

ANALISIS DATA SEBARAN PENYAKIT MENGGUNAKAN ALGORITMA DENSITY BASED SPATIAL CLUSTERING OF APPLICATIONS WITH NOISE

¹⁾Teguh Iman Hermanto, ²⁾Muhamad Agus Sunandar

^{1,2)}Teknik Informatika, STT Wastukencana Purwakarta

^{1,2)} Jl. Cikopak No. 53, Sadang, Purwakarta - Jawa Barat - Indonesia

E-mail : teguh@stt-wastukencana.ac.id

ABSTRAK

Dalam membantu mengembangkan teknologi untuk meningkatkan pelayanan kesehatan masyarakat yang lebih baik, membutuhkan suatu informasi serta data yang cukup agar dapat dianalisis lebih lanjut. Namun dalam hal melakukan monitoring daerah rentan penyakit masih menggunakan perhitungan dengan rata-rata dari hasil data yang ada dan dalam hal ini menghasilkan output yang kurang maksimal untuk melakukan kebijakan-kebijakan terkait pelayanan kesehatan. Masalah ini dapat diatasi dengan menerapkan teknik data mining dengan metode clustering. Tujuan dari penelitian ini adalah melakukan analisis daerah rentan penyakit yang ada di puskesmas mulyamekar agar dapat membantu kebijakan dalam memberikan penyuluhan ke daerah yang sesuai. Metode analisis yang digunakan adalah Knowledge Discovery in Database (KDD). Metode pengelompokan daerah rentan penyakit menggunakan metode clustering dan algoritma Density Based Spatial Clustering of Applications with Noise (DBSCAN) sebagai perhitungan clusteringnya dimana Clustering ini bertujuan untuk membagi daerah ke dalam cluster berdasarkan lokasi titik sebaran penyakit. Hasil penelitian yang diperoleh adalah dashboard hasil analisis sebaran data penyakit menggunakan algoritma DBSCAN yang terdiri dari peta sebaran penyakit, hasil cluster penyakit, presentase sebaran penyakit per kecamatan dan perbandingan minimum point dan minimum epsilon. Dengan adanya analisis ini dapat menjadi acuan terhadap kebijakan-kebijakan yang akan diambil oleh UPTD Puskesmas Mulyamekar dalam pengambilan keputusan.

Kata Kunci: *Data Mining, DBSCAN, KDD, Epsilon, Min Point.*

ABSTRACT

In helping to improve better public health services, it requires sufficient information and data for further analysis. However, in terms of monitoring disease-prone areas, it still uses calculations based on the average available data. This problem can be overcome by applying data mining techniques with the clustering method. The purpose of this study was to analyze the disease-prone areas in Mulyamekar Public Health Center in order to assist policies in providing education to the appropriate areas. The analysis method used is Knowledge Discovery in Database (KDD). The method of grouping disease susceptible areas uses the clustering method and the Density Based Spatial Clustering of Applications with Noise (DBSCAN) algorithm as a clustering calculation where this clustering aims to divide the areas into clusters based on the location of the disease distribution points. The results obtained are the dashboard of disease data distribution analysis results using the DBSCAN algorithm which consists of a map of disease distribution, results of disease clusters, percentage of disease distribution per district and comparison of minimum points and minimum epsilon. With this analysis, it can become a reference for the policies that will be taken by the UPTD Puskesmas Mulyamekar in making decisions.

Keyword: *Data Mining, DBSCAN, KDD, Epsilon, Min Poin*

1. Pendahuluan

Pertumbuhan ilmu pengetahuan dan teknologi informasi berkembang sangat pesat di era globalisasi ini. Dan banyak memberikan manfaat dalam kemajuan di berbagai bidang. Salah satunya dalam bidang kesehatan. Penggunaan teknologi informasi disebuah instansi kesehatan menjadi suatu keharusan untuk mempermudah pelayanan terhadap masyarakat. Puskesmas Mulyamekar Purwakarta dalam melakukan perangkingan masih menggunakan

rata-rata dari hasil data yang ada dan dalam hal ini menghasilkan output yang kurang maksimal. Tumpukkan data yang berada pada Puskesmas Mulyamekar sekarang ini hanya memberikan grafik atau statistik jumlah pasien yang berobat dengan penyakit yang diderita.

