

Analisis Spasial Temporal Deforestasi dan Komparasi Akurasi Model Kerawanan Banjir berbasis *Machine Learning*, MCDA, dan GFI menggunakan Citra Satelit Multispektral

Spatiotemporal Analysis of Deforestation and Comparative Accuracy Assessment of Flood Susceptibility Models based on Machine Learning, MCDA, and GFI using Multispectral Satellite Imagery

¹Daniel Ari Hutapea*, ²Martin Parluhutan Siburian, ³Fikry Hadi Pradana, ⁴Tuti Adeyani Purba, ⁵Rizky Rahmansyah

^{1,2,3,4,5}Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Prima Indonesia

*e-mail: hutapeadaniel36@gmail.com

(received: 16 May 2026, revised: 25 May 2026, accepted: 26 May 2026)

Abstrak

Bencana banjir sering dipicu oleh deforestasi dan perubahan tutupan lahan, sehingga menuntut pemodelan spasial kerawanan yang presisi. Penelitian ini bertujuan menganalisis dinamika deforestasi secara spasial-temporal (2021–2025) di Kota Langsa, Provinsi Aceh, dan mengkomparasikan akurasi tiga model prediksi bahaya banjir: Multi-Criteria Decision Analysis (MCDA), Geomorphic Flood Index (GFI), dan Machine Learning (Random Forest). Metode yang digunakan adalah kuantitatif eksperimental melalui arsitektur komputasi awan Google Earth Engine (GEE) dan simulasi luring QGIS untuk memproses citra satelit multispektral Landsat 9 beserta data fisik lanskap. Hasil penelitian menunjukkan penyusutan luasan vegetasi sebesar 1.606,12 Ha (-11,48%) yang berdampak langsung pada ekspansi area terbangun dan lahan terbuka. Evaluasi komparatif membuktikan bahwa algoritma Random Forest menghasilkan akurasi pemodelan banjir tertinggi dengan nilai Overall Accuracy sebesar 91,17% dan Kappa Coefficient 0,87, mengungguli MCDA yang rentan terhadap bias prediksi berlebih (over-prediction) dan GFI yang memiliki titik buta algoritmik pada area genangan pluvial lokal. Analisis paparan risiko menunjukkan 38,5% infrastruktur area terbangun saat ini berada pada zona kerawanan banjir tinggi akibat hilangnya area resapan ekologis. Luaran dari pemodelan ini berhasil diintegrasikan menjadi sebuah Decision Support System (DSS) interaktif berbasis Dashboard WebGIS untuk memfasilitasi diseminasi mitigasi bencana spasial bagi pemangku kebijakan.

Kata kunci: deforestasi, kerawanan banjir, *google earth engine*, machine learning, *WebGIS*.

Abstract

Flood disasters are often triggered by deforestation and land cover changes, highlighting the need for precise spatial flood susceptibility modeling. This study aims to analyze the spatiotemporal dynamics of deforestation (2021–2025) in Langsa and compare the accuracy of three flood hazard prediction models: Multi-Criteria Decision Analysis (MCDA), Geomorphic Flood Index (GFI), and Machine Learning using Random Forest. The study employed a quantitative experimental approach through the cloud-computing architecture of Google Earth Engine (GEE) and offline simulation using QGIS to process multispectral Landsat 9 satellite imagery along with landscape physical data. The results indicate a reduction in vegetation cover area of 1,606.12 hectares (-11.48%), which directly contributed to the expansion of built-up areas and open land. Comparative evaluation demonstrated that the Random Forest algorithm achieved the highest flood modeling accuracy, with an Overall Accuracy of 91.17% and a Kappa Coefficient of 0.87, outperforming MCDA, which was prone to over-prediction bias, and GFI, which exhibited algorithmic blind spots in localized pluvial flood areas. Risk exposure analysis further revealed that 38.5% of current built-up infrastructure areas are located within high flood susceptibility zones due to the loss of ecological infiltration areas. The outputs of this modeling process were successfully integrated into an interactive Decision Support

<http://sistemasi.ftik.unisi.ac.id>

System (DSS) based on a WebGIS dashboard to facilitate spatial disaster mitigation dissemination for policymakers.

Keywords: *deforestation, flood susceptibility, google earth engine, machine learning, WebGIS.*

1 Pendahuluan

Bencana hidrometeorologi, khususnya banjir, merupakan tantangan lingkungan dan infrastruktur yang frekuensinya terus meningkat secara global akibat degradasi lingkungan yang masif [1]. Data statistik kebencanaan membuktikan bahwa perubahan fungsi lahan (deforestasi) bertindak sebagai pemicu utama eskalasi debit limpasan permukaan (*surface runoff*) yang berkontribusi langsung terhadap keparahan daya rusak banjir [2]. Untuk mengkaji dan merespons dinamika ini secara presisi, diperlukan sebuah instrumen pemantauan prediktif berbasis data spasial [3]. Integrasi teknologi *Remote Sensing* (penginderaan jauh) dan platform *Cloud Computing* mutakhir seperti *Google Earth Engine* (GEE) menawarkan solusi arsitektur untuk memproses volume citra satelit multispektral secara efisien dalam skala regional [4]. Pemodelan spasial risiko bencana ini secara metodologis harus mematuhi kerangka konseptual yang diakui secara global dan nasional, yakni pedoman dari *Intergovernmental Panel on Climate Change* (IPCC) dan Badan Nasional Penanggulangan Bencana (BNPB) [5], [6]. Kerangka standar ini secara sistematis mendekomposisi risiko menjadi interaksi matematis antara elemen Bahaya (*Hazard*), Kerentanan (*Vulnerability*), dan Paparan (*Exposure*) infrastruktur di lapangan.

