

Optimasi XGBoost Menggunakan Grey Wolf Optimizer untuk Klasifikasi Status Gempa Bumi di Indonesia

XGBoost Optimization Using Grey Wolf Optimizer for Earthquake Status Classification in Indonesia

Wisnu Aji Sanjaya^{*1}, Yoka Romadani², Atika Ratna Dewi³

^{1,2,3} Program Studi Sains Data, Fakultas Informatika, Telkom University

e-mail: ^{*}wisnuajisanjaya@student.telkomuniversity.ac.id

Abstrak - Klasifikasi status gempa bumi diperlukan untuk mendukung analisis kejadian gempa secara cepat dan akurat. Penelitian ini bertujuan membandingkan performa algoritma Random Forest dan XGBoost serta mengoptimalkan hyperparameter menggunakan Grey Wolf Optimizer (GWO). Dataset yang digunakan berasal dari katalog gempa BMKG periode 2008–2025 dengan variabel lokasi, kedalaman, magnitudo, dan waktu kejadian. Hasil penelitian menunjukkan bahwa Random Forest dan XGBoost memperoleh accuracy sebesar 73%. Setelah dilakukan optimasi, GWO-Random Forest mencapai accuracy sebesar 74%, sedangkan GWO-XGBoost menjadi model terbaik dengan accuracy 75%, precision 75%, recall 74%, macro F1-score 74%, dan AUC 0,820. Hasil tersebut menunjukkan bahwa GWO mampu meningkatkan performa klasifikasi status gempa bumi.

Kata kunci – BMKG; Grey Wolf Optimizer; Klasifikasi Gempa; Random Forest; XGBoost.

Abstract - The classification of earthquake status is necessary to support the rapid and accurate analysis of earthquake events. This study aims to compare the performance of the Random Forest and XGBoost algorithms and to optimise hyperparameters using the Grey Wolf Optimizer (GWO). The dataset used was sourced from the BMKG earthquake catalogue for the period 2008–2025, comprising the variables of location, depth, magnitude and time of occurrence. The results of the study show that both Random Forest and XGBoost achieved an accuracy of 73%. Following optimisation, GWO-Random Forest achieved an accuracy of 74%, whilst GWO-XGBoost emerged as the best model with an accuracy of 75%, precision of 75%, recall of 74%, a macro F1-score of 74%, and an AUC of 0.820. These results demonstrate that GWO is capable of enhancing the performance of earthquake status classification.

Keywords – BMKG; Grey Wolf Optimizer; Earthquake Classification; Random Forest; XGBoost.

I. PENDAHULUAN

Gempa bumi merupakan salah satu bencana alam yang paling sering terjadi di Indonesia akibat posisi geografisnya yang berada pada pertemuan tiga lempeng tektonik utama, yaitu Lempeng Indo-Australia, Eurasia, dan Pasifik. Kondisi geologis tersebut menyebabkan Indonesia memiliki tingkat aktivitas seismik yang tinggi dengan karakteristik gempa yang bervariasi baik dari segi magnitudo, kedalaman, maupun lokasi episentrum [1]. Dampak yang ditimbulkan oleh gempa bumi tidak hanya berupa korban jiwa, tetapi juga kerusakan infrastruktur, gangguan aktivitas ekonomi, serta kerugian sosial yang signifikan sehingga

diperlukan upaya mitigasi bencana yang efektif melalui pemanfaatan teknologi dan analisis data [2], [3]. Seiring meningkatnya ketersediaan katalog gempa bumi yang dikelola oleh lembaga pemantauan seismik, pendekatan berbasis data (*data-driven approach*) menjadi salah satu alternatif yang banyak digunakan untuk mendukung analisis karakteristik gempa secara otomatis [4].

