



Analisis Klasterisasi Kerawanan Gempa Bumi di Provinsi Papua Menggunakan Algoritma *Invasive Weed Optimization* (IWO)

Lorna Yertas Baisa^{#1}, Danny Manongga^{#2}, Yessica Nataliani^{#3}

[#]Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana, Salatiga
Jl. O. Notohamidjojo 1-10, Blotongan, Salatiga, Jawa Tengah 50715

¹1972021019@student.uksw.edu

²danny.manongga@uksw.edu

³yessica.nataliani@uksw.edu

Abstrak— Gempa bumi adalah fenomena alam yang sering terjadi di Indonesia, termasuk di Provinsi Papua. Untuk mengurangi risiko dampak gempa bumi, diperlukan analisis untuk mengidentifikasi daerah-daerah yang rawan terhadap gempa bumi. Penelitian ini bertujuan untuk menganalisis klasterisasi kerawanan gempa di Provinsi Papua menggunakan algoritma *Invasive Weed Optimization* (IWO). Metode ini dipilih karena dapat menghasilkan klaster yang lebih baik dibandingkan dengan algoritma klasterisasi lainnya. Data yang digunakan adalah data kejadian gempa di Provinsi Papua yang terdiri dari atribut *latitude*, *longitude*, *magnitude*, dan *depth* mulai tahun 2018 sampai Februari 2023 yang diperoleh dari *website* Badan Geologi Amerika Serikat yaitu *United States Geological Survey* (USGS). Tahapan penelitian meliputi normalisasi data, klasterisasi menggunakan algoritma IWO, dan evaluasi hasil klasterisasi menggunakan SSE dan *F-Measure*. Jumlah klaster terbaik yang dihasilkan oleh metode Elbow yaitu sebanyak enam klaster kerawanan gempa di Provinsi Papua, yang diberi label Sangat Tidak Rawan, Tidak Rawan, Kurang Rawan, Cukup Rawan, Rawan dan Sangat Rawan. Dengan nilai parameter σ_{initial} sebesar 8, algoritma IWO menghasilkan nilai SSE dan *F-Measure* terkecil dibanding nilai parameter σ_{initial} lainnya, yaitu masing-masing sebesar 19.1002 dan 0.5137. Evaluasi hasil klasterisasi menggunakan SSE menunjukkan nilai yang baik dari 30 kali percobaan, dengan rata-rata SSE sebesar 19.218, lebih kecil dibanding dengan rata-rata SSE hasil metode *k-Means* dan DBSCAN yaitu masing-masing sebesar 19.307 dan 59.910.

Kata kunci— Klasterisasi, Kerawanan Gempa, Provinsi Papua, *Invasive Weed Optimization* (IWO)

I. PENDAHULUAN

Gempa bumi merupakan suatu fenomena alam yang terjadi karena pergerakan lempeng bumi yang saling bersentuhan atau bergeser. Gempa bumi dapat menyebabkan kerusakan yang parah terhadap bangunan dan infrastruktur, serta berdampak buruk terhadap kehidupan manusia. Gempa bumi juga dapat menyebabkan berbagai bencana

alam seperti tsunami, letusan gunung berapi, dan lainnya. Di Indonesia, gempa bumi sering terjadi karena wilayah Indonesia terletak pada cincin api Pasifik, yaitu kawasan di sekitar Samudera Pasifik yang memiliki banyak gunung berapi aktif dan zona subduksi lempeng bumi [1].

Salah satu provinsi di Indonesia yang juga sering terkena gempa bumi adalah Papua. Menurut data dari Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) Indonesia, sepanjang tahun 2020 hingga awal 2021, Provinsi Papua telah mengalami beberapa kali gempa bumi dengan kekuatan di atas 5 Magnitude. Pada pertengahan 2021 hingga awal 2023 terjadi gempa dengan kekuatan gempa yang bervariasi mulai dari 4 sampai yang tertinggi 6.2 Magnitude [2]. Beberapa diantaranya menyebabkan kerusakan pada bangunan. Menurut *Website United States Geological Survey* (USGS), Provinsi Papua juga termasuk dalam *ring of fire* atau Cincin Api Pasifik, yaitu daerah yang memiliki aktivitas vulkanik dan gempa bumi yang tinggi di sekitar Samudera Pasifik [3]. Hal ini dapat disebabkan oleh aktivitas gunung berapi dan adanya zona subduksi lempeng bumi antara Lempeng Indonesia-Australia dan Lempeng Pasifik.

Sejauh ini pemerintah telah melakukan beberapa upaya dalam menghadapi risiko bencana gempa di Provinsi Papua, seperti memberikan pelatihan dan sosialisasi kepada masyarakat, serta membangun infrastruktur yang tahan gempa. Namun, upaya ini dipandang belum cukup dan perlu ditingkatkan lagi karena kerawanan gempa di provinsi ini masih tergolong tinggi dan risiko bencana gempa masih sangat mungkin terjadi. Ada beberapa cara yang dapat diupayakan oleh pemerintah, salah satunya dengan melakukan analisis klasterisasi. Klasterisasi daerah kerawanan gempa di Provinsi Papua dipandang perlu dilakukan untuk mengetahui tingkat kerawanan gempa pada setiap daerah untuk dapat membantu pemerintah dalam mengambil keputusan strategis dan menyusun rencana mitigasi risiko bencana gempa yang lebih terarah dan efektif. Oleh karenanya, pemerintah dapat memberikan

perlakuan yang berbeda untuk setiap daerah dalam kesigapan menghadapi bencana gempa.

Klasterisasi merupakan sebuah metode analisis data yang biasa dipakai untuk mengelompokkan data yang memiliki karakteristik yang serupa ke dalam beberapa kelompok (*cluster*) berdasarkan beberapa kriteria tertentu. Tujuan utama dari klasterisasi adalah untuk mengelompokkan objek-objek yang serupa dan membedakan objek-objek yang berbeda secara visual, sehingga memudahkan analisis dan pemahaman terhadap data tersebut [4].

Saat ini, terdapat banyak algoritma klasterisasi yang telah digunakan untuk penelitian daerah kerawanan gempa bumi, seperti *fuzzy c-means clustering*, *Self-Organizing Map (SOM) clustering*, *k-means clustering*, *k-medoid clustering* dan algoritma lainnya. *k-Medoid clustering* merupakan algoritma klasterisasi yang digunakan untuk mengelompokkan data ke dalam kelompok-kelompok yang serupa berdasarkan jarak antara titik data. Algoritma ini sudah pernah diterapkan untuk memetakan pola sebaran gempa bumi Mentawai selama sepuluh tahun periode 2010 hingga 2019, dimana penelitian tersebut menunjukkan *layout* peta hasil perhitungan dan tampilan diagram batang dan lingkaran sebagai luarannya [5]. Gempa bumi juga dapat diklasterisasi berdasarkan daerah terjadinya dengan menggunakan algoritma *k-means* dan DBSCAN. Hasil klaster dibuat dalam bentuk peta dan menunjukkan bahwa algoritma *k-means* dinilai lebih akurat dengan dengan nilai indeks silhouette sebesar 0.54, sedangkan algoritma DBSCAN mempunyai nilai silhouette sebesar 0.17 [6]. Selain itu, gempa bumi juga dapat dikelompokkan dengan menggunakan algoritma *fuzzy possibilistic c-means* berdasarkan data titik gempa bumi di Pulau Sumatera sejak tahun 2013 sampai dengan 2018. Dari penelitian ini berhasil menunjukkan bahwa data dikelompokkan berdasarkan kedalaman saja, dan kekuatan gempa bumi menyebar di setiap klaster yang terbentuk. Dalam penelitian ini, ditemukan tiga klaster yang dapat digunakan untuk memahami pola sebaran gempa bumi di Pulau Sumatera selama periode waktu yang diteliti [7].

