

KLASTERISASI KERAWANAN GEMPA BUMI DI INDONESIA MENGUNAKAN ALGORITMA INVASIVE WEED OPTIMIZATION

Muhammad Maulana Kharyska Abadi, Amalia Anjani Arifiyanti, Dhian Satria Yudha Kartika

Sistem Informasi, Universitas Pembangunan Nasional "Veteran" Jawa Timur

Jl.Raya Rungkut Madya, Gunung Anyar, Surabaya

21082010143@student.upnjatim.ac.id

ABSTRAK

Indonesia merupakan wilayah dengan risiko gempa bumi tinggi karena terletak di pertemuan tiga lempeng tektonik utama. Meski berbagai upaya mitigasi telah dilakukan, langkah penting seperti pemetaan wilayah rawan gempa bumi di Indonesia belum diterapkan secara optimal. Hal ini menyebabkan upaya mitigasi masih kurang terarah. Penelitian ini bertujuan untuk klusterisasi atau mengelompokkan wilayah rawan gempa di Indonesia menggunakan algoritma *Invasive Weed Optimization* yang unggul dalam eksplorasi global. Tahapan penelitian meliputi pengumpulan data, *preprocessing data*, pembuatan model, evaluasi model, *deployment*, dan pengujian sistem. Data gempa diperoleh dari BMKG periode Januari 2014 hingga November 2024 sebanyak 84.733 kejadian dan setelah *preprocessing* menjadi 81.454 data dengan atribut *latitude*, *longitude*, *depth*, dan *magnitude*. Penentuan jumlah kluster optimal dilakukan dengan metode Elbow dan *Silhouette Score* yang menunjukkan empat kluster dengan nilai *Silhouette Score* 0.4910. Hasil klusterisasi IWO menghasilkan empat kluster yaitu Kurang Rawan, Cukup Rawan, Rawan, dan Sangat Rawan. Evaluasi menunjukkan IWO lebih unggul dibanding *K-Means* dan DBSCAN dengan nilai SSE 510.513, DBI 0.736, dan *Silhouette Score* 0.4927. Hasil kluster divisualisasikan dalam aplikasi berbasis website untuk membantu dan mendukung mitigasi bencana gempa bumi. Pengujian sistem menggunakan *blackbox testing* menunjukkan semua fitur berjalan sesuai ekspektasi.

Kata kunci : Gempa Bumi, Klusterisasi, *Invasive Weed Optimization*, Kerawanan Gempa

1. PENDAHULUAN

Gempa bumi adalah getaran atau guncangan permukaan bumi yang terjadi akibat pelepasan tiba-tiba energi elastis pada patahan di dalam kerak bumi. Energi ini merambat sebagai gelombang seismik dan menyebabkan permukaan tanah bergetar, terkadang disertai fenomena lanjutan seperti tsunami yang dapat menambah dampak kerusakan. Dalam waktu yang sangat singkat, hanya beberapa detik hingga menit, gempa dapat menimbulkan kerusakan infrastruktur, gangguan komunikasi, serta korban jiwa [1].

Indonesia merupakan salah satu negara dengan tingkat kerawanan gempa tertinggi di dunia karena terletak di wilayah Cincin Api Pasifik, tempat bertemunya Lempeng Indo-Australia, Eurasia, dan Pasifik yang saling bergerak dan bertumbukan. Berdasarkan data Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) periode Januari hingga November 2024, tercatat sebanyak 1.394 kejadian gempa bumi dengan magnitudo lebih dari 4, yang tersebar di berbagai wilayah Indonesia, baik yang dirasakan maupun tidak. Selain itu, terdapat zona megathrust, yaitu zona subduksi antar lempeng yang berpotensi menghasilkan gempa besar hingga magnitudo 9, sehingga kewaspadaan perlu ditingkatkan.

Berbagai upaya telah dilakukan pemerintah Indonesia untuk mengurangi dampak gempa bumi, seperti membangun infrastruktur tahan gempa dan meningkatkan edukasi serta kesadaran masyarakat. Namun, implementasinya belum merata di seluruh daerah. Salah satu langkah penting yang belum diimplementasikan adalah belum adanya pemetaan

wilayah rawan gempa yang dibuat berdasarkan pengelompokan data gempa secara sistematis. Dengan mengetahui daerah-daerah yang tergolong rawan berdasarkan pola gempa yang pernah terjadi, langkah pencegahan dan penanganan dapat disesuaikan secara lebih tepat dan efisien.

Sebagai upaya mitigasi, diperlukan pemetaan kerawanan daerah gempa melalui proses pengelompokan atau klusterisasi daerah atau wilayah berdasarkan data-data kejadian gempa bumi. Klusterisasi sendiri merupakan metode pengelompokan data ke dalam beberapa kelompok atau kluster, di mana setiap kluster berisi data yang memiliki kemiripan karakteristik [2]. Dengan mengumpulkan atribut terkait setiap wilayah dapat dikelompokkan ke dalam kluster tertentu sesuai tingkat kerawannya. Hasil dari proses klusterisasi ini akan sangat membantu dalam menyusun strategi mitigasi yang lebih terarah, efektif, dan sesuai dengan kebutuhan masing-masing daerah. Oleh karena itu, diperlukan metode klusterisasi yang mampu memberikan hasil optimal dalam pembagian wilayah rawan gempa.