Salah satu parameter utama yang digunakan untuk menggambarkan tingkat kekuatan gempa bumi adalah magnitudo, yaitu ukuran energi yang dilepaskan ketika terjadi pergeseran pada patahan bumi [5]. Nilai magnitudo secara luas digunakan sebagai dasar dalam mengklasifikasikan tingkat kekuatan gempa, misalnya *slight* (3,0–3,9), *light* (4,0–4,9), *moderate* (5,0–5,9), *strong* (6,0–6,9), dan *severe* ($\geq 7,0$) [6]. Namun demikian, distribusi data gempa berdasarkan lima kategori tersebut umumnya tidak seimbang karena kejadian gempa berkekuatan besar relatif lebih sedikit dibandingkan gempa berkekuatan rendah. Oleh karena itu, penelitian ini membentuk status gempa berdasarkan parameter magnitudo menjadi dua kategori, yaitu Gempa Ringan (magnitudo $< 5,0$) dan Gempa Sedang-Kuat (magnitudo $\geq 5,0$). Pendekatan ini bertujuan menghasilkan distribusi kelas yang lebih representatif sehingga proses pembelajaran model klasifikasi dapat dilakukan secara lebih efektif tanpa menghilangkan makna praktis dari tingkat kekuatan gempa.

Perkembangan teknologi Machine Learning telah membuka peluang baru dalam pengolahan data seismik, baik untuk deteksi kejadian gempa, estimasi magnitudo, maupun klasifikasi karakteristik gempa bumi. Berbagai algoritma telah diterapkan pada penelitian sebelumnya, seperti Support Vector Machine (SVM), Random Forest, Artificial Neural Network (ANN), Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), hingga Transformer untuk meningkatkan akurasi analisis data gempa [7], [8]. Selain itu, algoritma berbasis *gradient boosting* seperti XGBoost juga banyak digunakan karena memiliki kemampuan yang baik dalam memodelkan hubungan nonlinier, menangani data berdimensi tinggi, serta memberikan performa klasifikasi yang kompetitif pada berbagai kasus prediksi [9].

Meskipun demikian, berdasarkan penelitian terdahulu masih terdapat beberapa keterbatasan yang perlu dikembangkan. Sebagian besar penelitian lebih berfokus pada prediksi magnitudo, estimasi parameter gempa, atau Earthquake Early Warning, sedangkan penelitian mengenai klasifikasi status gempa masih relatif terbatas [8]. Selain itu, optimasi hyperparameter pada model XGBoost umumnya masih menggunakan pendekatan konvensional seperti *grid search* atau *random search*, sementara pemanfaatan algoritma optimasi metaheuristik, khususnya Grey Wolf Optimizer (GWO), masih jarang diterapkan pada kasus klasifikasi status gempa bumi. Penelitian menggunakan data gempa bumi Indonesia juga masih lebih sedikit dibandingkan penelitian yang menggunakan data dari Jepang, India, Turki, maupun Amerika Serikat [10]. Kondisi tersebut menunjukkan adanya peluang untuk mengembangkan model klasifikasi yang memiliki performa lebih baik melalui optimasi hyperparameter serta evaluasi pada karakteristik data gempa Indonesia.

Berdasarkan kesenjangan tersebut, penelitian ini mengusulkan model XGBoost yang dioptimasi menggunakan Grey Wolf Optimizer (GWO) untuk klasifikasi status gempa bumi di Indonesia. Berbeda dengan penelitian sebelumnya, penelitian ini menggunakan status gempa yang dibentuk berdasarkan parameter magnitudo menjadi dua kategori sehingga distribusi kelas menjadi lebih representatif untuk proses pembelajaran model. Selain itu, penelitian ini melakukan evaluasi secara komprehensif dengan membandingkan model usulan terhadap dua model baseline, yaitu Logistic Regression dan K-Nearest Neighbor

(KNN), serta tiga model pembandingan, yaitu Random Forest, XGBoost, dan LightGBM menggunakan skema pembagian data serta metrik evaluasi yang sama sehingga hasil perbandingan dilakukan secara objektif (*apple-to-apple*).

Berdasarkan uraian tersebut, penelitian ini bertujuan mengembangkan model klasifikasi status gempa bumi berbasis XGBoost yang dioptimasi menggunakan Grey Wolf Optimizer. Selanjutnya, performa model usulan dievaluasi menggunakan metrik Accuracy, Precision, Recall, dan Macro F1-score, kemudian dibandingkan dengan model baseline dan model pembandingan untuk mengetahui efektivitas optimasi yang dilakukan. Hasil penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan penerapan machine learning pada analisis data seismik serta menjadi referensi bagi penelitian selanjutnya yang berfokus pada klasifikasi status gempa bumi.