Meskipun penelitian klasterisasi daerah kerawanan gempa telah dikerjakan dalam beberapa penelitian sebelumnya dengan berbagai algoritma klasterisasi yang ada namun, belum ada penelitian yang menggunakan algoritma IWO dalam klasterisasi daerah kerawanan gempa bumi di Indonesia. IWO adalah sebuah algoritma optimasi yang terinspirasi dari pertumbuhan rumput liar (*gulma*) dalam suatu area. Algoritma ini dibuat oleh Mehrabian dan Lucas di tahun 2006. IWO merupakan algoritma optimasi yang terinspirasi dari mekanisme pertumbuhan rumput liar yang sangat cepat dan efisien dalam menyebar ke area-area yang belum pernah ditempati sebelumnya. Pada dasarnya, IWO dapat digunakan sebagai algoritma klasterisasi untuk mengelompokkan data berdasarkan kemiripan karakteristiknya. IWO memiliki beberapa kelebihan, diantaranya adalah kemampuannya untuk menangani masalah klasterisasi dengan data yang berukuran besar, tidak terbatas pada jenis fungsi objektif tertentu dan cukup mudah untuk diimplementasikan. Selain

itu, IWO juga memiliki kemampuan untuk menemukan solusi yang optimal atau mendekati optimal dalam waktu yang relatif singkat [8]. Algoritma IWO dipandang mampu memberikan hasil klaster yang lebih akurat karena telah terbukti efektif dalam menyelesaikan masalah optimasi yang kompleks.

Hal ini dibuktikan dengan penelitian tentang algoritma optimasi IWO yang dikombinasikan dengan *cooperative co-evolutionary invasive* atau disebut CCIW. Dari penelitian tersebut diketahui bahwa algoritma CCIW sangat efektif dalam menyelesaikan masalah penjadwalan pengujian final semikonduktor dan lebih baik daripada algoritma-algoritma yang dibandingkan dalam literatur [9]. Algoritma IWO juga pernah diterapkan untuk mengurangi level *sidelobe* pada *antenna array* dimana penelitian ini bertujuan untuk meningkatkan kinerja *antenna array* dalam menerima dan mengirimkan sinyal. Hasil penelitian menunjukkan bahwa pendekatan yang diusulkan berhasil mengurangi level *sidelobe* pada *antenna array* dan meningkatkan kinerja *antenna array* secara signifikan. Selain itu, metode ini juga lebih efektif dibandingkan dengan teknik reduksi level *sidelobe* lainnya yang telah dikembangkan sebelumnya [10]. Selain itu, algoritma IWO yang digabungkan dengan algoritma *Squirrel Search Algorithm (SSA)* selanjutnya disebut SSA-IWO juga memberikan hasil kinerja yang lebih baik. SSA-IWO dapat menghasilkan solusi optimal yang lebih baik dan stabil dalam menyelesaikan masalah optimasi yang kompleks. Oleh karena itu, algoritma SSA-IWO dapat dijadikan sebagai pilihan yang baik untuk menyelesaikan masalah optimasi yang kompleks [11].

Dalam konteks klasterisasi daerah kerawanan gempa bumi, algoritma IWO dapat digunakan untuk mengoptimalkan *centroid*. Pemilihan *centroid* yang tepat dapat meminimalkan jarak antara setiap data dengan titik-titik klaster, sehingga membentuk kelompok yang homogen. Dalam penelitian kali ini akan dilakukan klasterisasi daerah kerawanan gempa bumi di Provinsi Papua dengan menggunakan algoritma IWO, algoritma ini dipandang lebih baik dalam melakukan klasterisasi kerawanan gempa bumi setelah melakukan uji terlebih dahulu menggunakan algoritma klasterisasi pembandingan lainnya seperti *k-means* dan DBSCAN pada dataset gempa bumi. Hasil penelitian ini diharapkan dapat memberikan sumbangan dalam pengembangan ilmu pengetahuan dan teknologi terkait mitigasi risiko bencana gempa bumi di Provinsi Papua.

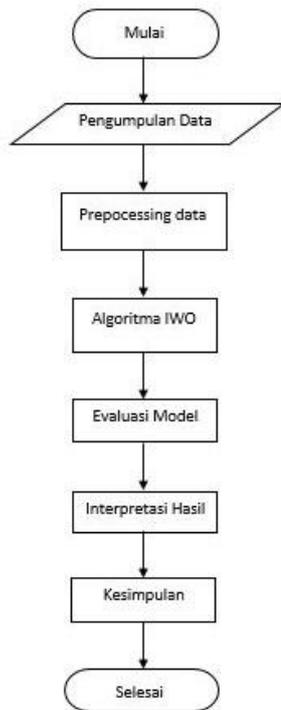
II. METODE PENELITIAN

Adapun alur penelitian ini ditunjukkan oleh Gambar 1 dan dapat dijelaskan sebagai berikut.

A. Pengumpulan Data

Data gempa bumi dari Provinsi Papua diperoleh dari *website* resmi Badan Geologi Amerika Serikat yaitu *United States Geological Survey (USGS)* [3]. Data gempa bumi yang diambil mulai dari tahun 2018 sampai dengan Februari 2023 sebanyak 647 data. Ada 13 atribut data yang

diperoleh dalam data gempa ini, yaitu *time*, *latitude*, *longitude*, *mag*, *depth*, *magType*, *dmin*, *rms*, *net*, *id*, *place*, *locationSource*, dan *magSource*. Namun dalam kasus klasterisasi daerah kerawanan gempa bumi, hanya empat atribut yang dibutuhkan yaitu *latitude*, *longitude*, *depth*, dan *mag*. Atribut *latitude* dan *longitude* digunakan untuk menentukan lokasi episentrum gempa bumi pada permukaan bumi. *Latitude* menunjukkan koordinat utara atau selatan suatu titik di bumi, sedangkan *longitude* menunjukkan koordinat timur atau baratnya. Atribut *depth* menunjukkan kedalaman hiposentrum, yaitu titik di bawah permukaan bumi di mana gempa bumi terjadi. Kedalaman hiposentrum memberikan informasi tentang jenis dan karakteristik gempa bumi yang terjadi. Atribut *mag* atau magnitudo digunakan untuk mengukur kekuatan atau energi gempa bumi. Magnitudo dapat diukur menggunakan berbagai skala, seperti skala Richter atau skala Moment, yang memberikan informasi tentang besar gempa bumi yang terjadi. Semakin besar magnitudo suatu gempa bumi, semakin besar pula dampaknya pada lingkungan sekitar dan masyarakat yang terdampak. Adapun data gempa tersebut dapat dilihat melalui Tabel I.