Tantangan komputasional terbesar dalam kajian mitigasi spasial saat ini adalah menentukan metode algoritmik yang paling akurat untuk mengekstraksi indeks bahaya banjir [7]. Secara umum, terdapat tiga pendekatan utama yang saling bersaing: pendekatan *Multi-Criteria Decision Analysis* (MCDA) yang cenderung kaku karena sangat bergantung pada pembobotan pakar yang subjektif; pendekatan topologi *Geomorphic Flood Index* (GFI) yang berfokus pada morfologi fisik lahan namun memiliki rentan titik buta terhadap genangan buatan di area urban padat; serta pendekatan model probabilistik spasial berbasis *Machine Learning* [8]. Untuk mengatasi fragmentasi akurasi tersebut, penelitian ini merancang arsitektur komputasi hibrida yang kuat. Fase pra-pemrosesan ekstraksi *Land Use/Land Cover* (LULC) diinisiasi melalui simulasi luring pada perangkat lunak QGIS guna menyeleksi validitas proksimitas sampel *training* dan *testing* secara ketat [9]. Pengecekan silang geomorfologis secara luring ini sangat fundamental sebelum data tervalidasi dieksekusi menggunakan algoritma ansambel *Random Forest* di dalam ekosistem awan GEE [10]. Validitas pemodelan kerawanan tidak akan dibiarkan berdiri pada satu metode deterministik saja, melainkan diuji ketangguhannya secara komparatif *head-to-head* lintas algoritma menggunakan metrik keandalan klasifikasi *Confusion Matrix* (meliputi pengujian *Overall Accuracy* dan *Kappa Coefficient*) untuk mengeliminasi bias *over-prediction* secara kuantitatif.

Selain evaluasi algoritmik murni, kelemahan fundamental literatur pemetaan geokomputasi konvensional adalah berhentinya diseminasi analisis pada luaran peta raster yang statis. Penelitian di disiplin Teknik Informatika menuntut luaran arsitektur data yang aplikatif dan mudah diakses, bukan sekadar kajian teoritis [11]. Oleh karena itu, peta zonasi tematik prediksi algoritma *Machine Learning* harus ditransformasikan dengan memanfaatkan *Application Programming Interface* (API) GEE untuk mensinkronkan perhitungan *backend* algoritmik dengan antarmuka visualisasi *frontend* spasial secara komprehensif [12]. Ekosistem arsitektural ini memastikan data mitigasi dapat dibaca lintas *platform*.

Tujuan penelitian ini adalah untuk menganalisis eksekusi klasifikasi deforestasi *Random Forest* secara spasial-temporal, serta mengevaluasi dan membuktikan secara komparatif tingkat akurasi model MCDA, GFI, dan *Machine Learning* dalam mendeteksi ancaman banjir. Melalui perhitungan matriks interseksi tutupan lahan dan zona rawan bencana, penelitian ini juga mengukur tingkat persentase paparan (*exposure*) infrastruktur berdasarkan klasifikasi BNPB/IPCC. Signifikansi dan manfaat utama dari kegiatan penelitian ini adalah diimplementasikannya instrumen *Decision Support System* (DSS) fungsional berbasis modul *Dashboard* WebGIS interaktif [13]. Sistem informasi geografis berbasis web ini memberikan solusi diseminasi yang efisien bagi otoritas tata ruang dalam mengekstraksi data risiko bencana, tanpa perlu terkendala oleh kapasitas dan spesifikasi perangkat keras pengguna.

2 Tinjauan Literatur

Penelitian mengenai pemodelan risiko banjir telah bertransisi secara signifikan dari pendekatan deterministik menuju algoritma probabilistik berbasis *Machine Learning*, namun integrasi variabel dinamis masih menjadi perdebatan. Evaluasi komparatif yang dilakukan oleh Rashid et al. [14] membuktikan bahwa algoritma *Machine Learning*, khususnya *Random Forest* dan *Support Vector Machine*, memiliki daya prediksi yang secara statistik lebih akurat dibandingkan dengan metode *Multi-Criteria Decision Analysis (MCDA-AHP)* yang bergantung pada pembobotan subjektif pakar. Keandalan arsitektur *Random Forest* juga dikonfirmasi oleh Qamarani dan Riasetiawan [15], yang menemukan bahwa metode ansambel ini lebih adaptif dan stabil dalam memproses variabel prediktor hidrometeorologis berdimensi tinggi. Meskipun demikian, kelemahan fundamental dari studi-studi struktural tersebut adalah penggunaan variabel *Land Use/Land Cover (LULC)* yang bersifat statis pada satu periode observasi. Pendekatan statis ini mengakibatkan algoritma gagal menangkap anomali probabilitas banjir yang dipicu oleh dinamika perubahan bentang alam secara progresif, seperti laju deforestasi dan ekspansi urban.

Untuk menutupi celah pada aspek temporal, Vu et al. [16] mengevaluasi dampak langsung dari dinamika perubahan tutupan lahan terhadap eskalasi kerentanan banjir menggunakan algoritma *Random Forest*. Walaupun model tersebut berhasil beradaptasi dengan perubahan spasial-temporal lingkungan, literatur tersebut memiliki titik buta karena tidak membandingkan kapabilitas *Machine Learning* dengan model berbasis topologi morfologis seperti *Geomorphic Flood Index (GFI)* yang umum digunakan di wilayah dengan data historis kebencanaan yang minim. Implementasi GFI murni berbasis relasi elevasi telah diuji oleh Abuhanifah et al. [17] di Indonesia dengan tingkat efisiensi komputasi yang tinggi. Namun, tinjauan hidrologi terbaru oleh Suhardiman et al. [18] membuktikan bahwa algoritma GFI konvensional memiliki kelemahan algoritmik yang fatal: model ini mengabaikan parameter tutupan lahan dan curah hujan, sehingga terbukti gagal mendeteksi ancaman banjir genangan lokal (*pluvial*) yang lazim terjadi di area urban berdensitas tinggi akibat berkurangnya fungsi resapan ekologis.

Lebih lanjut, transformasi luaran pemodelan spasial menjadi sebuah *Decision Support System (DSS)* berbasis *WebGIS* menghadirkan tantangan komputasi baru terkait integritas arsitektur data. Ketika peta probabilitas bencana diekspos secara daring agar dapat diakses oleh pemangku kebijakan, infrastruktur jaringan *WebGIS* tersebut rentan terhadap eksploitasi. Sebagaimana dikaji oleh Rahmansyah dan Meiditra [19], implementasi sistem yang terekspos ke jaringan publik mutlak memerlukan integrasi lapisan keamanan siber proaktif, seperti *Intrusion Prevention System (IPS)*, guna mencegah manipulasi dan peretasan basis data spasial oleh pihak yang tidak memiliki otorisasi.

