

Model Machine Learning Dalam Sistem Rekomendasi Kesiapsiagaan Gempa Megathrust Studi Padang

Eka Ridhawati¹

¹)Program Studi Rekayasa Perangkat Lunak, Institut Teknologi dan Bisnis Diniyyah Lampung
Jl. Ganjaran, Negeri Sakti, KM. 16, Gedong Tataan, Kab. Pesawaran, Prov. Lampung
E-mail: ekaridhawati@gmail.com

ABSTRAKS

Dokumen ini memberikan analisis mendetail mengenai penerapan metode machine learning (ML) dalam menciptakan sistem pendukung keputusan bagi kesiapsiagaan terhadap gempa bumi, dengan penekanan pada skenario megathrust berisiko tinggi dari segmen Mentawai yang mengancam Kota Padang, Indonesia. Dengan menggunakan dataset simulasi yang mencerminkan indikator geospasial, demografis, dan seismik yang telah ada, penelitian ini menerapkan model klasifikasi melalui algoritma Random Forest untuk mengenali dan memetakan area risiko yang mungkin terjadi. Metodologi ini meliputi penyusunan data sintesis, penandaan berdasarkan aturan, pelatihan model, penilaian, dan inferensi prediktif. Hasil menunjukkan tingkat akurasi klasifikasi yang tinggi dalam keadaan data sempurna, dan antarmuka bukti konsep dibuat untuk masukan pengguna berdasarkan skenario. Penelitian ini ditutup dengan anjuran untuk menggabungkan data waktu nyata dalam mendukung strategi pengurangan risiko bencana.

Kata Kunci: machine learning, algoritma Random Forest, megathrust

1. PENDAHULUAN

1.1 Referensi

Kota Padang yang berada di sepanjang pesisir barat Sumatera adalah salah satu wilayah perkotaan yang paling berisiko terhadap gempa bumi di Indonesia. Berlokasi dekat megathrust Sunda, terutama pada segmen Mentawai, area ini berisiko tinggi terhadap gempa besar dan tsunami susulan yang berarti [1]. Rekaman sejarah, termasuk gempa di Sumatera Barat pada 2009, menekankan perlunya strategi kesiapsiagaan yang terintegrasi. Tantangan dalam pengelolaan risiko bencana dalam konteks ini tidak hanya mencakup ketidakpastian geofisika tetapi juga kerentanan sosial dan infrastruktur, seperti area pesisir yang padat penduduk serta terbatasnya infrastruktur evakuasi. Pembuatan rencana evakuasi yang efektif serta program kesadaran masyarakat sangat krusial untuk meningkatkan ketahanan terhadap kemungkinan bencana di Kota Padang. Meningkatkan partisipasi masyarakat dan pendidikan akan sangat penting untuk membangun budaya kesiapsiagaan serta ketahanan dalam menghadapi potensi ancaman seismik [2].

Untuk menyelesaikan kompleksitas ini, sangat penting adanya sistem yang dapat merekomendasikan strategi evakuasi dan respons risiko yang tepat. Sistem rekomendasi untuk kesiapsiagaan bencana memanfaatkan data dalam waktu nyata atau hampiran waktu nyata untuk memberikan panduan yang spesifik pada lokasi tertentu. Sistem rekomendasi, atau sistem yang memberikan rekomendasi, merupakan jenis sistem penyaringan informasi yang menyajikan saran untuk

item yang paling sesuai bagi pengguna tertentu. Sistem ini umum di dunia digital saat ini, berperan krusial dalam berbelanja online, layanan streaming, media sosial, serta bidang lain yang menekankan pada personalisasi dan pengalaman pengguna.

Dalam studi ini, sistem itu dibangun menggunakan kerangka kerja pembelajaran mesin. Penggabungan metode pembelajaran mesin dengan program keterlibatan masyarakat dapat secara drastis memperbaiki efektivitas strategi persiapan bencana di wilayah yang rentan gempa [4, 5] seperti Kota Padang.

