

Implementasi Metode Density-Based Spatial Clustering of Application with Noise (DBSCAN) Dalam Clustering Titik Panas

Reno Septa Pradana⁽¹⁾, Muhammad Tanzil Furqon, S.Kom, M.CompSc⁽²⁾, Randy Cahya W, S.ST., M.Kom⁽³⁾
Teknik Informatika, Fakultas Ilmu Komputer Universitas Brawijaya, Malang, Indonesia.
Email: [renn.pradana\[at\]gmail.com](mailto:renn.pradana[at]gmail.com)⁽¹⁾, [m.tanzil.furqon\[at\]ub.ac.id](mailto:m.tanzil.furqon[at]ub.ac.id)⁽²⁾, [rendicahya\[at\]ub.ac.id](mailto:rendicahya[at]ub.ac.id)⁽³⁾

Abstrak -- Kebakaran hutan yang tidak terkendali adalah salah satu bencana yang dapat mengakibatkan kerugian materi sampai kehilangan nyawa. Kebakaran hutan yang berskala besar cukup sulit untuk dipadamkan, kadang-kadang membutuhkan waktu hingga berminggu-minggu agar semua titik api bisa padam. Kebakaran seharusnya dapat dicegah dengan cara mengetahui indikasi-indikasi terjadinya kebakaran. Salah satu indikasi terjadinya kebakaran adalah titik panas. Titik panas perlu dikelompokkan berdasarkan kemiripan sehingga diperoleh suatu informasi berupa tingkat potensi terjadinya kebakaran. DBSCAN merupakan salah satu metode *clustering* yang paling populer dan dapat digunakan untuk menyelesaikan permasalahan ini. Algoritma DBSCAN dapat diimplementasikan untuk mengelompokkan titik panas ke dalam 2 tingkat potensi kebakaran. Selain itu algoritma DBSCAN menghasilkan hasil yang cukup bagus dimana hasil dari evaluasi menggunakan *Silhouette Coefficient* memberikan nilai tertinggi yaitu 0.848423572 untuk eps 0.25 dan minpts 2.

Kata kunci : Titik panas, *data mining*, *clustering*, DBSCAN.

1. PENDAHULUAN

Kebakaran hutan yang tidak terkendali adalah salah satu bencana yang dapat mengakibatkan kerugian materi sampai kehilangan nyawa. Kebakaran hutan yang berskala besar cukup sulit untuk dipadamkan, kadang-kadang membutuhkan waktu hingga berminggu-minggu agar semua titik api bisa padam. Di Indonesia sendiri pernah terjadi kebakaran hutan dan lahan yang terjadi pada Juni hingga Oktober 2015. Kebakaran hutan dan lahan tersebut mengakibatkan kerugian finansial hingga Rp 221 triliun (Putri, 2015, para. 1). Seperti diketahui, pada periode tersebut terjadi kebakaran hutan dan lahan di Jambi, Riau, Sumatera Selatan, Kalimantan Selatan, Kalimantan Barat dan Kalimantan Timur. Penyebabnya yakni kesengajaan membakar, pembukaan lahan baru oleh sebagian masyarakat, buruknya pengelolaan ekosistem rawa gambut, musim kemarau panjang akibat *El Nino* serta lemahnya pengawasan (Putri, 2015, para. 3). Kerugian ini setara dengan 1,5 persen Produk Domestik Bruto nasional, artinya Kebakaran hutan dan lahan menghambat laju pembangunan (Putri, 2015 para. 4). Untuk menanggulangnya, BNPB mengeluarkan Rp 720

miliar untuk pemadaman kebakaran. Biaya tersebut di luar dari dana yang dikeluarkan Kementerian Lingkungan Hidup dan Kehutanan (KLHK), Kementerian Pekerjaan Umum dan Perumahan Rakyat (Kemenupera) dan Kementerian Kesehatan. Asap yang ditimbulkan oleh kebakaran hutan berdampak langsung pada kesehatan, khususnya gangguan saluran pernapasan (Putri, 2015, para. 5). Terdata 24 orang meninggal dunia, lebih dari 600 ribu jiwa terjangkit Infeksi Saluran Pernafasan Atas (ISPA), 60 juta jiwa terpapar asap dan sebanyak 2,61 juta hektare hutan dan lahan terbakar (Putri, 2015, para. 8).