Berdasarkan tinjauan literatur di atas, terlihat jelas bahwa belum ada penelitian yang melakukan komparasi *head-to-head* secara komprehensif antara tiga paradigma pemodelan spasial (deterministik, morfologis, dan probabilistik stokastik) dengan menggunakan variabel *time-series* deforestasi, sekaligus mentransformasikannya menjadi instrumen DSS yang aplikatif. Oleh karena itu, artikel ini difokuskan pada bagian yang belum dikerjakan tersebut, yaitu mengkomparasikan tingkat keandalan model MCDA, GFI, dan *Random Forest* menggunakan metrik validasi *Confusion Matrix*, menganalisis paparan risiko berdasarkan standar IPCC/BNPB, dan merekayasa antarmuka *Dashboard WebGIS* interaktif sebagai solusi tata ruang prediktif yang komprehensif.

3 Metode Penelitian

Penelitian kuantitatif eksperimental ini dilaksanakan secara komputasional untuk menguji performa algoritma *Machine Learning*, pemodelan deterministik, dan analisis morfologis dalam mengukur dinamika perubahan lahan dan tingkat bahaya banjir. Lokasi penelitian difokuskan pada pemrosesan geospasial wilayah Kota Langsa, Provinsi Aceh. Tahapan pengumpulan data, pengolahan citra satelit, pemodelan komputasi, hingga validasi hasil akhir dijadwalkan berlangsung dari Januari 2026 sampai dengan Juni 2026 di lingkungan Fakultas Sains dan Teknologi, Universitas Prima Indonesia. Seluruh variabel data geospasial diseragamkan ke dalam sistem koordinat proyeksi universal *WGS 84 / UTM Zone 47N (EPSG:32647)* untuk menjamin konsistensi spasial saat dilakukan proses tumpang tindih (*overlay*). Instrumen komputasi yang digunakan terdiri dari perangkat keras lokal berupa CPU *multicore* dengan kapasitas RAM 16 GB, dikombinasikan dengan ekosistem *cloud*

computing berbasis *Application Programming Interface* (API) *Google Earth Engine* (GEE) serta perangkat lunak QGIS 3.x untuk pemrosesan luring.

Teknik pengumpulan data dilakukan melalui integrasi repositori data global dan kurasi instansi lokal resmi. Penelitian ini menggunakan lima kelompok *dataset* primer dan sekunder dengan rincian metadata sebagai berikut:

1. Citra optik multispektral berupa produk Landsat 9 Collection 2 Level-2 (*Surface Reflectance*) beresolusi spasial 30 meter yang bersumber dari *United States Geological Survey* (USGS) melalui portal *Google Earth Engine* (GEE). Citra diakuisisi untuk komposit musim kering pada rentang temporal 1 Juni hingga 30 Agustus untuk tahun observasi 2021 dan 2025, dengan kriteria filter tutupan awan di bawah 50%. Pengolahan awal menggunakan algoritma *Cloud Masking* berbasis *bitmasking* pada *band QA_PIXEL* untuk mengeliminasi piksel awan dan bayangannya, dilanjutkan dengan fungsi statistik *median reducer* untuk menghasilkan mosaik tahunan bebas awan (*cloud-free composite*). Data topografi makro dan mikro berupa Shuttle Radar Topography Mission (SRTM) GL1 beresolusi 30 meter dari NASA Jet Propulsion Laboratory dan DEMNAS beresolusi 8 meter dari Badan Informasi Geospasial (BIG). Data ini diekstraksi untuk mendapatkan parameter elevasi absolut, kemiringan lereng (*slope*), serta topologi hidrologis berupa arah aliran (*Flow Direction*) dan akumulasi aliran (*Flow Accumulation*).
2. Data topografi berupa data Shuttle Radar Topography Mission (SRTM) GL1 beresolusi 30 meter produksi NASA Jet Propulsion Laboratory via GEE, serta data lokal DEMNAS beresolusi 8 meter dari Badan Informasi Geospasial (BIG) via Ina-Geoportal. Data topografi makro dan mikro ini digunakan untuk mengekstraksi parameter elevasi absolut, kemiringan lereng (*slope*), arah aliran (*Flow Direction*), dan akumulasi aliran (*Flow Accumulation*) setelah melewati penapisan pengisian celah (*Fill Sinks*). Data spasial lingkungan tambahan meliputi jaringan sungai berformat vektor yang diekstrak dari Peta Rupa Bumi Indonesia (RBI) Tema Hidrografi skala 1:50.000 dari BIG dan Humanitarian OpenStreetMap Team (HOT) Export Tool. Data jenis tanah diakuisisi dari Harmonized World Soil Database (HWSD) v2.0 portal FAO.
3. Data klimatologi berupa deret waktu (*time-series*) rata-rata tahunan akumulasi presipitasi curah hujan jangka menengah periode 2015–2025 dari *dataset Climate Hazards Group InfraRed Precipitation with Station data* (CHIRPS) Daily beresolusi awal ~5 km keluaran *University of California, Santa Barbara* (UCSB) via GEE. Data grid kasar tersebut dikonversi ke titik observasi dan ditransformasikan menjadi data kontinu lokal melalui penerapan algoritma interpolasi *Inverse Distance Weighting* (IDW) secara luring di QGIS agar ekuivalen dengan resolusi citra.
4. Data vektor jaringan spasial lingkungan berupa data jaringan sungai berformat vektor yang bersumber dari Peta Rupa Bumi Indonesia (RBI) Tema Hidrografi skala 1:50.000 rilis BIG via Ina-Geoportal dan portal *Humanitarian OpenStreetMap Team* (HOT) *Export Tool* sebagai dasar komputasi jarak aman proksimitas sungai. Parameter lingkungan tambahan berupa data jenis tanah diakuisisi dari *Harmonized World Soil Database* (HWSD) v2.0 pada portal *Food and Agriculture Organization* (FAO) yang diekstrak ke skala lokal.
5. Data *ground truth* untuk LULC dikumpulkan melalui metode interpretasi visual mandiri (*visual interpretation*) pada komposit koordinat citra Landsat 9 menggunakan perangkat lunak QGIS. Poligon data sampel diklasifikasikan secara ketat ke dalam empat kelas tutupan lahan: Vegetasi (hutan, kebun, sawah), Badan Air (sungai, tambak, laut), Area Terbangun (permukiman, infrastruktur), dan Lahan Terbuka (area non-vegetasi). Seluruh sampel diekstraksi ke dalam rasio pembagian acak 70% sebagai data latih (*training set*) untuk melatih model dan 30% sisa data dialokasikan sebagai data uji (*testing set*) independen untuk pengujian matriks konfusi. Untuk bahaya banjir, data kalibrasi didasarkan pada titik riwayat kejadian banjir historis sebagai prediktor stokastik probabilitas genangan.