Gambar. 1 Alur penelitian

TABEL I
DATA GEMPA BUMI PROVINSI PAPUA

No	latitude	longitude	depth	mag	time
1	-3.637	138.4007	-92.71	4.2	2018
2	-4.798	138.3883	-36.16	4.5	2018
3	-3.518	138.4194	-77.29	4.1	2018
4	-2.814	139.4573	-93.54	5	2018
5	-3.466	140.4719	-10	4.1	2018
6	-2.938	140.1223	-28.96	4.4	2018
...
647	-2.301	140.183	-25.24	5	2023

B. Pre-processing Data

Tahap *pre-processing* data terdiri dari empat tahap yaitu *data cleaning*, seleksi data, normalisasi data, dan transformasi data.

1) *Data Cleaning*. Dari sejumlah 647 data yang diperoleh selanjutnya dilakukan pembersihan data dengan menghapus data gempa yang terjadi di luar Provinsi Papua dan data gempa yang tidak lengkap (*missing value*). Hal ini dilakukan untuk memastikan keakuratan dan kevalidan data. Hasil dari proses data *cleaning* diperoleh 536 data.

2) *Seleksi Data*. Pada tahap ini dilakukan seleksi data dengan menghapus atau menghilangkan atribut-atribut yang tidak dibutuhkan dalam proses klasterisasi nantinya. Adapun atribut yang digunakan yaitu *latitude*, *longitude*, *depth*, dan *mag*.

3) *Normalisasi Data*. Hasil dari seleksi data selanjutnya diproses dengan melakukan normalisasi data. Normalisasi data dilakukan untuk menghindari distorsi hasil klasterisasi yang disebabkan oleh variabel dengan rentang nilai yang besar. Sebagai contoh, magnitudo gempa, kedalaman gempa, dan koordinat geografisnya yang dapat mendominasi perhitungan jarak dalam klasterisasi. Dengan normalisasi data, variabel-variabel gempa akan diperlakukan dengan proporsi yang sama seperti variabel lainnya. Dalam hal ini ukuran nilai angka akan dinormalisasi menjadi 0 sampai 1, sehingga hasil klasterisasi dapat lebih objektif dan representatif. Dalam normalisasi ini digunakan persamaan Min-Max yang ditunjukkan melalui Persamaan (1).

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \tag{1}$$

dimana x_{norm} adalah nilai data yang telah dinormalisasi, x adalah nilai data asli, x_{min} adalah nilai minimum dari seluruh data, dan x_{max} adalah nilai maksimum dari seluruh data. Hasil normalisasi data gempa bumi Provinsi Papua dapat dilihat pada Tabel II.

TABEL II
NORMALISASI DATA GEMPA BUMI

No	latitude	longitude	depth	mag
1	0.3	0.91	0.97	0.04
2	0.42	0.85	0.84	0.17
3	0.64	0.91	0.97	0.13
4	0.47	0.9	0.8	0.39
5	0.68	0.95	0.95	0
...
536	0.44	0.65	0.8	0

4) *Transformasi Data*. Tahap terakhir dari *pre-processing* data yaitu transformasi data. Dalam tahap ini format data akan diubah dengan menyesuaikan tipe data dan format data pada *tools* klasterisasi yang digunakan.

C. Algoritma IWO

Setelah melewati tahap *pre-processing* data, langkah selanjutnya adalah melakukan klasterisasi dengan algoritma IWO. Dalam algoritma IWO, parameter awalnya

yaitu penentuan *centroid* yang dilakukan secara *random*. Selanjutnya, *centroid* yang terpilih akan menjadi representasi dari rumput induk. Rumput induk akan menghasilkan rumput anak yang akan disebar pada seluruh area pencarian. Setelah itu, nilai *fitness* (ukuran seberapa baik atau buruk suatu individu dalam populasi menyelesaikan masalah optimisasi yang diberikan) dari setiap rumput anak akan dihitung. Rumput anak akan disebar pada seluruh area pencarian dengan menggunakan angka acak yang mengikuti distribusi normal dengan nilai *mean* yang sama dengan lokasi rumput induk. Selain itu, standar deviasi yang digunakan akan selalu diperbarui pada setiap iterasi. Kriteria berhenti pada algoritma IWO adalah jumlah iterasi maksimum yang telah ditentukan pada parameter awal telah tercapai. Titik pusat kluster akan dipilih berdasarkan tanaman rumput dengan nilai *fitness* terbaik. Untuk mengukur performa metode, nilai *Sum of Square Error* (SSE) akan dihitung. Adapun tahapan dari algoritma IWO adalah sebagai berikut.

1) *Inisialisasi Populasi*. Fase ini merupakan fase pertama dari serangkaian tahapan IWO. Ada tiga tahap yang menjadi bagian dalam tahap inisialisasi, yaitu memilih nilai awal pada parameter IWO, menerima data input, dan menentukan *centroid* awal secara *random*. Populasi awal dibuat dengan menentukan ukuran populasi dan batas atas dan bawah variabel dalam solusi. Pada kasus ini yaitu untuk mengkluster data gempa bumi di Provinsi Papua berdasarkan kekuatan dan kedalaman gempa. Populasi awal dapat terdiri dari beberapa solusi acak yang mewakili kombinasi nilai magnitudo dan kedalaman. Tabel III menjelaskan tentang parameter apa saja yang perlu diberikan nilai awal pada algoritma IWO.

TABEL III
PARAMETER-PARAMETER DALAM IWO

Parameter	Keterangan
k	Jumlah kluster
it_{max}	Banyaknya iterasi maksimal
k_{max}	Banyaknya maksimal koloni
S_{max}	Banyaknya maksimal benih
S_{min}	Jumlah minimal benih
N	<i>Nonlinear modulation index</i>
$\sigma_{initial}$	Standar deviasi awal
σ_{final}	Standar deviasi akhir
p_{max}	Banyaknya maksimal populasi tanaman
Dim	Dimensi masalah

Adapun nilai $\sigma_{initial}$ ditentukan secara acak, hal ini dilakukan untuk mencegah jatuhnya algoritma pada nilai lokal optima yang buruk. Dalam beberapa kasus, nilai $\sigma_{initial}$ yang sama pada setiap iterasi dapat menyebabkan algoritma terjebak pada satu titik tertentu dan tidak mampu mengeksplorasi area pencarian yang lebih luas. Dengan memberikan nilai $\sigma_{initial}$ yang bervariasi secara acak, algoritma IWO dapat mengeksplorasi area pencarian yang lebih luas dan menemukan solusi yang lebih baik secara keseluruhan. Nilai σ_{final} merupakan hasil perhitungan total standar deviasi keseluruhan data. Penentuan jumlah

it_{max} pada IWO dilakukan secara cermat dengan mempertimbangkan kompleksitas masalah yang dihadapi dan sumber daya komputasi yang tersedia. Penentuan nilai S_{max} dan S_{min} bergantung pada ukuran masalah yang akan diselesaikan, namun pada umumnya nilai S_{min} diambil sekitar 2-5% dari ukuran populasi total sedangkan S_{max} diambil sekitar 10-20% dari populasi total. *Dim* atau Dimensi *problem* ditentukan berdasarkan jumlah dimensi *problem*nya, pada penelitian ini terdapat empat dimensi *problem* yaitu *latitude*, *longitude*, *depth*, dan *magnitude*.

