

Optimasi Hiperparameter Berbasis Particle Swarm Optimization pada Model Boosting untuk Klasifikasi Kondisi Wilayah Rawan Banjir di Jawa Barat

Hyperparameter Optimization of Boosting Models Using Particle Swarm Optimization for Flood-Prone Area Classification in West Java

¹Afan Ramadhan^{*}, ²Anggun Dewanti, ³Egy Destiar Firmandani, ⁴Atika Ratna Dewi

^{1,2,3,4}Program Studi Sains Data, Universitas Telkom Purwokerto, Indonesia

¹afanramadhan@student.telkomuniversity.ac.id, ²anggunndewi@student.telkomuniversity.ac.id, ³egydestf@student.telkomuniversity.ac.id, ⁴atikad@telkomuniversity.ac.id

Received:
18 July 2026

Revised:
20 August 2026

Accepted:
23 July 2026

Published:
10 Agustus 2026

ABSTRAK

Banjir merupakan bencana alam paling dominan di Indonesia yang menyebabkan kerugian jiwa dan ekonomi secara masif setiap tahunnya, sehingga dibutuhkan sistem klasifikasi kondisi wilayah yang akurat untuk mendukung peringatan dini. Penelitian ini mengintegrasikan data curah hujan harian dari 460 stasiun BMKG periode 2020 hingga 2025, rekaman kejadian banjir dari BNPB-DIBI, serta fitur geospasial turunan dari DEM GLO-30 dan citra SAR Sentinel-1 sebagai masukan model. Enam model klasifikasi dibangun dan dibandingkan secara sistematis, yaitu XGBoost, LightGBM, dan CatBoost sebagai baseline beserta ketiganya yang dioptimasi menggunakan Particle Swarm Optimization (PSO). Hasil penelitian menunjukkan bahwa CatBoost baseline tampil sebagai model terbaik sebelum optimasi, sementara PSO-LightGBM berhasil melampaui seluruh model dengan F1 Macro tertinggi sebesar 0,5433 dan Recall Macro sebesar 0,5350 setelah optimasi diterapkan. Optimasi PSO terbukti efektif meningkatkan performa LightGBM dan XGBoost, namun memberikan dampak negatif pada CatBoost yang konfigurasi dasarnya sudah mendekati optimal untuk dataset ini. Analisis SHAP mengonfirmasi bahwa Runoff Potential sebagai fitur rekayasa berbasis domain hidrologi menjadi penentu prediksi paling dominan, diikuti oleh fitur elevasi dan backscatter SAR yang membuktikan kontribusi signifikan integrasi data remote sensing terhadap kemampuan diskriminasi model.

Kata Kunci : klasifikasi wilayah banjir, ensemble boosting, Jawa Barat, particle swarm optimization, remote sensing.

ABSTRACT

Flooding is the most prevalent natural disaster in Indonesia, causing substantial loss of life and significant economic damage each year. Therefore, an accurate regional flood condition classification system is essential to support early warning efforts. This study integrates daily rainfall data collected from 460 meteorological stations operated by the Meteorology, Climatology, and Geophysics Agency between 2020 and 2025, flood event records obtained from the National Disaster Management Agency, and geospatial features derived from the GLO-30 Digital Elevation Model (DEM) and Sentinel-1 Synthetic Aperture Radar (SAR) imagery as model inputs. Six classification models were systematically developed and evaluated, including baseline XGBoost, LightGBM, and CatBoost models, along with their respective Particle Swarm Optimization (PSO)-optimized variants. The results indicate that the baseline CatBoost model achieved the best performance prior to optimization, whereas PSO-LightGBM outperformed all competing models after optimization, attaining the highest Macro F1-score of 0.5433 and Macro Recall of 0.5350. PSO optimization proved effective in improving the performance of LightGBM and XGBoost but negatively affected CatBoost, whose default configuration was already close to optimal for the dataset used in this study. Furthermore, SHAP analysis confirmed that Runoff Potential, a hydrology domain-informed engineered feature, was the most influential predictor, followed by elevation and SAR backscatter features, highlighting the significant contribution of remote sensing data integration to the model's discriminative capability.

