
-0.955	-0.914	-1.641
-0.955	-0.914	-1.627
1.224	1.162	-1.613
0.135	1.162	-1.599

Data dalam tabel akan dilakukan proses kluster dengan nilai  $\epsilon = 0.6$  dan  $\text{minimum points} = 2$ .

$N_{0.6}(1) = \{6,7,8\}$ ;  $N_{0.6}(2) = \{3,9,10\}$ ;  $N_{0.6}(3) = \{2,9,10\}$ ;  
 $N_{0.6}(4) = \{\}$ ;  $N_{0.6}(5) = \{\}$ ;  $N_{0.6}(6) = \{1,7,8\}$ ;  $N_{0.6}(7) = \{1,6,8\}$ ;  
 $N_{0.6}(8) = \{1,6,7\}$ ;  $N_{0.6}(9) = \{2,3\}$ ;  $N_{0.6}(10) = \{2,3\}$ ;

Tabel 9. Sample Data hasil kluster

Income Group	Latest Trade Data	Country	Cluster
-0.955	-0.914	-1.725	1
0.679	1.162	-1.711	2
0.679	1.162	-1.697	2
0.679	-0.914	-1.683	noise
1.224	0.123	-1.669	noise
-0.955	-0.914	-1.655	1
-0.955	-0.914	-1.641	1
-0.955	-0.914	-1.627	1
1.224	1.162	-1.613	2
0.135	1.162	-1.599	2



Gambar 2. Hasil Kluster

2.4. Evaluasi

*Silhouette Coefficient* digunakan untuk melihat kualitas dan kekuatan kluster, seberapa baik suatu objek ditempatkan dalam suatu kluster. Metode ini merupakan gabungan dari metode *cohesion* dan *separation*. Tahapan perhitungan *silhouette coefficient*.

Perhitungan nilai  $\alpha$  untuk data yang berada dalam kluster 1 sebagai berikut :

$$a_1^1 = \frac{1}{m_1 - 1} \sum_{\substack{r=1 \\ r \neq j}}^{m_1} d(x_1^1, x_r^1) \quad (6)$$

$$a_1^1 = \frac{1}{4 - 1} = (d(x_1^1, x_2^1) + d(x_1^1, x_3^1) + d(x_1^1, x_4^1)) \quad (7)$$

$$a_1^1 = \frac{1}{3} (0 + 0 + 0) = 0 \quad (8)$$

Perhitungan nilai  $b$  untuk data yang berada dalam kluster 1 sebagai berikut :

$$b_1^1 = \min \left\{ \frac{1}{4} (2,659 + 2,659 + 2,659) \right\} \quad (9)$$

$$b_1^1 = \min (2,659) = 2,659 \quad (10)$$

Perhitungan nilai *silhouette coefficient* untuk data yang berada dalam kluster 1 sebagai berikut :

$$SI_1^1 = \frac{b_1^1 - a_1^1}{\max \{a_1^1, b_1^1\}} = \frac{2,659 - 0}{\max \{2,659, (0)\}} = 1 \quad (11)$$

Tabel 10. Nilai SC untuk setiap data dalam kluster 1

Data ke-i					
Data di	jarak	1	6	7	8
Kluster 1	1	-	0	0	0

	6	0	-	0	0
	7	0	0	-	0
	8	0	0	0	-
a	0	0	0	0	0
Data di	2	2,642	2,642	2,642	2,642
Kluster 2	3	2,642	2,642	2,642	2,642
	9	3,010	3,010	3,010	3,010
	10	2,345	2,345	2,345	2,345
	Rata - rata	2,660	2,660	2,660	2,660
b	2,660	2,660	2,660	2,660	2,660
SI	1	1	1	1	1

Nilai *silhouette coefficient* untuk keseluruhan kluster 1 :

$$SI_1 = \frac{1}{m_1} \sum_{i=1}^{m_1} SI_i^1 = \frac{1}{m_1} (SI_1^1 + SI_2^1 + SI_3^1 + SI_4^1) \quad (12)$$

$$SI_1 = \frac{1}{4} (1 + 1 + 1 + 1) = 1 \quad (13)$$

Tabel 11. Nilai SC untuk setiap data dalam kluster 2

Data ke-i					
	jarak	2	3	9	10
Data di	2	-	0	0,545	0,545
Kluster 2	3	0	-	0,545	0,545
	9	0,545	0,545	-	1,090
	10	0,545	0,545	1,090	-
	a	0,363	0,363	0,727	0,727
Data di	1	2,642	2,642	3,010	2,345
Kluster 1	6	2,642	2,642	3,010	2,345
	7	2,642	2,642	3,010	2,345
	8	2,642	2,642	3,010	2,345
	Rata - rata	2,642	2,642	3,010	2,345

b	2,642	2,642	3,010	2,345
SI	0,863	0,863	0,759	0,690

$$SI_2 = \frac{1}{4} (0,862 + 0,862 + 0,758 + 0,690) = 0,793 \quad (14)$$

$$SI = \frac{1}{k} \sum_{j=1}^k SI_j = \frac{1}{2} (SI_1 + SI_2) \quad (15)$$

$$SI = \frac{1}{2} (1 + 0,793) = 0,896 \quad (16)$$

### 3. Kesimpulan

Berdasarkan hasil uji coba dapat ditarik beberapa kesimpulan sebagai berikut :

- Penerapan kluster dengan data 10 negara menggunakan nilai eps 0.6 dan minpts 2 menghasilkan 2 kluster. 4 negara pada kluster pertama, 4 negara pada kluster kedua dan terdeteksi 2 negara sebagai noise. Sedangkan untuk data 246 negara terbentuk 4 kluster.
- Nilai global evaluasi yang dihasilkan dari penerapan kluster dengan data 10 negara yaitu 0,896 termasuk kategori baik. Sedangkan kluster dengan data 246 negara yaitu 0,068 termasuk kategori buruk.
- Pemberian nama untuk setiap kluster disesuaikan dengan jumlah kluster yang dihasilkan. Kluster dengan rata - rata data dengan nilai besar maka termasuk kluster negara – negara maju. Kluster kedua termasuk kluster negara berkembang dan seterusnya.

### Daftar Pustaka

- [1] Kantardzic, Mehmed. "Data Mining: Concepts, Models, Methods, and Algorithms (2<sup>nd</sup> ed.)". Wiley-IEEE Press. 2011.
- [2] Pasetyo, Eko. "Data Mining Konsep dan Aplikasi menggunakan MATLAB". Yogyakarta : Andi, 2012.
- [3] Hermawati, Fajar Astuti. "Data Mining". Yogyakarta : Andi, 2009.
- [4] Prasetyo, Eko. "Data Mining mengolah Data menjadi Informasi menggunakan Matlab". Yogyakarta : Andi, 2014
- [5] Susanto, Eko Budi. "Evaluasi hasil Kluster pada Dataset Iris, Soybean-small, Wine menggunakan Algoritma Fuzzy C-means dan K-means++". 2016.

### Biodata Penulis

*Sigit Kamseno, mahasiswa* Jurusan Teknik Informatika  
STMIK AMIKOM Yogyakarta

*Barka Satya*, menempuh D3 STMIK AMIKOM  
Yogyakarta Tahun 2001, S1 STMIK AMIKOM  
Yogyakarta Tahun 2005 MAGISTER TEKNIK  
INFORMATIKA STMIK AMIKOM  
.Saat ini menjadi Dosen di STMIK AMIKOM  
Yogyakarta.