2) *Tahap Menentukan Anggota Dari Tiap Rumput Induk*. Pada fase kedua ini, ada dua tahap yang dilakukan yaitu menghitung jarak tiap data dengan seluruh *centroid* lalu menentukan anggota dari masing-masing kluster yang terbentuk. Ada banyak metode perhitungan jarak yang umumnya digunakan seperti Manhattan, Minkowski, Euclidean, dan lainnya [12]. Dalam penelitian ini akan digunakan metode Euclidean *distance*. Euclidean *distance* merupakan salah satu cara yang digunakan untuk menghitung jarak antar dua titik dalam ruang Euclidean dimana mencakup ruang Euclidean berdimensi dua, tiga, atau bahkan lebih [13]. Persamaan (2) menjelaskan tentang metode perhitungan jarak yang digunakan yaitu Euclidean *Distance*.

$$d(x_i, y_k) = \sqrt{\sum_{j=1}^m (x_{ij} - y_{kj})^2} \quad (2)$$

dimana: $d(x_i, y_j)$ adalah jarak kemiripan, x_i adalah data ke- i , $i = 1, \dots, n$, y_k adalah kluster ke- k , $k = 1, \dots, c$, n adalah jumlah data, c adalah jumlah kluster, dan m adalah jumlah atribut.

3) *Tahap Menghasilkan Rumput Anak dan Daerah Penyebarannya*. Pada fase ini terdiri dari tiga tahap. Tahap pertama adalah menghitung nilai *fitness* dari setiap kluster. Tahap kedua adalah memilih jumlah rumput anak yang dapat diperoleh pada setiap rumput *parents*. Tahap ketiga adalah memilih posisi persebaran dari rumput anak. Nilai *fitness* dipakai untuk memilih banyaknya rumput anak yang bisa diperoleh dari setiap rumput induk berdasarkan nilai SSE dari setiap kluster. Banyaknya calon anak yang dapat dihasilkan oleh tiap rumput induk meningkat secara proporsional dengan nilai *fitness*-nya. Penentuan jumlah rumput anak yang dihasilkan menggunakan Persamaan (3).

$$n_{seed} = \frac{F_i - F_{worst}}{F_{best} - F_{worst}} = (S_{max} - S_{min}) + S_{min} \quad (3)$$

dimana n_{seed} adalah banyaknya rumput anak diproduksi, F_i adalah angka *fitness* dari rumput ke- i , F_{worst} adalah angka *fitness* terburuk pada koloni rumput, F_{best} adalah angka *fitness* terbaik pada koloni rumput, S_{max} adalah nilai maksimal rumput anak yang dapat dihasilkan oleh rumput *parents*, dan S_{min} adalah nilai minimal rumput anak yang dapat dihasilkan rumput *parents*. Pada tahapan memilih posisi persebaran dari rumput anak dilakukan penyebaran rumput anak secara acak pada daerah pencarian. Setelah

bibit dihasilkan, bibit tersebut akan disebar secara random pada sekitar area pencarian menggunakan angka acak dengan distribusi normal. Distribusi normal ini memiliki nilai rata-rata yang sama dengan posisi rumput *parents* dan $\sigma_{initial}$ yang berubah-ubah pada setiap iterasi, sesuai Persamaan (4).

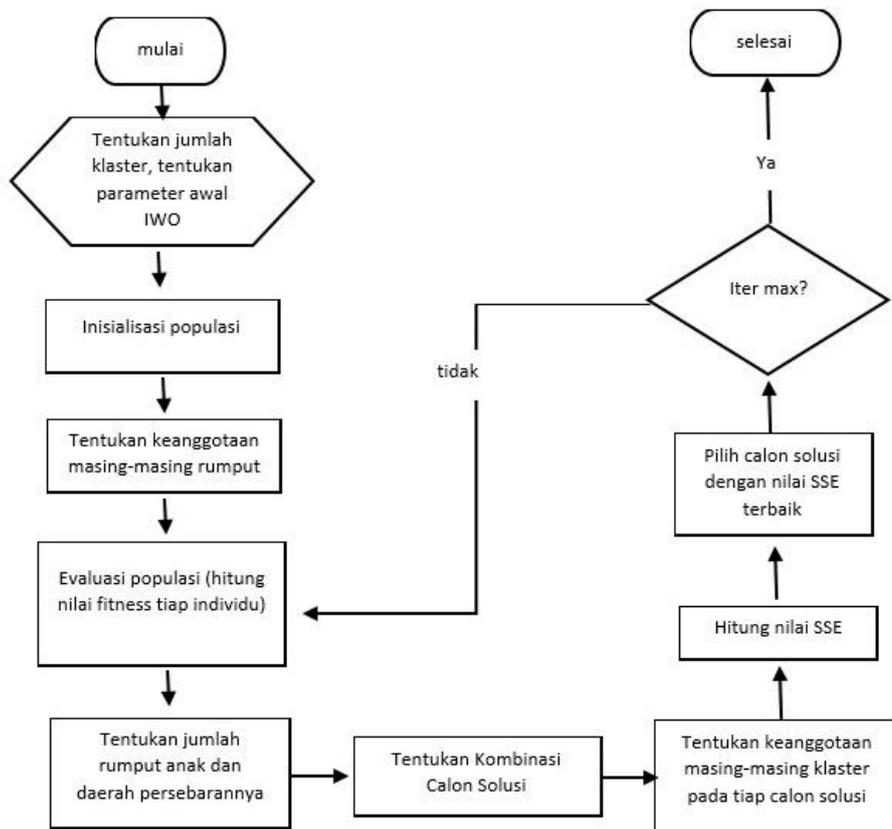
$$\sigma_{iter} = \frac{(iter_{max} - iter)^n}{(iter_{max})^n} (\sigma_{initial} - \sigma_{final}) + \sigma_{final} \quad (4)$$

dimana σ_{iter} adalah nilai standar deviasi saat ini, $iter_{max}$ adalah maksimal iterasi, n adalah *nonlinear modulation index*, $\sigma_{initial}$ adalah nilai standar deviasi awal, σ_{final} adalah nilai standar deviasi akhir.

4) *Tahap Memilih Kombinasi Calon Solusi.* Proses ini dilakukan dengan mempertahankan gen yang baik dan menggabungkannya dengan gen dari individu lain. Pada penelitian ini akan digabungkan gen dari beberapa solusi terbaik dan membuat kombinasi baru dari nilai *magnitude* dan kedalaman untuk membentuk solusi anak.

5) *Tahap Menentukan Anggota Dari Tiap Rumpuk pada Tiap Koloni Rumpuk.* Beberapa individu dalam populasi kemudian diacak atau dimutasi dengan mengubah nilai variabel dalam solusi. Misalnya, mengubah nilai magnitudo atau kedalaman dengan nilai acak dalam solusi individu yang dipilih secara acak.

6) *Tahap Penentuan Koloni Rumpuk yang Mempunyai Nilai Best Fitness.* Setelah tiap fase telah dilewati maka populasi dievaluasi kembali dengan menggunakan fungsi objektif untuk mencari solusi yang lebih baik. Tahap-tahap memilih calon solusi dan menentukan anggota dari tiap rumpuk ini dilakukan secara berulang-ulang hingga solusi yang ditemukan telah mencapai kriteria berhenti yang telah ditetapkan, seperti jumlah iterasi atau tingkat akurasi tertentu. Setelah kriteria berhenti terpenuhi, individu dengan nilai fungsi objektif terbaik dipilih sebagai solusi akhir yang merepresentasikan kluster gempa bumi di Provinsi Papua. Secara singkat, Gambar 2 menunjukkan alur algoritma IWO.



