

Clustering Titik Panas Bumi Pada Potensi Kebakaran Hutan Menggunakan K-Affinity Propagation

Geothermal Hotspot Clustering on Forest Fire Potential Using K-Affinity Propagation

Sudhan Primantoro^{1a)}, Rito Goejantoro², dan Surya Prangga³

^{1,2,3}Laboratorium Statistika Komputasi, Jurusan Matematika, FMIPA Universitas Mulawarman, Indonesia

^{a)} Corresponding author: *sudanp11@gmail.com*

ABSTRACT

K-Affinity Propagation is a development of affinity propagation from Brendan J. Frey and Delbert Dueck. The purpose of this research is to cluster geothermal hotspots on potential forest fires in Indonesia using K-Affinity Propagation for the period July 2022 and obtain optimal cluster results using standard deviation with ratio calculations. The optimal cluster results are 4 clusters, with the number of members in cluster 1 being 12 members with copies in West Sumatera Province, the number of members in cluster 2 being 12 members with copies in Southeast Sulawesi Province, the number of members in cluster 3 being 4 members with copies in Central Sulawesi Province, the number of members in cluster 4 being 1 member with copies in North Sulawesi Province. The optimal cluster results using standard deviation with the smallest ratio value is cluster 4 with a ratio value of 0.057.

Keywords: *k-affinity propagation, hotspots, standard deviations, exemplars, cluster*

1. Pendahuluan

Kebakaran hutan merupakan peristiwa yang menjadi perhatian masyarakat Indonesia. Menurut Peraturan Menteri Kehutanan Nomor: P.12/Menhut-II/2009, salah satu permasalahan lingkungan hidup utama yang menimbulkan kesulitan di bidang sosial, ekologi, dan ekonomi adalah kebakaran hutan. Kebakaran hutan sering terjadi akibat banyaknya titik panas yang terdeteksi di Indonesia dan juga ulah manusia yang berdampak pada sistem pencemaran udara (FWI, 2013). Teknologi penginderaan jauh yaitu satelit Terra/Aqua dengan sensor MODIS NASA dapat digunakan untuk memantau terjadinya kebakaran hutan. Kebakaran hutan dideteksi sebagai titik-titik api yang terindikasi atau berpotensi sebagai titik panas bumi. Titik panas permukaan bumi memiliki suhu relatif lebih tinggi dari permukaan lainnya (LAPAN, 2016).

Keberadaan titik panas mengindikasikan adanya suhu tinggi yang bisa jadi berpotensi kebakaran atau bisa juga titik panas tersebut hanya menunjukkan suhu tinggi tanpa potensi kebakaran. Oleh karena itu dilakukan *clustering* untuk menentukan apakah titik panas di area tertentu berpotensi tinggi atau rendah untuk mengalami kebakaran hutan sehingga dapat dilakukan tindakan pencegahan agar tidak menimbulkan kerugian yang lebih besar. Salah satu alat paling penting untuk analisis data adalah *clustering*, yang menemukan beberapa struktur mendasar dalam kumpulan item. Untuk secara otomatis mengatur hal-hal yang sebanding ke dalam satu kelompok dan membedakannya satu sama lain, menggunakan algoritma *clustering* untuk membagi sekumpulan objek atau titik data menjadi banyak kelompok (Guojun, G. & Michael, K., 2014). Dalam penelitian ini akan menggunakan metode *clustering K-Affinity Propagation*.

K-Affinity Propagation (K-AP) merupakan metode yang diadaptasi dari metode *Affinity Propagation* (AP) dengan tujuan menggunakan metode AP untuk menghasilkan jumlah *exemplars* yang ideal. Penelitian sebelumnya mengenai K-AP sudah pernah dilakukan oleh Sari, N.N., & Muhajir, M. pada tahun 2018 didapatkan hasil Metode *K-Affinity Propagation* lebih stabil dibandingkan *K-Means*, didapatkan kluster yang optimal sebanyak 4. Apriliana, A.S. & Muhajir, M. (2019) melakukan *clustering* dengan metode K-AP dan GIS pada akun Instagram destinasi wisata di Jawa, di mana didapatkan 410 destinasi wisata di Pulau Jawa 2018 dengan memposting di akun Instagram wisata, dengan terbagi menjadi 3 kategori yaitu alam memiliki persentase 50%, budaya memiliki persentase 43%, dan kategori buatan manusia memiliki persentase 7%.