Metode pembelajaran mesin, khususnya algoritma pembelajaran terawasi, semakin populer dalam manajemen bencana karena kemampuannya dalam menganalisis kumpulan data multidimensi yang rumit dan mengidentifikasi pola non-linier untuk mendukung proses pengambilan keputusan [6]. Di antara berbagai metode yang ada, Random Forest, yang merupakan pendekatan pembelajaran ensemble dengan pohon keputusan, sering diterapkan karena kekuatannya, akurasi tinggi, dan kemampuannya dalam mengatasi overfitting. Random Forest bekerja dengan membangun banyak pohon keputusan dan mengkombinasikan hasilnya untuk menghasilkan prediksi yang jelas, menjadikannya ideal untuk tugas klasifikasi multi-kelas seperti penilaian risiko.

Metode pembelajaran mesin telah menjadi semakin populer dalam manajemen bencana berkat kemampuannya dalam memproses data multidimensi yang rumit dan mengidentifikasi pola non-linier untuk mendukung pengambilan keputusan. Algoritma Random Forest, secara khusus, telah menunjukkan peningkatan yang

signifikan dalam efektivitasnya untuk pemodelan prediktif dalam penilaian risiko bencana, menjadikannya perangkat yang berharga untuk memperkuat strategi kesiapsiagaan di daerah yang rentan terhadap gempa [7]. Penggabungan pembelajaran mesin dengan program kesiapsiagaan komunitas dapat mendukung evakuasi yang cepat dan memperkuat langkah-langkah keselamatan secara keseluruhan di Kota Padang saat terjadi gempa. Pelaksanaan solusi pembelajaran mesin bersamaan dengan partisipasi masyarakat dapat meningkatkan efisiensi dan daya tahan respons bencana di Kota Padang, yang pada akhirnya menyelamatkan jiwa saat terjadi gempa. Pendekatan ini tidak hanya menggunakan teknologi mutakhir tetapi juga memberdayakan komunitas lokal untuk mengambil langkah-langkah proaktif dalam kesiapsiagaan bencana, menjamin lingkungan perkotaan yang lebih tahan banting. Akhirnya, kerja sama antara teknologi dan upaya masyarakat sangat krusial untuk mempromosikan kerangka kerja ketahanan bencana yang menyeluruh di area perkotaan seperti Kota Padang. Kolaborasi antara mesin pembelajaran dan partisipasi komunitas ini bisa menciptakan peluang untuk strategi pengurangan risiko bencana yang lebih efektif, menghubungkan inovasi teknologi dengan wawasan dan praktik setempat [8]. seperti Kota Padang. Kolaborasi antara mesin pembelajaran dan partisipasi komunitas ini bisa menciptakan peluang untuk strategi pengurangan risiko bencana yang lebih efektif, menghubungkan inovasi teknologi dengan wawasan dan praktik setempat [8]. Pelaksanaan strategi ini memerlukan kerja sama yang terus-menerus antara pemerintah daerah, lembaga masyarakat, dan ahli teknologi untuk menjamin kesiapsiagaan bencana yang berkelanjutan di Kota Padang. Kerjasama ini sangat krusial untuk menangani tantangan spesifik yang dihadirkan oleh pemandangan geografis dan demografis Padang, sehingga memungkinkan pendekatan yang tepat untuk pengurangan risiko bencana. Menggabungkan pengetahuan lokal ke dalam sistem pembelajaran mesin bisa meningkatkan akurasi dan relevansi model prediktif, sehingga menciptakan cara manajemen bencana yang lebih efektif di wilayah rawan bencana seperti Kota Padang. Untuk mencapai tujuan ini, penting sekali membangun kerjasama di antara berbagai pihak yang terlibat, seperti lembaga pemerintah, institusi pendidikan, dan komunitas, agar tercipta kesatuan dalam usaha kesiapsiagaan bencana.

