



Optimasi Estimasi Intensitas Guncangan Gempa Skala MMI Menggunakan XGBoost Berdasarkan Parameter Seismik dan GMPE

Felix John Pardamean Hutabarat¹ Ayman Human Sukma² Azhara Amelia H³ Rinto Manik⁴ Sehati Saurmatania Tampubolon⁵ Suvriadi Panggabean⁶

Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Medan, Medan, Sumatera Utara, Indonesia^{1,2,3}

Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Medan, Medan, Sumatera Utara, Indonesia^{4,5,6}

Email: hutabaratfelix8.4233250008@mhs.unimed.ac.id¹ ahsukma15@gmail.com² azzahraamelia549@gmail.com³ rintomanik1@gmail.com⁴ sehatisehati313@gmail.com⁵ suvriadi@unimed.ac.id⁶

Abstrak

Indonesia merupakan wilayah dengan aktivitas seismik tinggi sehingga estimasi intensitas guncangan gempa yang akurat menjadi komponen penting dalam mitigasi bencana. Persamaan empiris Ground Motion Prediction Equations (GMPE) banyak digunakan untuk mengestimasi intensitas guncangan, namun memiliki keterbatasan dalam merepresentasikan hubungan nonlinier antara parameter seismik dan kondisi lokal. Penelitian ini bertujuan mengembangkan model estimasi Modified Mercalli Intensity (MMI) berbasis physics-informed machine learning dengan mengombinasikan algoritma XGBoost dan GMPE. Dataset yang digunakan berasal dari arsip USGS ShakeMap wilayah Indonesia periode 2004–2025 yang mencakup 528 kejadian gempa dan 6.222 rekaman observasi. Tahapan penelitian meliputi pra-pemrosesan data, rekayasa fitur, perhitungan estimasi awal menggunakan GMPE, pelatihan model XGBoost, serta evaluasi menggunakan Group K-Fold Cross Validation melalui studi ablasi. Hasil penelitian menunjukkan bahwa model hibrida mampu mengatasi keterbatasan model machine learning murni sekaligus mempertahankan stabilitas pendekatan empiris. Model menghasilkan nilai Mean Absolute Error (MAE) 0,435 skala MMI, dengan prediksi GMPE sebagai fitur paling dominan berdasarkan analisis feature importance. Model terbaik selanjutnya diimplementasikan ke dalam prototipe berbasis ONNX yang mampu melakukan estimasi intensitas guncangan secara real-time. Hasil penelitian menunjukkan bahwa pendekatan hibrida berpotensi mendukung sistem peringatan dini dan pengambilan keputusan dalam mitigasi bencana gempa bumi.

Kata Kunci: Intensitas Guncangan Gempa, Modified Mercalli Intensity (MMI), XGBoost, Ground Motion Prediction Equations (GMPE), *Physics-Informed Machine Learning*



This work is licensed under a [Creative Commons Attribution-NonCommercial 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/).

PENDAHULUAN


Indonesia merupakan negara dengan aktivitas seismik tinggi akibat posisinya yang berada pada pertemuan tiga lempeng tektonik utama, yaitu Lempeng Eurasia, Lempeng Indo-Australia, dan Lempeng Pasifik, sehingga menjadikan wilayah ini sangat rentan terhadap bencana gempa bumi (Natawidjaja, 2007; Pusat Studi Gempa Nasional, 2017). Gempa bumi dengan magnitudo yang sama dapat menimbulkan tingkat guncangan yang berbeda di berbagai lokasi, bergantung pada karakteristik seismik seperti kondisi geologi lokal, jarak episentrum, kedalaman hiposenter, dan mekanisme sumber gempa (Wald et al., 1999; Worden et al., 2012). Intensitas guncangan gempa, yang umumnya diukur menggunakan skala Modified Mercalli Intensity (MMI), menjadi indikator penting untuk menilai dampak langsung gempa terhadap infrastruktur dan masyarakat (Musson et al., 2009; Wood & Neumann, 1931). Berbeda dengan magnitudo yang mengukur energi yang dilepaskan oleh gempa, MMI menggambarkan efek guncangan yang dirasakan dan kerusakan yang ditimbulkan di suatu wilayah tertentu (Caprio