Keywords : *flood area classification, ensemble boosting, West Java, particle swarm optimization, remote sensing.*

PENDAHULUAN

Banjir merupakan bencana alam yang paling sering terjadi dan menimbulkan dampak paling luas di Indonesia (Kurniadi et al., 2024). Badan Nasional Penanggulangan Bencana (BNPB) mencatat bahwa dalam dua dekade terakhir (2005–2024), banjir menjadi jenis bencana paling dominan di Indonesia dengan sekitar 16.359 kejadian tercatat yang mengakibatkan 4.316 korban jiwa, 923 orang hilang, 185.827 orang luka-luka, serta lebih dari 48 juta jiwa terdampak. Indonesia juga menempati posisi keempat secara global dalam hal jumlah penduduk yang terpapar risiko banjir tinggi dengan sekitar 75,7 juta jiwa atau 27% dari total populasi berada dalam kategori berisiko tinggi (Nikhil et al., 2025). Provinsi Jawa Barat tercatat sebagai salah satu wilayah dengan frekuensi kejadian banjir tertinggi di Indonesia yang dipicu oleh curah hujan tinggi berkisar 2.000–3.000 mm per tahun, degradasi hutan, alih fungsi lahan, serta kepadatan penduduk yang tinggi (Rahayu et al., 2025). Kondisi ini diperparah oleh perubahan iklim yang secara konsisten meningkatkan intensitas dan frekuensi kejadian hidrometeorologi ekstrem, termasuk banjir bandang yang memiliki daya rusak jauh lebih besar dibandingkan banjir biasa (Priyambodoho et al., 2022). Besarnya skala kerugian akibat banjir, yang mencakup korban jiwa, kerusakan infrastruktur, serta gangguan terhadap pertumbuhan ekonomi, menempatkan penanggulangan banjir sebagai prioritas utama dalam manajemen risiko bencana di Indonesia (BNPB, 2024).


Upaya meminimalkan dampak banjir secara signifikan bergantung pada ketersediaan sistem deteksi dini yang akurat dan tepat waktu. Penelitian menunjukkan bahwa sistem peringatan dini banjir yang efektif mampu menekan angka kematian akibat banjir hingga 43% dan mengurangi kerugian ekonomi sebesar 35–50% (Nearing et al., 2024). Namun demikian, pendekatan konvensional dalam pemantauan dan prediksi banjir menghadapi berbagai keterbatasan. Sistem pemantauan hidrologi berbasis stasiun pengukur debit dan curah hujan *in-situ* membutuhkan jaringan infrastruktur yang padat, biaya operasional dan pemeliharaan yang besar, serta cakupan wilayah yang terbatas terutama di daerah terpencil (Tian et al., 2019). Model hidrologi fisik berbasis mekanisme (*physically-based hydrological model*) yang selama ini banyak digunakan juga memerlukan data masukan yang sangat rinci, kalibrasi intensif per sub-DAS, dan keahlian teknis tinggi sehingga implementasinya sulit dilakukan secara luas di negara berkembang (Painter et al., 2025). Keterbatasan cakupan jaringan pemantauan dan kompleksitas metode ini mengakibatkan kapasitas prediksi banjir di banyak wilayah rawan, termasuk Jawa Barat menjadi kurang memadai untuk mendukung respons darurat yang tepat waktu.

Perkembangan *machine learning* (ML) telah membuka peluang dalam prediksi dan pemetaan kerentanan banjir yang lebih efisien dan skalabel. Integrasi data *remote sensing*, seperti data elevasi *Digital Elevation Model* (DEM) resolusi tinggi dan citra *Synthetic Aperture Radar* (SAR) dari satelit Sentinel-1 dengan algoritma ML terbukti mampu menghasilkan model prediksi banjir yang komprehensif tanpa bergantung sepenuhnya pada jaringan stasiun pengukur (Siddiqui et al., 2025; Saha et al., 2024). Di antara berbagai pendekatan ML, algoritma ensemble berbasis gradient boosting, khususnya *eXtreme Gradient Boosting* (XGBoost), *Light Gradient Boosting Machine* (LightGBM), dan *Categorical Boosting* (CatBoost) telah menunjukkan keunggulan dalam tugas klasifikasi dan prediksi banjir berkat kemampuannya menangani data tidak seimbang, fitur nonlinier, serta efisiensi komputasi yang tinggi (Elkhrachy et al., 2022; Szczepanek, 2022; Aydin & Iban, 2023). Studi terdahulu secara konsisten melaporkan performa tinggi ketiga model ini dalam berbagai konteks prediksi banjir, dengan nilai *Area Under the Curve* (AUC) yang umumnya melampaui 0,90 (Zhang et al., 2025). Meskipun demikian, sebagian besar penelitian yang ada menggunakan konfigurasi *hyperparameter default* atau metode pencarian kisi (grid search) yang memiliki keterbatasan dalam menjelajahi ruang pencarian hiperparameter berdimensi tinggi secara optimal, serta tidak menyertakan analisis komparasi yang sistematis antarmodel untuk menentukan model terbaik pada konteks wilayah studi yang spesifik (Abdel-Fattah et al., 2023; Kurugama et al., 2024).