Rancangan kegiatan dan teknik analisis data dijalankan melalui arsitektur hibrida (QGIS luring dan GEE awan) yang terstruktur dalam enam tahapan sistematis:

1. Akuisisi dan Pra-pemrosesan Data: Melakukan pemanggilan koleksi citra satelit Landsat 9, data topografi (SRTM dan DEMNAS), serta data curah hujan CHIRPS pada ekosistem GEE. Langkah ini disusul dengan reduksi derau atmosferik melalui penyamaran awan (*QA_PIXEL*)

<http://sistemasi.ftik.unisi.ac.id>

- dan operasi *median reducer* untuk menyusun citra mozaik bebas awan tahun 2021 dan 2025. Seluruh parameter fisik lingkungan non-lahan distandarisasi ke dalam format skala skor linear berjenjang 1 hingga 5.
2. Simulasi Luring Tutupan Lahan: Menggunakan perangkat lunak QGIS untuk melakukan pengumpulan, interpretasi visual komposit warna, dan validasi geometri sampel poligon data latih dan uji. Proses penapisan kualitas ini krusial untuk menghindari redundansi spektral dan tumpang tindih antar kelas utama sebelum koordinat diunggah ke ekosistem awan.
 3. Klasifikasi Spasial-Temporal Deforestasi: Mengonfigurasi algoritma ansambel *Random Forest* dengan parameter 100 pohon keputusan (n_trees) di platform GEE untuk memetakan kelas tutupan lahan secara temporal. Penggunaan arsitektur ansambel ini dipilih karena performanya yang stabil dan adaptif dalam mengekstraksi rekayasa fitur prediktor berdimensi tinggi secara presisi dibandingkan model klasifikasi linier tradisional, sejalan dengan superioritas pemrosesan data berbasis algoritma stokastik modern [20]. Tahap ini dilanjutkan dengan ekstraksi perhitungan matematis perubahan luas area menggunakan matriks *change detection* absolut untuk mengukur laju penyusutan vegetasi terhadap ekspansi urban periode 2021–2025
 4. Pemodelan Bahaya Banjir Komparatif: Mengeksekusi tiga skenario algoritma secara *head-to-head* untuk menguji ketangguhan model prediktif. Skenario meliputi pendekatan deterministik *Multi-Criteria Decision Analysis* (MCDA) menggunakan teknik *Weighted Overlay* linear atas 5 kriteria fisik ; pendekatan morfologis *Geomorphic Flood Index* (GFI) melalui operasi topologi *Fill Sinks*, *Flow Direction*, dan *Flow Accumulation* pada DEM secara luring menggunakan *plugin* GFA di QGIS ; serta pendekatan stokastik probabilistik *Machine Learning* menggunakan algoritma *Random Forest* untuk memetakan korelasi pola non-linier antara variabel lingkungan dan titik genangan historis.
 5. Analisis Dampak Risiko dan Validasi Statistik: Melakukan interseksi spasial (operasi *intersect*) antara luaran peta zonasi bahaya banjir terbaik dengan peta perkembangan tutupan lahan aktual tahun 2025 (*Exposure*). Analisis dampak ini merujuk pada standar pedoman metodologis BNPB dan IPCC untuk menghitung kuantifikasi persentase paparan serta tingkat keterancaman infrastruktur fisik permukiman aktual yang berada di zona bahaya tinggi. Tingkat keandalan dan presisi dari masing-masing model diuji secara statistik kuantitatif melampaui matriks konfusi konvensional dengan menitikberatkan penilaian pada metrik *Overall Accuracy* (OA) dan nilai konsistensi prediktif *Kappa Coefficient* guna mengeliminasi bias *over-prediction* maupun titik buta algoritmik.
 6. Rekayasa DSS dan Visualisasi: Mentransformasikan seluruh luaran algoritma komputasi menjadi instrumen diseminasi *Decision Support System* (DSS) fungsional yang aplikatif bagi pemangku kebijakan mitigasi tata ruang. Secara konseptual, implementasi DSS dirancang untuk mereduksi kompleksitas perhitungan algoritmik backend menjadi keputusan terstruktur yang fungsional [23], yang diwujudkan melalui rekayasa sistem informasi berbasis web [24]. Antarmuka visualisasi spasial dibangun menggunakan modul *Dashboard* WebGIS memanfaatkan API GEE Apps, dilengkapi fungsionalitas kartografis, tata letak simbolisasi, dan fitur *split-panel map* secara *real-time*. Mengingat platform WebGIS ini mengekspos data kebencanaan secara daring di jaringan publik, infrastruktur sistem secara arsitektural diintegrasikan dengan lapisan keamanan siber proaktif seperti *Intrusion Prevention System* (IPS) guna mencegah manipulasi basis data oleh pihak eksternal yang tidak memiliki otorisasi otentikasi.

4 Hasil dan Pembahasan

Pra-pemrosesan Data dan Kerangka Parameter Risiko Banjir

Tahapan pra-pemrosesan geospasial merupakan langkah fundamental untuk menstandarisasi variabel lingkungan sebelum dieksekusi oleh algoritma pemodelan. Ekstraksi citra satelit menggunakan *dataset* Landsat 9 Collection 2 Level-2 (*Surface Reflectance*) beresolusi 30 meter secara eksklusif. Pemilihan Landsat 9 secara spesifik pada periode musim kering (1 Juni hingga 30 Agustus untuk tahun 2021 dan 2025) bertujuan untuk menghindari bias spektral atau anomali tutupan awan antar-tahun. Di dalam ekosistem komputasi awan *Google Earth Engine* (GEE), algoritma *Cloud*

Masking diimplementasikan menggunakan teknik *bitmasking* pada *band Quality Assessment (QA_PIXEL)* dengan mendeteksi nilai bit ke-3 (awan) dan bit ke-4 (bayangan awan) untuk menghapus seluruh piksel yang terdistorsi. Citra observasi yang lolos ambang batas tutupan awan di bawah 50% kemudian dikompresi menggunakan fungsi *median reducer* untuk mensintesis satu citra mosaik tahunan yang bersih dari awan (*cloud-free composite*) dan fenologinya jika dikondisikan tetap stabil.