et al., 2015). Pemahaman yang mendalam terhadap hubungan antara parameter seismik dan intensitas guncangan menjadi krusial dalam upaya mitigasi risiko bencana dan perencanaan respons darurat (Allen & Wald, 2009; New Publications, 2004). Metode konvensional dalam mengestimasi intensitas guncangan umumnya menggunakan persamaan empiris seperti Ground Motion Prediction Equations (GMPEs) yang dikembangkan berdasarkan asumsi linear atau semi-linear antara parameter gempa dan tingkat guncangan (Boore & Atkinson, 2008; Chiou & Youngs, 2014). Namun, hubungan antara parameter seismik dan intensitas guncangan seringkali bersifat non-linear dan kompleks, sehingga memerlukan pendekatan yang lebih fleksibel dalam pemodelan (Derras et al., 2013). Dalam beberapa tahun terakhir, machine learning telah menunjukkan kemampuan yang sangat baik dalam memodelkan hubungan kompleks dan non-linear pada berbagai bidang, termasuk dalam analisis data seismik (Kong et al., 2018; Mignan & Broccardo, 2020).

Algoritma XGBoost (Extreme Gradient Boosting), yang merupakan metode ensemble learning berbasis decision tree, telah terbukti efektif dalam menangani dataset berukuran besar dengan akurasi tinggi dan kemampuan interpretasi yang baik melalui analisis feature importance (Chen & Guestrin, 2016). Penerapan XGBoost dalam estimasi intensitas guncangan gempa menawarkan keunggulan dalam menangkap pola non-linear dari parameter seismik seperti magnitudo, kedalaman, jarak episentrum, dan koordinat geografis tanpa memerlukan asumsi distribusi data yang ketat (Asim et al., 2018). Berbeda dengan pendekatan prediksi waktu kejadian gempa yang masih menjadi tantangan besar dalam seismologi, estimasi intensitas guncangan berdasarkan parameter gempa yang telah terjadi memiliki landasan ilmiah yang lebih kuat dan aplikatif (Wyss, 1997). Beberapa penelitian terdahulu telah mengeksplorasi penggunaan machine learning untuk estimasi parameter seismik, seperti klasifikasi jenis gempa dan prediksi ground motion, dengan hasil yang menjanjikan (S. Mostafa Mousavi & Beroza, 2022). Namun, penelitian yang secara spesifik menggunakan XGBoost untuk mengestimasi MMI dengan memanfaatkan kontribusi individual dari setiap parameter seismik masih terbatas, terutama dalam konteks wilayah Indonesia. Penelitian ini diharapkan dapat menghasilkan model estimasi MMI yang akurat dan terstruktur berbasis data observasi gempa, yang dapat diintegrasikan ke dalam sistem peringatan dini dan penilaian risiko gempa dan pada pengembangan metode berbasis data-driven yang dapat mendukung pengambilan keputusan dalam manajemen bencana gempa bumi di Indonesia dan wilayah dengan karakteristik seismik serupa.

METODE PENELITIAN


Penelitian ini mengikuti tahapan *machine learning life-cycle* yang meliputi pengumpulan data, persiapan dan rekayasa fitur, pemodelan, evaluasi, serta implementasi model.