Gambar. 2 Tahapan algoritma IWO

D. *Evaluasi Model*

Untuk evaluasi model digunakan SSE dan *F-Measure*. SSE adalah metrik evaluasi yang umum digunakan untuk mengukur kualitas klusterisasi pada algoritma IWO. SSE mengukur seberapa jauh data poin dari pusat kluster mereka. Semakin kecil nilai SSE, semakin baik kualitas klusterisasi. Untuk menghitung SSE pada algoritma IWO, langkah-langkahnya adalah sebagai berikut: (1) Hitung

pusat massa (*centroid*) untuk setiap kluster; (2) Untuk setiap data poin, hitung jaraknya dari pusat kluster terdekat; (3) Jumlahkan jarak kuadrat setiap data poin ke pusat kluster terdekat. Rumus SSE dapat dituliskan pada Persamaan (5).

$$SSE = \sum_{k=1}^c \sum_{x_i \in C_k} (x_i - \mu_k)^2 \quad (5)$$

dimana c adalah jumlah kluster yang dihasilkan oleh algoritma, C_k adalah himpunan kluster ke- k , x_i adalah data ke- i pada kluster C_k , μ_k adalah nilai rata-rata dari data pada kluster ke- k (*centroid* ke- k). *F-Measure* adalah sebuah nilai yang diperoleh dari hasil perhitungan *Precision* dan *Recall* antara kelas hasil kluster dengan kelas sesungguhnya yang pada data input. Dengan *F-Measure*, maka dapat dilakukan evaluasi lebih lanjut terhadap kualitas klusterisasi yang dihasilkan oleh algoritma tersebut. Nilai *Precision* dan *Recall* diperoleh melalui Persamaan (6) dan Persamaan (7).

$$p_{ij} = \frac{n_{ij}}{n_j} \tag{6}$$

$$r_{ij} = \frac{n_{ij}}{n_i} \tag{7}$$

dimana p_{ij} adalah nilai *Precision* dari kelas ke- i cluster ke- j , r_{ij} adalah nilai *Recall* dari kelas ke- i cluster ke- j , n_i adalah banyaknya data pada kelas ke- i yang akan menjadi hasil *query*, n_j adalah banyaknya data pada kluster ke- j yang merupakan hasil *query*, n_{ij} adalah banyaknya elemen dari kelas ke- i yang terinput pada kluster ke- j .

III. HASIL DAN PEMBAHASAN

Analisis klusterisasi dilakukan pada data gempa bumi di Provinsi Papua yang terdiri dari 543 data gempa mulai tahun 2018 sampai dengan Februari 2023. Tabel IV menunjukkan Parameter IWO yang dipakai pada penelitian ini.

TABEL IV
NILAI-NILAI PARAMETER IWO YANG DIGUNAKAN DALAM PENGUJIAN

Parameter	Nilai	Keterangan
N_0	4	Jumlah populasi awal
it_{max}	50	Maksimal Jumlah iterasi
Dim	4	Dimensi Problem
p_{max}	40	Maksimal banyaknya populasi tanaman
S_{max}	50	Jumlah maksimal benih
S_{min}	10	Jumlah minimum benih
$\sigma_{initial}$	8	Standar deviasi awal
σ_{final}	4.16	Standar deviasi akhir
k	6	Jumlah kluster
n	4	Nonlinear modulation index

Nilai-nilai parameter ini diterapkan pada algoritma IWO dengan penentuan jumlah kluster yang ingin dibentuk adalah enam kluster sesuai dengan pengujian yang dilakukan pada Tabel V. it_{max} sebanyak 50 kali iterasi, jumlah ini dipilih setelah mempertimbangkan kompleksitas masalah yang dihadapi dalam penelitian ini. Dimensi *problem* dalam penelitian ini adalah 4 sesuai dengan banyaknya variabel yang digunakan sedangkan nilai P_{max} yang digunakan adalah 40 berdasarkan karakteristik masalah yang dihadapi dan kompleksitas data. Nilai S_{min} adalah 10 yang diambil 5% dari ukuran populasi total sedangkan nilai S_{max} adalah 50 yang diambil sekitar 10% dari ukuran populasi keseluruhan. Dalam penelitian ini digunakan lima nilai angka $\sigma_{initial}$ yaitu 3, 5, 7, 8, dan 10 karena setelah dicobakan nilai-nilai ini dianggap mempengaruhi tingkat konvergensi algoritma lebih baik

dibanding nilai lainnya, sedangkan nilai σ_{final} adalah 4.16 yang diperoleh dari hasil perhitungan total standar deviasi keseluruhan data.

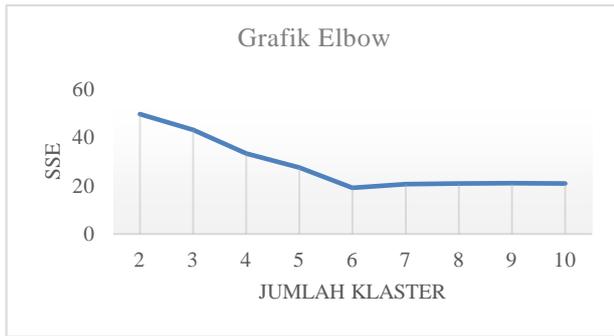
A. Penentuan Kluster Optimal

Tabel V menunjukkan nilai SSE dari setiap jumlah kluster yang dicobakan mulai dari 2 hingga 30 kluster. Dari tabel tersebut dapat dilihat bahwa semakin banyak kluster yang dibentuk maka akan berbanding lurus dengan penurunan nilai SSEnya. Namun, parameter jumlah kluster yang optimal tidak dapat ditentukan hanya berdasarkan nilai SSE yang paling kecil. Salah satu parameter jumlah kluster optimal dapat ditentukan menggunakan grafik Elbow, Jumlah enam kluster dinilai paling optimal setelah dilakukan 30 kali percobaan menggunakan parameter IWO dan diperoleh penurunan nilai SSE paling tajam, seperti ditunjukkan pada Tabel V.

TABEL V
PENENTUAN JUMLAH KLUSTER OPTIMAL

Percobaan	Jumlah kluster	Nilai SSE
1	2	49.6355793600000
2	3	43.1472501600000
3	4	33.3461945100000
4	5	27.4700507192570
5	6	19.1002654518228
6	7	20.6387174165576
7	8	20.8713648109255
8	9	20.9757146997944
9	10	20.8713648109255
10	11	20.8713648109255
11	12	19.6989673196968
12	13	18.9367609851268
13	14	17.7590656729915
14	15	16.5768964593983
15	16	17.6139921551931
16	17	16.2218008532153
17	18	16.2279611278211
18	19	15.8109330311720
19	20	15.7070004542836
20	21	15.2264200338944
21	22	14.8444034489460
22	23	13.3742472812805
23	24	14.0409028893046
24	25	12.7702947546066
25	26	14.8843720957785
26	27	15.3759869279487
27	28	15.3154271776721
28	29	14.6708045014982
29	30	13.426151720240
30	31	13.0386546539596

Jika menggunakan grafik Elbow maka dapat dilihat bahwa ada perubahan yang tajam dalam penurunan SSE dari jumlah kluster lima ke jumlah kluster enam yang membentuk siku sehingga jumlah kluster di titik 6 dianggap sebagai jumlah kluster paling optimal.