Penelitian ini mengusulkan kerangka klasifikasi kondisi wilayah terhadap potensi banjir, banjir bandang, dan normal di Provinsi Jawa Barat dengan membandingkan enam konfigurasi model secara sistematis. Model yang digunakan terdiri dari tiga algoritma *ensemble boosting* yaitu XGBoost, LightGBM, dan CatBoost, beserta variannya yang dioptimasi menggunakan algoritma *Particle Swarm Optimization* (PSO). PSO dipilih karena kemampuannya menjelajahi ruang hiperparameter berdimensi tinggi secara efisien dibandingkan metode pencarian konvensional seperti grid search (Xu et al., 2024; Saleh et al., 2024). Dataset yang digunakan mencakup data curah hujan harian dari 460 stasiun di Jawa Barat periode 2020–2025, data kejadian banjir dari BNPB-DIBI, serta fitur geospasial turunan dari DEM GLO-30 dan citra SAR Sentinel-1. Penelitian ini bertujuan untuk membangun model klasifikasi kondisi banjir yang mengintegrasikan data hidrometeorologi dan *remote sensing*, serta menentukan pendekatan pemodelan terbaik untuk mendukung sistem peringatan dini banjir di Provinsi Jawa Barat.

METODE

Penelitian ini menggunakan alur kerja yang terstruktur dalam empat tahap utama sebagaimana diilustrasikan pada Gambar 1. Tahap pertama adalah akuisisi data dari dua sumber utama, yaitu data hidrometeorologi berupa curah hujan harian dari 460 stasiun BMKG di Provinsi Jawa Barat periode 2020–2025 beserta rekaman 4.231 kejadian banjir dari BNPB-DIBI, serta data geospasial berupa *Digital Elevation Model* (DEM) GLO-30 dan citra *Synthetic Aperture Radar* (SAR) polarisasi VH dan VV dari satelit Sentinel-1. Dari DEM GLO-30 diturunkan fitur topografi meliputi kemiringan lereng (*slope*), *Topographic Wetness Index* (TWI), dan kerapatan drainase, sementara dari citra SAR diekstraksi nilai backscatter yang sensitif terhadap keberadaan genangan air.



Gambar 1. Diagram Alir Penelitian

Tahap prapemrosesan dilakukan secara berbeda untuk setiap sumber data. Data stasiun cuaca melalui pembersihan data dan koreksi nilai tidak valid, sedangkan data citra SAR diproses melalui pemilihan orbit, kalibrasi radiometrik, dan pembersihan speckle noise. Setelah penggabungan data, dilakukan penyingkiran pencilaan menggunakan metode *Winsorization*, imputasi nilai yang hilang menggunakan *Iterative Imputer* berbasis XGBRegressor, dan penskalaan fitur dengan RobustScaler. Mengingat adanya ketidakseimbangan kelas yang signifikan antara kelas Normal, Banjir, dan Banjir Bandang diterapkan strategi pembobotan sampel berbasis *smoothed inverse frequency* untuk memberikan bobot pelatihan yang proporsional. Dataset kemudian dibagi dengan rasio 70:30 menggunakan *stratified split* untuk menjamin keterwakilan distribusi kelas pada kedua partisi.