Kemajuan terbaru telah menyaksikan penggunaan dalam prediksi risiko, evaluasi kerentanan, dan sistem tanggap cepat. Dalam studi ini, kami mengusulkan kerangka kerja rekomendasi yang berbasis ML dan disesuaikan dengan profil risiko Padang. Kegiatan ini bertujuan untuk mengelompokkan zona risiko gempa bumi dan

memberikan rekomendasi mengenai keputusan evakuasi dengan pendekatan yang sistematis dan berbasis data.

Penelitian ini memanfaatkan *Random Forest Classifier* dari pustaka Scikit-Learn di Python, yang terkenal akan ketangguhannya dalam mengelola data yang bising dan interaksi fitur yang rumit. Random Forest merupakan metode ensemble yang menciptakan sejumlah pohon keputusan dan mengkombinasikan hasilnya untuk meningkatkan akurasi serta menurunkan varians. Metode ini sangat efisien untuk masalah klasifikasi yang melibatkan hasil kategorikal seperti tingkat risiko multi-kelas yang kita hadapi.

Model ini dilatih menggunakan dataset sintesis, mengoptimalkan *hyperparameter* untuk meningkatkan akurasi klasifikasi serta memastikan prediksi yang dapat diandalkan untuk penilaian risiko seismik di Kota Padang. Kinerja model dinilai melalui metode validasi silang, menjamin keandalannya dalam meramalkan area risiko dalam berbagai situasi. Efektivitas model akan diuji lebih lanjut dengan membandingkan hasil prediksinya dengan peristiwa seismik yang terjadi di dunia nyata serta tanggapan masyarakat mengenai strategi evakuasi. Hasilnya akan memberikan pemahaman mengenai penerapan model dan kemungkinan pelaksanaan di dunia nyata dalam memperbaiki kesiapsiagaan terhadap gempa bumi di Kota Padang. Integrasi metode pembelajaran mesin ke dalam sistem kesiapsiagaan bencana dapat secara signifikan meningkatkan kemampuan prediksi dan responsivitas manajemen darurat, terutama di area berisiko tinggi seperti Kota Padang. Pendekatan ini tidak hanya memperbaiki penilaian risiko tetapi juga memperkuat ketahanan komunitas melalui keputusan yang tepat dan tindakan yang proaktif.

Prosedur yang dilalui meliputi langkah-langkah berikut:

- Pembagian data: 80% untuk pelatihan, 20% untuk pengujian
- Penyesuaian *hyperparameter*: pencarian *grid* berdasarkan tinggi pohon dan jumlah estimator
- Penilaian model: ketepatan, matriks kebingungan, presisi, pengembalian, dan nilai F1
- *Cross-validation* (5-fold) diterapkan untuk meminimalkan risiko *overfitting* serta menaksir kesalahan generalisasi.


1.2.1. Inferensi Risiko dan Ilustrasi Simulasi Antarmuka

Fungsi klasifikasi waktu nyata dirancang untuk menerima masukan pengguna terkini (karakteristik lokasi) dan memprediksi zona risiko yang relevan. Fungsi ini akan memberikan kesempatan bagi pengguna untuk mendapatkan umpan balik langsung mengenai tingkat risiko, mendukung pengambilan keputusan yang tepat waktu selama kejadian seismik [10]. Pelaksanaan fungsi klasifikasi waktu nyata ini diharapkan mampu secara drastis memperbaiki proses pengambilan keputusan bagi warga dan pihak berwenang selama kejadian seismik, yang pada akhirnya meningkatkan respons terhadap bencana. Kerangka kerja yang diajukan tidak hanya mendukung penilaian risiko secara real-time tetapi juga memberdayakan masyarakat untuk mengambil keputusan yang tepat selama peristiwa seismik, sehingga meningkatkan kesiapsiagaan bencana secara keseluruhan.