Untuk melakukan klusterisasi kerawanan tersebut, algoritma *Invasive Weed Optimization* (IWO) dipilih karena memiliki keunggulan dalam menentukan posisi pusat kluster (centroid) secara optimal, bahkan pada dataset yang besar. *Invasive Weed Optimization* terinspirasi dari cara tumbuhan gulma menyebar dan beradaptasi mencari lingkungan terbaik untuk tumbuh [3]. Algoritma ini mampu mengeksplorasi dan mengeksploitasi ruang solusi secara efektif, sehingga diharapkan mampu

menghasilkan pembagian wilayah rawan gempa yang lebih akurat dibandingkan dengan metode lain seperti *K-Means* atau *DBSCAN*. Dengan menerapkan algoritma *Invasive Weed Optimization*, proses klusterisasi kerawanan gempa di Indonesia dapat dilakukan secara lebih optimal, dan hasilnya dapat dijadikan acuan dalam perencanaan mitigasi bencana gempa bumi di Indonesia.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Pada penelitian terdahulu yang dilakukan oleh [4] dengan judul “Analisis Klusterisasi Kerawanan Gempa Bumi di Provinsi Papua Menggunakan Algoritma *Invasive Weed Optimization* (IWO)”, hasil dari penelitian ini menunjukkan bahwa metode *Invasive Weed Optimization* efektif dalam mengelompokkan daerah rawan gempa di Provinsi Papua ke dalam enam klaster utama berdasarkan parameter seperti magnitudo dan kedalaman. Pemodelan ini memberikan gambaran sebaran kerawanan gempa yang lebih terfokus dan mampu membantu pihak terkait dalam menentukan kebijakan mitigasi bencana secara lebih tepat di Provinsi Papua. Penelitian lain juga dilakukan oleh [5] dengan judul “Analisis Gempa Bumi di Indonesia dengan Metode *Clustering*”, pengelompokan daerah rawan gempa bumi di Indonesia dilakukan menggunakan algoritma *K-Means*. Hasil dari penelitian ini menunjukkan bahwa wilayah Indonesia dapat diklasifikasikan ke dalam tiga klaster, yaitu klaster *Low* dengan 209 wilayah, *Medium* dengan 863 wilayah, dan *High* dengan 41 wilayah dari total 1113 kategori kasus yang diuji. Penelitian ini memberikan wawasan mengenai sebaran kerawanan gempa bumi yang dapat digunakan untuk upaya mitigasi bencana di Indonesia.

Berdasarkan hasil dari penelitian terdahulu dan juga permasalahan yang telah diidentifikasi, solusi yang diusulkan adalah pemetaan daerah rawan gempa bumi di Indonesia dengan melakukan klusterisasi kerawanan gempa bumi di Indonesia menggunakan algoritma *Invasive Weed Optimization*.

2.2. Clustering

Clustering adalah teknik untuk mengelompokkan data ke dalam beberapa grup atau klaster berdasarkan kemiripan karakteristik. Teknik ini termasuk dalam metode unsupervised learning karena proses pengelompokkannya tidak membutuhkan label atau kategori tertentu sebagai acuan, sehingga semua data dianggap setara [6].

Tujuan utama dari *clustering* adalah menemukan pola atau struktur tersembunyi dalam kumpulan data. Klaster yang baik adalah kelompok data yang anggotanya saling mirip satu sama lain, namun berbeda dengan kelompok lainnya. Dengan cara ini, pola dalam data akan lebih mudah dikenali dan bisa membantu dalam proses analisis atau pengambilan keputusan.

2.3. Invasive Weed Optimization

Invasive Weed Optimization (IWO) adalah algoritma pemecahan masalah yang terinspirasi dari cara gulma menyebar dan tumbuh di lingkungan baru. Proses algoritma ini melibatkan beberapa komponen utama, seperti inisialisasi, reproduksi, mutasi, kompetisi, dan penghentian, yang bekerja bersama untuk mencapai solusi optimal [7]. Tahapan algoritma *Invasive Weed Optimization* terbagi menjadi enam langkah utama yaitu:

a. Inisialisasi Populasi

Tahap dimulai dengan menentukan parameter dasar algoritma, menerima data masukan, dan menetapkan posisi awal *centroid* secara acak. Untuk parameter parameter yang akan digunakan seperti pada Tabel 1.

Tabel 1. Parameter Algoritma IWO

Parameter	Keterangan
k	Jumlah klaster
itmax	Jumlah iterasi maksimum
N0	Ukuran populasi awal
Smax	Jumlah maksimum benih/anak per individu
Smin	Jumlah minimum benih/anak per individu
N	<i>Nonlinear modulation index</i>
$\sigma_{initial}$	Standar deviasi awal
σ_{final}	Standar deviasi akhir
Pmax	Ukuran populasi maksimum

b. Menentukan Anggota dari Tiap Gulma Induk

Pada tahap ini melakukan dua langkah yaitu menghitung jarak tiap data dengan seluruh *centroid* dan menentukan anggota dari masing-masing klaster yang terbentuk. Perhitungan jarak tiap data dengan seluruh *centroid* menggunakan persamaan *Euclidean Distance* berikut:

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

c. Menghasilkan Gulma Anak dan Daerah Penyebarannya

Pada tahap ini terdapat tiga langkah yaitu menghitung nilai fitness, memilih jumlah gulma anak, dan menentukan posisi penyebaran gulma anak. Perhitungan jumlah gulma anak yang dihasilkan dihitung menggunakan persamaan:

$$nseed = \left(\frac{F_i - F_{worst}}{F_{best} - F_{worst}} \right) = (S_{max} - S_{min}) + S_{min} \quad (2)$$