Dari permasalahan dan penjelasan dari beberapa penelitian mengenai titik panas bumi dan metode *K-Affinity Propagation*, maka peneliti akan mencoba mengimplementasikan metode *K-Affinity Propagation*. Oleh karena itu judul yang diangkat yaitu “*Clustering Titik Panas Bumi Pada Potensi Kebakaran Hutan Menggunakan K-Affinity Propagation*”.

2. Tinjauan Pustaka

2.1 Analisis Kluster

Kluster adalah proses pengelompokan data menjadi beberapa kelompok sehingga objek di dalam satu kelompok memiliki banyak kesamaan dan memiliki banyak perbedaan dengan objek di kelompok. Perbedaan dan persamaannya biasanya berdasarkan nilai atribut dari objek tersebut dan dapat juga berupa perhitungan jarak (Han, dkk. 2012). Menurut Mulaab (2017), analisis kluster ialah proses pengelompokan satu *set* benda

fisik atau abstrak ke dalam kelas objek yang sama. Kluster adalah sekumpulan objek-objek data yang *similar* antar satu sama lain dalam kelompok yang sama dan *dissimilar* terhadap objek-objek yang berbeda kelompok. Objek akan dikelompokkan ke dalam satu atau lebih kelompok sehingga objek-objek yang berada dalam satu kelompok akan mempunyai kesamaan yang tinggi antara satu dengan lainnya. *Clustering* merupakan salah satu metode data *mining* yang bersifat *unsupervised*, maksudnya metode ini diterapkan tanpa adanya latihan (*training*) dan tanpa guru (*teacher*) serta tidak membutuhkan target *output*. *Clustering* memegang peranan penting dalam aplikasi *data mining*, misalnya pengaksesan informasi, *text mining*, aplikasi basis data dan analisis web.

2.1. K-Affinity Propagation

K-Affinity Propagation (K-AP) merupakan metode yang diadaptasi dari metode *Affinity Propagation* (AP) dengan tujuan menggunakan metode AP untuk menghasilkan jumlah *exemplars* yang ideal. Teknik pengelompokan baru yang disebut K-AP dapat menemukan *exemplars* di antara semua titik data, dan kemudian menggunakan titik data di sekitar contoh tersebut untuk membuat kluster. Menentukan K ideal dengan membandingkan banyaknya indeks dan menemukan K yang optimal (Muhajir & Sari, 2019).

Berdasarkan persyaratan dan kriteria yang telah ditentukan, K-AP dapat menghasilkan K kluster dengan menetapkan aturan atau kontrol dalam proses pengiriman pesan. Keuntungan lain dari K-AP adalah, tidak seperti kepercayaan pada AP yang merupakan parameter yang ditentukan pengguna, kepercayaan terhadap salah satu objek menjadi contoh, yang kemudian secara otomatis diadaptasi oleh K-AP. Selain itu, K-AP memiliki biaya *overhead* komputasi yang lebih rendah dibandingkan AP karena penggunaan memori yang lebih sedikit selama pemrosesan. Algoritma K-AP sebagai berikut (Zhang, dkk, 2010):

1. Memasukkan matriks *similarity*

$$\{s(i, k)_{i, k \in (1, \dots, N) i \neq k}, K\} \tag{1}$$

2. Menginisialisasikan matriks *availability* dan *confidence*

$$\forall i, k : a(i, k) = 0 \tag{2}$$

$$\forall i : \eta^{keluar}(i) = \min(s) \tag{3}$$

3. Memperbarui matriks *responsibility*

$$r(i, k) = s(i, k) - \max\{\eta^{keluar}(i) + a(i, k), \max_{k': k' \notin (i, k)} \{a(i, k') + s(i, k')\}\} \tag{4}$$