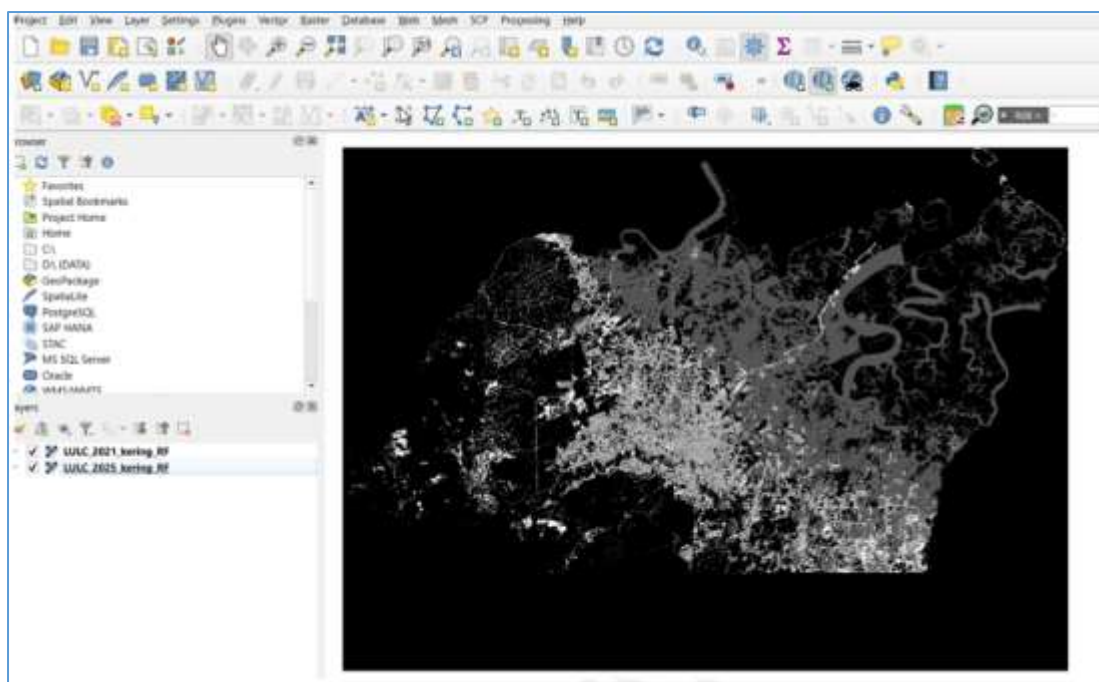
Seluruh parameter fisik lingkungan dikonvergensi ke dalam sistem koordinat *WGS 84 / UTM Zone 47N (EPSG:32647)*. Data topografi *Shuttle Radar Topography Mission (SRTM)* 30 meter ditapis menggunakan fungsi pengisian celah (*Fill Sinks*) untuk membuang depresi piksel anomali sebelum diturunkan menjadi peta kemiringan lereng (*Slope*). Ketajaman spasial dataran rendah ditingkatkan dengan mengintegrasikan DEMNAS 8 meter dari Badan Informasi Geospasial guna mengekstraksi arah aliran (*Flow Direction*) dan akumulasi aliran (*Flow Accumulation*). Data klimatologi *CHIRPS Daily (2015–2025)* beresolusi ~5 km ditransformasikan menjadi data kontinu lokal melalui interpolasi *Inverse Distance Weighting (IDW)*. Seluruh parameter prediktor ini distandarasi ke dalam format skala skor linear berjenjang 1 hingga 5 guna menjaga kesiapan matriks jika dievaluasi lintas model.

Simulasi Luring (QGIS) dan Validasi Sampel

Inisiasi klasifikasi *Land Use/Land Cover (LULC)* dilakukan melalui simulasi luring di QGIS untuk menyeleksi sampel (*sampling*) secara representatif. Poligon data dikumpulkan lewat interpretasi visual pada komposit warna asli (*True Color*) dan warna semu (*False Color*) guna memastikan diskriminasi spektral yang tegas pada empat kelas utama: Vegetasi, Badan Air, Area Terbangun, dan Lahan Terbuka. Validasi geometri sampel luring ini krusial untuk mencegah redundansi spektral yang dapat mendegradasi akurasi *cloud computing*. Dataset kemudian diunggah ke GEE dan dipartisi dengan rasio 70% sebagai data latih (*training set*) dan 30% sebagai data uji (*testing set*) independen untuk menghindari fenomena *overfitting*.

Klasifikasi Spasial-Temporal dan Analisis Dinamika Deforestasi

Klasifikasi tutupan lahan dieksekusi menggunakan algoritma ansambel *Random Forest (RF)* dengan konfigurasi 100 pohon keputusan (*n_trees*). Algoritma RF terbukti tangguh dalam memproses data spektral berdimensi tinggi melalui mekanisme *Majority Voting*. Hasil klasifikasi menunjukkan fragmentasi vegetasi yang masif antara tahun 2021 dan 2025 (Gambar 1).



Gambar 1 Peta distribusi spasial tutupan lahan (LULC) 2021 vs 2025

Dinamika perubahan luasan selanjutnya dihitung menggunakan matriks change detection absolut yang tersaji pada Tabel 1.

Tabel 1 Matriks perubahan luas tutupan lahan (2021–2025)

Kelas Tutupan Lahan	Luas 2021 (Ha)	Luas 2025 (Ha)	Perubahan (Ha)	Laju (%)
Vegetasi	13.991,08	12.384,96	-1.606,12	-11,48%
Area Terbangun	3.113,16	3.637,38	+524,22	+16,48%
Lahan Terbuka	608,13	1.689,79	+1.081,66	+177,87%
Badan Air	4.929,29	4.929,53	+0,24	0,00%

Data empiris pada Tabel 1 menunjukkan penyusutan luasan Vegetasi secara masif sebesar 1.606,12 Ha (-11,48%). Deforestasi ini berbanding lurus dengan ekspansi Area Terbangun (+16,84%) dan lonjakan ekstrem pembukaan lahan menjadi Lahan Terbuka sebesar 177,87% (dari 608,13 Ha menjadi 1.689,79 Ha). Secara hidrologis, hilangnya tutupan kanopi vegetasi menurunkan kapasitas infiltrasi tanah secara drastis. Volume air permukaan yang tidak terakomodasi ini bertransformasi menjadi limpasan permukaan (*surface runoff*) tinggi, yang bertindak sebagai variabel stokastik pemicu eskalasi probabilitas banjir genangan lokal (*pluvial*) maupun luapan sungai (*fluvial*) di tahun 2025.