Penentuan posisi penyebaran gulma anak dilakukan menggunakan distribusi normal dengan rata-rata posisi gulma induk dan nilai $\sigma_{initial}$ yang berubah setiap iterasi sesuai dengan persamaan:

$$\sigma_{iter} = \left(\frac{iter_{max} - iter}{iter_{max}} \right)^n (\sigma_{initial} - \sigma_{final}) + \sigma_{final} \quad (3)$$

d. Memilih Kombinasi Calon Gulma

Tahap ini dilakukan penggabungan gen terbaik untuk membentuk gulma baru.

e. Menentukan Anggota dari Tiap Gulma pada Tiap Koloni Gulma

Pada tahap ini, mutasi dilakukan bertujuan untuk meningkatkan variasi dalam populasi.

f. Penentuan Koloni Gulma yang Mempunyai Nilai *Best Fitness*

Setelah semua tahap dilalui, populasi dievaluasi kembali menggunakan fungsi objektif untuk menemukan solusi terbaik. Proses ini diulang hingga kriteria penghentian tercapai, seperti jumlah iterasi maksimum. Setelah kriteria terpenuhi, individu dengan nilai *fitness* terbaik dipilih sebagai solusi akhir, yang mencerminkan hasil klusterisasi optimal.

2.4. Evaluasi Model

Evaluasi model merupakan proses analisis untuk menilai kualitas hasil klusterisasi. Penilaian model klusterisasi dapat dilakukan dengan mengukur seberapa baik dan efektif data telah dikelompokkan ke dalam klaster yang dihasilkan [8]. Dalam penelitian ini digunakan tiga metrik utama:

a. *Sum of Squared Errors* (SSE)

Sum of Squared Errors (SSE) adalah metode statistik yang menghitung total selisih kuadrat antara data aktual dan hasil model [9]. Nilai SSE yang lebih kecil menunjukkan titik-titik data lebih dekat ke pusat klasternya, menandakan klaster yang kompak dan homogen. Persamaannya:

$$SSE = \sum_{k=1}^c \sum_{x_i \in C_k} (x_i - \mu_k)^2 \quad (4)$$

b. *Davies-Bouldin Index* (DBI)

Davies-Bouldin Index (DBI) adalah metode evaluasi internal yang digunakan untuk mengukur kualitas pembentukan klaster [10]. DBI mengukur rasio antara kekompakan tiap klaster (*cohesion*) dengan jarak antar-klaster (*separation*). Nilai DBI yang lebih kecil berarti klaster terpisah dengan baik dan masing-masing kompak. Persamaannya:

$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} \left(\frac{\sigma_i + \sigma_j}{d(c_i, c_j)} \right) \quad (5)$$

c. *Silhouette Score*

Silhouette Score adalah metode evaluasi klaster yang menggabungkan pengukuran kekompakan dan keterpisahan data [11]. Nilai *Silhouette Score* mendekati 1 menunjukkan setiap titik lebih dekat ke klasternya sendiri daripada ke klaster lain. Rata-rata skor dihitung dengan persamaan:


$$s(i) = \frac{b(i) - a(i)}{\max(a(i), b(i))} \quad (6)$$

3. METODE PENELITIAN

Metode penelitian adalah kerangka sistematis yang digunakan untuk memperoleh dan menganalisis data dalam rangka mencapai tujuan penelitian.

3.1. Alur Penelitian

Penelitian ini terdiri dari beberapa tahap, dimulai dengan identifikasi masalah, studi literatur, analisis kebutuhan, pengumpulan data, *preprocessing data*, pembuatan model, evaluasi, dan *deployment*. Alur Penelitian tersebut ditampilkan pada Gambar 1.



Gambar 1. Alur Penelitian

3.2. Identifikasi Masalah

Indonesia merupakan salah satu negara yang berada pada jalur cincin api (*ring of fire*), sehingga memiliki tingkat aktivitas seismik yang tinggi dan rentan terhadap bencana gempa bumi. Setiap tahunnya, terjadi ribuan gempa bumi dengan variasi lokasi, magnitudo, dan kedalaman yang berbeda-beda. Kondisi ini menuntut adanya pemahaman yang lebih baik mengenai pola distribusi gempa bumi di berbagai wilayah Indonesia, terutama dalam konteks upaya mitigasi bencana dan perencanaan kebijakan penanggulangan.

Untuk mendukung hal tersebut, diperlukan pemahaman tentang distribusi gempa di berbagai wilayah. Klusterisasi dapat membantu mengelompokkan data gempa berdasarkan karakteristik tersebut, namun diperlukan algoritma yang mampu menangani data terkait. Algoritma *Invasive Weed Optimization* menawarkan eksplorasi ruang solusi yang lebih menyeluruh dan adaptif dalam penentuan pusat klaster. Penelitian ini bertujuan menerapkan *Invasive Weed Optimization* untuk klusterisasi kerawanan gempa bumi di Indonesia.

3.3. Studi Literatur

Studi literatur dilakukan dengan mengumpulkan berbagai sumber seperti buku, jurnal, dan publikasi lain yang relevan dengan topik dan tujuan penelitian. Tahap ini bertujuan membangun landasan konseptual yang kuat melalui identifikasi teori, model, serta temuan-temuan dari penelitian sebelumnya.