Dari keterangan diatas, apabila kebakaran sudah terjadi maka kerugian yang ditimbulkan untuk negara sangatlah besar. Seharusnya kebakaran dapat dicegah agar tidak menimbulkan kerugian. Untuk melakukan pencegahan tersebut, diperlukan informasi mengenai indikasi terjadinya kebakaran. Indikasi terjadinya kebakaran hutan dapat diketahui melalui titik panas. Titik panas memiliki kemungkinan untuk menggerombol dalam ruang secara alami mengikuti hukum Geografi 1 Tobler yaitu semuanya terkait dengan segala sesuatu yang lain, tetapi hal-hal yang dekat

lebih terkait daripada hal-hal yang jauh. *Clustering* merupakan salah satu metode *data mining* yang cocok digunakan untuk menganalisis data spasial persebaran titik panas yang berukuran besar. *Clustering* merupakan proses pengelompokan kumpulan objek ke dalam kelas-kelas (*clusters*) sehingga objek-objek dalam satu *cluster* memiliki kemiripan yang tinggi tetapi tidak mirip terhadap objek dari *cluster* lain (Usman, 2014). Salah satu metode *clustering* yang populer adalah DBSCAN.


Penelitian ini menerapkan metode *clustering* untuk mengelompokkan data persebaran titik panas di Indonesia pada periode Juni hingga Agustus 2015. Tujuan dari penelitian ini adalah untuk membentuk *cluster* titik panas menggunakan algoritma DBSCAN berdasarkan tingkat potensi terjadinya kebakaran dan melakukan evaluasi hasil *clustering* menggunakan metode *Silhouette Coefficient*. Algoritma DBSCAN dipilih dikarenakan mampu membentuk *cluster* yang lebih fleksibel, tidak perlu menentukan jumlah *cluster*, dan juga mampu memisahkan data yang dianggap *noise* atau tidak memiliki kemiripan dengan data lain.

2. KAJIAN PUSTAKA

2.1 Density-based spatial clustering of application with noise (dbscan)


Konsep dasar dari algoritma DBSCAN adalah *density reachability* dan *density connected* serta bergantung dengan parameter radius maksimum dari sebuah ketetangaan / *cluster* (*eps*) dan jumlah minimal objek di dalam sebuah ketetangaan / *cluster* (*minPts*). DBSCAN menyatakan bahwa sebuah *cluster* dapat dibentuk jika untuk setiap titik data, pada dalam radius tertentu *eps* dari titik data tersebut terdapat minimal *minPts* titik objek (Liman, Indriati, S.Kom., & Ir. Sutrisno, M.T., 2014).

Density reachability menjelaskan bahwa dua titik objek yang berdekatan berada pada suatu *cluster* jika jarak antar titik objek $< Eps$ dan di dalam ketetangaan dari salah satu titik objek tersebut terdapat minimal *minPts* titik objek.



Gambar 1. Ilustrasi density reachability

Density Connectivity adalah tahapan lanjutan dari DBSCAN setelah *density reachability* berhasil didefinisikan. titik objek P dan Q disebut *density connected* jika ada deretan (*sequence*) titik objek yang *density-reachable* (P,O, Q,) di antara P dan Q dimana O *density-reachable* dari Q.