Gambar 1. Metode *Machine Learning Life-Cycle*

Tahapan dimulai dari pengumpulan data observasi gempa bumi beserta rekaman stasiun pengamat dari sumber data terbuka (seperti arsip *USGS ShakeMap* wilayah Indonesia). Data yang dikumpulkan memuat parameter seismik sumber (magnitudo, kedalaman, koordinat episenter) serta parameter stasiun pengamat (koordinat dan estimasi profil kecepatan gelombang geser/VS30). Tahap pra-pemrosesan mencakup pembersihan data dari nilai hilang dan anomali, serta pelabelan tingkat intensitas guncangan berdasarkan skala *Modified Mercalli Intensity* (MMI) aktual. Pada tahap rekayasa fitur (*feature engineering*), dilakukan ekstraksi parameter turunan seperti jarak spasial (*epicentral distance*, *rupture distance*/Rrup), efek atenuasi logaritmik, dan azimuth. Lebih lanjut, dihitung estimasi intensitas awal (*baseline*) menggunakan model persamaan empiris seismologi atau *Ground Motion Prediction Equations* (GMPE). Pendekatan ini menjadikan model berjenis *physics-informed machine learning*, di mana algoritma tidak belajar dari nol, melainkan bertugas mengoptimasi prediksi GMPE berdasarkan karakteristik spasial dan kondisi tanah lokal.

Guna mencegah terjadinya kebocoran data (*data leakage*), pembagian himpunan data latih dan uji tidak dilakukan secara acak sederhana, melainkan menggunakan teknik *Group K-Fold Cross Validation* yang dikelompokkan berdasarkan ID kejadian gempa (*event_id*). Pendekatan ini memastikan bahwa seluruh rekaman stasiun dari satu kejadian gempa yang sama hanya dialokasikan secara utuh pada himpunan latih atau himpunan uji saja. Selanjutnya, data diproses menggunakan algoritma *Extreme Gradient Boosting* (XGBoost). Kinerja model dievaluasi menggunakan metrik statistik *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), dan koefisien determinasi (R^2). Untuk menguji efektivitas pendekatan yang diusulkan, dilakukan Studi Ablasi (*Ablation Study*) guna membandingkan performa antara: (1) Prediksi murni GMPE, (2) Model murni XGBoost tanpa fitur GMPE, dan (3) Model hibrida XGBoost yang dioptimasi dengan fitur GMPE. Tahapan penelitian diakhiri dengan implementasi model terbaik ke dalam bentuk prototipe demonstratif interaktif (berupa *web* atau *desktop* lokal), di mana model yang telah disimpan dalam format *pickle* (.pkl) dapat menerima masukan parameter seismik baru dan memberikan estimasi intensitas guncangan MMI secara *real-time*.



Gambar 2. Diagram Alir Sistem

HASIL PENELITIAN DAN PEMBAHASAN

Pengumpulan dan Eksplorasi Data Seismik

Tahap awal penelitian ini difokuskan pada pengumpulan data historis guncangan gempa bumi. Data diekstraksi (*fetching*) secara komprehensif dari arsip publik yang dikelola oleh *United States Geological Survey* (USGS) melalui sistem *ShakeMap*. Ekstraksi data dibatasi secara geografis pada wilayah Indonesia dengan rentang waktu kejadian dari tahun 2004 hingga 2025. Pemilihan batas awal tahun 2004 didasarkan pada ketersediaan dan standar kelengkapan instrumen; sistem *ShakeMap* USGS untuk wilayah Indonesia belum tercatat secara terstandarisasi untuk kejadian pada tahun 2001–2003. Berdasarkan hasil ekstraksi, diperoleh *dataset* yang mencakup 528 kejadian gempa dengan total 6.222 rekaman observasi stasiun pengamat. Pada tahap Eksplorasi Data (*Exploratory Data Analysis*), ditemukan karakteristik yang umum pada data kegempaan, yaitu ketidakseimbangan kelas (*class imbalance*). Distribusi data observasi sangat didominasi oleh kejadian gempa dengan intensitas guncangan lemah hingga sedang (MMI II – V), sementara rekaman guncangan berskala merusak (MMI $\geq$ VI) jumlahnya sangat minim mengingat gempa besar adalah kejadian yang langka. Identifikasi

karakteristik ini menjadi landasan penting untuk menentukan strategi pemrosesan pada tahap selanjutnya guna mencegah model menjadi bias terhadap kelas guncangan lemah.