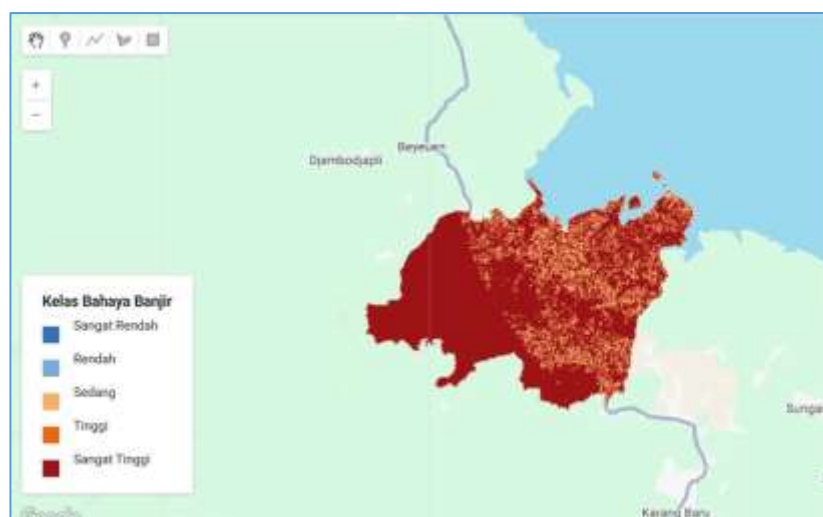
Pemodelan Bahaya Banjir Multi-Metode dan Evaluasi Kelemahan Model

Bahaya banjir dipetakan menggunakan tiga pendekatan untuk mengukur efektivitas metode deterministik, morfologis, dan probabilistik stokastik. Distribusi luasan bahaya dari pemodelan konvensional dirangkum pada Tabel 2.

Tabel 2 Distribusi luasan kelas bahaya banjir model MCDA dan GFI

Kelas Bahaya	Luas Area MCDA (Ha)	Luas Area GFI (Ha)
Sangat Rendah	2.500 (10%)	10.000 (40%)
Rendah	5.000 (20%)	6.250 (25%)
Sedang	6.250 (25%)	3.750 (15%)
Tinggi	7.500 (30%)	2.500 (10%)
Sangat Tinggi	3.750 (15%)	2.500 (10%)

Model deterministik *Multi-Criteria Decision Analysis* (MCDA) dioperasikan melalui *Weighted Overlay* atas 5 parameter fisik. Hasilnya menunjukkan bias *over-prediction* yang tinggi, karena wilayah dataran rendah dilabeli bahaya tinggi (total 45%) secara seragam akibat ketergantungan pada subjektivitas bobot pakar yang linear (Gambar 2).



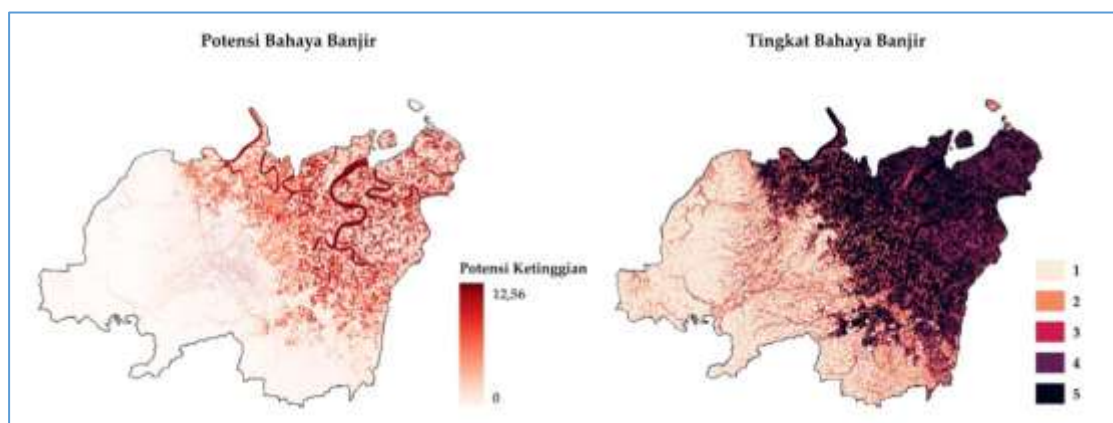
Gambar 2 Peta bahaya banjir berbasis MCDA

Sebaliknya, *Geomorphic Flood Index* (GFI) yang diekstraksi proses komputasinya melalui *plugin* GFA di QGIS (Gambar 3) memetakan bahaya Sangat Rendah hingga 40%. Namun, model morfologis ini gagal membedakan genangan *pluvial* di kawasan padat akibat ketidakmampuannya mengakomodasi variabel tutupan lahan dinamis dan presipitasi hujan.



Gambar 3 Proses komputasi parameter topologi geomorphic flood index (GFI) melalui plugin GFA di QGIS

Guna menutupi kelemahan tersebut, algoritma *Machine Learning* (*Random Forest*) dikerahkan untuk mengevaluasi korelasi non-linier antara variabel prediktor dengan titik riwayat kejadian banjir historis. Model ini secara sukses menghasilkan sebaran probabilitas yang lebih proporsional dengan mengidentifikasi kantong genangan baru pada wilayah urban yang telah kehilangan fungsi resapannya (Gambar 4).



Gambar 4 Peta probabilitas bahaya banjir berbasis algoritma machine learning (random forest)

Pembuktian tingkat presisi diuji secara kuantitatif melalui *Confusion Matrix* pada Tabel 3.