Menciptakan prototipe antarmuka yang menyatukan model dalam dasbor manajemen bencana simulasi, yang memvisualisasikan zona dengan peta berwarna dan menyarankan rute yang aman. Penggabungan pembelajaran mesin dalam sistem pengelolaan bencana dapat secara substansial meningkatkan kesiapan dan strategi respons komunitas, menjamin evakuasi yang tepat waktu dan meningkatkan keselamatan secara keseluruhan selama kejadian seismik. Rencana evakuasi yang diusulkan bertujuan untuk meningkatkan penanganan dengan memberikan pemahaman praktis yang diperoleh dari evaluasi data secara real-time, yang pada akhirnya mendukung ketahanan Kota Padang terhadap risiko seismik.

1.2.2. Arsitektur Sistem

Desain arsitektur sistem dibuat untuk mematuhi jalur terstruktur dari pengambilan input hingga keluaran pengguna melalui sebuah Mesin pembelajaran mesin. Gambar 1 di bawah ini menunjukkan komponen-komponen utama yang ada.



Gambar 1. Arsitektur sistem.

Gambar 1 menggambarkan arsitektur sistem dari ujung ke ujung yang dirancang untuk klasifikasi risiko gempa bumi serta saran evakuasi dengan memanfaatkan pembelajaran mesin. Proses ini mengikuti langkah-langkah yang terencana seperti yang dijelaskan di bawah ini:

1. Input Data

Sistem dimulai dengan mengumpulkan data yang relevan, termasuk lokasi geografis, densitas penduduk, dan karakteristik infrastruktur. Fitur-fitur ini adalah indikator utama kerentanan di wilayah yang rentan gempa.

2. Pra-pemrosesan Data

Data mentah mengalami proses pembersihan, normalisasi, dan transformasi agar sesuai digunakan dalam pemodelan. Langkah ini dapat meliputi pengelolaan nilai yang tidak ada, penskalaan data numerik, dan pengkodean variabel kategori [11].

3. Model Machine Learning (Random Forest)

Klasifikasi dengan Random Forest dilakukan dengan memanfaatkan data historis atau simulasi yang sudah diberi label [12]. Ia menganalisis hubungan yang rumit dan tidak linier antara fitur input dan kategori zona risiko yang telah ditentukan sebelumnya (rendah, menengah, tinggi).

4. Prediksi Zona Risiko

Setelah dilatih, model memprediksi klasifikasi risiko dari data masukan baru, menetapkan apakah suatu lokasi termasuk dalam kategori risiko rendah, menengah, atau tinggi berdasarkan atribut yang dimiliki.

5. Rekomendasi Evakuasi

Berdasarkan risiko yang diperkirakan, sistem menawarkan saran yang relevan dengan situasi, seperti lokasi evakuasi terdekat, zona aman, dan rute terbaik yang disesuaikan dengan tempat dan klasifikasi risiko pengguna.

Arsitektur ini menggambarkan cara kecerdasan buatan dapat diimplementasikan secara efisien dalam sistem pengurangan risiko bencana (DRR), memperbaiki pengambilan keputusan sebelum, saat, dan setelah terjadinya gempa bumi.

2. PEMBAHASAN

2.1 Gambaran statistik per zona risiko

Tabel 1 berikut menyajikan nilai rata-rata beberapa variabel kunci berdasarkan kategori zona risiko:

Tabel 1. Nilai rata-rata beberapa variabel kunci berdasarkan kategori zona Risiko.

Risk Zone	Distance to Beach (km)	Elevation (m)	Population Density (people/km²)	Number of Buildings
Low	9,76	128,87	5.375,33	546.79
Medium	11,83	22,91	5.672,70	520.44
High	2,68	9,94	5.33,40	480.10


Zona Tinggi didominasi oleh daerah yang berdekatan dengan pantai serta memiliki elevasi rendah (< 20 m). Zona Rendah memiliki elevasi yang jauh lebih tinggi (>100 m), meskipun tidak selalu lebih jauh dari lautan. Tidak terdapat perbedaan yang signifikan dalam kepadatan penduduk di antara zona, menunjukkan bahwa parameter geografis menentukan pengklasifikasian awal.