II. TINJAUAN TEORI

2.1 Gempa Bumi dan Parameter Magnitudo

Gempa bumi merupakan getaran yang terjadi di permukaan bumi akibat pelepasan energi secara tiba-tiba dari dalam kerak bumi yang menghasilkan gelombang seismik. Aktivitas gempa bumi umumnya dipengaruhi oleh pergerakan lempeng tektonik, aktivitas vulkanik, maupun sesar aktif yang menyebabkan deformasi batuan [11]. Salah satu parameter utama yang digunakan untuk menggambarkan karakteristik gempa adalah magnitudo, yaitu ukuran besarnya energi yang dilepaskan ketika terjadi gempa bumi. Semakin besar nilai magnitudo, semakin besar pula energi yang dilepaskan dan potensi dampak yang dapat ditimbulkan. Pada penelitian ini, parameter magnitudo digunakan sebagai dasar pembentukan status gempa menjadi dua kategori, yaitu Gempa Ringan (magnitudo $< 5,0$) dan Gempa Sedang-Kuat (magnitudo $\geq 5,0$). Pengelompokan tersebut dilakukan untuk memperoleh distribusi kelas yang lebih representatif pada proses klasifikasi [6].

2.2 Machine Learning untuk Klasifikasi Gempa

Machine Learning merupakan salah satu cabang kecerdasan buatan (*Artificial Intelligence*) yang memungkinkan komputer mempelajari pola dari data untuk menghasilkan prediksi maupun klasifikasi tanpa diprogram secara eksplisit. Pada bidang seismologi, machine learning telah banyak diterapkan untuk deteksi gempa, estimasi magnitudo, prediksi aktivitas seismik, hingga klasifikasi karakteristik gempa bumi [8]. Berbagai algoritma seperti Logistic Regression, K-Nearest Neighbor (KNN), Random Forest, XGBoost, dan LightGBM telah menunjukkan performa yang baik pada permasalahan klasifikasi berbasis data tabular [7].

2.3 Extreme Gradient Boosting (XGBoost)

Extreme Gradient Boosting (XGBoost) merupakan algoritma *ensemble learning* berbasis teknik *gradient boosting* yang membangun model secara bertahap melalui kombinasi beberapa *decision tree*. XGBoost memiliki keunggulan dalam menangani hubungan nonlinier, mengurangi risiko *overfitting* melalui mekanisme regularisasi, serta mampu melakukan komputasi secara efisien sehingga banyak digunakan pada berbagai permasalahan klasifikasi maupun prediksi. Fungsi objektif XGBoost dinyatakan sebagai berikut.

$$[Obj(\theta) = L(\theta) + \Omega(\theta)]$$

dengan $(L(\theta))$ merupakan fungsi kerugian (*loss function*), sedangkan $(\Omega(\theta))$ merupakan fungsi regularisasi yang digunakan untuk mengendalikan kompleksitas model sehingga meningkatkan kemampuan generalisasi.

2.4 Grey Wolf Optimizer (GWO)

Grey Wolf Optimizer (GWO) merupakan algoritma optimasi metaheuristik yang terinspirasi dari perilaku berburu dan struktur kepemimpinan kawanan serigala abu-abu. [Sitasi] Dalam algoritma ini terdapat empat tingkatan hierarki, yaitu Alpha ((α)), Beta ((β)), Delta ((δ)), dan Omega ((ω)), di mana posisi solusi terbaik direpresentasikan oleh serigala Alpha. [Sitasi] Selama proses optimasi, posisi setiap individu diperbarui berdasarkan posisi tiga individu terbaik sehingga ruang pencarian dapat dieksplorasi secara efektif. Persamaan pembaruan posisi pada GWO ditunjukkan sebagai berikut.


$$[X^*(t + 1) = \frac{X_1^* + X_2^* + X_3^*}{3}]$$

Pada penelitian ini, GWO digunakan untuk mengoptimasi beberapa hyperparameter XGBoost, yaitu *n_estimators*, *max_depth*, *learning_rate*, *subsample*, dan *colsample_bytree* sehingga diperoleh kombinasi parameter yang mampu meningkatkan performa klasifikasi dibandingkan penggunaan parameter bawaan model.