Tahap pemodelan dilakukan dalam dua skenario yang dibandingkan secara sistematis. Skenario pertama adalah pemodelan baseline menggunakan konfigurasi hiperparameter default untuk ketiga algoritma *ensemble boosting* yaitu XGBoost, LightGBM, dan CatBoost. Skenario kedua adalah pemodelan dengan optimasi *hyperparameter* menggunakan *Particle Swarm Optimization* (PSO) yang diterapkan secara independen pada masing-masing model, menghasilkan varian PSO-XGBoost, PSO-LightGBM, dan PSO-CatBoost. PSO dipilih karena kemampuannya menjelajahi ruang hiperparameter berdimensi tinggi secara efisien dibandingkan metode konvensional seperti grid search. Pada setiap skenario, ketiga model dilatih menggunakan data latih yang sama sehingga perbandingan antarmodel berlangsung dalam kondisi yang setara dan adil.

Tahap akhir adalah interpretasi hasil yang mencakup dua komponen analisis. Pertama, dilakukan analisis komparasi performa keenam model menggunakan lima metrik evaluasi yaitu *Accuracy*, *Precision Macro*, *Recall Macro*, *F1-Score Macro*, dan ROC-AUC dengan pendekatan *One-vs-Rest* (OvR). Kedua, model terbaik diinterpretasikan secara kuantitatif menggunakan analisis *SHapley Additive exPlanations* (SHAP) untuk mengidentifikasi fitur yang paling berpengaruh terhadap keputusan klasifikasi pada setiap kelas.

A. Dataset

Fitur masukan yang digunakan dalam penelitian ini dikelompokkan menjadi tiga kategori utama. Kelompok *pertama* adalah fitur hidrometeorologi yang bersumber dari jaringan stasiun BMKG meliputi

curah hujan harian dan *Antecedent Precipitation Index* (API). Kelompok kedua adalah fitur topografi dan SAR yang diturunkan dari DEM GLO-30 dan citra Sentinel-1. Kelompok ketiga adalah fitur rekayasa (*engineered features*) yang dibentuk dari kombinasi fitur dasar berbasis pengetahuan domain hidrologi yaitu *Water Accumulation Index*, *Runoff Potential*, dan *SAR Polarization Difference*. Keseluruhan fitur yang digunakan beserta sumber dan keterangannya dirangkum pada Tabel 1.

Tabel 1. Fitur Dataset

Kelompok Fitur	Nama Fitur	Sumber Data
Hidrometeorologi	Curah hujan harian (<i>rainfall_mm</i>)	Stasiun BMKG
Hidrometeorologi	Indeks Presipitasi Anteseden (<i>API</i>)	Stasiun BMKG
Topografi	Kemiringan Lereng (<i>slope</i>)	DEM GLO-30
Topografi	<i>Topographic Wetness Index</i> (TWI)	DEM GLO-30
Topografi	Kerapatan Drainase	DEM GLO-30
SAR	<i>Backscatter</i> VH (<i>SAR_VH</i>)	Sentinel-1
SAR	<i>Backscatter</i> VV (<i>SAR_VV</i>)	Sentinel-1
Rekayasa Fitur	<i>Water Accumulation Index</i>	Turunan
Rekayasa Fitur	<i>Runoff Potential</i>	Turunan
Rekayasa Fitur	<i>SAR Polarization Difference</i>	Turunan

B. XGBoost

XGBoost adalah algoritma ensemble berbasis pohon keputusan yang membangun model secara bertahap dengan meminimalkan fungsi objektif yang menggabungkan *loss function* dan regularisasi pada setiap iterasi. Algoritma ini dirancang untuk memanfaatkan komputasi paralel sehingga proses pelatihan dapat berlangsung secara efisien. Keunggulan XGBoost juga terletak pada mekanisme regularisasi L1 dan L2 yang secara eksplisit membatasi kompleksitas model sehingga risiko *overfitting* dapat ditekan secara sistematis (Elghouat et al., 2024; Szczepanek, 2022). Fungsi objektif yang diminimalkan pada setiap iterasi ke- t diformulasikan sebagai:

$$\mathcal{L}^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)}) + f_t(x_i) + \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (1)$$

Dimana:

- l : *loss function*
- f_t : pohon ke- t
- T : jumlah daun
- γ dan λ : parameter regularisasi

Pendekatan optimasi bertahap ini memungkinkan XGBoost menghasilkan prediksi yang akurat bahkan pada dataset dengan distribusi kelas yang tidak seimbang (Zhang et al., 2025).