Penelitian ini dibuat berdasarkan latar belakang di atas, sehingga dapat dirumuskan permasalahan yang terjadi yaitu bagaimana melakukan analisis daerah rentan penyakit menggunakan algoritma Density Based Spatial

Clustering of Applications With Noise (DBSCAN). Tujuan dari penelitian ini adalah untuk menganalisis daerah rentan penyakit menggunakan algoritma Density Based Spatial Clustering of Applications With Noise (DBSCAN) sebagai alat bantu untuk memberikan kebijakan dan memonitoring penyuluhan[1].

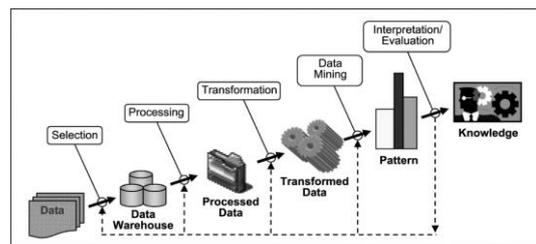
Pada tahun 2015, Ni Made Anindya Santika Devi dkk menghasilkan sebuah penelitian dengan judul “Implementasi Metode Clustering DBSCAN pada Proses Pengambilan Keputusan”. Penelitian ini berfokus pada implementasi Metode DBSCAN pada proses pengambilan keputusan untuk membantu perusahaan menentukan pelanggan potensialnya[2]. Hasil uji coba pada penelitian ini menunjukkan bahwa Metode DBSCAN telah berhasil melakukan proses clustering untuk membantu proses pengambilan keputusan dalam penentuan pelanggan potensial dengan membentuk sejumlah cluster. Spatial Data Clustering merupakan salah satu teknik penting pada data mining yang digunakan untuk mendapatkan informasi atau pengetahuan pada data spasial dalam jumlah yang besar dari berbagai aplikasi[3].

Pada tahun 2016, Muhamad Tanzil Furqon menghasilkan penelitian dengan judul “Clustering The Potential Risk Of Tsunami Using Density-Based Spatial Clustering Of Application With Noise (dbscan)”. Dalam penelitian ini dijelaskan DBSCAN merupakan algoritma yang masuk dalam kategori density-based clustering, yaitu proses pembentukan cluster dilakukan berdasarkan tingkat kedekatan/kerapatan jarak antar obyek dalam dataset tersebut. Beberapa kelebihan yang dimiliki algoritma DBSCAN dibandingkan dengan algoritma clustering yang lain diantaranya adalah kemampuannya dalam mendeteksi outlier/noise. Hal tersebut dikarenakan konsep density based yang digunakan, yaitu obyek yang tidak memiliki kedekatan jarak dengan obyek yang lainnya akan dikenal sebagai outlier. Hasil penelitian adalah Algoritma DBSCAN dapat diimplementasikan untuk mengelompokkan potensi resiko tsunami ke dalam 81 kelompok tingkat potensi resiko tsunami[4].

Pada tahun 2017, Diah Safitri dkk melakukan sebuah penelitian untuk mengelompokkan kabupaten/kota di provinsi Jawa Tengah berdasarkan produksi padi sawah dan padi ladang. Dalam penelitian ini dijelaskan bagaimana algoritma DBSCAN dapat mengelompokkan 35 kabupaten/kota di Jawa Tengah berdasarkan hasil produksi padi sawah dan padi ladang. Algoritma DBSCAN digunakan dengan minimal points 2 dan nilai epsilon 0,9. Hasil dari penelitian ini adalah terbentuknya 2 kelompok dengan 1 noise dimana kelompok pertama merupakan cluster dengan hasil produksi yang rendah dan kelompok kedua merupakan cluster dengan hasil produksi tinggi [5].