3.4. Analisis Kebutuhan

Analisis kebutuhan dilakukan agar proses klusterisasi gempa bumi dapat berjalan efektif dengan menganalisis kebutuhan yaitu data yang diperlukan untuk keperluan klusterisasi kerawanan gempa bumi di Indonesia.

3.5. Pengumpulan Data

Pengumpulan data melakukan pengambilan data gempa bumi yang akan dianalisis dari sumber resmi BMKG untuk periode Januari 2014 hingga November 2024, meliputi seluruh kejadian gempa di wilayah Indonesia. Setiap data yang mencakup atribut-atribut penting. Pemilihan rentang waktu dan atribut yang digunakan bertujuan untuk memastikan bahwa data yang dikumpulkan sudah lengkap dan cukup untuk mendukung proses klasterisasi kerawanan gempa bumi di Indonesia.

3.6. Preprocessing Data

Preprocessing data merupakan proses awal yang dilakukan untuk mengolah data mentah agar siap digunakan dalam analisis lanjutan. Tahap *preprocessing* mencakup empat langkah utama, yaitu *data cleaning* untuk menghapus data yang tidak relevan atau mengandung kesalahan, pemilihan atribut guna menentukan atribut yang akan digunakan, normalisasi data untuk menyamakan skala nilai antar atribut, serta transformasi data agar data lebih sesuai dengan kebutuhan algoritma yang digunakan.

3.7. Pembuatan Model

Pembuatan model merupakan proses inti dalam penelitian yang bertujuan untuk membuat pemodelan dengan algoritma yang mampu mengelompokkan data. Pada tahap ini, dilakukan penerapan algoritma *Invasive Weed Optimization* untuk proses klasterisasi.

3.8. Evaluasi

Evaluasi dilakukan untuk mengukur seberapa baik hasil klasterisasi yang diperoleh dari masing-masing algoritma. Proses ini menggunakan tiga indikator, yaitu *Sum of Squared Errors (SSE)*, *Davies-Bouldin Index*, dan *Silhouette Score*. Ketiga metrik ini memberikan gambaran menyeluruh tentang kualitas dan keakuratan model klasterisasi yang dibuat. Pada tahap ini juga dilakukan perbandingan hasil evaluasi dari ketiga algoritma yang digunakan, yaitu *Invasive Weed Optimization*, *K-Means*, dan *DBSCAN*.

3.9. Deployment

Deployment merupakan proses implementasi model yang telah dibangun ke dalam website yang dapat diakses. Dalam penelitian ini, *deployment* dilakukan dengan membangun aplikasi berbasis web menggunakan framework Flask. website ini dirancang untuk menampilkan hasil klasterisasi kerawanan gempa bumi.

3.10. Pengujian Sistem

Pengujian sistem dilakukan untuk memastikan bahwa setiap fitur dalam website berjalan sesuai dengan fungsi yang diharapkan. Metode pengujian yang digunakan adalah *Blackbox Testing*, yaitu pengujian yang tanpa memperhatikan kode program. Pengujian ini dilakukan pada fitur-fitur pada website.

4. HASIL DAN PEMBAHASAN

Tahap hasil dan pembahasan dalam penelitian ini memuat keluaran dari setiap tahapan yang telah dilakukan, mulai dari proses pengumpulan dan *preprocessing data*, pemodelan klasterisasi, evaluasi model, hingga *deployment* dengan implementasi akhir dalam bentuk aplikasi berbasis website.

4.1. Pengumpulan Data

Pengumpulan data dilakukan melalui situs resmi Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Data yang digunakan dalam penelitian ini merupakan data kejadian gempa bumi di Indonesia yang tercatat dari Januari 2014 hingga November 2024, dengan total sebanyak 84733 kejadian. Data tersebut terdiri dari 11 atribut, yaitu Event ID, Date Time, Latitude, Longitude, Magnitude, Mag Type, Depth (km), Phase Count, Azimuth Gap, Location, dan Agency. Pengumpulan data dilakukan melalui situs resmi Badan Meteorologi, Klimatologi, dan Geofisika (BMKG). Data gempa dapat dilihat melalui Tabel 2.

Tabel 2. Data Gempa Bumi di Indonesia

No	Latitude	Longitude	Depth	Magnitude
1	2.8063	129.415	10	3.435
2	3.657	126.724	31	3.957
3	2.818	129.413	10	3.556
4	2.952	128.851	12	4.308
...	...	...	...	...
84733	6.992	127.706	252	4.227

4.2. Preprocessing Data

Preprocessing data mencakup empat tahap yaitu *data cleaning*, pemilihan atribut, normalisasi data, dan transformasi data.

a. Data Cleaning

Tahap *data cleaning* dilakukan untuk memastikan bahwa data yang digunakan dalam analisis benar-benar merepresentasikan wilayah Indonesia. Langkah pertama adalah menghapus seluruh baris data yang mengandung nilai kosong agar tidak memengaruhi hasil analisis. Selanjutnya, data disaring berdasarkan koordinat geografis, dengan hanya mempertahankan kejadian gempa yang berada dalam rentang *latitude* -11° hingga 6° dan *longitude* 95° hingga 141°, yang merupakan batas geografis wilayah Indonesia. Data di luar koordinat tersebut dihilangkan karena berada di luar cakupan analisis. Selain itu, dilakukan juga penyaringan tambahan berdasarkan nama lokasi, di mana kata kunci seperti 'Philippine', 'Malay', 'Timor', 'Micronesia', 'Indian', 'China', dan 'Arafura' digunakan untuk mengidentifikasi peristiwa gempa yang kemungkinan terjadi di luar wilayah Indonesia. Baris data yang mengandung kata kunci tersebut juga dihapus untuk memperkuat fokus analisis hanya pada wilayah Indonesia.