III. METODE

3.1 Tahapan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk mengembangkan model klasifikasi status gempa bumi menggunakan algoritma machine learning. Tahapan penelitian dimulai dari pengumpulan dataset, proses *data preprocessing*, pembentukan variabel target, pembagian dataset, pembangunan model klasifikasi, optimasi hyperparameter menggunakan Grey Wolf Optimizer (GWO), hingga evaluasi performa model. Diagram alur penelitian ditunjukkan pada **Gambar 1**.



Gambar 1. Diagram Alur Penelitian

3.2 Dataset Penelitian

Dataset yang digunakan pada penelitian ini berasal dari InaTEWS Earthquake Repository yang dikelola oleh Badan Meteorologi, Klimatologi, dan Geofisika (BMKG) melalui katalog Earthquake Event Catalog. Repositori tersebut menyediakan katalog kejadian gempa bumi yang berisi parameter utama seperti waktu kejadian, koordinat episentrum, kedalaman, dan magnitudo gempa. Dataset diunduh melalui halaman Earthquake Event Catalog dan digunakan sebagai sumber data utama dalam penelitian.

Tabel 1. Deskripsi Dataset Penelitian

Komponen	Keterangan
Sumber Data	BMKG – InaTEWS Earthquake Repository
URL Dataset	https://repogempa.bmkg.go.id/eventcatalog
Jenis Data	Earthquake Event Catalog
Periode Data	2008–2014
Jumlah Data	17.778 data
Jumlah Fitur	7 fitur
Target	Status Gempa
Jumlah Kelas	2 kelas

Tabel 2. Variabel Penelitian

Variabel	Tipe Data	Keterangan
latitude	Float	Koordinat lintang gempa
longitude	Float	Koordinat bujur gempa
depth	Float	Kedalaman gempa (km)
mag	Float	Magnitudo gempa
tahun	Integer	Tahun kejadian
bulan	Integer	Bulan kejadian
hari	Integer	Hari kejadian
Status_Gempa	Kategorikal	Variabel target

Berdasarkan Tabel 2, penelitian ini menggunakan tujuh variabel prediktor, yaitu latitude, longitude, depth, magnitudo (mag), tahun, bulan, dan hari kejadian gempa, serta satu variabel target berupa *Status_Gempa*. Variabel-variabel prediktor dipilih karena merepresentasikan karakteristik spasial, temporal, dan seismik dari setiap kejadian gempa bumi. Sementara itu, *Status_Gempa* digunakan sebagai variabel target yang akan diprediksi oleh model machine learning dalam proses klasifikasi.

Tabel 3. Distribusi Kelas Status Gempa

Status Gempa	Jumlah Data	Persentase
Gempa Ringan	9.986	56,17%
Gempa Sedang-Kuat	8.792	43,83%
Total	17.778	100%

Berdasarkan Tabel 3, dataset penelitian terdiri atas 17.778 data gempa yang terbagi menjadi dua kelas, yaitu Gempa Ringan sebanyak 9.986 data (56,17%) dan Gempa Sedang-Kuat sebanyak 8.792 data (43,83%). Distribusi kedua kelas menunjukkan proporsi yang relatif seimbang, sehingga diharapkan dapat mengurangi potensi bias model terhadap salah satu

kelas serta mendukung proses pelatihan dan evaluasi model klasifikasi secara lebih representatif.

3.3 Data Preprocessing

Tahap *preprocessing* dilakukan untuk meningkatkan kualitas data sebelum digunakan pada proses pembelajaran model.

Tahapan yang dilakukan meliputi:

- Data Cleaning, yaitu menghapus data duplikat, menangani *missing value*, dan memastikan kesesuaian tipe data.
- Exploratory Data Analysis (EDA) untuk mengetahui karakteristik dataset melalui analisis distribusi data, distribusi kelas, serta hubungan antar fitur.
- Feature Engineering, yaitu mengekstraksi atribut waktu menjadi fitur tahun, bulan, dan hari.
- Pembentukan Target, yaitu mengubah nilai magnitudo menjadi variabel Status_Gempa, terdiri atas Gempa Ringan ($magnitudo < 4,0$) dan Gempa Sedang-Kuat ($magnitudo \geq 4,0$).
- Label Encoding untuk mengubah label kategorikal menjadi nilai numerik.