2. Metode Penelitian

Knowledge Discovery In Databases (KDD) adalah keseluruhan proses nontrivial untuk mencari dan mengidentifikasi pola (pattern) dalam data, dimana pola yang ditemukan bersifat sah, baru, dapat bermanfaat dan dapat dimengerti. KDD berhubungan dengan teknik integrasi dan penemuan ilmiah, interpretasi dan visualisasi dari pola-pola sejumlah kumpulan data[6].



Gambar 1. Tahapan Metode KDD

2.1. Pengumpulan Data

Sumber data utama yang digunakan yaitu laporan data bulan Oktober 2019 sampai dengan Desember 2019 dan hanya diambil berdasarkan diagnosis Asma, Aspa, Pnumonia, dan TBC dengan 736 record. Data tersebut nantinya akan diproses untuk dapat menentukan daerah rentan penyakit sesuai dengan sistem data mining yang digunakan[7]. Berdasarkan hasil pengumpulan data primer maka dilakukan pemilihan atribut yang akan diproses. Contoh data awal pasien yang didapatkan dapat dilihat pada tabel 1

Tabel 1. Contoh Data Pasien

Tanggal	Nama	Umur	Gender	Alamat	Kd Diagnosa	Keterangan
01-Oct-19	Josina	67	P	Purwakarta	J45	Asma
01-Oct-19	Gilang M	7	L	Babakancikao	R05	ISPA
01-Oct-19	Umi T	59	P	Babakancikao	J06	Pneumonia
01-Oct-19	Tn. Surahman	58	L	Purwakarta	J13	TBC
01-Oct-19	Enung	49	P	Campaka	J45	Asma

2.2. Data Selection

Setelah melakukan pengumpulan data dilakukanlah penyeleksian atribut kepada data awal yang didapatkan yaitu sebanyak 736 record, penyeleksian ini bertujuan untuk memilih dan memilah atribut apa saja yang harus diambil

ataudibuang. Atribut pada data yang telah diseleksi akan diolah untuk melakukan data mining dan atribut yang tidak diperlukan akan dibuang[8]. Untuk keseluruhan data pasien dapat dilihat pada lampiran 2. Adapun 2 atribut yang akan diteliti antara lain :

1. Atribut Alamat yaitu atribut sebagai pembeda antar alamat lainnya.
2. Atribut Kode Diagnosis yaitu atribut yang akan dijadikan patokan sebagai dasar untuk menentukan data daerah sebaran penyakit.

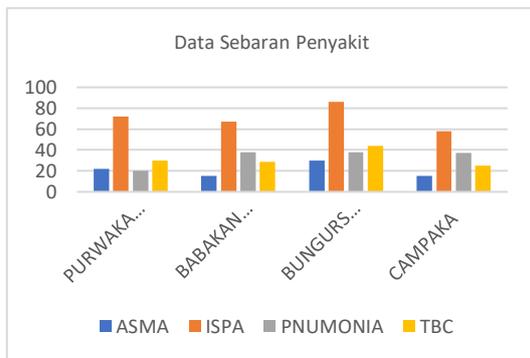
Contoh data pasien Puskesmas Mulyamekar yang sudah melalui proses *data selection* dapat dilihat pada tabel 2.

Tabel 2. Hasil Data Selection

Alamat	Kode Diagnosis
Purwakarta	J45
Babakancikao	R05
Babakancikao	J06
Bungursari	J13
Campaka	J45

2.3. Pre-processing/Cleaning

Data awal pasien mempunyai data yang lengkap ada juga yang tidak lengkap, termasuk data yang mempunyai data ganda dan adapun data yang kosong[9]. Pada proses *data mining* data yang seperti itu akan memberi hasil yang kurang baik akhirnya. Maka dari itu diperlukan langkah *preprocessing* atau *data cleaning* yang harus dilakukan, agar data pada pasien yang tidak diperlukan dihilangkan atau dihapus[10]. Hasil dari proses *cleaning* terkumpul data yang siap ditransformasi sejumlah 626 data bisa dilihat pada gambar 2.