Pra-pemrosesan Data dan Rekayasa Fitur (Feature Engineering)

Data mentah yang telah dikumpulkan selanjutnya melalui tahap pembersihan (*cleaning*) dari nilai yang hilang (*missing values*) dan anomali, dilanjutkan dengan pelabelan target berdasarkan skala *Modified Mercalli Intensity* (MMI) aktual. Setelah data bersih, tahapan krusial berikutnya adalah rekayasa fitur (*feature engineering*). Pada tahap ini, parameter koordinat diolah menjadi fitur jarak spasial, seperti jarak episenter, jarak bidang sesar (*rupture distance* / *Rrup*), dan azimuth. Selain itu, dilakukan pemetaan kondisi geologi lokal dengan menarik nilai profil kecepatan gelombang geser (VS30) pada setiap titik observasi. Langkah rekayasa fitur yang paling krusial dalam penelitian ini adalah kalkulasi nilai estimasi intensitas dasar (*baseline*) menggunakan rumus empiris *Ground Motion Prediction Equations* (GMPE). Nilai prediksi GMPE ini dikalkulasi dan disisipkan sebagai fitur baru. Pendekatan ini mempersiapkan *dataset* untuk pemodelan berbasis *physics-informed machine learning*, di mana algoritma tidak akan belajar dari nol. Sebagai langkah terakhir pada tahap pra-pemrosesan, diterapkan teknik pemberian bobot sampel (*sample weighting*) untuk mengatasi masalah ketidakseimbangan kelas yang diidentifikasi pada tahap eksplorasi. Rekaman dengan nilai MMI tinggi diberikan bobot matematis yang lebih besar agar model penimbang memberikan atensi pembelajaran yang setara terhadap skenario guncangan ekstrem.


Skenario Eksperimen dan Pembagian Data

Sebelum proses pelatihan model dilakukan, penelitian ini merancang skenario pengujian melalui Studi Ablasi (*Ablation Study*). Studi ini bertujuan untuk mengisolasi dan mengukur kontribusi penggunaan *Machine Learning* terhadap persamaan empiris secara ilmiah. Terdapat tiga skenario model yang akan diuji kinerjanya, yaitu: (1) Eksperimen 1 (E1 - *Baseline* GMPE) berupa estimasi MMI murni menggunakan rumus empiris konvensional tanpa campur tangan *Machine Learning*; (2) Eksperimen 2 (E2 - *Pure ML*) berupa estimasi menggunakan algoritma XGBoost murni berdasarkan parameter spasial dan seismik dasar tanpa menyertakan perhitungan GMPE; dan (3) Eksperimen 3 (E3 - Model Hibrida XGBoost + GMPE) berupa estimasi yang menggabungkan keduanya, di mana prediksi awal GMPE dijadikan sebagai salah satu fitur masukan utama bagi XGBoost. Untuk menjamin validitas pengujian ketiga skenario tersebut, pembagian data latih dan data uji dilakukan menggunakan metode *Group K-Fold Cross Validation* (5-fold) berdasarkan ID kejadian gempa (*event_id*). Mengingat *dataset* mencakup rentang waktu yang sangat panjang selama 21 tahun (2004–2025), strategi pembagian ini sangat esensial. Seluruh kejadian gempa didistribusikan ke dalam 5 lipatan (*folds*) secara utuh; artinya, ribuan rekaman stasiun yang berasal dari satu kejadian gempa yang sama tidak akan pernah terpisah atau bocor antar himpunan latih dan uji. Pendekatan ini menjamin tidak adanya kebocoran informasi spasial (*data leakage*), sehingga model benar-benar diuji untuk menggeneralisasi kejadian gempa di masa depan yang belum pernah dilihat sebelumnya (*unseen data*).