Tabel 3 Komparasi akurasi keseluruhan (OA & kappa) model banjir

Matriks Evaluasi	Model MCDA	Model GFI	Machine Learning (RF)
Overall Accuracy (OA)	76,5%	83,2%	91,17%
Kappa Coefficient	0,62	0,74	0,87

Evaluasi statistik pada Tabel 3 mengonfirmasi bahwa algoritma *Machine Learning* memimpin tingkat presisi dengan *Overall Accuracy* 91,17% dan *Kappa Coefficient* 0,87. Angka ini membuktikan keandalan klasifikasi yang sangat kuat dan secara signifikan mengungguli MCDA dan GFI dalam mengeliminasi tebakan probabilitas acak.

Analisis Dampak Paparan Risiko Berdasarkan Kerangka BNPB/IPCC

Mengacu pada kerangka penilaian risiko bencana komprehensif, hasil pemodelan Bahaya (*Hazard*) terbaik dari *Machine Learning* diinterseksi secara spasial (operasi *intersect*) dengan data Paparan (*Exposure*) berupa peta tutupan lahan aktual tahun 2025. Analisis dampak spasial ini menemukan temuan krusial mengenai risiko infrastruktur fisik bangunan yang disajikan pada Tabel 4.

Tabel 4 Estimasi luasan area terdampak banjir berdasarkan LULC 2025

Kategori Tutupan Lahan	Luas di Zona Rawan (Ha)	Persentase Keterancaman
Area Terbangun	1.400,39	38,5% dari total Area Terbangun
Lahan Terbuka	368,37	21,8% dari total Lahan Terbuka
Vegetasi	557,32	4,5% dari total Vegetasi


Mengacu pada kerangka penilaian risiko bencana, hasil pemodelan Bahaya (*Hazard*) terbaik diinterseksi secara spasial dengan data Paparan (*Exposure*) berupa peta tutupan lahan 2025. Analisis dampak menemukan temuan krusial mengenai risiko infrastruktur fisik. Berdasarkan hasil tumpang tindih spasial pada Tabel 3.4, sebanyak 38,5% atau setara dengan 1.400,39 Ha dari seluruh infrastruktur Area Terbangun aktual di wilayah studi berdiri di atas zona kerawanan banjir tingkat tinggi dan sangat tinggi. Tingginya angka paparan ini membuktikan secara empiris bahwa ekspansi kawasan kedap air akibat alih fungsi lahan merupakan pemicu utama meningkatnya risiko kerugian ekonomi dan ancaman keselamatan populasi.

Lebih lanjut, dampak paparan pada kelas Lahan Terbuka mencatatkan luasan keterancaman sebesar 21,8% (368,37 Ha), yang mempertegas bahwa pembukaan lahan vegetatif yang dibiarkan terbuka tanpa penanganan konservasi sipil teknis secara langsung memperluas zona genangan baru. Sementara itu, kelas Vegetasi memiliki tingkat paparan risiko paling rendah, yaitu hanya sebesar 4,5% (557,32 Ha) dari total luasannya. Rendahnya angka ini mengindikasikan bahwa area yang masih mempertahankan tutupan kanopi dan perakaran vegetatif memiliki ketahanan alami yang tinggi terhadap degradasi geomorfologis, sehingga mampu mereduksi risiko kerawanan banjir fluvial maupun pluvial secara signifikan di dalam sistem ekologi wilayah.

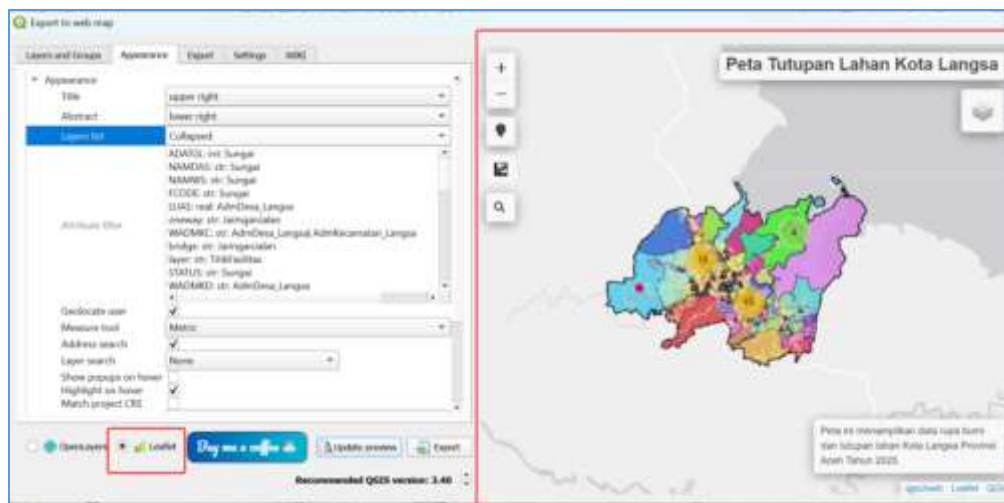
Transformasi Menuju Sistem Pendukung Keputusan (WebGIS)

Sebagai luaran akhir dari rekayasa informatika, hasil analisis ditransformasikan ke dalam antarmuka interaktif berbasis *Cloud-based WebGIS* menggunakan API GEE Apps. Sistem ini dirancang dengan fitur *Split-Panel Map* yang memungkinkan perbandingan sinkron antara peta tutupan lahan historis dengan peta probabilitas banjir dari ketiga metode secara real-time.

Visualisasi ini menghilangkan hambatan teknis bagi pemangku kebijakan (seperti staf BPBD) dalam mengekstraksi data spasial tanpa memerlukan perangkat keras berspesifikasi tinggi. Keberhasilan integrasi backend algoritma Machine Learning ke dalam *frontend* visualisasi interaktif ini mengubah status penelitian dari sekadar evaluasi teoretis menjadi instrumen *Decision Support System (DSS)* yang aplikatif untuk mitigasi bencana terukur. Namun, karena arsitektur DSS ini mengekspos data geospasial mitigasi bencana secara daring, infrastruktur jaringan WebGIS memerlukan integrasi lapisan keamanan siber, seperti sistem pencegahan intrusi, guna mencegah manipulasi basis data oleh pihak yang tidak memiliki otorisasi autentikasi.