Gambar 2. Hasil proses data cleaning

2.4. Transformation

Data pasien yang telah melalui proses seleksi dan *preprocessing/cleaning* ditransformasikan dan disimpan ke dalam bentuk yang bisa diterapkan pada sistem yang akan dibuat. Karena akan mencari data sebaran, maka dalam tahapan ini perlu dilakukan perubahan data alamat menjadi bentuk *Latitude* dan *Longitude*[11]. Dari data pada tabel 3.

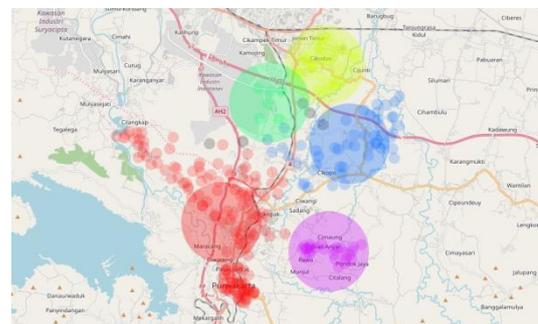
Tabel 3. Hasil Data Transformation

Latit ude	Longtit ude	Kode Diagnosis
-	107.45	J45
6.526918	5559	

-	107.42	J06
6.501318	9142	
-	107.43	J06
6.486991	9785	
-	107.46	J06
6.533399	5000	
-	107.51	J45
6.477469	1784	

3. Analisa dan Pembahasan

Berdasarkan tahap – tahap yang telah dilakukan dan dijabarkan sebelumnya, tahap selanjutnya sesuai dengan metode Knowledge Discovery in Database (KDD) adalah tahap *data mining*. Berikut adalah penjelasan lebih lanjut mengenai model *data mining*[12]. Teknik *data mining* yang dipilih adalah metode *Clustering* dengan menggunakan algoritma Density Based Spatial Clustering of Application with Noise (DBSCAN). *Clustering* dan algoritma DBSCAN sangat tepat digunakan untuk mencapai tujuan awal penelitian ini yaitu menemukan informasi terhadap daerah rentan penyakit[13]. Dimana pada tahap ini data-data yang telah dikumpulkan dan ditransformasikan mulai dikelompokkan menggunakan algoritma DBSCAN. Visualisasi yang digunakan dalam implementasi proses *data mining* menggunakan algoritma DBSCAN adalah RStudio.Machinemining yang digunakan dalam implementasi proses *data mining* menggunakan algoritma DBSCAN adalah RStudio. Pada proses pengolahan *dataset* digunakan beberapa skenario dengan menentukan nilai *epsilon* dan nilai *minPts*[14]. Untuk skenario diberikan nilai *epsilon* sebesar 0,01, 0,011, 0,012 dan 0,013 dengan *minPts* 1, 2, 3, 4, 5. Skenario dilakukan pada 4 penyakit yaitu ISPA, TBC, Asma dan Pneumonia [15]. Hasil *cluster* penyakit ISPA dengan nilai *epsilon* 0,012 dan *minPts* 5 dapat dilihat pada gambar 3.



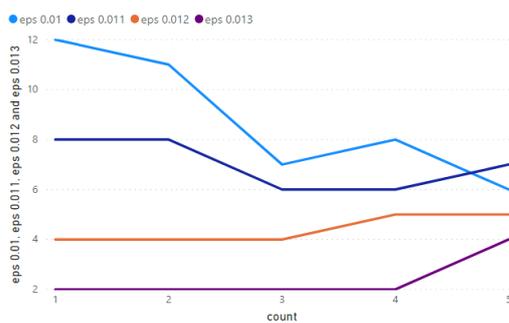
Gambar 3. Hasil Cluster Penyakit ISPA

Pada hasil *cluster* penyakit ISPA dengan nilai *epsilon* 0,012 dan *minPts* 5 dapat dilihat pada gambar 3 terbentuk 5 *cluster* dengan *noise* 5. Untuk mengetahui jumlah *cluster* yang terbentuk berdasarkan nilai *epsilon* dan *minPts* langkah selanjutnya adalah melakukan skenario pengujian yang dapat dilihat pada tabel 4.