2.2 Distribusi data berdasarkan zona Risiko

Diagram batang yang terlihat pada Gambar 2 menggambarkan distribusi 300 titik data sintesis yang terklasifikasi ke dalam tiga zona risiko gempa bumi: Rendah, Sedang, dan Tinggi. Diagram batang yang terlihat pada Gambar 2 menggambarkan distribusi 300 titik data sintesis yang terklasifikasi ke dalam tiga zona risiko gempa bumi: Rendah, Sedang, dan Tinggi.

- Kategori Zona Risiko Rendah menguasai kumpulan data, dengan lebih dari 220 poin data. Ini menggambarkan wilayah pedalaman yang ditandai oleh ketinggian tinggi dan jarak lebih jauh dari pantai.
- Wilayah Risiko Sedang meliputi sekitar 60 lokasi. Tempat-tempat ini umumnya berada pada ketinggian sedang (sekitar 20–50 meter) dan terletak di area peralihan antara pegunungan yang aman dan lahan rendah yang berisiko.
- Zona Risiko Tinggi mengandung kurang dari 20 titik data. Ini menunjukkan keadaan geografis yang terbatas di mana tempat harus berada dekat dengan laut (kurang dari 5 km) dan memiliki ketinggian rendah (di bawah 20 meter).

Distribusi data sengaja diputar karena logika klasifikasi yang berbasis aturan. Dalam dataset dunia nyata, distribusinya bisa sangat bervariasi tergantung pada kondisi topografi daerah yang diteliti. Visualisasi ini membantu menekankan konsentrasi area yang dianggap aman dibandingkan dengan area yang memerlukan upaya mitigasi dan kesiapan yang lebih terfokus, terutama di wilayah rentan tsunami.



Gambar 2. Distribusi kategori zona risiko.

2.3 Visualisasi spasial distribusi jarak dan ketinggian menurut zona risiko

Diagram distribusi ini, seperti terlihat pada Gambar 3, memvisualisasikan penyebaran lokasi dalam dua dimensi geografis yang penting: jarak dari pantai (sumbu x) dan ketinggian di atas permukaan laut (sumbu y), dengan titik-titik yang diberi kode warna menurut klasifikasi zona risiko.


- Zona Risiko Rendah (oranye) mendominasi bagian atas grafik. Wilayah ini ditandai oleh ketinggian yang tinggi, umumnya lebih dari 50 meter, terlepas dari jarak menuju pantai.
- Area Risiko Menengah (hijau) berada di rentang ketinggian menengah (sekitar 20–50 meter). Tempat-tempat ini mungkin masih terkena dampak gempa bumi.

Walaupun memiliki ketinggian yang sedang, wilayah-wilayah tersebut tidak begitu rentan terhadap guncangan namun lebih rentan terhadap banjir tsunami.

- Zona Risiko Tinggi (biru) terletak di sisi kiri bawah plot, menunjukkan area dengan elevasi rendah (< 20 meter) dan berdekatan dengan pantai (< 5 km). Zona ini adalah yang paling mudah terdampak jika terjadi gempa bumi megathrust yang kemudian disusul tsunami.

Visualisasi spasial ini secara jelas menunjukkan logika zonasi risiko: risiko semakin tinggi seiring dengan kedekatan ke garis pantai dan berkurang dengan peningkatan ketinggian. Klasifikasi titik-titik Risiko Tinggi dalam area spasial yang terbatas menekankan kebutuhan akan sistem peringatan dini serta perencanaan evakuasi yang berorientasi pada wilayah-wilayah penting ini.

Gambar ini sangat krusial untuk perencanaan spasial dan otoritas pengelolaan bencana dalam menanggulangi komunitas yang berisiko tinggi dengan langkah-langkah kesiapsiagaan yang diutamakan.



Gambar 3. Visualisasi spasial distribusi jarak dan elevasi.

2.4 Hasil prediksi simulasi

Tabel 2 berikut menunjukkan contoh hasil prediksi dari dataset simulasi.