Gambar 2. Ilustrasi density connectivity

Konsep dari algoritma DBSCAN adalah sebagai berikut (Zakariya, et al., 2012) :

1. *Epsilon (eps)*. *Epsilon* adalah jarak yang menentukan kedekatan antara suatu objek dengan objek lain disekitarnya. Objek – objek yang memenuhi nilai *epsilon* dikatakan memiliki kedekatan dengan suatu objek yang diamati.
2. Jumlah objek minimum (*minPts*). *MinPts* menentukan pembentukan *cluster*. Suatu *cluster* akan dibentuk jika jumlah objek yang berdekatan telah melebihi dari nilai minimum (*minPts*) yang diberikan.
3. Selanjutnya algoritma ini menamai objek - objek yang terletak dekat dengan nilai *epsilon* yang diberikan disebut objek *core* sedangkan objek -

objek yang memiliki kedekatan dengan objek *core* disebut dengan objek *border*. Di luar itu, objek - objek yang bukan merupakan objek *core* atau *border* merupakan suatu *outlier* atau anomali.

Komputasi dari algoritma *Density-Based Spatial Clustering of Application with Noise* dapat dilakukan dengan langkah-langkah sebagai berikut (Devi, Putra, & Sukarsa, 2015) :

1. Inialisasi parameter *minPts*, *eps*
2. Tentukan titik awal atau *p* secara acak
3. Ulangi langkah 3 sampai 5 hingga semua titik diproses
4. Hitung *eps* atau semua jarak titik yang *density reachable* terhadap *p* menggunakan fungsi Euclidian Distance sebagaimana ditunjukkan dalam persamaan (1) berikut:

$$E(x, y) = \sqrt{\sum_{i=0}^n (X_i - Y_i)^2} \quad (1)$$

5. Jika titik yang memenuhi *eps* lebih dari *minPts* maka titik *p* adalah *core point* dan *cluster* terbentuk
6. Jika *p* adalah *border point* dan tidak ada titik yang *density reachable* terhadap *p*, maka proses dilanjutkan ke titik yang lain .

2.2 Titik Panas (*Hotspot*)

Menurut Anderson, *et.al.* (1999), pada awalnya *hotspot* diidentikkan dengan titik api, namun dalam kenyataannya tidak semua *hotspot* mengindikasikan adanya titik api. Istilah *hotspot* lebih tepat bila bersinonimkan dengan titik panas.

Sebuah titik panas merupakan satu *pixel* pada potret satelit adalah suatu areal 1.1 km², dimana tinggi temperatur permukaannya mengindikasikan adanya kebakaran. Panas permukaan tersebut diukur oleh satelit NOAA yang dilengkapi oleh sensor-sensor radiometer mutakhir beresolusi sangat tinggi (Heryalianto, 2006).

Hotspot adalah titik panas yang diindikasikan sebagai lokasi kebakaran hutan dan lahan. Parameter ini sudah digunakan secara meluas di berbagai negara untuk memantau kebakaran

hutan dan lahan dari satelit. Cara deteksi terjadinya kebakaran hutan dan lahan adalah dengan pengamatan titik panas (*hotspot*). Titik panas (*hotspot*) dapat dideteksi dengan satelit NOAA (National Oceanic and Atmospheric Administration) yang dilengkapi sensor AVHRR (Advanced Very High Resolution Radiometer). Dalam mendeteksi kebakaran hutan, satelit NOAA tidak mendeteksi kebakaran (suhu) secara langsung namun yang dideteksi adalah *hotspot* (Heryalianto, 2006).

Sebuah titik panas (*hotspot*) dapat mencerminkan sebuah areal yang mungkin terbakar sebagian atau seluruhnya karena itu tidak menunjukkan secara pasti seberapa besar areal yang terbakar. Jumlah titik panas (*hotspot*) dapat sangat bervariasi dari suatu pengukuran selanjutnya tergantung dari waktu pengukuran pada hari itu (aktivitas api berkurang pada malam hari dan paling tinggi pada sore hari), cuaca (sensor yang digunakan tidak dapat menembus awan dan asap) dan organisasi apa yang memberikan data tersebut (tidak terdapat standar ambang batas temperatur atau suhu untuk mengidentifikasi titik panas) (Heryalianto, 2006).