Tabel 4. Skenario Clustering penyakit ISPA

No	Epsilon	minPts	Jumlah Cluster	Jumlah Noise	Jumlah Tercluster
1	0,01	1	12	0	283
2	0,01	2	11	1	282
3	0,01	3	7	9	274
6	0,011	1	8	0	283
7	0,011	2	8	0	283
8	0,011	3	6	4	279
11	0,012	1	4	0	283
12	0,012	2	4	0	283
15	0,012	5	5	5	278
16	0,013	1	2	0	283
17	0,013	2	2	0	283
18	0,013	3	2	0	283

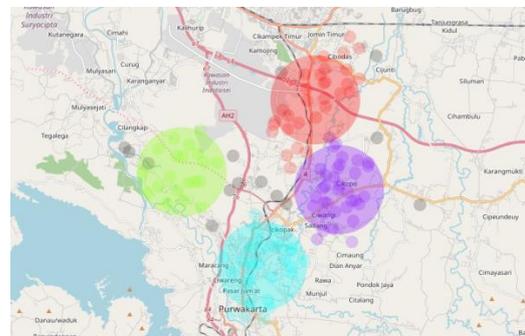
Setelah dilakukan skenario pengujian, hasil grafik dari analisis cluster penyakit ISPA dengan nilai epsilon 0.01 sampai 0,13 dan nilai minPts 1 sampai 5 dapat dilihat pada gambar 4.



Gambar 4. hasil skenario pengujian cluster penyakit ISPA

Selanjutnya analisis dilanjutkan dengan membentuk cluster penyakit TBC dengan nilai epsilon 0,012 dan minPts 5 dapat dilihat pada

gambar 5.



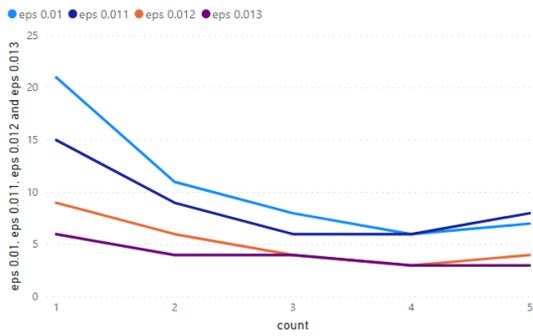
Gambar 5. Hasil Cluster Penyakit TBC

Pada hasil cluster penyakit TBC dengan nilai epsilon 0,012 dan minPts 5 dapat dilihat pada gambar 5 terbentuk 4 cluster dengan noise 14. Untuk mengetahui jumlah cluster yang terbentuk berdasarkan nilai epsilon dan minPts langkah selanjutnya adalah melakukan skenario pengujian yang dapat dilihat pada tabe

Tabel 5. Skenario Pengujian Penyakit TBC

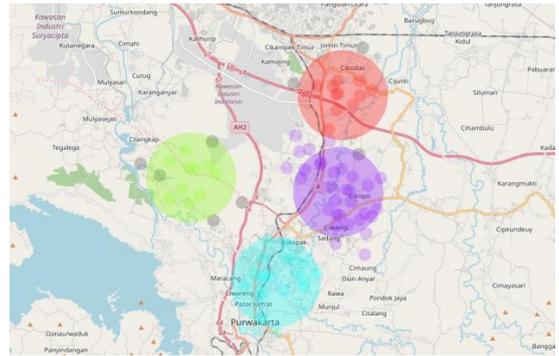
No	Epsilon	minPts	Jumlah Cluster	Jumlah Noise	Jumlah Tercluster
1	0,01	1	21	0	128
2	0,01	2	11	10	118
3	0,01	3	8	16	112
6	0,011	1	15	0	128
7	0,011	2	9	6	122
8	0,011	3	6	12	116
11	0,012	1	9	0	128
12	0,012	2	6	3	125
13	0,012	3	4	7	121
16	0,013	1	6	0	128
17	0,013	2	4	2	126
18	0,013	3	4	2	126

Setelah dilakukan skenario pengujian, hasil grafik dari analisis cluster penyakit TBC dengan nilai epsilon 0.01 sampai 0,13 dan nilai minPts 1 sampai 5 dapat dilihat pada gambar 6.