Tabel 2. Contoh hasil prediksi

Beach distance (km)	Elevation (mdpl)	Population density	Number of buildings	Historical seismic activity	Risk zone
7,55	7,25	2648	242	1	Medium
19,02	127,65	6539	191	0	Low
14,67	63,56	5199	453	0	Low

2.5 Evaluasi kinerja model

2.5.1. Matriks kebingungan

Matriks kebingungan yang ditampilkan pada Gambar 4 menunjukkan seberapa efektif model pembelajaran mesin dalam mengklasifikasikan area risiko gempa bumi (Rendah, Sedang, Tinggi) berdasarkan dataset uji.



Gambar 4. Matriks kebingungan

Tabel 3. Kinerja model

	Predicted: Low	Predicted: Medium	Predicted: High
Actual: Low	73	0	0
Actual: Medium	0	24	0
Actual: High	0	0	3

Berdasarkan data pada Tabel 3, dapat disimpulkan bahwa:

- Model mengklasifikasikan setiap instance di semua kategori dengan tepat tanpa adanya kesalahan klasifikasi.
- Dominasi diagonal dalam matriks (semua elemen non-nol berada di diagonal) menunjukkan akurasi prediksi yang sempurna pada dataset ini.
- Kinerja setiap kelas:

o Risiko Rendah: 73 dari 73 tepat

o Risiko Sedang: 24 dari 24 tepat

o Risiko Tinggi: 3 dari 3 akurat

Model Random Forest mencapai hasil seperti ini pada uji coba: presisi, recall, dan F1-score untuk semua kelas mencapai 1,00. Tidak ada hasil positif yang salah (false positive) atau hasil negatif yang salah (false negative) dalam matriks kebingungan. Integrasi ini akan membuat model lebih berguna dan tahan dalam situasi nyata, sehingga bisa membuat prediksi yang lebih akurat di berbagai kondisi geospasial. Temuan ini menunjukkan kemampuan model untuk mengurangi kesalahan klasifikasi yang biasa terjadi, sehingga meningkatkan peluang penggunaannya secara lebih luas dalam analisis geospasial.

Kinerja ini, meskipun sangat baik, perlu diartikan dengan hati-hati karena dataset digunakan adalah sintesis dan secara alami konsisten dengan aturan tertentu. Oleh karena itu, meskipun hasilnya menggembirakan, pemeriksaan tambahan terhadap dataset dunia nyata sangat penting agar model tetap dapat diandalkan dan diterapkan dalam situasi nyata. Pekerjaan ke depan perlu berfokus pada penerapan model Random Forest pada dataset nyata guna mengevaluasi kemampuan dan fleksibilitasnya di berbagai lingkungan geospasial, memastikan bahwa model tersebut berguna dan tahan dalam penerapan praktis. Beralih dari dataset sintesis ke dataset dunia nyata bisa memberi pemahaman yang berguna mengenai bagaimana model bekerja dalam situasi berbagai kondisi, serta meningkatkan penerapan model dalam dunia nyata.

Iterasi berikutnya membutuhkan penggabungan dengan data geospasial nyata dari BMKG, BPS, dan lapisan GIS yang tersedia secara terbuka.

2.5.2. Contoh prediksi zona risiko

Diberikan lokasi baru dengan parameter:

- Jarak dari pantai: 2,0 km
- Ketinggian: 10 m
- Kepadatan penduduk: 8.500/km²
- Kepadatan bangunan: 600/km²
- Aktivitas seismik: aktif (1)

Model memprediksi zona "risiko tinggi". Ini sesuai dengan pemahaman di bidangnya dan memastikan aturan yang sudah tertanam dalam fungsi pembangkitan data tersebut berjalan dengan benar. Sistem seperti ini bisa digunakan untuk memberi peringatan awal, peringatan evakuasi, dan meningkatkan kekuatan infrastruktur.