C. LightGBM

LightGBM merupakan varian *gradient boosting* yang dirancang untuk efisiensi komputasi tinggi pada data berdimensi besar melalui dua teknik utama yaitu *Gradient-based One-Side Sampling* (GOSS) dan *Exclusive Feature Bundling* (EFB). GOSS bekerja dengan mempertahankan seluruh sampel yang memiliki gradien besar sekaligus mengambil sebagian kecil sampel bergradien kecil secara acak sehingga distribusi informasi pelatihan tetap terjaga tanpa harus memproses keseluruhan data pada setiap iterasi (Wang et al., 2024). Sementara itu, EFB menggabungkan fitur-fitur yang bersifat saling eksklusif menjadi satu bundel tunggal sehingga dimensi ruang fitur yang harus diproses berkurang secara signifikan (Saputra et al., 2026). Fungsi *gain* pemisahan pada LightGBM diformulasikan sebagai:

$$\text{Gain} = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (2)$$

Dimana:

- G_L, G_R : jumlah *gradient* di cabang kiri dan kanan
- H_L, H_R : jumlah *Hessian* di cabang kiri dan kanan
- λ : parameter regularisasi L2
- γ : ambang batas minimum *gain*

Kombinasi GOSS dan EFB menjadikan LightGBM secara konsisten lebih cepat dibandingkan XGBoost pada dataset berukuran besar tanpa penurunan akurasi yang signifikan sehingga algoritma ini sesuai untuk skenario klasifikasi dengan volume data tinggi (Saha et al., 2024; Szczepanek, 2022).

D. CatBoost

CatBoost adalah algoritma *gradient boosting* yang dikembangkan khusus untuk menangani fitur kategorikal secara langsung tanpa memerlukan proses *encoding* manual sebagaimana umumnya dibutuhkan oleh algoritma *boosting* lainnya. Algoritma ini menggunakan teknik *Ordered Target Statistics* yang mengonversi fitur kategorikal menjadi nilai numerik berdasarkan statistik target dengan mempertimbangkan urutan data pelatihan sehingga kebocoran informasi target atau *target leakage* dapat dicegah secara efektif selama proses pelatihan berlangsung (Abedi et al., 2022; Costache et al., 2025). Estimasi nilai target untuk kategori k pada CatBoost dihitung menggunakan:

$$\hat{x}_i^j = \frac{\sum_{p=1}^{i-1} \mathbf{1}[x_p^j = x_i^j] \cdot y_{\sigma_p} + a \cdot P}{\sum_{p=1}^{i-1} \mathbf{1}[x_p^j = x_i^j] + a} \quad (3)$$

Dimana:

- σ : permutasi acak dari data latih
- y_{σ_p} : nilai label target pada observasi ke- p
- P : nilai prior global dari variabel target
-
- a : *smoothing parameter* yang mengontrol keseimbangan antara informasi lokal dan prior global

Mekanisme ini menjadikan CatBoost unggul dalam menangani heterogenitas fitur pada dataset yang mengandung campuran fitur numerik dan kategorikal sekaligus menghasilkan estimasi yang lebih stabil dibandingkan metode *encoding* konvensional (Saber et al., 2022; Elkhachy et al., 2022).

D. Particle Swarm Optimization

Particle Swarm Optimization (PSO) merupakan algoritma optimasi metaheuristik yang terinspirasi dari perilaku sosial kawanan burung dalam mencari sumber makanan. Setiap solusi kandidat direpresentasikan sebagai partikel yang bergerak dalam ruang pencarian dengan posisi diperbarui berdasarkan pengalaman terbaik partikel itu sendiri (*personal best*) dan pengalaman terbaik seluruh kawanan (*global best*). Kemampuan penjelajahan yang adaptif ini menjadikan PSO lebih efisien dalam menemukan konfigurasi *hyperparameter* optimal dibandingkan *grid search* (Xu et al., 2024; Saleh et al., 2024).

$$v_i(t+1) = w \cdot v_i(t) + c1 \cdot r1 \cdot (pbest_i - x_i(t)) + c2 \cdot r2 \cdot (gbest - x_i(t)) \quad (4)$$


$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (5)$$

Dimana:

- v_i : kecepatan partikel ke- i
- x_i : posisi partikel ke- i
- w : bobot inersia
- $c1$ dan $c2$: koefisien akselerasi kognitif dan sosial
- $r1$ dan $r2$: bilangan acak dalam rentang 0 sampai 1
- $pbest_i$: posisi terbaik partikel ke- i
- $gbest$: posisi terbaik seluruh partikel


Pada penelitian ini, PSO diterapkan untuk mengoptimasi jumlah estimator, kedalaman pohon, dan learning rate dengan fungsi kebugaran berupa 1 dikurangi F1 Macro pada data uji. Konfigurasi $w = 0,729$ serta $c1 = c2 = 1,494$ dipilih untuk menjaga keseimbangan antara eksplorasi global dan eksploitasi lokal selama pencarian. Proses ini diulang hingga iterasi maksimum tercapai sehingga diperoleh kombinasi *hyperparameter* optimal tanpa penjelajahan menyeluruh seperti pada *grid search* (Xu et al., 2024).

HASIL DAN PEMBAHASAN



Gambar 2. Sebaran stasiun cuaca berdasarkan elevasi

Dataset yang digunakan dalam penelitian ini bersumber dari jaringan 460 stasiun pengukur curah hujan BMKG yang tersebar di seluruh Provinsi Jawa Barat dengan variasi elevasi yang mencakup dataran rendah hingga kawasan pegunungan sebagaimana ditunjukkan pada Gambar 2. Sebaran spasial stasiun yang merata di berbagai zona topografi menjamin keterwakilan kondisi hidrometeorologi yang beragam sebagai masukan model. Setelah penggabungan dengan data kejadian banjir dan fitur geospasial. Kelas Normal mendominasi dengan 3.578 sampel, diikuti kelas Banjir sebanyak 2.171 sampel, sementara kelas Banjir Bandang hanya berjumlah 208 sampel sebagaimana ditunjukkan pada Gambar 3. Rasio ketidakseimbangan antara kelas mayoritas dan minoritas mencapai lebih dari 17 berbanding 1, kondisi ini secara langsung memengaruhi kemampuan model dalam mengenali kejadian Banjir Bandang yang justru paling kritis secara kebencanaan.



Gambar 3. Distribusi kelas target

Oleh karena itu, penerapan strategi pembobotan sampel berbasis *smoothed inverse frequency* pada tahap prapemrosesan menjadi keputusan yang tepat untuk mencegah bias prediksi model secara sistematis ke arah kelas mayoritas.

Sebelum proses pemodelan dilakukan, hiperparameter PSO dikonfigurasi sebagaimana dirangkum pada Tabel 2. Nilai bobot inersia $w = 0,729$ serta koefisien akselerasi kognitif dan sosial masing-masing $c_1 = c_2 = 1,494$ mengacu pada konfigurasi standar yang umum digunakan dalam literatur PSO karena kombinasi tersebut mampu menjaga keseimbangan antara eksplorasi global pada tahap awal iterasi, ketika partikel masih menyebar luas di ruang pencarian dan eksploitasi lokal pada tahap akhir serta ketika partikel mulai memusat menuju kandidat solusi terbaik. Ukuran populasi sebanyak 15 partikel dan batas iterasi maksimum sebanyak 10 siklus dipilih untuk menjaga efisiensi komputasi. Fungsi *fitness* yang diminimalkan adalah $1 - F1$ Macro pada data uji. Dengan demikian, PSO mengarahkan pencarian hiperparameter untuk meningkatkan kinerja klasifikasi pada seluruh kelas, termasuk kelas minoritas seperti Banjir Bandang tanpa bergantung pada akurasi keseluruhan yang cenderung bias terhadap kelas mayoritas.

Tabel 2. Konfigurasi parameter PSO

Parameter	Nilai	Keterangan
Jumlah Partikel	15	Ukuran populasi pencarian
Iterasi Maksimum	10	Batas siklus optimasi
Bobot Inersia (w)	0,729	Pengontrol momentum kecepatan partikel
Koefisien Kognitif (c_1)	1,494	Tarikan partikel ke posisi terbaik individu
Koefisien Sosial (c_2)	1,494	Tarikan partikel ke posisi terbaik global
Batas Estimator	50 - 300	Rentang jumlah pohon yang dieksplorasi
Batas Kedalaman	3 - 10	Rentang kedalaman pohon yang dieksplorasi
Batas <i>Learning Rate</i>	0,01-0,30	Rentang <i>learning rate</i> yang dieksplorasi
<i>Fitness Function</i>	$1 - F1$ Score	Metrik diminimalkan PSO