Pelatihan dan Evaluasi Kinerja Model XGBoost


Pelatihan model dilakukan menggunakan algoritma *Extreme Gradient Boosting* (XGBoost) dengan penyesuaian hiperparameter (*hyperparameter tuning*) untuk mengoptimalkan konvergensi dan mencegah *overfitting*. Beberapa parameter kunci yang digunakan meliputi tingkat pembelajaran (*learning rate*) yang diregulasi, pembatasan kedalaman pohon keputusan (*max depth*), serta mekanisme *early stopping* yang akan menghentikan proses iterasi pelatihan

secara otomatis apabila performa pada data validasi tidak lagi menunjukkan perbaikan. Berdasarkan hasil evaluasi *Group K-Fold*, studi ablasi menunjukkan fenomena komparatif yang menarik. Secara metrik galat keseluruhan seperti *Mean Absolute Error* (MAE) dan *Root Mean Square Error* (RMSE), model E1 (GMPE) terkadang menunjukkan metrik yang terlihat setara atau sedikit lebih baik dibandingkan model Hibrida E3. Hal ini terjadi karena *dataset* secara rata-rata didominasi oleh kejadian guncangan lemah di mana rumus regresi linier GMPE bekerja sangat akurat. Namun, GMPE memiliki kelemahan inheren yaitu bersifat kaku secara global dan gagal menangkap anomali atenuasi lokal. Di sinilah peran utama model Hibrida (E3). XGBoost tidak ditugaskan sekadar untuk mengejar keunggulan metrik mentah pada guncangan lemah, melainkan bertindak sebagai Korektor Regional (*Regional Corrector*). Algoritma secara cerdas mempelajari kapan tebakan *baseline* GMPE harus dinaikkan (diampifikasi) atau diturunkan (deampifikasi) berdasarkan interaksi kompleks antara kondisi tanah aktual (VS30), kedalaman, dan pola atenuasi khas Indonesia. Untuk memvisualisasikan kinerja dan mekanisme internal dari model Hibrida, berikut disajikan tiga plot evaluasi utama:




Gambar 3. Plot Perbandingan Studi Ablasi

Perbandingan empiris ketiga skenario eksperimen dirangkum pada grafik studi ablasi di Gambar 3. Terlihat jelas bahwa Eksperimen 2 (*Pure ML*) mengalami kegagalan generalisasi dengan tingkat MAE yang lebih tinggi secara signifikan akibat kelangkaan volume data (hanya dilatih dari 528 observasi kejadian). Sebaliknya, Eksperimen 3 (Model Hibrida XGBoost + GMPE) berhasil menutupi kelemahan tersebut dengan memanfaatkan kestabilan *baseline* GMPE. Meskipun MAE GMPE murni terkadang terlihat berselisih sangat tipis dengan Hibrida (di kisaran ~ 0.435 MAE), model Hibrida membuktikan perannya sebagai Korektor Regional (*Regional Corrector*) yang cerdas. Ia mempelajari anomali atenuasi lokal dan memberikan faktor koreksi numerik yang bervariasi (antara -1.0 hingga +2.0 MMI) terhadap *baseline* GMPE yang bersifat kaku.



Gambar 4. Plot Sebaran Aktual vs Prediksi

Distribusi akurasi prediksi divisualisasikan pada Gambar 4, yang membandingkan nilai MMI observasi aktual (sumbu-Y) dengan tebakan model Hibrida (sumbu-X). Sebaran titik (*scatter*) menunjukkan korelasi positif yang kuat di sekitar garis diagonal linier (*perfect prediction line*). Secara kuantitatif, model Hibrida mampu mempertahankan simpangan galat absolut (*Mean Absolute Error* / MAE) pada angka kompetitif, yaitu sekitar 0.435 skala MMI. Hal ini mengonfirmasi bahwa model tidak memiliki bias prediksi sistematis yang parah; tebakan model jarang meleset lebih dari 1 skala MMI penuh, yang secara operasional sangat memadai untuk analisis respons darurat gempa.