Gambar 6. Hasil Skenario Pengujian *Cluster* Penyakit TBC

Selanjutnya analisis dilanjutkan dengan membentuk *cluster* penyakit Asma dengan nilai *epsilon* 0,012 dan *minPts* 5 dapat dilihat pada gambar 7.



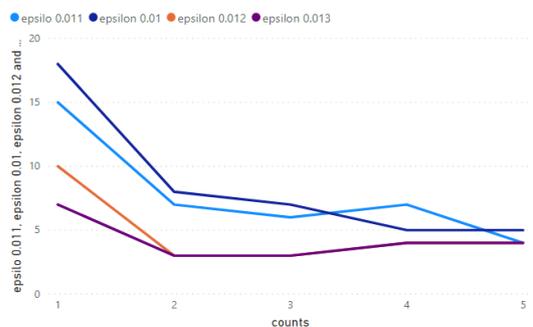
Gambar 7. Hasil *Cluster* Penyakit ASMA

Pada hasil *cluster* penyakit Asma dengan nilai *epsilon* 0,012 dan *minPts* 5 dapat dilihat pada gambar 7 terbentuk 4 *cluster* dengan *noise* 8. Untuk mengetahui jumlah *cluster* yang terbentuk berdasarkan nilai *epsilon* dan *minPts* langkah selanjutnya adalah melakukan skenario pengujian yang dapat dilihat pada tabel 6

Tabel 6. Skenario *Clustering* Penyakit ASMA

No	Epsilon	minPts	Jumlah Cluster	Jumlah Noise	Jumlah Tercluster
1	0,01	1	18	0	82
2	0,01	2	8	10	72
3	0,01	3	7	12	70
6	0,011	1	15	0	82
7	0,011	2	7	8	74
8	0,011	3	6	10	72
11	0,012	1	10	0	82
12	0,012	2	3	7	75
13	0,012	3	3	7	75
16	0.013	1	7	0	82
17	0.013	2	3	4	78
18	0.013	3	3	4	78

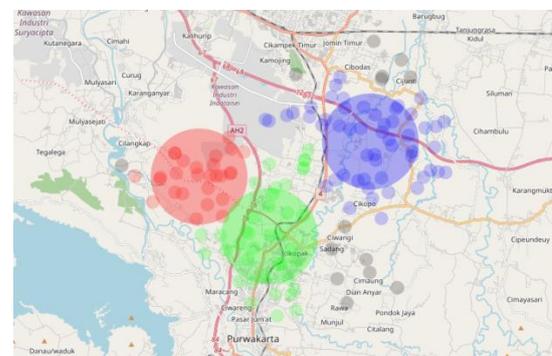
Setelah dilakukan skenario pengujian, hasil grafik dari analisis *cluster* penyakit Asma dengan nilai *epsilon* 0.01 sampai 0,13 dan nilai *minPts* 1 sampai 5 dapat dilihat pada gambar 8.



Gambar 8. Hasil Skenario Pengujian *Cluster* Penyakit Asma

Selanjutnya analisis dilanjutkan dengan

membentuk *cluster* penyakit Pneumonia dengan nilai *epsilon* 0,012 dan *minPts* 5 dapat dilihat pada gambar 9.