Hasil evaluasi keenam model disajikan pada Tabel 3. Di antara model *baseline*, CatBoost tampil sebagai yang terbaik dengan *F1 Macro* 0,5324 dan *ROC-AUC* 0,7823, mengungguli LightGBM dan XGBoost yang masing-masing mencatatkan *F1 Macro* 0,5038 dan 0,4993. Keunggulan CatBoost pada tahap *baseline* ini sejalan dengan kemampuan bawaannya dalam menangani heterogenitas fitur melalui

mekanisme *Ordered Target Statistics* yang mereduksi *target leakage* selama pelatihan. Setelah optimasi PSO diterapkan, PSO-LightGBM berhasil tampil sebagai model terbaik secara keseluruhan dengan *F1 Macro* tertinggi sebesar 0,5433 dan *Recall Macro* terbaik sebesar 0,5350, melampaui seluruh model termasuk CatBoost *baseline* yang sebelumnya dominan. Peningkatan ini menunjukkan bahwa LightGBM memiliki sensitivitas tinggi terhadap konfigurasi hiperparameter sehingga sangat diuntungkan oleh eksplorasi PSO yang mampu menjangkau kombinasi optimal yang tidak ditemukan oleh konfigurasi *default*. Sebaliknya, PSO-CatBoost justru mengalami penurunan *F1 Macro* dari 0,5324 menjadi 0,5227, mengindikasikan bahwa algoritma CatBoost yang sudah adaptif secara bawaan memiliki sensitivitas tertentu terhadap perubahan hiperparameter pada ruang pencarian yang telah ditetapkan, sehingga konfigurasi *default*-nya sudah mendekati optimal untuk karakteristik dataset ini.

Tabel 3. Pebandingan Metrik Evaluasi Model


Model	Accuracy	Precision	Recall	F1	ROC-AUC
XGBoost	0,7254	0,5316	0,4977	0,4993	0,7677
LightGBM	0,7321	0,5191	0,5032	0,5038	0,7718
CatBoost	0,7478	0,5868	0,5248	0,5324	0,7823
XGBoost + PSO	0,7427	0,5528	0,5275	0,5332	0,7723
LightGBM + PSO	0,7472	0,5682	0,5350	0,5433	0,7706
CatBoost + PSO	0,7349	0,6290	0,5119	0,5227	0,7753

Untuk memahami pola kesalahan prediksi dengan lebih baik, *confusion matrix* dari CatBoost *baseline* sebagai model terbaik sebelum optimasi dan PSO-LightGBM sebagai model terbaik setelah optimasi dibandingkan secara langsung pada Gambar 4. CatBoost *baseline* berhasil mengklasifikasikan 887 sampel Normal dan 446 sampel Banjir dengan benar, namun hanya mampu mengidentifikasi 4 dari 62 sampel Banjir Bandang secara tepat. PSO-LightGBM menunjukkan perbaikan nyata pada kelas Banjir Bandang dengan 6 prediksi benar, disertai peningkatan pada kelas Banjir menjadi 448 prediksi benar. Pola kesalahan yang paling dominan pada keduanya adalah salah klasifikasi antara kelas Banjir dan Normal, yang secara hidrologi dapat dipahami karena batas antara kondisi curah hujan tinggi tanpa banjir dan kondisi banjir seringkali dipengaruhi oleh faktor lokal seperti kapasitas tampung saluran dan kondisi tanah yang tidak sepenuhnya tertangkap oleh fitur agregat berskala kilometer. Tantangan pada kelas Banjir Bandang yang sangat minoritas ini relevan dengan temuan ketidakseimbangan kelas pada Gambar 3 dan mengonfirmasi bahwa peningkatan representasi data Banjir Bandang melalui teknik augmentasi atau pengumpulan data tambahan berpotensi menjadi arah pengembangan penelitian selanjutnya yang paling berdampak.