4. Memperbarui *self-responsibility*

$$r(i, k) = \eta^{keluar}(i) - \max_{k': k' \neq i} \{a(i, k') + s(i, k')\} \tag{5}$$

5. Memperbarui matriks *availability*

$$a(i, k) = \min\{0, r(k, k) + \sum_{i': i' \notin (i, k)} \max\{0, r(i', k)\}\} \tag{6}$$

6. Memperbarui *self-availability*

$$a(k, k) = \sum_{i': i' \neq (k)} \max\{0, r(i', k)\} \tag{7}$$

7. Memperbarui *confidence*

$$\eta^{masuk}(i) = a(i, i) - \max_{k': k' \neq i} \{a(i, k') + s(i, k')\} \tag{8}$$

$$\eta^{keluar}(i) = -R^k(\{\eta^{masuk}(j), j \neq i\}) \tag{9}$$

8. Kombinasi *availability* dan *responsibility*

$$c(i, k) = \arg \max_j \{a(i, k) + r(i, k)\} \tag{10}$$

Keterangan:

- a* : *availability*
- r* : *responsibility*
- s* : *similarity*
- $\eta^{masuk}(i), \eta^{keluar}(i)$: *confidence*
- k'* : kandidat nilai *exemplars* lain/ nilai max dari keseluruhan.
- Arg max : hasil dari nilai *availability* dan *responsibility* yang maksimum
- $R^k(\{\eta^{masuk}(j), j \neq i\})$: nilai k terbesar dari η^{masuk} .

2.3 Deviasi Standar

Menurut (Bunkers, dkk, 1996) nilai deviasi standar dapat digunakan untuk menilai kebaikan dari suatu klaster, adapun persamaan (11) deviasi standar dalam klaster sebagai berikut:

$$S_w = K^{-1} \sum_{k=1}^K S_k \tag{11}$$

di mana S_k merupakan deviasi standar untuk variabel tertentu pada klaster ke- K . Adapun persamaan (12) dari deviasi standar antar klaster sebagai berikut:

$$\begin{aligned} S_B &= \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}} \\ &= \sqrt{\frac{\sum_{i=1}^n (X_i^2 - 2\bar{X}X_i + \bar{X})}{n-1}} \\ &= \sqrt{\frac{\sum_{i=1}^n X_i^2 - 2 \frac{\sum X_i}{n} \sum X_i + n \left(\frac{\sum X_i}{n}\right)^2}{n-1}} \\ &= \sqrt{\frac{\sum_{i=1}^n X_i^2 - 2 \frac{\sum X_i}{n} \sum X_i + \frac{(\sum X_i)^2}{n}}{n-1}} \\ &= \sqrt{\frac{\sum_{i=1}^n X_i^2 - 2 \frac{(\sum X_i)^2}{n} + \frac{(\sum X_i)^2}{n}}{n-1}} \\ &= \sqrt{\frac{\sum_{i=1}^n X_i^2 - \frac{(\sum X_i)^2}{n}}{n-1}} \end{aligned} \tag{12}$$

$$S = \frac{S_w}{S_B} \tag{13}$$

Keterangan:

- S_B : Deviasi Standar antar klaster
- S_w : Deviasi Standar dalam klaster
- \bar{X} : Rata-rata total untuk seluruh K klaster
- X_i : Data awal ke- I

Pendekatan yang dihasilkan dari pembagian S_w dan S_b dengan nilai rasio terkecil adalah pendekatan yang optimal. Suatu klaster dianggap terbentuk dengan baik jika klaster tersebut menunjukkan tingkat variabilitas yang tinggi antar klaster dan tingkat kesamaan (homogenitas) yang tinggi di antara anggotanya.