Gambar 9. Hasil *Cluster* Penyakit Pneumonia

Pada hasil *cluster* penyakit Pneumonia dengan nilai *epsilon* 0,012 dan *minPts* 5 dapat

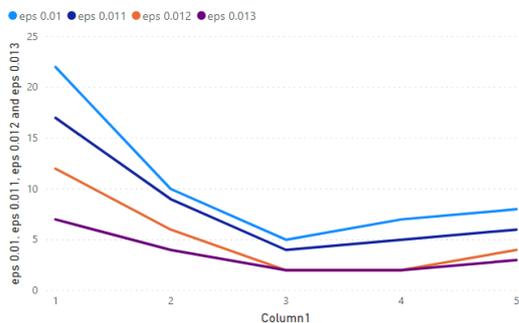
dilihat pada gambar 9 terbentuk 3 *cluster* dengan *noise* 14. Untuk mengetahui jumlah *cluster* yang terbentuk berdasarkan nilai *epsilon* dan

minPts langkah selanjutnya adalah melakukan skenario pengujian yang dapat dilihat pada tabel 7.

Tabel 7. Skenario *Clustering* Penyakit Pneumonia

No	Epsilon	minPts	Jumlah Cluster	Jumlah Noise	Jumlah Tercluster
1	0,01	1	22	0	133
2	0,01	2	10	12	121
3	0,01	3	5	22	111
6	0,011	1	17	0	133
7	0,011	2	9	8	125
8	0,011	3	4	18	115
11	0,012	1	12	0	133
12	0,012	2	6	6	127
13	0,012	3	2	14	119
16	0.013	1	7	0	133
17	0.013	2	4	3	130
18	0.013	3	2	7	126

Setelah dilakukan skenario pengujian, hasil grafik dari analisis *cluster* penyakit Pneumonia dengan nilai *epsilon* 0.01 sampai 0,13 dan nilai *minPts* 1 sampai 5 dapat dilihat pada gambar 10



Gambar 10. hasil skenario pengujian *cluster* penyakit Asma

4. KESIMPULAN

Berdasarkan dari hasil analisis pada proses *Clustering* menggunakan R Studio, penentuan nilai *epsilon* dan nilai *min points* sangat mempengaruhi jumlah *cluster* yang terbentuk. Untuk penyakit ISPA ada 5 *cluster* yang didapatkan dengan daerah sebaran penyakit ISPA paling tinggi berada pada *Cluster* 1 dengan daerah Purwakarta dan Babakanckiao, lalu untuk penyakit TBC ada 4 *cluster* yang didapatkan dengan daerah sebaran penyakit TBC paling tinggi berada pada *Cluster* 4 dengan daerah Bungursari dan Campaka, lalu untuk penyakit Asma ada 4 *cluster* yang didapatkan dengan daerah sebaran penyakit asma paling tinggi berada pada *Cluster* 4 dengan daerah Bungursari dan Campaka, lalu untuk penyakit Pneumonia ada 4 *cluster* yang didapatkan dengan daerah sebaran penyakit Pneumonia paling tinggi berada pada

Cluster 4 dengan daerah Bungursari dan Campaka.

Untuk kepentingan lebih lanjut dalam penelitian ini maka ada beberapa saran sebagai berikut :

1. Pada penelitian selanjutnya diharapkan data yang digunakan untuk penelitian dan jenis penyakit yang diteliti ditambahkan agar mendapatkan hasil yang lebih baik.
2. Pada penelitian selanjutnya diharapkan dapat menambah area cakupan menjadi beberapa puskesmas agar daerah sebaran yang dihasilkan semakin luas

Penelitian selanjutnya juga bisa mencoba menggunakan algoritma data *mining* selain algoritma *Density Based Spatial Clustering of Application with Noise*, sehingga dapat dicari algoritma yang paling efisien dan efektif.

REFERENSI

- [1] J. Zhang and Z. Shao, "Research on bird habitat discovery based on DBSCAN algorithm," *Proc. - 8th Int. Conf. Instrum. Meas. Comput. Commun. Control. IMCCC 2018*, pp. 746–750, 2018, doi: 10.1109/IMCCC.2018.00161.
- [2] Suyanto, *Data mining : untuk klasifikasi dan klasterisasi data*. Bandung: Penerbit Informatika, 2017.
- [3] A. S. Devi, I. K. G. D. Putra, and I. M. Sukarsa, "Implementasi Metode Clustering DBSCAN pada Proses Pengambilan Keputusan," *Lontar Komput. J. Ilm. Teknol. Inf.*, vol. 6, no. 3, p. 185, 2015, doi: 10.24843/lkjiti.2015.v06.i03.p05.
- [4] M. Tanzil Furqon and L. Muflikhah,