b. Pemilihan Atribut

Pemilihan atribut dilakukan untuk memfokuskan analisis hanya pada fitur-fitur yang paling relevan terhadap proses klasterisasi gempa bumi di

Indonesia. Dari keseluruhan atribut yang tersedia dalam dataset, dipilih empat atribut utama, yaitu *latitude*, *longitude*, *depth*, dan *magnitude*. *latitude* dan *longitude* digunakan karena merepresentasikan letak geografis pusat gempa. Atribut *depth* dan *magnitude* menggambarkan karakteristik fisik gempa. Keempat atribut ini akan digunakan sebagai dasar dalam proses analisis selanjutnya

c. Normalisasi Data

Normalisasi data bertujuan untuk menyeragamkan skala nilai antar atribut agar tidak terjadi dominasi atribut tertentu dalam proses klusterisasi akibat perbedaan skala. Pada tahap ini digunakan metode *min-max normalization*, yang mengkonversi nilai setiap atribut ke dalam rentang antara 0 hingga 1. Proses ini dilakukan berdasarkan rumus min-max:

$$x_{\text{norm}} = \frac{x - x_{\text{min}}}{x_{\text{max}} - x_{\text{min}}} \quad (7)$$

Hasil normalisasi data gempa bumi Indonesia dapat dilihat pada Tabel 3.

Tabel 3. Normalisasi Data Gempa Bumi

No	Latitude	Longitude	Depth	Magnitude
1	0.236	0.711	0.335	0.469
2	0.850	0.694	0.012	0.444
3	0.876	0.690	0.041	0.446
4	0.643	0.616	0.158	0.401
5	0.149	0.378	0.115	0.314

d. Transformasi Data

Transformasi data yang bertujuan untuk memastikan bahwa format dan tipe data sesuai dengan kebutuhan teknis algoritma klusterisasi. Pada tahap ini, seluruh atribut yang digunakan dalam analisis yaitu *latitude*, *longitude*, *depth*, dan *magnitude* dikonversi ke dalam tipe data float32. Pemilihan tipe ini dilakukan untuk meningkatkan efisiensi penggunaan memori serta memastikan kompatibilitas data dengan algoritma yang diterapkan pada tahap selanjutnya.

Setelah melalui keempat tahapan *preprocessing*, yaitu *data cleaning*, pemilihan atribut, normalisasi data, dan transformasi data. Dari total 84733 data gempa bumi yang dikumpulkan pada tahap awal, hanya 81454 data yang dapat digunakan untuk analisis lebih lanjut. Proses ini memastikan bahwa data yang digunakan benar-benar bersih dan sesuai dengan kebutuhan analisis klusterisasi.

4.3. Pembuatan Model

Proses pembuatan model dimulai dengan menentukan nilai K optimal yang akan digunakan sebagai salah satu parameter penting dalam penerapan algoritma *Invasive Weed Optimization*. Setelah nilai K ditetapkan, langkah selanjutnya adalah membangun model klusterisasi menggunakan algoritma IWO untuk mengelompokkan data gempa bumi berdasarkan karakteristik fisik gempa bumi.

a. Penentuan K Optimal


Untuk menentukan jumlah kluster optimal (nilai K) yang akan digunakan dalam proses klusterisasi,

digunakan metode Elbow dan *Silhouette Score*. Tahapan ini melibatkan pengujian nilai K dari 2 hingga 20 kluster. Metode Elbow dilakukan dengan menghitung nilai WCSS (*Within-Cluster Sum of Squares*) untuk setiap nilai K, kemudian hasilnya divisualisasikan dalam bentuk grafik. Grafik tersebut memplot hubungan antara jumlah kluster dan nilai WCSS, di mana titik penurunan tajam pada kurva menunjukkan indikasi jumlah kluster yang optimal. *Silhouette Score* digunakan untuk mengevaluasi seberapa baik data dalam setiap kluster.

Tabel 4. Penentuan Jumlah Kluster Optimal

Percobaan	Jumlah Kluster	Nilai Silhouette Score
1	2	0.4812
2	3	0.4725
3	4	0.4910
4	5	0.4406
5	6	0.4593
6	7	0.4301
7	8	0.4349
8	9	0.4185
9	10	0.4199
10	11	0.4292
11	12	0.4117
12	13	0.4132
13	14	0.3977
14	15	0.3965
15	16	0.3991
16	17	0.4015
17	18	0.4071
18	19	0.4111
19	20	0.3928

Berdasarkan hasil perhitungan yang ditunjukkan pada Tabel 4 yang menunjukkan nilai *Silhouette Score* dari setiap kluster yang dicoba mulai dari 2 hingga 20 kluster dan visualisasi grafik Elbow pada Gambar 2, Sehingga jumlah kluster empat dipilih sebagai jumlah kluster yang paling optimal. Pemilihan ini didasarkan pada titik siku yang terbentuk pada grafik WCSS serta nilai *Silhouette Score* tertinggi yang mendukung kualitas pemisahan kluster yang baik. Dengan demikian, empat kluster digunakan dalam proses klusterisasi gempa bumi di Indonesia menggunakan algoritma *Invasive Weed Optimization*.