Titik panas (*hotspot*) hanya memberikan sedikit informasi apabila tidak didukung oleh analisa dan interpretasi lanjutan. Kelompok titik panas (*hotspot*) dan atau titik panas (*hotspot*) yang berjumlah besar dan berlangsung secara terus menerus adalah indikator yang baik untuk kebakaran (titik api). Data titik panas (*hotspot*) bermanfaat apabila dikombinasikan dengan informasi-informasi seperti mengenai penggunaan lahan, penutupan tanaman, habitat binatang atau peta-peta lainnya. Kesalahan bias atau geografi dari sebuah titik panas (*hotspot*) dapat sampai sejauh 3 km (Heryalianto, 2006).

3. PERANCANGAN

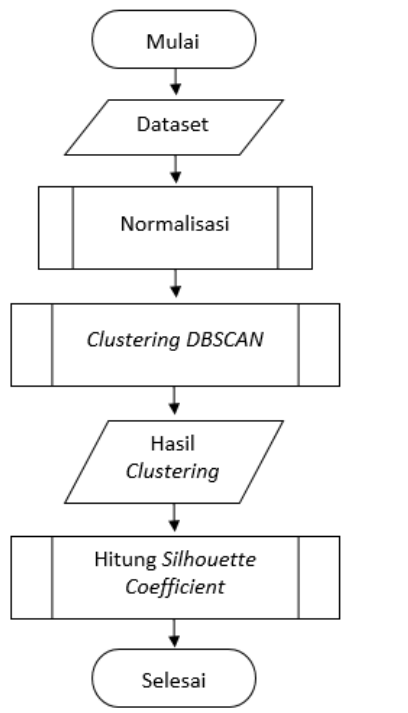
3.1 Gambaran Sistem

Secara garis besar, sistem memiliki dua proses utama, yaitu proses clustering menggunakan algoritma DBSCAN dan proses validasi sekaligus perhitungan kualitas hasil clustering (Gambar 4). Pada proses clustering dataset akan dikelompokkan ke dalam sejumlah cluster tertentu

menggunakan algoritma DBSCAN. Hasil proses tersebut kemudian divalidasi dengan menggunakan metode validasi Silhouette Coefficient (Kaufman 2009) untuk mengetahui kualitas hasil clustering seperti pada persamaan (2) berikut (Handoyo, et al., 2014; Kaufman & Rousseeuw, 1990):

$$s(i) = \frac{b(i)-a(i)}{\max(a(i),b(i))} \quad (2)$$

dimana $s(i)$ merupakan nilai Silhouette Coefficient, $a(i)$ merupakan rata-rata jarak antara titik i dengan seluruh titik dalam A (cluster dimana titik i berada), $b(i)$ adalah rata-rata jarak antara titik i ke seluruh titik dalam cluster selain A .



Gambar 3. Diagram Alir Sistem

3.2 Preprocessing

Sebelum data dikelompokkan menggunakan algoritma DBSCAN, maka data harus dipastikan sudah siap untuk diproses. Preprocessing data diperlukan untuk memastikan bahwa data telah sesuai sehingga nantinya dapat menghasilkan analisa yang tepat. Proses preprocessing dilakukan dengan melihat karakteristik data, dimana data titik panas yang digunakan memiliki 3 fitur dengan rentang nilai yang berbeda. Pada proses clustering dengan menggunakan algoritma DBSCAN, tahap perhitungan jarak antar titik data menggunakan

fungsi *Euclidean Distance*. Perbedaan rentang nilai antar fitur akan sangat mempengaruhi hasil proses clustering. Fitur yang memiliki rentang nilai yang sangat besar akan mendominasi hasil perhitungan jarak antar titik data. Oleh sebab itu, perlu dilakukan proses normalisasi untuk menyamakan rentang nilai seluruh fitur yang digunakan dengan menggunakan fungsi Normalisasi Min-max sesuai dengan persamaan (3) berikut (Fatkhayah, 2012):

$$N' = \frac{N-Min}{Max-Min} (New_{Max} - New_{Min}) + New_{Min} \quad (3)$$

dimana N' merupakan nilai hasil normalisasi N , Min nilai minimum untuk fitur x , Max nilai maksimum fitur x , new_max nilai maksimum rentang nilai baru fitur x , dan new_min nilai minimum rentang nilai fitur x .