2.4 Standarisasi Data

Standarisasi data adalah mengubah skala data ke dalam bentuk lain sehingga data memiliki distribusi yang diharapkan. Setiap data dilakukan operasi matematika yang sama pada data aslinya. Berarti kita mengubah semua data untuk menjaga perbedaan antar data relatif tetap. Dapat digunakan teknik standarisasi dengan menentukan nilai rata dan varian dalam persamaan sebagai berikut:

Cara menghitung nilai standarisasi data dapat dilihat pada Persamaan (14).

$$Z_{i,l} = \frac{X_{i,l} - \bar{X}_l}{S_l} \tag{14}$$

di mana nilai rata-rata \bar{X}_l dihitung menggunakan Persamaan (15) sebagai berikut.

$$\bar{X}_l = \frac{1}{n} \sum_{i=1}^n X_{i,l} \tag{15}$$

selanjutnya nilai deviasi standar dihitung menggunakan Persamaan (16).

$$S_l = \sqrt{\frac{\sum_{i=1}^n X_{i,l}^2 - \frac{(\sum X_{i,l})^2}{n}}{n-1}} \tag{16}$$

dengan,

- n : banyak pengamatan
- $X_{i,l}$: data ke- i variabel ke- l

- \bar{X}_l : rata-rata variabel ke- l
 S_l : deviasi standar variabel ke- l
 $Z_{i,l}$: standardisasi data ke- i pada variabel ke- l

3. Metodologi Penelitian

3.1. Waktu dan Tempat Penelitian

Penelitian dilaksanakan pada bulan April 2023 sampai dengan Maret 2024. Penelitian ini dilakukan di Laboratorium Statistika Komputasi Gedung B Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Mulawarman (FMIPA Unmul) yang beralamatkan di Jalan Barong Tongkok Kampus Gunung Kelua Samarinda.

3.2 Rancangan Penelitian

Rancangan penelitian ini merupakan penelitian non eksperimen karena data yang digunakan berupa data sekunder, yaitu data yang diperoleh dari situs resmi NASA LANCE FIRM MODIS Active Fire. Penelitian ini bersifat *ex post facto*, artinya data dikumpulkan setelah semua kejadian yang dipersoalkan berlangsung atau telah berlalu (Suryabrata, 2003). Penelitian ini dilakukan dengan cara mengumpulkan data berdasarkan persebaran titik panas yang kemudian digunakan sebagai bahan untuk penelitian ini.

3.3 Populasi dan Sampel Penelitian

Populasi dalam penelitian ini adalah persebaran titik panas bumi di Indonesia. Sedangkan sampel dalam penelitian ini adalah persebaran titik panas bumi di Indonesia pada bulan Juli 2022.

3.4 Teknik Sampling

Teknik sampling yang digunakan pada penelitian ini adalah *purposive sampling* di mana peneliti mempertimbangkan sampel yang menyesuaikan keadaan penelitian seperti data potensi kebakaran hutan di Indonesia pada tahun 2022 berdasarkan persebaran titik panas sehingga dapat menggambarkan keadaan puncak musim panas di Indonesia pada bulan Juli 2022.

3.5 Teknik Pengumpulan Data dan Teknik Analisis Data

Data sekunder diperoleh dari situs web resmi dari NASA LANCE FIRM MODIS Active Fire yaitu https://firms.modaps.eodis.nasa.gov/active_fire/. Data yang digunakan yaitu data titik panas pada periode Juli 2022 di Indonesia. Variabel penelitian meliputi *latitude*, *longitude*, *brightness temperature*, *confidence*, dan *fire radiative power* (FRP) di Indonesia bulan Juli tahun 2022. Tahap perhitungan pada proses implementasi *K-Affinity Propagation Clustering* titik panas bumi dilakukan dengan langkah-langkah sebagai berikut:

1. Mendeskripsikan data
2. Melakukan perhitungan Standardisasi data
3. Melakukan Perhitungan algoritma *K-Affinity Propagation*
 - a. Menentukan jumlah *exemplars*
 - b. Melakukan perhitungan terhadap nilai Matriks *similarity* untuk memberikan informasi tentang kesamaan antar setiap *exemplars*.
 - c. Melakukan perhitungan terhadap nilai Matriks *Responsibility* mengukur kecocokan elemen k untuk menjadi *exemplars* pada elemen i .
 - d. Melakukan perhitungan terhadap nilai Matriks *Availability* untuk mengkuantifikasi seberapa tepat bagi i untuk memilih k sebagai *exemplars*, dengan mempertimbangkan dukungan komponen lain sehingga k perlu dijadikan *exemplars*.
 - e. Melakukan perhitungan perulangan untuk memperbaharui nilai *responsibility*, *availability*, dan *confidence*.
 - f. Dilakukan iterasi sampai hasil nilai kombinasi *availability* dan *responsibility* tidak berubah atau mendapatkan hasil yang sama pada perhitungan sebelum dan sesudahnya *availability* dan *responsibility* dapat dikatakan iterasi selesai.
4. Mendapatkan hasil kluster
5. Melakukan perhitungan nilai deviasi standar
6. Menentukan kluster optimal

4. Hasil dan Pembahasan

4.1 Statistika Deskriptif

Deskripsi untuk variabel-variabel yang digunakan. Variabel-variabel tersebut adalah data titik panas atau *hotspot* yang berisikan informasi berupa nilai *latitude*, *longitude*, *brightness temperature*, *confidence*, dan *fire radiative power* untuk 29 Provinsi di Indonesia yang diperoleh dari hasil pemantauan satelit MODIS. Nilai-nilai ukuran data yang mendeskripsikan kelima variabel tersebut ditunjukkan pada Tabel 1.

Tabel 1. Statistika Deskriptif Persebaran Titik Panas di Indonesia

	Rata-rata	deviasi standar	Minimum	Maksimum
<i>Brightness</i>	315,300	2,452	309,525	319,865
<i>Confidence</i>	55,211	11,984	7,167	69,844
<i>FRP</i>	16,020	7,263	7,600	40,831

Berdasarkan Tabel 1 dapat diketahui bahwa nilai rata-rata *brightness temperature* yaitu sebesar 315,300, deviasi standar *brightness temperature* sebesar 2,452 Nilai deviasi standar lebih rendah daripada nilai rata-rata sehingga data kurang bervariasi. Nilai terendah *brightness temperature* adalah sebesar 309.525 yang terletak pada Provinsi Banten, dan nilai tertinggi *brightness temperature* adalah sebesar 319,865 yang terletak pada Provinsi Kalimantan Barat. Nilai rata-rata *confidence* yaitu sebesar 55,211, deviasi standar *confidence* sebesar 11,984 nilai deviasi standar lebih tinggi daripada nilai rata-rata sehingga data bervariasi. Nilai terendah *confidence* adalah sebesar 7,167 yang terletak pada Provinsi Sulawesi Utara, dan nilai tertinggi *confidence* adalah sebesar 69,844 yang terletak pada Provinsi Sulawesi Selatan. Kemudian nilai rata-rata FRP yaitu sebesar 16,020, deviasi standar FRP sebesar 7,263 nilai deviasi standar lebih rendah daripada nilai rata-rata sehingga data kurang bervariasi. Nilai terendah FRP adalah sebesar 1,184 yang terletak pada Provinsi Maluku Utara, dan nilai tertinggi FRP adalah sebesar 15,250 yang terletak pada Provinsi Jambi.

4.2 Hasil Kluster Berdasarkan Metode K-Affinity Propagation

Proses *clustering K-Affinity Propagation* dimulai dengan mencari nilai kesamaan (*similarity*) tiap data yang telah distandardisasi. Dilanjutkan menentukan *responsibility* menggunakan hasil dari proses *similarity*, setelah ditemukan nilai *responsibility* dilanjutkan mencari nilai *availability*. Dalam melakukan proses *responsibility* dan *availability* dilakukan iterasi sampai konvergen, dimana nilai *availability* tidak berubah dalam iterasi selanjutnya. Kemudian dilakukan penjumlahan nilai *responsibility* dan *availability* untuk menentukan kluster.