Mengintegrasikan model prediktif ke dalam strategi manajemen bencana bisa membuat masyarakat lebih siap dan memastikan respons cepat terhadap ancaman yang mungkin terjadi. Kemampuan prediktif ini menekankan pentingnya spasial. Pemetaan dan pembagian area berdasarkan tingkat risiko dalam upaya mempersiapkan diri dan mengatasi bencana secara efektif. Selanjutnya, memasukkan faktor sosial-ekonomi ke dalam penilaian risiko bisa membuat prediksi lebih tepat dan membantu membuat strategi tanggap bencana yang lebih sesuai. Penggabungan faktor-faktor tersebut membantu memahami lebih dalam tentang kerentanan yang ada di dalam komunitas, sehingga dapat dibuat rencana pengelolaan bencana serta penyaluran sumber daya yang lebih efektif. Manajemen bencana yang baik membutuhkan pengecekan dan penyesuaian strategi secara terus menerus agar sesuai dengan kebutuhan masyarakat yang terus berubah, sehingga tindakan yang diambil tepat sasaran dan sesuai dengan situasi di lapangan.

3. KESIMPULAN

Studi ini memperluas pemahaman dalam bidang informatika bencana dengan menunjukkan cara pembelajaran mesin dapat mendukung persiapan menghadapi gempa bumi. Dengan menganalisis kasus simulasi di Padang, kami membuktikan bahwa model pembelajaran mesin yang dibuat dengan baik mampu mengklasifikasikan zona berisiko gempa secara efektif berdasarkan indikator spasial dan demografi utama. Algoritma Random Forest, dalam kondisi yang dikendalikan, mampu mengklasifikasikan dengan akurasi sempurna. Namun, untuk beralih dari prototipe ke implementasi nyata, dibutuhkan pengujian tambahan dengan data yang benar-benar ada, partisipasi dari berbagai pihak yang terlibat, serta penggabungan sistem dengan kerangka kerja nasional dalam menangani bencana. Pendekatan yang diajukan mendukung tidak hanya pemahaman tentang situasi yang terjadi, tetapi juga kesiapan dalam melakukan operasi, sesuai dengan tujuan yang lebih luas dari Kerangka Kerja Sendai untuk Pengurangan Risiko Bencana. Penerapan di dunia nyata menghadapi beberapa kendala, seperti keragaman data dan adanya data yang tidak lengkap dalam dataset nyata, kebutuhan akan data spasial

dengan resolusi yang tinggi (sampai tingkat sub-kelurahan), masalah aksesibilitas bagi publik, serta kemudahan dalam menggunakan antarmuka sistem. Kami ingin memperbaiki sistem dengan menggabungkan beberapa komponen, seperti algoritma perutean (misalnya Dijkstra atau A*) untuk merencanakan jalur evakuasi, sensor lalu lintas dan lingkungan yang bekerja secara real-time untuk mengevaluasi risiko secara dinamis, serta integrasi Web-GIS menggunakan platform seperti Leaflet atau API ArcGIS.

PUSTAKA

- D. Chaudhary, An innovative method for earthquake prediction system based on LSTM-GAN model, 113–118 (2025).
<https://doi.org/10.1201/9781003559115-20>
- H. Frananda, F. Yulianda, M. Boer, and I. Nurjaya, The Modeling of Tsunami Based on Existing Land Cover in Padang City (2023).
<https://doi.org/10.4108/eai.19-11-2022.2332296>
- H.P. Rahayu, L.K. Comfort, R. Haigh, D. Amaratunga, and D. Khoirunnisa, A study of people-centered early warning system in the face of near-field tsunami risk for Indonesian coastal cities. *Int. J. Disaster Resil. Built Environ.* **11**(2), 241–262 (2020).
<https://doi.org/10.1108/IJDRBE-10-2019-0068>
- R. Astri, F. Faradika, M.R.A., and A. Kamal, Digital Management of Micro, Small and Medium Enterprises (MSME) Activities Based on the Unified Approach. *Sci. J. Informatics* **8**(2), 258–267 (2021).
<https://doi.org/10.15294/sji.v8i2.29339>
- T. Sharma, A. Singhal, K. Kundu, and N. Agarwal, Machine Learning/Deep Learning for Natural Disasters (2022).
<https://doi.org/10.1201/9781003245469-7>