Tabel 4. Tahapan Data Preprocessing

Tahapan	Deskripsi
Data Cleaning	Menghapus duplikasi data, menangani <i>missing value</i> , dan memperbaiki tipe data
Exploratory Data Analysis	Analisis distribusi data, distribusi kelas, serta hubungan antar fitur
Feature Engineering	Menambahkan atribut tahun, bulan, dan hari
Pembentukan Target	Membentuk Status Gempa berdasarkan magnitudo
Label Encoding	Mengubah label menjadi numerik

3.4 Pembagian Dataset

Dataset dibagi menggunakan metode Hold-Out Validation dengan komposisi 80% data pelatihan, 10% data validasi, dan 10% data pengujian. Pembagian dilakukan menggunakan Stratified Sampling agar proporsi setiap kelas tetap terjaga pada masing-masing subset data.

Selanjutnya dilakukan proses StandardScaler pada algoritma Logistic Regression dan K-Nearest Neighbor karena kedua algoritma sensitif terhadap skala data. Sementara itu, Random Forest, dan XGBoost tidak memerlukan proses standardisasi karena berbasis pohon keputusan.

3.5 Model Klasifikasi

Penelitian ini menggunakan lima model klasifikasi yang terdiri atas dua model *baseline*, 2 model pembandingan, dan 2 model optimasi.

Tabel 5. Konfigurasi Model Penelitian

Jenis Model	Algoritma
Baseline	Logistic Regression K-Nearest Neighbor
Pembanding	Random Forest XGBoost
Model Optimasi	GWO-XGBoost GWO-Random Forest

3.6 Optimasi Hyperparameter Menggunakan Grey Wolf Optimizer

Optimasi dilakukan pada model XGBoost menggunakan algoritma Grey Wolf Optimizer (GWO). Tujuan optimasi adalah memperoleh kombinasi hyperparameter terbaik sehingga mampu meningkatkan performa klasifikasi.

Hyperparameter yang dioptimasi meliputi `n_estimators`, `max_depth`, `learning_rate`, `subsample`, dan `colsample_bytree`. Proses optimasi menggunakan 3-Fold Cross Validation dengan Macro F1-Score sebagai fungsi objektif.

Tabel 6. Konfigurasi Optimasi GWO

Parameter	Nilai
Optimizer	Grey Wolf Optimizer
Epoch	20
Population Size	15
Cross Validation	3-Fold
Objective Function	Macro F1-Score

Tabel 7. Ruang Pencarian Hyperparameter

Hyperparameter	Rentang Nilai
<code>n_estimators</code>	100–1000
<code>max_depth</code>	3–15
<code>learning_rate</code>	0,01–0,30
<code>subsample</code>	0,50–1,00
<code>colsample_bytree</code>	0,50–1,00

3.7 Evaluasi Model


Evaluasi model dilakukan menggunakan data pengujian (*testing set*) yang tidak digunakan pada proses pelatihan maupun optimasi. Performa model diukur menggunakan metrik Accuracy, Precision, Recall, dan Macro F1-Score. Selain itu, analisis Confusion Matrix, Learning Curve, dan Feature Importance digunakan untuk mengevaluasi kemampuan klasifikasi serta interpretabilitas model yang dihasilkan.

IV. HASIL DAN PEMBAHASAN

4.1 Exploratory Data Analysis (EDA)


Tahap Exploratory Data Analysis (EDA) dilakukan untuk memahami karakteristik dataset sebelum proses pembangunan model. Analisis meliputi distribusi kelas target, distribusi

magnitudo, distribusi kedalaman gempa, tren kejadian gempa berdasarkan waktu, serta hubungan antar variabel. Hasil EDA digunakan sebagai dasar dalam proses *feature engineering* dan pembentukan variabel target.




Gambar 2. Distribusi Status Gempa

Distribusi kelas menunjukkan bahwa dataset terdiri atas 9.986 data Gempa Ringan (56,17%) dan 8.792 data Gempa Sedang-Kuat (43,83%). Distribusi tersebut menunjukkan bahwa dataset relatif seimbang sehingga dapat mengurangi potensi bias model terhadap salah satu kelas selama proses pelatihan.