3.3 Dataset

Data yang digunakan dalam penelitian ini adalah data persebaran titik panas di Indonesia pada periode Juni hingga Agustus 2015 yang diunduh dari halaman situs NASA. Data tersebut terdiri dari 39638 *records* dengan 13 fitur. Data yang akan digunakan dalam proses pengujian dibatasi hanya data titik panas dengan fitur *confidence* diatas 80% yang berjumlah 11171 *records*. Dari 13 fitur yang ada, hanya akan digunakan sebanyak 4 fitur. Fitur yang digunakan antara lain :

- a. *Brightness*, merupakan tingkat kecerahan suhu dari satu *pixel* api pada *channel* 21/22 diukur dalam kelvin.
- b. *Confidence*, merupakan tingkat keyakinan yang diperoleh pada saat proses deteksi titik api. Fitur *confidence* hanya berperan sebagai *filter*.
- c. *Bright_t31*, merupakan tingkat kecerahan suhu dari satu *pixel* api pada *channel* 31 diukur dalam kelvin.

Frp (fire radiative power), menggambarkan kekuatan radiasi api dalam megawatt.

4. HASIL DAN PEMBAHASAN

Pengujian dilakukan dengan mengevaluasi kualitas hasil clustering algoritma DBSCAN menggunakan Silhouette Coefficient berdasarkan kombinasi masukan dua parameter yaitu eps dan $minPts$. Hasil pengujian ditunjukkan pada tabel

berikut:

Tabel 1. Hasil Pengujian Parameter minPts

Eps	minPts	Jumlah Cluster	Jumlah Noise	Silhouette Coefficient
0.05	<u>2</u>	<u>13</u>	<u>55</u>	<u>0.674630196</u>
0.05	3	6	72	0.645304968
0.05	4	4	87	0.559303436
0.05	5	2	103	0.537567959
0.05	6	2	113	0.568013513
0.05	7	2	118	0.565573614
0.05	8	1	131	0.0
0.05	9	1	150	0.0
0.05	10	1	154	0.0

Tabel 2. Hasil Pengujian Parameter eps


Eps	minPts	Jumlah Cluster	Jumlah Noise	Silhouette Coefficient
0.05	2	13	55	0.674630196
0.10	2	4	10	0.745448544
0.15	2	2	2	0.842423282
0.20	2	2	2	0.842423282
<u>0.25</u>	<u>2</u>	<u>2</u>	<u>1</u>	<u>0.848423572</u>
0.30	2	2	0	0.844771013
0.35	2	1	0	0.0
0.40	2	1	0	0.0
0.45	2	1	0	0.0

Dari kedua skenario uji coba yang telah dilakukan, diperoleh bahwa kombinasi nilai parameter $minPts = 2$ dan $eps = 0.25$ menghasilkan nilai *Silhouette Coefficient* tertinggi yaitu 0.848423572 dengan jumlah *cluster* yang terbentuk sebanyak 2, sedangkan jumlah *noise* sebanyak 1.

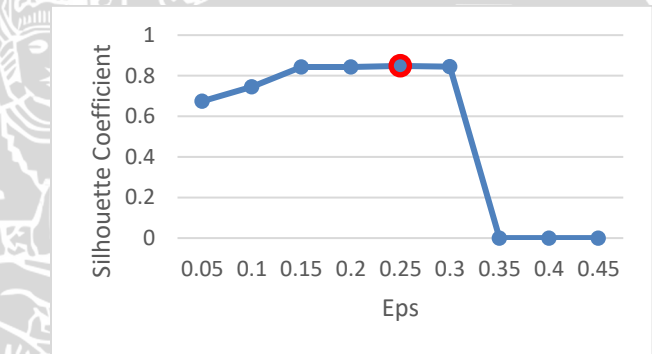
4.1 Pengaruh Nilai minpts dan eps terhadap Silhouette Coefficient