Gambar 2. Metode elbow untuk penentuan k optimal

b. Pemodelan Klasterisasi Menggunakan IWO

Dalam proses pemodelan klasterisasi kerawanan gempa bumi di Indonesia, digunakan algoritma *Invasive Weed Optimization*. Untuk menjalankan IWO, sejumlah parameter awal harus ditentukan agar proses optimasi berjalan efektif dan efisien seperti pada Tabel 5.

Tabel 5. Nilai Parameter IWO

Parameter	Nilai	Keterangan
k	4	Jumlah klaster
itmax	70	Jumlah iterasi maksimum
N0	20	Ukuran populasi awal
Smax	20	Jumlah maksimum benih/anak per individu
Smin	5	Jumlah minimum benih/anak per individu
N	4	<i>Nonlinear modulation index</i>
$\sigma_{initial}$	0.5	Standar deviasi awal
σ_{final}	0.01	Standar deviasi akhir
Pmax	40	Ukuran populasi maksimum

Penentuan nilai $\sigma_{initial}$ berperan penting untuk menghindari jebakan pada nilai lokal optima yang buruk. Jika nilai $\sigma_{initial}$ konstan dalam setiap iterasi, algoritma cenderung mengeksplorasi area terbatas dan berisiko gagal menemukan solusi terbaik. Oleh karena itu, nilai ini dipilih agar memungkinkan eksplorasi area pencarian yang lebih luas. Sementara itu, nilai σ_{final} diperoleh dari perhitungan total standar deviasi. Smin dan Smax ditentukan dengan proporsi 2-5% dan 10-20% dari populasi total sebagai kontrol penyebaran individu baru. Jumlah iterasi maksimum dipilih sebanyak 70 kali dengan pertimbangan keseimbangan antara kedalaman pencarian solusi dan efisiensi komputasi.

Setelah semua parameter ditetapkan, pemodelan dilakukan dengan menggunakan dua atribut utama

yaitu *depth* dan *magnitude* yang merepresentasikan tingkat kerawanan fisik dari kejadian gempa. Atribut *latitude* dan *longitude* tetap digunakan dalam tahap visualisasi, tetapi tidak dimasukkan dalam proses klasterisasi agar hasil klaster benar-benar fokus pada karakteristik fisik gempa, bukan jarak kedekatan geografis antar lokasi.


Hasil dari proses *Invasive Weed Optimization* menghasilkan empat klaster yang mencerminkan tingkat kerawanan gempa berdasarkan kombinasi kedalaman dan kekuatan gempanya. Empat klaster tersebut kemudian diberi label Kurang Rawan, Cukup Rawan, Rawan, dan Sangat Rawan. Detail untuk Tingkat kerawanan seperti pada Tabel 6. Klaster dengan label kurang rawan mewakili gempa dangkal dengan kekuatan rendah hingga sedang. Karena dampaknya kecil di permukaan, klaster ini dikategorikan sebagai kurang rawan. Klaster ini tersebar luas di seluruh wilayah Indonesia. Dominasi klaster ini mengindikasikan banyaknya kejadian gempa ringan yang meski sering, dampaknya relatif kecil di permukaan. Klaster dengan label cukup rawan merepresentasikan gempa berkedalaman sangat dalam dengan magnitudo cukup tinggi. Karena terjadi di kedalaman yang jauh, dampaknya di permukaan biasanya lebih ringan, tapi tetap perlu diwaspadai. Sehingga dikategorikan sebagai cukup rawan. Klaster dengan label rawan mencerminkan gempa berkedalaman menengah dengan kekuatan magnitudo menengah hingga tinggi. Klaster ini berpotensi menimbulkan guncangan yang cukup kuat. Klaster dengan label sangat rawan memiliki karakteristik gempa dangkal dan berkekuatan tinggi yang secara umum memiliki dampak yang signifikan di permukaan. Daerah atau wilayah klaster ini termasuk yang paling berisiko mengalami guncangan kuat.

Tabel 6. Tingkat Kerawanan Tiap Klaster


Tingkat Kerawanan	Distribusi Data	Rentang Depth	Rata-Rata Depth	Rentang Magnitude	Rata-Rata Magnitude
Kurang Rawan	46132	1 -189.75 Km	23.74 Km	0.99 – 3.76	3.13
Cukup Rawan	1413	305.09 – 750 Km	496.96 Km	2.66 – 7.27	4.43
Rawan	10336	81.89 – 341.8 Km	167.67 Km	2.11 – 7.06	3.99
Sangat Rawan	23573	1 – 186 Km	26.09 Km	3.76 – 7.89	4.38

Pada Gambar 3, klaster kurang rawan ditunjukkan oleh titik-titik berwarna hijau, klaster cukup rawan ditunjukkan oleh titik-titik berwarna kuning, klaster rawan ditunjukkan oleh titik-titik berwarna oranye dan klaster sangat rawan ditunjukkan oleh titik-titik merah.