Gambar. 3 Jumlah kluster optimal menggunakan metode *elbow*

Adapun enam kluster yang terbentuk selanjutnya akan diberi label mulai dari Sangat Tidak Rawan, Tidak Rawan, Kurang Rawan, Cukup Rawan, Rawan, sampai Sangat Rawan. Penentuan label tersebut disesuaikan dengan hasil analisis parameter kerawanan gempa yaitu besaran kekuatan dan kedalaman gempanya serta struktur geologi sesuai dengan lokasi tiap daerahnya. Menurut BMKG ukuran kekuatan gempa dalam *magnitude* terbagi menjadi *mag* 2.5 – 5.4 menimbulkan kerusakan ringan, *mag* 5.5 – 6.0 menimbulkan kerusakan ringan pada infrastuktur gedung/bangunan, *mag* 6.1 – 6.9 menimbulkan kerusakan bangunan pada pemukiman padat penduduk, dan *mag* 7.0 – 7.9 yang sudah masuk dalam kategori gempa besar yang menyebabkan kerusakan bangunan yang lebih fatal [14]. Berdasarkan kedalamannya, gempa terbagi menjadi tiga yaitu: gempa dangkal (kedalaman hiposentrum < 60 km), gempa menengah (kedalaman hiposentrum 60-300 km), gempa dalam (kedalaman hiposentrum > 300 km). Selain itu, parameter yang digunakan juga didasarkan pada letak geografis atau lokasi terjadinya gempa berdasarkan titik koordinatnya untuk melihat struktur geologi dan batuan dari daerah tersebut yang juga dapat berpengaruh pada tingkat kerawanan gempanya [15].

Setelah menentukan jumlah kluster optimal dan parameter tingkat kerawanan gempa maka pengujian dilanjutkan dengan menguji data gempa yang telah dinormalisasi menggunakan parameter IWO yang sudah ditentukan. Pengujian dilakukan sebanyak lima kali dengan $\sigma_{initial}$ yang ditentukan secara acak yaitu 3, 5, 7, 8, dan 10 untuk melihat nilai standar deviasi awal pada percobaan beberapa yang menghasilkan nilai paling ideal pada SSE-nya (pengaruh perubahan $\sigma_{initial}$ pada terhadap hasil). Setelah dilakukan lima kali percobaan maka diperoleh hasil bahwa nilai $\sigma_{initial}$ yang paling ideal adalah nilai 8 (ditunjukkan oleh Tabel VI). Adapun hasil klusterisasi dengan $\sigma_{initial} = 8$ dan menghasilkan enam kluster dapat dilihat pada Tabel VI.

TABEL VI
EVALUASI MODEL MENGGUNAKAN SSE DAN *F-MEASURE*

$\sigma_{initial}$	SSE	<i>F-Measure</i>
3	25.0911336125696	0.4537601616
5	22.6537626390751	0.4211179123
7	19.1002654518229	0.4821437059
8	19.1002654518228	0.5136602080
10	24.0699466078287	0.4659609011

TABEL VII
HASIL KLUSTERISASI ENAM KLASTER

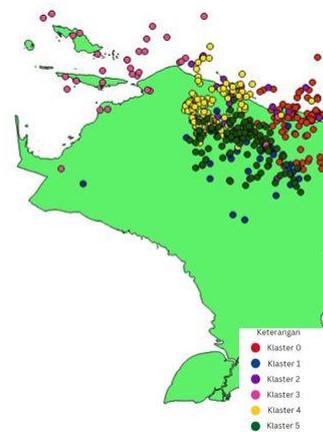
No	<i>k</i>	Lat.	Long.	Depth	Mag
1	0	0.3	0.91	0.97	0.04
2	0	0.42	0.85	0.84	0.17
...
105	1	0.45	0.74	0.41	0.43
106	1	0.45	0.68	0.8	0.35
...
152	2	0.77	0.52	0.97	0.7
153	2	0.8	0.56	0.97	0.65
...
214	3	0.88	0.04	0.76	0.22
215	3	0.65	0.08	0.97	0.39
...
265	4	0.74	0.54	0.81	0
267	4	0.46	0.69	0.97	0.35
...
426	5	0.29	0.56	0.52	0.04
427	5	0.23	0.88	0.69	0
...
536	5	0.44	0.65	0.8	0

B. Evaluasi Model

Untuk memastikan bahwa hasil klusterisasi telah optimal maka dilakukan pengujian dengan melihat nilai SSE dan *F-Measure*-nya. Semakin rendah SSE, semakin baik kualitas klusterisasi sedangkan semakin jika nilai yang dihasilkan oleh *F-Measure* semakin besar, maka dapat diartikan bahwa kemampuan algoritma menemukan kembali kelas label dari tiap *record* data semakin baik. Hasil pengujian SSE dan *F-Measure* ditunjukkan oleh Tabel VI.

Dari Tabel VI dapat dilihat bahwa nilai SSE yang paling rendah dan nilai *F-Measure* yang paling tinggi ada pada model dengan $\sigma_{initial} = 8$, yaitu model yang digunakan dalam penelitian ini. Selanjutnya hasil klusterisasi juga ditampilkan dalam *layout* peta seperti pada Gambar 4 sehingga dapat terlihat dengan jelas penyebaran masing-masing klasternya.

Pada Gambar 4, kluster 0 ditunjukkan oleh titik-titik berwarna merah, kluster 1 ditunjukkan oleh titik-titik berwarna biru, kluster 2 ditunjukkan oleh titik-titik berwarna ungu dan kluster 3 ditunjukkan oleh titik-titik merah muda, kluster 4 ditunjukkan oleh titik-titik berwarna kuning dan kluster 5 ditunjukkan oleh titik-titik berwarna hijau.



Gambar. 4 Hasil klusterisasi dengan layout peta

C. Penentuan Tingkat Kerawanan Klaster

Hasil klasterisasi gempa bumi juga ditampilkan dalam bentuk tabel sehingga dapat dilihat perbedaan *range* antara setiap klaster yang terbentuk. Klaster disusun mulai dari Klaster Sangat Tidak Rawan, Tidak Rawan, Kurang Rawan, Cukup Rawan dan Sangat Rawan. Pada Tabel VIII dapat diketahui bahwa rata-rata gempa bumi yang terjadi di

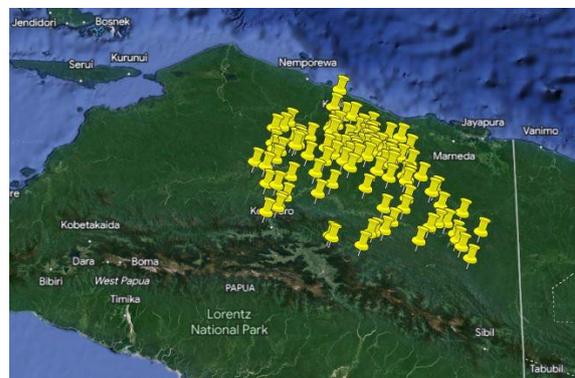
Provinsi Papua tergolong dalam gempa dangkal yang memiliki kedalaman kurang dari 80 km dan kekuatan gempa tergolong yang cukup kuat yaitu rata-rata di atas 4 *magnitude*. Hal ini dipengaruhi oleh beberapa faktor seperti letak geografis, interaksi antar lempeng, kerapatan sesar aktif, dan aktivitas vulkanik. Oleh karenanya, dari enam klaster yang terbentuk maka ditentukan tingkat kerawanan setiap klaster seperti yang diuraikan pada Tabel VIII.