Berdasarkan hasil clustering algoritma DBSCAN pada Gambar 4 dan 5 dapat dilihat bahwa perubahan nilai masukan minPts dan eps sangat berpengaruh terhadap kualitas hasil clustering. Nilai minPts dan eps yang semakin besar akan semakin menurunkan kualitas hasil clustering. Hal tersebut dikarenakan pengaruh dari nilai eps yang semakin besar maka akan semakin luas cakupan kerapatan suatu cluster, sehingga kemungkinan obyek yang berjauhan letaknya akan dikelompokkan dalam cluster yang sama sehingga semakin memperbesar rasio jarak intra-cluster hasil clustering. Sedangkan pengaruh nilai minPts

terhadap hasil cluster adalah dengan semakin besar nilai minPts maka akan semakin sulit suatu obyek yang meskipun jaraknya saling berdekatan tetapi jika jumlah obyeknya tidak memenuhi syarat minPts (jumlah minimal obyek dalam satu cluster) maka tidak dimasukkan dalam satu cluster yang sama.



Gambar 4. Pengaruh minpts terhadap Silhouette Coefficient




Gambar 5. Pengaruh eps terhadap Silhouette Coefficient

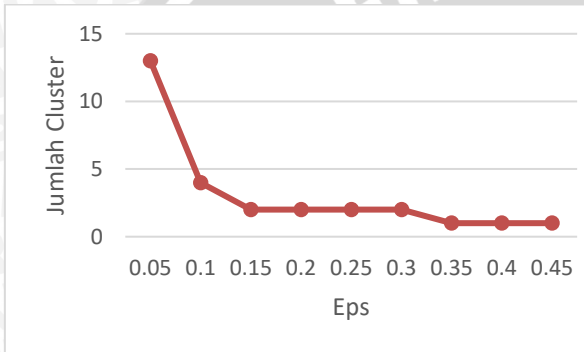
4.2 Pengaruh Nilai minpts dan eps terhadap Jumlah Cluster

Nilai eps yang semakin besar menggambarkan jarak cakupan kerapatan suatu obyek dengan obyek yang lain semakin luas sehingga kemungkinan menghasilkan cluster akan semakin besar. Hal tersebut dapat dilihat pada Gambar 7 dimana semakin besar nilai eps maka semakin sedikit jumlah cluster yang terbentuk karena semakin banyak obyek yang tergabung dalam masing-masing cluster. Sedangkan semakin besar nilai minPts akan semakin memperkecil kemungkinan terbentuknya suatu cluster. Hal tersebut dikarenakan dikarenakan syarat jumlah minimal obyek yang berdekatan dalam cluster semakin besar sehingga membutuhkan lebih

banyak obyek untuk membentuk suatu cluster, demikian pula sebaliknya.




Gambar 6. Pengaruh minpts terhadap Jumlah Cluster




Gambar 7. Pengaruh eps terhadap Jumlah Cluster

4.3 Pengaruh Nilai eps terhadap Jumlah Noise

Noise merupakan obyek yang memiliki karakteristik berbeda dibandingkan dengan sebagian besar obyek dalam dataset. Salah satu kelebihan dari algoritma DBSCAN adalah mampu dengan baik mendeteksi noise karena konsep dari algoritma DBSCAN adalah mengelompokkan obyek berdasarkan kerapatannya (density-based) dengan obyek yg lain, sehingga akan mengabaikan obyek dengan karakteristik yang tidak mirip dengan obyek disekitarnya. Berdasarkan hasil clustering dataset titik panas pada Tabel 1 dan 2 sebelumnya, maka analisa pengaruh nilai eps dan minPts terhadap jumlah noise dapat dilihat pada Gambar 8 dan 9 berikut:



Gambar 8. Pengaruh minpts terhadap Jumlah Noise



Gambar 9. Pengaruh eps terhadap Jumlah Noise

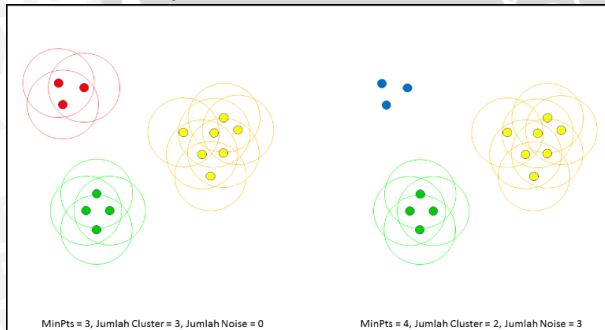
Dari Gambar 8 dapat dilihat bahwa semakin besar nilai minPts maka akan semakin tinggi jumlah noise yang dihasilkan. Hal tersebut dikarenakan kemampuan membentuk cluster dalam proses clustering menggunakan DBSCAN semakin kecil, sehingga obyek obyek yang tidak dapat membentuk cluster akan dikategorikan sebagai noise. Hal tersebut juga tergambar dari pengaruh nilai eps yang berkebalikan dengan minPts. Semakin besar nilai eps justru mengakibatkan semakin menurunnya jumlah noise yang dihasilkan. Hal tersebut disebabkan oleh pengaruh dari nilai eps yang semakin besar akan semakin memperluas cakupan area cluster sehingga kemungkinan pembentukan cluster akan semakin besar dan kemungkinan suatu obyek masuk kedalam suatu cluster juga semakin besar.

4.4 Analisis Pengujian Kualitas Hasil Clustering

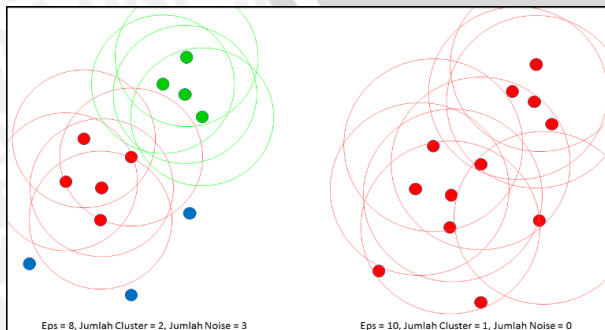
Dari hasil pengujian yang dilakukan, perubahan nilai parameter *minPts* dan *eps* sangat mempengaruhi kualitas *cluster* yang dibentuk. Dari hasil tersebut dapat diambil kesimpulan bahwa semakin besar nilai *minPts* maka nilai *Silhouette*

Coefficient akan relatif turun. Hal ini kemungkinan disebabkan ketika *minPts* dinaikkan terdapat *cluster* yang tidak memenuhi syarat *minPts* tersebut. Sehingga hilangnya *cluster* tersebut berpeluang mengakibatkan turunnya jarak *inter-cluster* sehingga nilai *Silhouette Coefficient* relatif akan turun. Selain itu jumlah *cluster* yang dibentuk akan semakin kecil, tetapi jumlah *noise* akan semakin banyak. Hal ini dikarenakan semakin besar nilai *minPts* maka kriteria terbentuknya sebuah *cluster* akan semakin sulit, sehingga peluang titik dianggap sebagai *noise* akan semakin besar seperti yang diilustrasikan pada Gambar 10.

Sedangkan semakin besar nilai *eps* maka nilai *Silhouette Coefficient* seharusnya relatif turun. Hal ini disebabkan karena semakin luas cakupan dari suatu *cluster* akan meningkatkan rata-rata jarak antar titik dalam satu *cluster*. Selain itu, semakin besar *eps* akan menghasilkan jumlah *cluster* dan jumlah *noise* semakin sedikit. Hal ini dikarenakan semakin besar nilai *eps* maka, peluang sebuah titik masuk kedalam suatu *cluster* akan semakin besar sehingga *cluster* yang terbentuk akan semakin sedikit dan peluang sebuah titik dianggap sebagai *noise* akan semakin kecil juga seperti yang diilustrasikan pada Gambar 11.