- “Clustering the Potential Risk of Tsunami Using Density-Based Spatial Clustering of Application With Noise (DbSCAN),” *J. Environmental Eng. Sustain. Technol.*, vol. 3, no. 1, pp. 1–8, 2016, doi: 10.21776/ub.jeest.2016.003.01.1.
- [5] T. Wuryandari, R. Rahmawati, K. Pati, K. Demak, and K. Brebes, “Metode DbSCAN Untuk Pengelompokan Kabupaten / Kota Di Provinsi Jawa Tengah,” vol. 5, no. 1, pp. 1–6, 2017.
- [6] B. E. V. Comendador, L. W. Rabago, and B. T. Tanguilig, “An educational model based on Knowledge Discovery in Databases (KDD) to predict learner’s behavior using classification techniques,” *ICSPCC 2016 - IEEE Int. Conf. Signal Process. Commun. Comput. Conf. Proc.*, pp. 1–6, 2016, doi: 10.1109/ICSPCC.2016.7753623.
- [7] B. N. Sari and A. Primajaya, “Penerapan Clustering DbSCAN Untuk Pertanian Padi Di Kabupaten Karawang,” *J. Inform. dan Komput.*, vol. 4, no. 1, pp. 28–34, 2019, [Online]. Available: www.mapcoordinates.net/en.
- [8] C. R. M. Rosa, M. T. A. Steiner, and P. J. Steiner Neto, “Knowledge discovery in data bases: A case study in a private institution of higher education,” *IEEE Lat. Am. Trans.*, vol. 16, no. 7, pp. 2027–2032, 2018, doi: 10.1109/TLA.2018.8447372.
- [9] S. Pramana, B. Yuniarto, S. Mariyah, I. Santoso, and NooraeniRani, *Data mining dengan R konsep setara implementasi*. Bogor: IN MEDIA, 2018.
- [10] Y. Cheng and Q. Liu, “Process and Application of Data Mining in the University Library,” *2019 4th IEEE Int. Conf. Big Data Anal. ICBDA 2019*, pp. 123–127, 2019, doi: 10.1109/ICBDA.2019.8713202.
- [11] J. Xia, J. Li, P. Dong, and K. Yang, “An ArcGIS add-in for spatiotemporal data mining in climate data,” *Earth Sci. Informatics*, vol. 13, no. 1, pp. 185–190, 2020, doi: 10.1007/s12145-019-00404-0.
- [12] R. Beniwal, V. Gupta, M. Rawat, and R. Aggarwal, “Data Mining with Linked Data: Past, Present, and Future,” *Proc. 2nd Int. Conf. Comput. Methodol. Commun. ICCMC 2018*, no. Iccmc, pp. 1031–1035, 2018, doi: 10.1109/ICCMC.2018.8487861.
- [13] E. Arriyanti, I. Arfyanti, and P. Adytia, “Spatial coordinate trial: Converting non-spatial data dimension for DBSCAN,” *Int. Conf. Electr. Eng. Comput. Sci. Informatics*, pp. 223–228, 2019, doi: 10.23919/EECSI48112.2019.8977130.
- [14] G. M. Nandana, S. Mala, and A. Rawat, “Hotspot detection of dengue fever outbreaks using DBSCAN Algorithm,” *Proc. 9th Int. Conf. Cloud Comput. Data Sci. Eng. Conflu. 2019*, pp. 158–161, 2019, doi: 10.1109/CONFLUENCE.2019.8776916.
- [15] H. Yu, L. Y. Chen, J. T. Yao, and X. N. Wang, “A three-way clustering method based on an improved DBSCAN algorithm,” *Phys. A Stat. Mech. its Appl.*, vol. 535, p. 122289, 2019, doi: 10.1016/j.physa.2019.122289.