Gambar 3. Distribusi Magnitudo Gempa

Sebagian besar kejadian gempa memiliki magnitudo antara 3 hingga 5 SR, sedangkan gempa dengan magnitudo tinggi memiliki frekuensi yang lebih sedikit. Karakteristik tersebut sesuai dengan pola distribusi kejadian gempa yang umum ditemukan pada katalog seismik.



Gambar 4. Distribusi Kedalaman Gempa

Sebagian besar kejadian gempa berada pada kategori gempa dangkal hingga menengah. Kondisi ini menunjukkan bahwa wilayah Indonesia didominasi oleh aktivitas gempa tektonik dengan kedalaman relatif rendah.



Gambar 5. Tren Kejadian Gempa Tahun 2008–2014

Visualisasi menunjukkan fluktuasi jumlah kejadian gempa pada setiap tahun pengamatan. Perubahan jumlah kejadian dipengaruhi oleh aktivitas tektonik yang berbeda pada masing-masing periode.

4.2 Hasil Evaluasi Model Baseline

Tabel 8. Hasil Evaluasi Model Baseline

Model	Accuracy	Precision	Recall	Macro F1
Logistic Regression	0.62	0.62	0.62	0.61
K-Nearest Neighbor (KNN)	0.67	0.67	0.67	0.67

Berdasarkan Tabel 8, model K-Nearest Neighbor (KNN) menunjukkan performa yang lebih baik dibandingkan Logistic Regression pada seluruh metrik evaluasi. Logistic Regression memperoleh nilai accuracy sebesar 62% dengan Macro F1-Score sebesar 0,61, sedangkan KNN berhasil meningkatkan accuracy menjadi 67% dan Macro F1-Score menjadi 0,67. Peningkatan tersebut menunjukkan bahwa KNN lebih mampu mengenali pola nonlinier pada data gempa dibandingkan Logistic Regression yang mengasumsikan hubungan linier antar fitur. Meskipun demikian, kedua model masih menunjukkan performa yang relatif terbatas sehingga diperlukan algoritma yang lebih kompleks untuk meningkatkan kemampuan klasifikasi status gempa.

4.3 Hasil Evaluasi Model Pemanding

Tabel 9. Perbandingan Model Machine Learning

Model	Accuracy	Precision	Recall	Macro F1
Random Forest	0.73	0.73	0.73	0.73
XGBoost	0.73	0.74	0.73	0.73

Berdasarkan Tabel 9, Random Forest dan XGBoost menunjukkan performa klasifikasi yang relatif setara dengan nilai accuracy sebesar 73% dan macro F1-score sebesar 0,73. Meskipun demikian, XGBoost memiliki nilai precision yang sedikit lebih tinggi, yaitu 0,74 dibandingkan Random Forest sebesar 0,73, sedangkan nilai recall kedua model sama, yaitu 0,73. Hasil tersebut menunjukkan bahwa kedua algoritma memiliki kemampuan klasifikasi yang baik, namun masih memiliki peluang untuk ditingkatkan melalui proses optimasi hyperparameter menggunakan Grey Wolf Optimizer (GWO).

4.4 Hasil Optimasi GWO

Berdasarkan Tabel 11, Grey Wolf Optimizer (GWO) berhasil memperoleh kombinasi hyperparameter terbaik untuk model Random Forest. Hasil optimasi menunjukkan bahwa model menggunakan 273 pohon keputusan (n_estimators) dengan kedalaman maksimum 28

(max_depth), min_samples_split sebesar 3, dan min_samples_leaf sebesar 1. Selain itu, nilai max_features sebesar 0,8736 dan max_samples sebesar 0,5000 menunjukkan bahwa setiap pohon dibangun menggunakan sebagian fitur dan sampel data, sedangkan penggunaan kriteria entropy serta bootstrap=True mendukung proses pembentukan ensemble yang lebih beragam. Kombinasi hyperparameter tersebut selanjutnya digunakan sebagai konfigurasi akhir pada model GWO-Random Forest untuk proses pelatihan, validasi, dan pengujian.