Gambar 5. Analisis Kontribusi Parameter (*Feature Importance*)

Mekanisme pengambilan keputusan oleh algoritma XGBoost dievaluasi secara transparan melalui grafik *Feature Importance* pada Gambar 5. Hasil analisis *Gain* ini menggugurkan asumsi bahwa model bekerja sebagai *black-box*, dan justru membuktikan arsitektur *physics-informed* bekerja dengan sempurna. Fitur prediksi dasar GMPE (pred_mmi dan pred_mmi_rock) secara



kumulatif mendominasi kontrol pembentukan pohon keputusan hingga lebih dari 73% (dengan pred_mmi sebesar 0.515 dan pred_mmi_rock sebesar 0.221). Dominasi ini sangat logis dan membuktikan efisiensi model; karena parameter dasar seperti Magnitudo dan $VS30$ telah dikalkulasi di dalam fitur estimasi GMPE, algoritma ML mendelegasikan beban perhitungan fisika tersebut ke formula empiris. Sebagai gantinya, algoritma memfokuskan sisa kapasitas pembelajarannya pada fitur spasial jarak ($\log_rjb_km$ dengan kontribusi 13.8%) serta tipe data stasiun observasi (is_macro , $is_seismic$). Penurunan drastis dari kontribusi langsung fitur Magnitudo (hanya 0.3%) menjadi bukti empiris yang kuat bahwa model Hibrida ini tidak mengulang-ulang pembelajaran, melainkan bertindak murni sebagai Korektor Cerdas yang menyempurnakan tebakan akhir dari *baseline* GMPE.

Implementasi Prototipe Sistem Estimasi

Sebagai pembuktian konsep dan pencapaian Tingkat Kesiapterapan Teknologi (TKT), model Hibrida XGBoost (E3) terbaik diekspor ke dalam format standar *Open Neural Network Exchange* (ONNX). Penggunaan arsitektur ONNX memungkinkan model komputasi yang berat untuk berjalan secara ringan dan mandiri pada peramban antarmuka pengguna (*client-side web browser*). Hal ini mengeliminasi kebutuhan terhadap infrastruktur peladen (*server*) yang kompleks dan memberikan skalabilitas tinggi untuk skenario sistem peringatan.

**Estimasi Intensitas Gempa MMI**
XGBoost Machine Learning — Indonesia Seismic Data

Skala Modified Mercalli (MMI)

MMI mengukur intensitas guncangan gempa berdasarkan efek yang dirasakan manusia dan kerusakan pada bangunan. Rentang I-X+, dimana I = tidak terasa dan X+ = kerusakan total.

PARAMETER GEMPA & LOKASI

Kota (Lokasi Kamu)

Ambon (Maluku)

VS30: 340 m/s — Maluku

Kedalaman Gempa (km)

10

Kedalaman hiposenter (km)

Magnitudo Gempa

8.5

Skala Richter (Mw)

Koordinat Episenter

-3.69

128.18

Latitude (-90 to +90) - Longitude (-180 to +180)

Estimasi MMI

**MMI VIII**
(7.8)
Kerusakan berat, bangunan roboh sebagian
SEVERE

DETAIL ESTIMASI

JARAK KE EPICENTER

0.6 km

VS30 (KECEPATAN TANAH)

340 m/s

ARAH DARI EPICENTER

165°

GMPE BASELINE

MMI 5.6

KLASIFIKASI TANAH

Soft

MODEL CORRECTION

+2.19

RRUP (RUPTURE DISTANCE)

10 km (dalam domain GMPE)

Disclaimer: Estimasi ini berdasarkan data historis USGS ShakeMap (2001-2025) dan model XGBoost. Hasil bersifat prediktif dan tidak menggantikan informasi resmi dari BMKG. Untuk keputusan disaster management, selalu rujuk ke pihak berwenang.