TABEL VIII
TINGKAT KERAWANAN TIAP KLASTER

Tingkat Kerawanan	Range Depth	Range Mag	Rata-Rata Depth	Rata-Rata Mag
Sangat Tidak Rawan	16.080 – 77.580 km	4.2 – 5.0	45.000 km	4.52
Tidak Rawan	34.280 – 90.550 km	4.0 – 5.1	38.290 km	4.45
Kurang Rawan	35.000 – 116.700 km	4.3 – 5.5	78.790 km	4.81
Cukup Rawan	5.248 – 48.300 km	4.0 – 5.3	22.480 km	4.46
Rawan	5.000 – 33.590 km	4.5 – 5.6	16.141 km	4.61
Sangat Rawan	8.850 – 34.580 km	4.9 – 6.2	20.500 km	5.82

Dari analisis yang dilakukan, baik itu dengan melihat kekuatan gempa, kedalaman gempa, dan lokasi terjadinya gempa, maka diberikan label pada setiap klaster seperti pada Tabel VIII. Pada Klaster "Sangat Tidak Rawan" kekuatan gempa yang paling mendominasi yaitu 4.0 *magnitude* dengan pusat kedalaman gempa yang dominan yaitu gempa menengah, jika dilihat dari lokasi terjadinya gempa pada daerah ini tidak ada aktivitas vulkanik yang dapat memicu gempa yang besar. Pada klaster ini didominasi oleh beberapa distrik di Kabupaten Sarmi, diantaranya Distrik Pantai Timur Bagian Barat, Distrik Pantai Timur pada Kampung Kampung Komra, dan Kampung Ansudu Dua, Kampung Betaf Dua, Kampung Sunum 1, Distrik Bonggo. Selain itu di Kabupaten Mamberamo Raya yaitu Distrik Mamberamo Hulu pada Kampung Haya, Kampung Douw dan Distrik Rufaer. Selanjutnya, di Kabupaten Jayapura terdapat Distrik Kaureh Kampung Umbron, Kampung Lapua, Distrik Unurun Guay pada Kampung Guryard dan Distrik Airu. Persebaran daerah Klaster ini dapat dilihat pada Gambar 5.

Selanjutnya pada klaster "Tidak Rawan" kekuatan gempa pada klaster ini masih relatif rendah dengan kedalaman pusat gempa masih dikategori gempa menengah, berdasarkan titik-titik gempunya pada daerah ini tidak ada aktivitas vulkanik yang dapat memicu gempa yang lebih besar. Beberapa daerah yang masuk dalam klaster ini yaitu Kabupaten Kepulauan Yapen diantaranya Distrik Yawakutat, Distrik Angkaisera, Distrik Sawai di Kabupaten Mamberamo Raya, Distrik Supiori Timur, Distrik Swandiwe, Distrik Supiori Kabupaten Biak Numfor, Distrik Warsa dan arah laut bagian utara dari Kepulauan Yapen. Sebaran daerah dalam klaster "Tidak Rawan" dapat dilihat pada Gambar 6.



Gambar. 5 Klaster "sangat tidak rawan"



Gambar. 6 Klaster "tidak rawan"

Pada klaster "Kurang Rawan" kekuatan gempa yang mendominasi yaitu kisaran 4.4 *Magnitude* dengan kedalaman hiposentrum gempa tergolong gempa menengah. Gambar 7 menunjukkan daerah-daerah yang masuk dalam klaster ini yang terdiri dari Kabupaten Jayapura diantaranya Distrik Airu, Kampung Umbron yang terletak di Distrik Kaureh, Kabupaten Sarmi yaitu Distrik Bonggo, Kabupaten Mamberamo Raya diantaranya Kampung Nengke Dua, Kampung Fokri, Kampung Betaf Dua, Kampung Papesena 1 yang berada di Distrik Mamberamo Hulu, selain itu ada Distrik Mamberamo

Barat yaitu Kampung Baso, dan Kampung Waaf di Distrik Tor Atas.



Gambar. 7 Klaster "kurang rawan"

Klaster "Cukup Rawan" memiliki data gempa yang paling dominan dengan kekuatan 4.4 Magnitude namun hiposentrum gempa cukup dangkal, ini dipengaruhi oleh letak geografis daerahnya yang berada di zona subduksi sehingga rentan terhadap gempa. Daerah-daerah yang mendominasi klaster ini yaitu Kota Jayapura, Distrik Muara Tami, daerah sekitaran Pegunungan Cycloop, beberapa daerah di Kabupaten Jayapura yaitu Distrik Depapare, Distrik Yapsi dan Distrik Abepura, beberapa kampung pada Distrik Kaureh yaitu Kampung Santosa, Kampung Guyard, juga ada Kampung Soskotek dan Kampung Senggi Distrik Keerom. Adapun daerah-daerah dalam klaster ini dapat dilihat dalam Gambar 8.



Gambar. 8 Klaster "cukup rawan"

Selanjutnya, pada Klaster "Rawan" yang ditunjukkan pada Gambar 9 didominasi gempa dengan kekuatan 4.7 Magnitude dan kedalaman pusat gempa yang mendominasi yaitu 10 km dan tergolong gempa dangkal. Berdasarkan letak geografisnya, daerah-daerah pada klaster ini terletak di daerah subduksi sehingga memiliki risiko gempa yang signifikan. Beberapa daerah yang masuk dalam klaster ini diantaranya Kabupaten Mamberamo Raya pada Distrik Mamberamo Tengah diantaranya Kampung Kwerba, Danau Bira, Kampung Burmeso, Kampung Muaramarei, Kampung Kasonaweja, Kampung Metaweja, Kampung Anggreso, Kampung Sikari di Distrik Rufaer. Kabupaten

Sarmi pada Distrik Apawer Hulu Kampung Sasawapece, Kampung Syoremania, Kampung Aurimi, Distrik Tor Atas pada Kampung Omte, Distrik Pantai Timur pada Kampung Betaf, Kampung Yanben, Distrik Sarmi Timur pada Kampung Bagaiserwar, Distrik Pantai Barat pada Kampung Karfasia dan arah laut bagian utara dari Distrik Sarmi.



Gambar. 5 Klaster "rawan"

Pada klaster "Sangat Rawan" ditemukan bahwa gempa dengan kekuatan yang besar berkumpul di klaster ini dengan kekuatan gempa yang mendominasi adalah 5.5 Magnitude dan hiposentrum gempa paling mendominasi adalah 10 km. Kekuatan gempa yang besar juga dipengaruhi oleh struktur geologi dan batuanannya dan juga daerah-daerah dalam klaster ini tergolong dalam zona aktif patahan besar sehingga sering terjadi gempa bumi. Klaster ini terdiri dari beberapa daerah di Kabupaten Mamberamo Raya yaitu pada Distrik Mamberamo Tengah diantaranya Kampung Marine Valen, Kampung Sosawakweser, dan Kampung Bota Bora, selain itu juga ada di Kabupaten Sarmi Distrik Apawer Hulu pada Kampung Aurimi, Kampung Wakde Distrik Pantai Timur bagian Barat, Kampung Betaf Distrik Pantai Timur dan arah laut Sarmi. Sebaran daerah pada klaster ini dapat dilihat melalui Gambar 10.