Pada perhitungan menggunakan bantuan *software R*, diperoleh hasil kluster K=2 pada jumlah iterasi ke 128. Adapun hasil *exemplars* dari tiap kluster dengan menggunakan K=2 disajikan pada Tabel 2.

Tabel 2. *Exemplars* dan Kluster K=2 Pada Persebaran Titik Panas di Indonesia

Kluster	<i>Exemplars</i>	Anggota	Jumlah
1	Sumatera Selatan	Aceh, Sumatera Utara, Riau, Sumatera Barat, Jambi, Sumatera Selatan, Lampung, Bangka Belitung, Jawa Tengah, Kalimantan Barat, Kalimantan Timur, Kalimantan Utara, Sulawesi Tengah, Sulawesi Selatan, Nusa Tenggara Barat, Kepulauan Riau.	16
2	Sulawesi Tenggara	Banten, Jawa Barat, Jawa Timur, Kalimantan Tengah, Kalimantan Selatan, Sulawesi Tenggara, Sulawesi Utara, Gorontalo, Maluku, Papua, Nusa Tenggara Timur, Maluku Utara, Papua Barat.	13

Setelah dilakukan perhitungan kluster pada K=2, maka dilakukan perhitungan pada K=3. Pada perhitungan K=3 juga menggunakan bantuan *software R* dan diperoleh hasil kluster K=3 pada jumlah iterasi ke 143. Adapun hasil *exemplars* dari tiap kluster dengan menggunakan K=3 disajikan pada Tabel 3.

Tabel 3. *Exemplars* dan Kluster K=3 Pada Persebaran Titik Panas di Indonesia

Kluster	<i>Exemplars</i>	Anggota	Jumlah
1	Sumatera Barat	Aceh, Sumatera Utara, Riau, Sumatera Barat, Jambi, Sumatera Selatan, Lampung, Bangka Belitung, Jawa Tengah, Kalimantan Barat, Kalimantan Timur, Kepulauan Riau.	12
2	Sulawesi Tenggara	Banten, Jawa Barat, Jawa Timur, Kalimantan Tengah, Kalimantan Selatan, Sulawesi Tenggara, Sulawesi Utara, Gorontalo, Maluku, Nusa Tenggara Timur, Nusa Tenggara Barat, Maluku Utara, Papua Barat.	13
3	Sulawesi Tengah	Kalimantan Utara, Sulawesi Tengah, Sulawesi Selatan, Papua.	4

Setelah dilakukan perhitungan kluster pada K=3, maka dilakukan perhitungan pada K=4. Pada perhitungan K=4 juga menggunakan bantuan *software R* dan diperoleh hasil kluster K=4 pada jumlah iterasi

ke 165. Adapun hasil *exemplars* dari tiap kluster dengan menggunakan $K=4$ disajikan pada Tabel 4.

Tabel 4. *Exemplars* dan Kluster $K=4$ Pada Persebaran Titik Panas di Indonesia

Kluster	<i>Exemplars</i>	Anggota	Jumlah
1	Sumatera Barat	Aceh, Sumatera Utara, Riau, Sumatera Barat, Jambi, Sumatera Selatan, Lampung, Bangka Belitung, Jawa Tengah, Kalimantan Barat, Kalimantan Timur, Kepulauan Riau.	12
2	Sulawesi Tenggara	Banten, Jawa Barat, Jawa Timur, Kalimantan Tengah, Kalimantan Selatan, Sulawesi Tenggara, Gorontalo, Maluku, Nusa Tenggara Timur, Nusa Tenggara Barat, Maluku Utara, Papua Barat.	12
3	Sulawesi Tengah	Kalimantan Utara, Sulawesi Tengah, Sulawesi Selatan, Papua.	4
4	Sulawesi Utara	Sulawesi Utara.	1

Setelah dilakukan perhitungan kluster pada $K=4$, maka dilakukan perhitungan pada $K=5$. Pada perhitungan $K=5$ juga menggunakan bantuan *software R* dan diperoleh hasil kluster $K=5$ pada jumlah iterasi ke 159. Adapun hasil *exemplars* dari tiap kluster dengan menggunakan $K=5$ disajikan pada Tabel 5.