Pada Gambar 4, untuk visualisasi yang lebih baik dibuat heatmap daerah kerawanan gempa bumi di Indonesia yang klaster kurang rawan ditunjukkan warna hijau, klaster cukup rawan ditunjukkan oleh warna kuning, klaster rawan ditunjukkan oleh warna oranye dan klaster sangat rawan ditunjukkan oleh warna merah.



Gambar 3. Hasil klasterisasi dengan layout peta



Gambar 4. Daerah kerawanan gempa bumi di Indonesia

4.4. Evaluasi

Tabel 7. Perbandingan Evaluasi Algoritma

Algoritma	Sum of Squared Errors	Davies-Bouldin Index	Silhouette Score
IWO	510.513	0.736	0.4927
K-Means	512.710	0.734	0.4910
DBSCAN	1734.8168	1.3394	0.4161

Berdasarkan hasil evaluasi yang ditampilkan pada Tabel 7, kinerja algoritma *Invasive Weed Optimization* dibandingkan dengan *K-Means* dan *DBSCAN* dianalisis menggunakan tiga metrik yaitu *Sum of Squared Errors*, *Davies-Bouldin Index*, dan *Silhouette Score*. Hasilnya menunjukkan bahwa algoritma IWO unggul dibandingkan *K-Means* dan *DBSCAN*.

IWO mencatat nilai SSE sebesar 510.513 yang menunjukkan tingkat kekompakan kluster yang tinggi. Pada metrik *Davies-Bouldin Index*, IWO memiliki nilai 0.736. Perbedaan ini sangat kecil dan tidak signifikan terhadap *Davies-Bouldin Index K-Means*. Namun, dari segi *Silhouette Score*, IWO mencatat nilai tertinggi sebesar 0.4927 yang menandakan bahwa struktur kluster yang dihasilkan IWO lebih sesuai dengan distribusi data.

Secara keseluruhan, dari ketiga metrik evaluasi tersebut, IWO menunjukkan performa paling seimbang antara kekompakan dan pemisahan kluster. Sehingga IWO dinilai sebagai algoritma yang paling tepat digunakan dalam proses klusterisasi untuk kerawanan gempa bumi di Indonesia.

4.5. Deployment

Untuk meningkatkan pemahaman terhadap tingkat kerawanan gempa bumi di Indonesia,

dikembangkan sebuah aplikasi berbasis website. Aplikasi ini dirancang sebagai media visualisasi interaktif yang memungkinkan untuk mengakses informasi gempa secara *real-time*, menelusuri data historis, memahami hasil klusterisasi kerawanan, serta melakukan simulasi edukatif.

a. Fitur Gempa Bumi *Real-Time*

Fitur yang menyediakan informasi terkini tentang aktivitas gempa bumi di Indonesia yang diperoleh langsung dari API BMKG. Visualisasi ditampilkan dalam bentuk peta interaktif yang mencakup 1 gempa terbaru, 15 gempa terakhir dengan magnitudo lebih dari 5, dan 15 gempa terakhir yang dirasakan masyarakat.

b. Fitur Data Historis

Fitur yang menyajikan data gempa bumi dari tahun 2014 hingga 2024 dalam bentuk tabel yang interaktif. Pengguna dapat melakukan filter berdasarkan magnitudo, kedalaman, atau tahun kejadian. Data juga dapat diunduh untuk keperluan analisis lanjutan.

c. Fitur Klusterisasi Kerawanan Gempa Bumi

Fitur yang menampilkan hasil klusterisasi menggunakan algoritma IWO yang mengelompokkan data gempa menjadi empat kluster berdasarkan kedalaman dan kekuatan gempa. Kluster-kluster ini divisualisasikan ke dalam peta Indonesia untuk menunjukkan sebaran daerah rawan.

d. Fitur Simulasi

Fitur yang berguna untuk mensimulasikan data gempa baru dan melihat tingkat kerawannya berdasarkan model yang telah dibuat dan hasilnya divisualisasikan sebagai indikator warna sesuai kluster risiko.

4.6. Pengujian Sistem

Dalam penelitian ini, pengujian sistem dilakukan dengan menggunakan metode *black box testing*, yang berfokus pada pengujian fungsi-fungsi sistem tanpa melihat struktur internal dari sistem atau aplikasi. Selain itu, *black box testing* juga digunakan untuk menilai kinerja sistem dari sudut pandang pengguna, guna memastikan sistem berfungsi secara optimal dalam penggunaan sehari-hari.

Tabel 8. Pengujian *Blackbox Testing*

No.	Fitur Pengujian	Skenario	Output yang diharapkan	Status Pengujian
1.	Fitur informasi <i>real-time</i>	Buka halaman <i>real-time</i> kemudian klik gempa bumi terkini atau 15 gempa bumi <i>magnitude</i> lebih dari 5 atau 15 gempa bumi dirasakan.	Peta menampilkan satu penanda gempa bumi terkini di lokasi sebenarnya atau 15 penanda gempa bumi dengan <i>magnitude</i> > 5 sesuai keterangan penanda map atau 15 penanda gempa bumi dirasakan dengan ukuran penanda berbeda sesuai keterangan penanda map.	<i>Passed</i>
2.	Fitur data historis <i>download CSV</i>	Buka halaman data historis, kemudian klik <i>download CSV</i>	Tampil dialog unduhan CSV berhasil.	<i>Passed</i>