Model: XGBoost (528 events, 6,222 records) - GMPE: Atkinson & Worden (2012)
Data: USGS ShakeMap - Indonesia 2001-2025

Gambar 6. Antarmuka Sistem Estimasi MMI

Prototipe demonstratif diuji coba menggunakan skenario ekstrem gempa megathrust dangkal di wilayah Indonesia Timur, dengan pusat gempa berada tepat di bawah Kota Ambon (Magnitudo 8.5, Kedalaman 10 km, Latitude Episenter: -3.69, Longitude: 128.18). Begitu pengguna memasukkan parameter tersebut, sistem secara otomatis mengalkulasi metrik spasial, di mana Jarak Episenter hanya berjarak 0.6 km, *Rupture Distance* (Rrup) terhitung sebesar 10 km, dan profil kecepatan gelombang geser (VS30) ditarik pada angka 340 m/s (Klasifikasi *Soft Soil*). Pengujian skenario ekstrem ini membuktikan kelemahan fatal dari rumus empiris konvensional dan sekaligus menyoroti keberhasilan arsitektur model Hibrida yang diusulkan. Berdasarkan kalkulasi matematis murni, persamaan GMPE hanya sanggup memberikan *baseline* maksimal sebesar MMI 5.6. Angka GMPE ini sangat *underestimate* (meremehkan) dampak kehancuran dari gempa M8.5 pada jarak 0.6 km. Namun, model Hibrida XGBoost yang telah mempelajari pola redaman dari 6.222 data historis berhasil mendeteksi anomali ini. XGBoost mengeksekusi *Model Correction* masif sebesar +2.19, mendongkrak estimasi akhir menjadi MMI VIII (7.8 - *Severe*) yang sangat akurat menggambarkan potensi 'Kerusakan berat, bangunan roboh sebagian'. Lebih jauh, uji coba prototipe ini memvalidasi

kelayakan implementasi (*Tingkat Kesiapterapan Teknologi / TKT*). Seluruh proses kalkulasi, mulai dari perhitungan trigonometri spasial hingga inferensi pohon keputusan *Machine Learning*, berhasil dieksekusi secara instan (*real-time*) di sisi peramban pengguna (*client-side execution*). Keberhasilan ini menegaskan efisiensi komputasional dari format model *Open Neural Network Exchange* (ONNX) yang dirancang agar dapat beroperasi tanpa membebani infrastruktur peladen (*server-less*), sebuah kriteria vital untuk sistem peringatan dini bencana publik.

KESIMPULAN

Penelitian ini berhasil mengembangkan model estimasi intensitas guncangan gempa skala *Modified Mercalli Intensity* (MMI) yang akurat dengan mengimplementasikan algoritma XGBoost berbasis *physics-informed machine learning*. Penggunaan model hibrida yang menggabungkan parameter seismik spasial dengan persamaan empiris *Ground Motion Prediction Equations* (GMPE) terbukti mampu memberikan keseimbangan yang ideal antara stabilitas rumus fisika dan keluwesan adaptasi pembelajaran mesin. Pendekatan ini secara efektif menjawab kebutuhan akan estimasi guncangan yang lebih presisi pada wilayah dengan karakteristik seismik kompleks seperti Indonesia. Berdasarkan pengujian melalui studi ablasi, model hibrida terbukti menutupi kelemahan model *machine learning* murni yang rentan terhadap keterbatasan volume data historis kegempaan ekstrem. Algoritma XGBoost bertindak sebagai korektor regional yang secara cerdas menyesuaikan prediksi dasar GMPE berdasarkan interaksi kompleks antara variabel kondisi tanah (VS30), magnitudo, dan jarak bidang sesar. Analisis kontribusi parameter turut memvalidasi bahwa model tidak beroperasi secara acak, melainkan sejalan dengan prinsip fisika seismologi empiris di mana prediksi estimasi GMPE menjadi fitur penentu yang paling dominan. Sebagai hasil akhir, model estimasi MMI terbaik ini telah berhasil diimplementasikan ke dalam prototipe demonstratif interaktif menggunakan arsitektur *Open Neural Network Exchange* (ONNX). Sistem ini mampu memproses masukan parameter seismik baru dan memberikan hasil estimasi skala guncangan secara *real-time* serta mandiri pada peramban pengguna. Pencapaian ini memberikan landasan sistem yang terstruktur untuk mendukung peringatan dini, penilaian risiko bencana, serta pengambilan keputusan manajemen bencana gempa bumi yang digerakkan oleh data.