D. Hasil Perbandingan Kinerja Algoritma IWO, K-Means dan DBSCAN Menggunakan Metrik SEE

Seperti yang sudah dijelaskan dalam bagian sebelumnya bahwa algoritma IWO dipilih sebagai metode dalam penelitian dengan studi kasus ini karena algoritma optimasi ini dipandang lebih akurat daripada algoritma lainnya dalam menentukan titik centroidnya. Untuk membuktikan hal tersebut maka disajikan hasil uji kinerja antara algoritma IWO, *k-means*, dan DBSCAN menggunakan metrik SSE, adapun percobaan dilakukan sebanyak 30 kali sehingga diperoleh hasil seperti pada Tabel IX.



Gambar. 10 Kluster “sangat rawan”

TABEL IX
PERBANDINGAN SSE IWO, K-MEANS, DAN DBSCAN

Algoritma	Rata-Rata SSE
IWO	19.218
<i>k-Means</i>	19.307
DBSCAN	59.910

IV. KESIMPULAN

Algoritma IWO berhasil diterapkan untuk melakukan klusterisasi daerah kerawanan gempa di Provinsi Papua. Algoritma IWO dipilih karena memiliki kinerja yang lebih baik dalam klusterisasi daerah kerawanan gempa di Provinsi Papua dibandingkan dengan algoritma klusterisasi lainnya yaitu *k-means* dan DBSCAN. Evaluasi keberhasilan klusterisasi yang digunakan dalam penelitian ini adalah metrik SSE dan *F-Measure* yang menunjukkan kinerja yang baik, dengan nilai SSE 19.100 dan *F-Measure* 0.5136. Berdasarkan hasil evaluasi, terdapat enam kluster yang terbentuk yaitu kluster Sangat Tidak Rawan, Sangat Rawan, Kurang Rawan, Cukup Rawan, Rawan dan Sangat Rawan. Hasil dari penelitian ini diharapkan dapat menjadi acuan bagi pemerintah dan masyarakat setempat dalam merencanakan tindakan mitigasi dan persiapan menghadapi gempa bumi di Provinsi Papua dengan melihat bahwa setiap daerah yang ada memiliki risiko yang cukup besar terhadap gempa bumi.

Untuk penelitian berikutnya disarankan untuk dapat menggunakan algoritma klusterisasi lainnya untuk membandingkan hasil dan tingkat akurasi dalam mengelompokkan wilayah kerawanan gempa bumi di Provinsi Papua, selain itu dengan data hasil klusterisasi yang ada maka diharapkan penelitian ini dapat dikembangkan dengan melakukan analisis prediksi terhadap salah satu daerah yang memiliki tingkat kerawanan tertentu untuk mengetahui adakah kemungkinan daerah tersebut pada beberapa tahun mendatang berpindah kluster.

REFERENSI

- [1] A. Wahyu and R. Rushendra, “Klusterisasi Dampak Bencana Gempa Bumi,” *JEPIN (Jurnal Edukasi Dan Penelit. Inform.*, vol. 8, no. 1, pp. 175–179, 2022, doi: 10.26418/Jp.V8i1.
- [2] BMKG, “Stasiun Cuaca Jayapura.” <https://www.bmkg.go.id/cuaca/prakiraan-cuaca.bmkg?Kota=KotaJayapura&AreaID=501447&Prov=35> (accessed Feb. 18, 2023).
- [3] USGS, “United States Geological Survey.” <https://www.usgs.gov/> (accessed Feb. 20, 2023).
- [4] A. Primandana, S. Adinugroho, and C. Dewi, “Optimasi Penentuan Centroid pada Algoritme K-Means Menggunakan Algoritme Pillar (Studi Kasus: Penyandang Masalah Kesejahteraan Sosial di Provinsi Jawa Timur,” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 3, no. 11, pp. 10678–10683, 2019.
- [5] Y. Setiawan, S. A. Suprianto, A. Wijanarko, and D. S. R. M. Yusa, “Pemetaan Kelompok Sebaran Titik Gempa Bumi Mentawai Dengan Metode K-Medoids Clustering,” *J. Teknoinfo*, vol. 6, no. 1, pp. 124–131, 2022, doi: 10.33365/jti.v16i1.932.
- [6] F. Reviantika, C. N. Harahap, and Y. Azhar, “Analisis Gempa Bumi Pada Pulau Jawa Menggunakan Clustering Algoritma K-Means,” *J. Din. Inform.*, vol. 9, no. 1, pp. 51–60, 2020.
- [7] S. Putriana, E. Ernawati, and D. Andreswari, “Clustering Data Titik Gempa Dengan Metode Fuzzy Possibilistic C-Means (Studi Kasus: Titik Gempa Pulau Sumatera Tahun 2013- 2018),” *Rekursif J. Inform.*, vol. 9, no. 1, pp. 14–29, 2021, doi: 10.33369/rekursif.v9i1.14984.
- [8] M. Misaghi and M. Yaghoobi, “Improved Invasive Weed Optimization Algorithm (IWO) based on Chaos Theory for Optimal Design of PID Controller,” *J. Comput. Des. Eng.*, vol. 6, no. 3, pp. 284–295, 2019, doi: 10.1016/j.jcde.2019.01.001.
- [9] H.-Y. Sang, P.-Y. Duan, and J.-Q. Li, “An Effective Invasive Weed Optimization Algorithm for Scheduling Semiconductor Final Testing Problem,” *Swarm Evol. Comput.*, vol. 38, pp. 42–53, 2018, doi: 10.1016/j.swevo.2017.05.007.
- [10] G. Sun, Y. Liu, H. Li, S. Liang, A. Wang, and B. Li, “An Antenna Array Sidelobe Level Reduction Approach through Invasive Weed Optimization,” *Int. J. Antennas Propag.*, vol. 2018, pp. 1–16, 2018, doi: 10.1155/2018/4867851.
- [11] H. Hu, L. Zhang, Y. Bai, P. Wang, and X. Tan, “A Hybrid Algorithm Based on Squirrel Search Algorithm and Invasive Weed Optimization for Optimization,” *IEEE Access*, vol. 7, pp. 105652–105668, 2019, doi: 10.1109/ACCESS.2019.2932198.
- [12] M. Nishom, “Perbandingan Akurasi Euclidean Distance, Minkowski Distance, dan Manhattan Distance pada Algoritma K-Means Clustering berbasis Chi-Square,” *J. Inform. J. Pengemb. IT*, vol. 4, no. 1, pp. 20–24, 2019, doi: 10.30591/Jpit.V4i1.1253.
- [13] W. W. Pribadi, A. Yunus, and A. S. Wiguna, “Perbandingan Metode K-Means Euclidean Distance dan Manhattan Distance Pada Penentuan Zonasi Covid-19 di Kabupaten Malang,” *JATI (Jurnal Mhs. Tek. Inform.*, vol. 6, no. 2, pp. 493–500, 2022, doi: 10.36040/jati.v6i2.4808.
- [14] BMKG, “Skala Intensitas Gempabumi (SIG) BMKG.” <https://www.bmkg.go.id/Gempabumi/Skala-Intensitas-Gempabumi.Bmkg> (accessed Mar. 25, 2023).
- [15] BPBD Provinsi NTB, “Gempa Bumi.” <https://bpbd.ntbprov.go.id/pages/gempa-bumi> (accessed Mar. 25, 2023).