Gambar 10. Ilustrasi Pengaruh Parameter MinPts



Gambar 11. Ilustrasi Pengaruh Parameter Eps

4.5 Analisis Pengujian Kualitas Hasil Clustering

Tabel 3. Tingkat Potensi Terjadinya Kebakaran

Cluster	Rata-Rata Brightness (K)
Cluster 2	478.5
Cluster 1	336.3

Pada Tabel 6.3 merupakan hasil *clustering* menggunakan algoritma DBSCAN dengan *minPts* = 2 dan *eps* = 0.25 yang menghasilkan 2 *cluster*. Dari hasil tersebut *cluster* ke 2 memiliki rata-rata suhu permukaan (*brightness*) lebih tinggi dibandingkan dengan *cluster* ke 1, yang artinya *cluster* ke 2 memiliki tingkat potensi kebakaran lebih tinggi dibandingkan *cluster* ke 1.

5. KESIMPULAN

Berdasarkan hasil perancangan, implementasi dan pengujian yang telah dilakukan maka dapat diambil kesimpulan sebagai berikut :

- Algoritma DBSCAN dapat diimplementasikan untuk mengelompokkan titik panas ke dalam 2 tingkat potensi terjadinya kebakaran.
- Clustering* menggunakan algoritma DBSCAN menghasilkan hasil yang cukup bagus dengan cukup tingginya nilai *Silhouette Coefficient* pada proses pengujian.

6. DAFTAR PUSTAKA

[1] Devi, N. M. A. S., Putra, I. K. G. D. & Sukarsa, I. M., 2015. Implementasi Metode Clustering DBSCAN pada Proses Pengambilan Keputusan, Bukit Jimbaran: Lontar Komputer Vol.6, No.3.

[2] Fadli, A., 2011. *Konsep Data Mining*. [Online] Available at: <http://ilmukomputer.org/2011/03/14/konsep-data-mining/> [Accessed 2 Maret 2016].

[3] Fatkhiyah, E., 2012. *Rancangan Proses Training Untuk Mendukung Penentuan Kualitas Air Minum Kemasan*, Yogyakarta: Prosiding Seminar Nasional Aplikasi Sains & Teknologi (SNAST) Periode III.

[4] Handoyo, R., Mangkudjaja, R. & Nasution, S. M., 2014. *Perbandingan Metode Clustering Menggunakan Metode Single Linkage dan K - Means Pada Pengelompokan Dokumen*, Bandung: JSM STMIK Mikroskil Vol. 15, No. 2.

[5] Heryaliyanto, S. C., 2006. *Studi Tentang Sebaran Titik Panas (Hotspot) Sebagai Penduga Kebakaran Hutan Dan Lahan Di Propinsi Kalimantan Barat Tahun 2003 Dan Tahun 2004*. Bogor: Institut Pertanian Bogor.

[6] Kaufman, L. & Rousseeuw, P. J., 1990. *Finding Groups in Data : An Introduction to Cluster Analysis*. Canada: John Wiley & Sons, Inc.

[7] Liman, N. S., I. S. & I. S. M., 2014. *Implementasi Algoritma Density-Based Spatial Clustering of Application with Noise (DBSCAN) Pada Mesin Pencari Dokumen Hasil Penelitian*, Malang: Teknik Informatika Universitas Brawijaya.

[8] Putri, W. D., 2015. *BNPB Catat Kerugian Akibat Kebakaran Hutan 2015 Rp 221 Triliun*. [Online] Available at: <http://www.republika.co.id/berita/nasional/umum/15/12/20/nzms82359-bnpb-catat-kerugian-akibat-kebakaran-hutan-2015-rp-221-triliun> [Accessed 2 Maret 2016].

[9] Usman, M., 2014. *Spatial Clustering Berbasis Densitas Untuk Persebaran Titik Panas Sebagai Indikator Kebakaran Hutan Dan Lahan Gambut Di Sumatera*, Bogor: Pascasarjana Institut Pertanian Bogor.

[10] Zakariya, A. Z., Djunaidy, A. & Kusumawardani, R. P., 2012. *Pembuatan Aplikasi Pendeteksi Anomali Pada Pola Konsumsi Listrik Pelanggan Kota Surabaya Menggunakan Algoritma Klasterisasi Berbasis Densitas*, Surabaya: Jurnal Teknik Pomits Vol. 1, 1-5.