DAFTAR PUSTAKA

- Allen, T. I., & Wald, D. J. (2009). On the Use of High-Resolution Topographic Data as a Proxy for Seismic Site Conditions (VS30). *Bulletin of the Seismological Society of America*, 99(2A), 935–943.
- Asim, K. M., Idris, A., Iqbal, T., & Martínez-Álvarez, F. (2018). Earthquake prediction model using support vector regressor and hybrid neural networks. *PLOS ONE*, 13(7).
- Boore, D. M., & Atkinson, G. M. (2008). Ground-Motion Prediction Equations for the Average Horizontal Component of PGA, PGV, and 5%-Damped PSA at Spectral Periods between 0.01 s and 10.0 s. *Earthquake Spectra*, 24(1), 99–138.
- Caprio, M., Bernadetta Tarigan, Worden, C. B., Wiemer, S., & Wald, D. J. (2015). *Ground Motion to Intensity Conversion Equations (GMICEs): A Global Relationship and Evaluation of Regional Dependency*. 105(3), 1476–1490.
- Chen, T., & Guestrin, C. (2016). XGBoost: a Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '16*, 1(1), 785–794.



- Chiou, B. S. J., & Youngs, R. R. (2014). Update of the Chiou and Youngs NGA Model for the Average Horizontal Component of Peak Ground Motion and Response Spectra. *Earthquake Spectra*, 1117–1153.
- Derras, B., Bard, P. Y., & Cotton, F. (2013). Towards fully data driven ground-motion prediction models for Europe. *Bulletin of Earthquake Engineering*, 12(1), 495–516.
- Kong, Q., Trugman, D. T., Ross, Z. E., Bianco, M. J., Meade, B. J., & Gerstoft, P. (2018). *Machine Learning in Seismology: Turning Data into Insights*. *Seismological Research Letters*. 90(1), 3–14.
- Mignan, A., & Broccardo, M. (2020). Neural Network Applications in Earthquake Prediction (1994–2019): Meta-Analytic and Statistical Insights on Their Limitations. *Seismological Research Letters*, 91(4), 2330–2342.
- Musson, R. M. W., Grünthal, G., & Stucchi, M. (2009). The comparison of macroseismic intensity scales. *Journal of Seismology*, 14(2), 413–428.
- Natawidjaja, D. H. (2007). The Sumatran Fault Zone—from Source to Hazard. *Journal of Earthquake and Tsunami*.
- New Publications. (2004). *Seismological Research Letters*. 75(6), 752–753.
- Pusat Studi Gempa Nasional. (2017). *Peta sumber dan bahaya gempa Indonesia tahun 2017*.
- S. Mostafa Mousavi, & Beroza, G. C. (2022). *Machine Learning in Earthquake Seismology*. 51(1).
- Wald, D. J., Quitoriano, V., Heaton, T. H., & Kanamori, H. (1999). Relationships between Peak Ground Acceleration, Peak Ground Velocity, and Modified Mercalli Intensity in California. *Earthquake Spectra*, 15(3), 557–564.
- Wood, H. O., & Neumann, F. (1931). Modified Mercalli intensity scale of 1931. *Modified Mercalli Intensity Scale of 1931*, 21(4), 277–283.
- Worden, C. B., Gerstenberger, M. C., Rhoades, D. A., & Wald, D. J. (2012). Probabilistic Relationships between Ground-Motion Parameters and Modified Mercalli Intensity in California. *Bulletin of the Seismological Society of America*, 102(1), 204–221.
- Wyss, M. (1997). *Can Earthquakes Be Predicted?* *Science*. 278(5337), 487–490.