Tabel 5. *Exemplars* dan Kluster $K=5$ Pada Persebaran Titik Panas di Indonesia

Kluster	<i>Exemplars</i>	Anggota	Jumlah
1	Sumatera Barat	Aceh, Sumatera Utara, Riau, Sumatera Barat, Jambi, Sumatera Selatan, Lampung, Bangka Belitung, Kalimantan Barat, Kalimantan Timur, Kepulauan Riau.	11
2	Sulawesi Tenggara	Banten, Jawa Barat, Kalimantan Tengah, Kalimantan Selatan, Sulawesi Tenggara, Gorontalo, Maluku, Maluku Utara, Papua Barat.	9
3	Sulawesi Tengah	Kalimantan Utara, Sulawesi Tengah, Sulawesi Selatan.	3
4	Sulawesi Utara	Sulawesi Utara.	1
5	Nusa Tenggara Timur	Jawa Tengah, Jawa Timur, Papua, Nusa Tenggara Timur, Nusa Tenggara Barat.	5

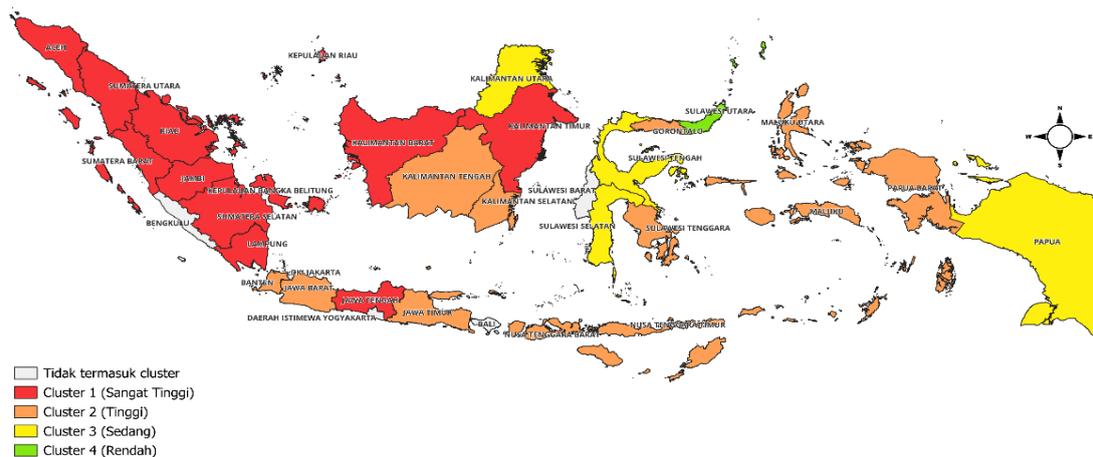
4.3 Evaluasi Kluster Terbaik

Kluster terbaik dipilih berdasarkan nilai rasio terkecil. Adapun hasil perhitungan kluster optimal menggunakan deviasi standar kluster pada data persebaran titik panas di Indonesia pada semua kluster disajikan pada Tabel 6.