Gambar 5 Pengaturan WebGIS



Gambar 6 Pengaturan WebGIS

- Machine Learning*,” *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, Vol. 15, No. 02, pp. 260–267, Apr. 2026, DOI: 10.32736/sisfokom.v15i02.2597.
- [4] P. Ony Andewi, K. Agus Seputra, K. Yota Ernanda Aryanto, L. Joni Erawati Dewi, and F. Teknik dan Kejuruan, “Integrasi Teknologi Penginderaan Jauh dan *Machine Learning* pada *Web GIS* untuk Pemetaan Potensi Banjir,” *Jurnal Pendidikan Teknologi dan Kejuruan*, vOl. 22, No. 1, pp. 12–23, Jan. 2025, DOI: <https://doi.org/10.23887/jptkundiksha.v22i1.87455>.
- [5] N. Ghea Salsabila, M. Sodik Imanudin, and L. Prima, “*Spatial Modeling of Flood-Risk Areas in Palembang City, South Sumatera*,” *Journal of Wetlands Environment Management (JWEM)*, Vol. 12, No. 1, pp. 31–43, 2024, DOI: <https://dx.doi.org/10.20527/ijwem.v12i1.19953>.
- [6] J. Jumadi *et al.*, “*Utilizing Open Access Spatial Data for Flood Risk Mapping: A Case Study in the Upper Solo Watershed*,” *Geoplanning*, Vol. 11, No. 2, pp. 189–204, 2024, DOI: 10.14710/geoplanning.11.2.189-204.
- [7] M. R. P. Putra, Muhirin, Kusri, R. Ashari, and A. W. Z. Imam, “*Flood Prediction using Machine Learning Model Integrated with Geographical Information System*,” *Khazanah Informatika : Jurnal Ilmu Komputer dan Informatika*, Vol. 10, No. 2, pp. 121–126, Mar. 2025, DOI: 10.23917/khif.v10i2.3723.
- [8] S. E. Purwati and Y. Pristyanto, “*Model Random Forest and Support Vector Machine for Flood Classification in Indonesia*,” *Sinkron : jurnal dan penelitian teknik informatika*, Vol. 8, No. 4, pp. 2261–2268, Oct. 2024, DOI: 10.33395/sinkron.v8i4.13973.
- [9] A. D. Hariyanto, A. Yudono, and A. D. Wicaksono, “*Comparison of Land Cover Change Prediction Models: A Case Study in Kedungkandang District, Malang City*,” *Geoplanning*, Vol. 11, No. 1, pp. 85–98, 2024, DOI: 10.14710/geoplanning.11.1.85-98.
- [10] H. A. Katili, Syartinilia, F. Irmansyah, and Widiatmaka, “*Land use Change and Future Prediction in Banggai Islands Regency, Central Sulawesi, Indonesia*,” *Jurnal Pengelolaan Sumberdaya Alam dan Lingkungan (Journal of Natural Resources and Environmental Management)*, Vol. 15, No. 5, p. 804, 2025, DOI: 10.29244/jpsl.15.5.804.
- [11] K. Aditya, I. Ridwan, and Nurlina, “*Flood Risk Modelling based on Machine Learning using Google Earth Engine in Hulu Sungai Utara Regency*,” *Nature Environment and Pollution Technology*, Vol. 24, No. 4, Dec. 2025, DOI: 10.46488/NEPT.2025.v24i04.D1756.
- [12] C. A. Lizar, H. Satriawan, and C. Azizah, “*Analisis Wilayah Kerentanan Bencana Banjir Berbasis Sistem Informasi Geografis di Kota Lhokseumawe*,” *Teras Jurnal : Jurnal Teknik Sipil*, Vol. 14, No. 1, pp. 53–67, Mar. 2024, DOI: 10.29103/tj.v14i1.1004.
- [13] H. S. D. Kospa, H. Haidir, A. S. Natul, and S. A. Hamim, “*Pendampingan Penyusunan Peta Kerentanan berbasis WebGIS sebagai Upaya Peningkatan Mitigasi Bencana di Kawasan Pembangunan Pelabuhan Tanjung Carat, Banyuasin II, Sumatera Selatan*,” *I-Com: Indonesian Community Journal*, Vol. 5, No. 2, pp. 635–646, Jun. 2025, DOI: 10.70609/icom.v5i2.6738.
- [14] M. Rashid *et al.*, “*Integrated Data-Driven Multi-Criteria Analysis and Machine Learning Approaches for Assessment of Flood Susceptibility Mapping*,” *Water 2026*, Vol. 18, No. 7, Apr. 2026, DOI: 10.3390/w18070844.
- [15] L. S. Qamarani and M. Riassetiawan, “*Klasifikasi Level Banjir menggunakan Random Forest dan Support Vector Machine*,” *Indonesian Journal of Electronics and Instrumentation Systems (IJEIS)*, Vol. 14, No. 2, pp. 199–208, 2024, DOI: doi.org/10.22146/ijeis.97043.
- [16] V. T. Vu *et al.*, “*Predicting Land use Effects on Flood Susceptibility using Machine Learning and Remote Sensing in Coastal Vietnam*,” *Water Pract. Technol.*, Vol. 18, No. 6, pp. 1543–1555, Jun. 2023, DOI: <https://doi.org/10.2166/wpt.2023.088>.
- [17] R. F. Abuhanifah, F. Usman, and T. A. Rachmawati, “*Pemetaan Risiko Bencana Banjir menggunakan Geomorphic Flood Index di Kecamatan Trenggalek, Kabupaten Trenggalek*,” *Planning for Urban Region and Environment*, Vol. 12, No. 4, pp. 217–228, 2023.
- [18] A. Ferdiansyah *et al.*, “*Modified Geomorphic Flood Index (GFI) using Land use Parameter and Effective Rainfall Ratio at Cikapundung River*,” in *E3S Web of Conferences*, EDP Sciences, Apr. 2024. DOI: 10.1051/e3sconf/202451301003.
- [19] R. Rahmansyah and I. Meiditra, “*Network Security System Implementation using Intrusion Prevention System and HoneyPot Technology at the Regional Revenue Office (Bapenda) of*

- Padang City,” Internet of Things and Artificial Intelligence Journal*, Vol. 5, No. 3, pp. 797–817, Sep. 2025, DOI: 10.31763/iota.v5i3.1013.
- [20] A. M. Husein and M. Harahap, “Pendekatan Data Science untuk menemukan Churn Pelanggan pada Sector Perbankan dengan *Machine Learning*,” *Data Sciences Indonesia (DSI)*, Vol. 1, No. 1, pp. 8–13, Nov. 2021, DOI: 10.47709/dsi.v1i1.1169.