No.	Fitur Pengujian	Skenario	Output yang diharapkan	Status Pengujian
3.	Fitur klasterisasi kerawanan gempa	Buka halaman klasterisasi kerawanan gempa dan tunggu semua elemen tampil	Tampil peta, tabel, dan grafik terkait analisis hasil klasterisasi gempa bumi menggunakan algoritma <i>invasive weed optimization</i> .	<i>Passed</i>
4.	Fitur simulasi input dan hasil	Buka halaman simulasi, kemudian isi <i>form</i> manual, lalu klik simulasi data gempa	Tampil hasil berupa <i>badge</i> berwarna dan ringkasan data <i>input</i> , serta menambahkan penanda baru di titik <i>input</i> dengan warna klaster yang sesuai.	<i>Passed</i>

Mengacu pada Tabel 8, terdapat 4 skenario pengujian yang memuat *output* yang diharapkan beserta hasil uji coba. Hasil dari seluruh skenario menunjukkan bahwa sistem menghasilkan output yang sesuai dengan ekspektasi

5. KESIMPULAN DAN SARAN

Hasil penelitian menunjukkan bahwa klasterisasi kerawanan gempa bumi di Indonesia menggunakan algoritma *Invasive Weed Optimization* berhasil mengelompokkan data gempa di Indonesia menjadi empat klaster yang merepresentasikan tingkat kerawanan berbeda yaitu kurang rawan, cukup rawan, rawan, dan sangat rawan. Algoritma *Invasive Weed Optimization* menunjukkan performa yang kompetitif dan cenderung lebih unggul dibandingkan *K-Means* dan DBSCAN berdasarkan evaluasi menggunakan metrik *Sum of Squared Errors*, *Davies-Bouldin Index*, dan *Silhouette Score*. Visualisasi hasil klasterisasi dalam bentuk peta memberikan informasi yang dapat dimanfaatkan untuk mendukung upaya mitigasi bencana gempa bumi.

DAFTAR PUSTAKA

- [1] S. Wahyuningsi, A. Budianta, R. Awalia, and R. Mardin, "Arahan Mitigasi Terhadap Penurunan Tingkat Risiko Bencana Gempabumi Pada Permukiman Di Sekitar Jalur Sesar Palu-Koro," *J. Urban Reg. Plan. Tadulako*, vol. 3, no. 1, pp. 71–81, 2024.
- [2] N. Nur Afidah, "Penerapan Metode Clustering dengan Algoritma K-means untuk Pengelompokkan Data Migrasi Penduduk Tiap Kecamatan di Kabupaten Rembang," *Prism. Pros. Semin. Nas. Mat.*, vol. 6, pp. 729–738, 2023, [Online]. Available: <https://journal.unnes.ac.id/sju/index.php/prisma/>
- [3] M. Can, "Invasive-Weed-Optimization-Based Extreme Learning Machine for Prediction of Lake Water Level Using Major Atmospheric–Oceanic Climate Scenarios," *Sustainability*, vol. 16, no. 17, p. 7825, 2024, doi: 10.3390/su16177825.
- [4] L. Y. Baisa, D. Manongga, and Y. Nataliani, "Analisis Klasterisasi Kerawanan Gempa Bumi di Provinsi Papua Menggunakan Algoritma *Invasive Weed Optimization* (IWO)," *J. Edukasi dan Penelit. Inform.*, vol. 9, no. 2, p. 176, 2023, doi: 10.26418/jp.v9i2.65312.
- [5] A. Prasetyo, M. M. Effendi, and M. N. Dwi M, "Analisis Gempa Bumi Di Indonesia Dengan Metode Clustering," *Bull. Inf. Technol.*, vol. 4, no. 3, pp. 338–343, 2023, doi: 10.47065/bit.v4i3.820.
- [6] M. Produk *et al.*, "Penerapan Metode K-Means Pada Data Penjualan Untuk," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 5, no. 1, pp. 228–236, 2023.
- [7] M. Suresh, R. M. Mallika, A. Divya, and K. Purnima, "Exploring the Potential of Invasive Weed Optimization: A Population- Based Metaheuristic for Optimization Problems," vol. 44, no. 7, pp. 1307–1320, 2023.
- [8] S. Suraya, M. Sholeh, and U. Lestari, "Evaluation of Data Clustering Accuracy using K-Means Algorithm," *Int. J. Multidiscip. Approach Res. Sci.*, vol. 2, no. 01, pp. 385–396, 2023, doi: 10.59653/ijmars.v2i01.504.
- [9] R. Nainggolan, R. Perangin-Angin, E. Simarmata, and A. F. Tarigan, "Improved the Performance of the K-Means Cluster Using the Sum of Squared Error (SSE) optimized by using the Elbow Method," *J. Phys. Conf. Ser.*, vol. 1361, no. 1, pp. 0–6, 2019, doi: 10.1088/1742-6596/1361/1/012015.
- [10] T. Lidia Putri and R. Danar Dana, "Penerapan Data Mining Pada Clustering Data Harga Rumah Dki Jakarta Menggunakan Algoritma K-Means," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 1, pp. 1174–1179, 2024, doi: 10.36040/jati.v8i1.8957.
- [11] S. Paembonan and H. Abduh, "Penerapan Metode Silhouette Coefficient untuk Evaluasi Clustering Obat," *PENA Tek. J. Ilm. Ilmu-Ilmu Tek.*, vol. 6, no. 2, p. 48, 2021, doi: 10.51557/pt_jiit.v6i2.659.