Tabel 6. Hasil Perhitungan Kluster Optimal

Kluster K	S_w	S_b	Rasio
2	1,919	12,700	0,151
3	1,791	10,063	0,178
4	1,230	21,531	0,057
5	1,043	0,643	1,643

Berdasarkan Tabel 6 dapat dilihat bahwa kluster menggunakan metode K-AP dengan jumlah kluster 2 memiliki nilai rasio sebesar 0,151, jumlah kluster 3 memiliki nilai rasio sebesar 0,178, jumlah kluster 4 memiliki nilai rasio sebesar 0,057 dan untuk jumlah kluster 5 memiliki nilai rasio sebesar 1,643. Berdasarkan hal tersebut, maka kluster 4 lebih baik digunakan untuk melakukan pengelompokan persebaran titik panas di Indonesia. Hal tersebut dikarenakan jumlah kluster pada $K=4$ memiliki nilai *rasio* terkecil. Hasil kluster terbaik persebaran titik panas di Indonesia dalam *spatial mapping* disajikan pada Gambar 1.



Gambar 1. Kluster Optimal Pada Persebaran Titik Panas di Indonesia

5. Kesimpulan

Hasil kluster optimal pada persebaran titik panas di Indonesia pada Juli 2022 menggunakan *K-Affinity Propagation* terbagi atas kategori sangat tinggi, tinggi, sedang, dan rendah. Kluster 1 terdapat 12 Provinsi yang bergabung dengan *exemplars* provinsi Sumatera Barat dengan tingkat potensi kebakaran hutan sangat tinggi. Pada kluster 2 terdapat 12 provinsi dengan *exemplars* provinsi Sulawesi Tenggara dengan tingkat potensi kebakaran hutan yang tinggi. Selanjutnya, pada kluster 3 terdapat 4 provinsi dengan *exemplars* provinsi Sulawesi Tengah dengan tingkat potensi kebakaran hutan sedang. Kemudian, pada kluster 4 terdapat 1 provinsi dengan *exemplars* provinsi Sulawesi Utara dengan tingkat potensi kebakaran hutan rendah. Sedangkan pada provinsi Jakarta, Yogyakarta, Bali dan Sulawesi Utara tidak termasuk ke dalam kluster karena tidak ada kebakaran hutan.

6. Daftar Pustaka

- Apriliana, A. dan Muhajir, M. (2019). “*K-Affinity Propagation Clustering and GIS on Instagram Account of Tourist Destination in Java*,” *SEMANTIK*, pp. 122-129.
- Bunkers, M. J., Miller, J. R., & DeGaetano, A. T. (1996). Definition of climate regions in the northern plains using an objective cluster modification technique. *Journal of Climate*, 9 (1), 130-146.
- FWI. (2013). *Kebakaran Hutan dan Lahan: Bukan Bencana Alam, Awal Bencana Ekologi*. Tersedia di: <http://fwi.or.id/publikasi/kebakaran-hutan-dan-lahan-bukan-bencana-alam-awal-bencana-ekologi>, diakses pada 30 November 2023.
- Guojun, G. dan Michael, K. (2014). “*Subspace Clustering Using Affinity Propagation*,”.
- Han, J., Kamber, M. & Pei, J. (2012). *Data Mining Concepts and Techniques Third Edition*. Waltham USA: Pearson Education, Inc.
- LAPAN. (2016). *Panduan Teknis (V.01) Informasi Titik Panas (Hotspot) Kebakaran Hutan/Lahan*. Jakarta: Pusat Pemanfaatan Penginderaan Jauh Deputy Bidang Penginderaan Jauh-LAPAN, Tersedia di: <http://modis-catalog.lapan.go.id/monitoring>, diakses pada 9 Februari 2023.
- Muhajir, M., & Sari, N.N. (2019). *K-Affinity Propagation (K-AP) and K-Means Clustering for Classification of Earthquakes in Indonesia*. *Proceeding – 2018 International Symposium on Advanced Intelligent Informatics: Revolutionize Intelligent Informatics Spectrum for Humanity, SAIN 2018*, 6-10.
- Mulaab. (2017). *Data Mining Konsep dan Aplikasi*. Media Nusa Creative.
- Zhang, X., Wang, W., Norvag, K., & Sebag, M. (2010). K-AP: Generating specified K clusters by efficient Affinity Propagation. *Proceedings- IEEE International Conference on Data Mining, ICDM*, December, 1187-1192.