Tabel 10. Hyperparameter Terbaik Hasil Optimasi GWO-Random Forest

Hyperparameter	GWO RF
n_estimators	273
max_depth	28
min_samples_split	3
min_samples_leaf	1
max_features	0.8736
max_samples	0.5000
criterion	entropy
bootstrap	True

Tabel 11. Perbandingan Performa Sesudah Optimasi GWO-Random Forest

Model	Accuracy	Precision	Recall	Macro F1
GWO-RF	0.73	0.74	0.73	0.73

Berdasarkan Tabel 11, model GWO-Random Forest memperoleh nilai accuracy sebesar 74%, precision sebesar 0,74, recall sebesar 0,73, dan macro F1-score sebesar 0,73. Dibandingkan dengan Random Forest sebelum optimasi, penerapan Grey Wolf Optimizer (GWO) berhasil meningkatkan nilai accuracy dari 73% menjadi 74%, yang menunjukkan bahwa optimasi hyperparameter mampu meningkatkan kemampuan model dalam mengklasifikasikan status gempa bumi secara lebih akurat tanpa mengurangi keseimbangan performa antar kelas.

Berdasarkan Tabel 12, Grey Wolf Optimizer (GWO) menghasilkan kombinasi hyperparameter terbaik yang terdiri atas n_estimators sebesar 628, max_depth sebesar 12, learning_rate sebesar 0,0125, subsample sebesar 0,6000, colsample_bytree sebesar 0,9551, gamma sebesar 0,8863, reg_alpha sebesar 0,7343, dan reg_lambda sebesar 5,0000. Kombinasi hyperparameter tersebut selanjutnya digunakan sebagai konfigurasi akhir model GWO-XGBoost pada proses pelatihan, validasi, dan pengujian untuk memperoleh performa klasifikasi yang lebih optimal dibandingkan model XGBoost sebelum dilakukan optimasi.

Tabel 12. Hyperparameter Terbaik Hasil Optimasi GWO-XGBoost


Hyperparameter	GWO XGBoost
n_estimators	284
max_depth	10
learning_rate	0.0280
subsample	0.8200
colsample_bytree	0.9243
Gamma	0.2017
reg_alpha	0.0019
reg_lambda	1.283

Tabel 13. Perbandingan Performa Sesudah Optimasi GWO-XGBoost

Model	Accuracy	Precision	Recall	Macro F1
GWO-XGBoost	0.75	0.75	0.74	0.74

Berdasarkan Tabel 13, model GWO-XGBoost memperoleh nilai accuracy sebesar 74%, precision sebesar 0,75, recall sebesar 0,74, dan macro F1-score sebesar 0,74. Hasil tersebut menunjukkan bahwa optimasi hyperparameter menggunakan Grey Wolf Optimizer (GWO) mampu menghasilkan model dengan performa klasifikasi yang baik serta menjaga keseimbangan kinerja antar kelas. Dibandingkan dengan model XGBoost sebelum optimasi, penerapan GWO memberikan peningkatan pada nilai precision dan macro F1-score, sehingga model menjadi lebih efektif dalam mengklasifikasikan status gempa bumi.

4.6 Validation ROC dan Learning Curve

**Gambar 6.** Validasi dan Learning Curva GWO-XGBoost

Gambar 6 menunjukkan kurva ROC dan learning curve dari model GWO-XGBoost. Berdasarkan kurva ROC, model memperoleh nilai Area Under Curve (AUC) sebesar 0,820, yang menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan kelas Gempa Ringan dan Gempa Sedang-Kuat. Nilai AUC yang berada di atas 0,80 mengindikasikan bahwa model memiliki kemampuan diskriminasi yang baik dalam proses klasifikasi. Sementara itu, learning curve menunjukkan bahwa nilai *training loss* dan *validation loss* mengalami penurunan seiring bertambahnya jumlah *boosting round*. Meskipun *training loss* terus menurun hingga mencapai sekitar 0,32, *validation loss* cenderung stabil pada kisaran 0,50 setelah sekitar 300 iterasi. Kondisi tersebut menunjukkan bahwa model telah mencapai proses konvergensi dengan baik tanpa mengalami peningkatan *validation loss* yang signifikan, sehingga mengindikasikan bahwa model memiliki kemampuan generalisasi yang cukup baik terhadap data yang belum pernah dilihat sebelumnya.

V. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, penerapan Grey Wolf Optimizer (GWO) berhasil meningkatkan performa model klasifikasi status gempa bumi, dengan GWO-XGBoost menjadi model terbaik yang memperoleh accuracy sebesar 75%, precision sebesar 75%, recall sebesar 74%, dan macro F1-score sebesar 74%. Hasil tersebut menunjukkan bahwa optimasi hyperparameter menggunakan GWO mampu meningkatkan kinerja model dibandingkan sebelum optimasi. Untuk penelitian selanjutnya, disarankan menggunakan dataset dengan cakupan yang lebih luas, menambahkan parameter seismik yang lebih beragam, serta membandingkan GWO dengan algoritma optimasi metaheuristik lainnya agar diperoleh model klasifikasi yang lebih akurat dan robust.

VI. DAFTAR PUSTAKA

- [1] I. Keilmuan, "PEMETAAN DAN ANALISIS DISTRIBUSI GEMPA BUMI PADA WILAYAH PUSAT GEMPA REGIONAL (PGR) IV MAKASSAR," *Sains,Teknologi, Integr. Keilmuan dan Komput.*, vol. 3, no. 4, pp. 179–186, 2025.
- [2] 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, pp. 71–81, 2024, doi: <https://doi.org/10.22487/peweka.v3i1.32>.
- [3] I. Hanif, C. Sulaiman, and A. Zaenudin, "Seminar Nasional Ilmu Teknik dan Aplikasi Industri Mikrozonasi Potensi Bahaya Gempa Bumi Daerah Singaraja Berdasarkan Analisis Studi Mikrotremor," *SeminarNasionalIlmuTeknikdanAplikasiIndustri*, vol. 7, no. 2024, pp. 149–158, 2025, doi: <https://doi.org/10.23960/prosidingsinta.v7i.155>.
- [4] M. P. Isken *et al.*, "Qseek : A Data-Driven Framework for Automated Earthquake Detection , Localization and Characterization," *Seismica*, vol. 4, 2025, doi: 10.26443/seismica.v4i1.1283.
- [5] M. Cocco *et al.*, "Fracture Energy and Breakdown Work During Earthquakes," *Annu. Rev. Earth Planet. Sci.*, vol. 51, pp. 217–252, 2023, doi: <https://doi.org/10.1146/annurev-earth-071822-100304>.
- [6] N. H. Fahim, A. U. Muhib, R. A. Tanvir, and A. Al Noman, "Real-Time Earthquake Magnitude Classification from Initial P-Waves : Models , Dataset , and Comparative Analysis for South Asia," *2025 28th Int. Conf. Comput. Inf. Technol.*, 2025, doi: 10.1109/ICCIT68739.2025.11489542.that.
- [7] A. Navarro-rod  guez *et al.*, "Recent Advances in Early Earthquake Magnitude Estimation by Using Machine Learning Algorithms: A Systematic Review," *Appl. Sci.*, vol. 15, no. 7, pp. 1–33, 2025, doi: <https://doi.org/10.3390/app15073492>.
- [8] Y. Zhao, S. Lv, and P. Liu, "Advances in Earthquake Prevention and Reduction Based on Machine Learning : A Scoping Review," *IEEE Access*, vol. 12, no. October, pp. 143908–143929, 2024, doi: 10.1109/ACCESS.2024.3467149.
- [9] M. Sun, J. Yang, C. Yang, and W. Wang, "Heliyon Research on prediction of PPV in open-pit mine used RUN-XGBoost model," *Heliyon*, vol. 10, no. 7, p. e28246, 2024, doi: 10.1016/j.heliyon.2024.e28246.
- [10] Y. Hu, W. Wang, L. Li, and F. Wang, "Applying Machine Learning to Earthquake Engineering : A Scientometric Analysis of World Research," *buildings*, vol. 14, no. 5, 2024, doi: <https://doi.org/10.3390/buildings14051393>.
- [11] A. Ismail, A. S. A. Rashid, T. Amhadi, R. Nazir, M. Irsyam, and L. Faizal, "Exploring the Evolution of Seismic Hazard and Risk Assessment Research : A Bibliometric Analysis," *Sustain.*, vol. 16, no. 7, 2024, doi: <https://doi.org/10.3390/su16072687>.