Gambar 4. Confusion matrix CatBoost *baseline* dan PSO-LightGBM

Confusion matrix pada Gambar 4 menunjukkan bahwa kesalahan klasifikasi kedua model terutama terjadi antara kelas Normal dan Banjir. CatBoost *baseline* salah mengklasifikasikan 183 sampel Normal sebagai Banjir dan 200 sampel Banjir sebagai Normal, sedangkan PSO LightGBM menghasilkan masing masing 162 dan 193 kesalahan pada kedua kelas tersebut. Pada kelas Banjir Bandang, PSO LightGBM meningkatkan prediksi yang benar dari 4 menjadi 6 sampel dibandingkan CatBoost *baseline*, meskipun sebagian besar sampel kelas tersebut masih diklasifikasikan sebagai Normal. Pola ini menunjukkan bahwa optimasi memberikan perbaikan terbatas pada kemampuan model dalam membedakan kelas Banjir Bandang, sementara ambiguitas antara kondisi Normal dan Banjir masih menjadi sumber kesalahan utama dalam prediksi.



Gambar 5. SHAP *feature importance*

Interpretabilitas PSO-LightGBM sebagai model terbaik dianalisis lebih lanjut menggunakan metode SHAP dengan hasil yang ditampilkan pada Gambar 5. Runoff Potential muncul sebagai fitur paling dominan dengan nilai rata-rata SHAP absolut sebesar 0,237, jauh melampaui fitur peringkat kedua yaitu *DEM_mean_5km* sebesar 0,174 dan fitur peringkat ketiga yaitu *SAR_VV_3km* sebesar 0,150. Dominasi ini secara ilmiah relevan karena *Runoff Potential* merupakan *feature engineering* yang merepresentasikan kombinasi antara akumulasi curah hujan anteseden dan kapasitas limpasan permukaan berdasarkan kemiringan lereng sehingga menjadi alasan yang kuat terhadap potensi pembentukan aliran permukaan yang memicu banjir. Posisi kedua fitur geospasial tersebut turut mengonfirmasi bahwa integrasi data elevasi dan citra SAR memberikan kontribusi prediktif yang substansial dan tidak dapat digantikan sepenuhnya oleh data curah hujan.

Fitur topografi lain seperti *slope_mean_5km* dengan nilai SHAP 0,131 serta *Topographic Wetness Index* pada berbagai skala spasial juga secara konsisten menempati posisi 20 fitur teratas, menunjukkan bahwa karakteristik medan menjadi faktor penentu yang menjelaskan mengapa wilayah dengan curah hujan serupa dapat menghasilkan respons banjir yang berbeda. Selain itu, fitur hidrometeorologi berbasis waktu yaitu *rainfall_lag_1* dengan nilai SHAP 0,120 dan *Antecedent Precipitation Index* sebesar 0,119 turut menempati posisi yang signifikan, mengindikasikan bahwa kondisi curah hujan hari sebelumnya dan akumulasi anteseden memberikan konteks temporal yang relevan dan tidak tertangkap apabila model hanya mengandalkan data curah hujan harian sesaat. Susunan peringkat fitur ini secara keseluruhan menegaskan bahwa interaksi antara faktor hidrologi, topografi, dan temporal menjadi kunci utama dalam menentukan keputusan klasifikasi model.

KESIMPULAN

Penelitian ini menunjukkan bahwa integrasi data hidrometeorologi, fitur topografi, dan *remote sensing* mampu membentuk pendekatan *machine learning* untuk mengklasifikasikan kondisi wilayah berdasarkan potensi banjir di Jawa Barat. Perbandingan *baseline* model dan model dengan optimisasi *hyperparameter* menunjukkan bahwa efektivitas optimasi bergantung pada karakteristik masing masing algoritma sehingga tidak semua model memperoleh peningkatan performa setelah optimasi. Temuan tersebut menegaskan bahwa pemilihan model perlu mempertimbangkan karakteristik data, tujuan klasifikasi, serta kemampuan model dalam menangani perbedaan distribusi antarkelas.

Secara keseluruhan, kombinasi *boosting model*, *Particle Swarm Optimization*, dan *SHAP analysis* menghasilkan kerangka pemodelan yang tidak hanya berorientasi pada performa klasifikasi, tetapi juga memungkinkan interpretasi terhadap faktor yang memengaruhi keputusan model. Penggunaan *F1 Macro* dan *Recall Macro* memberikan penilaian yang lebih representatif terhadap performa pada seluruh kelas, sementara hasil *SHAP analysis* menunjukkan bahwa fitur berbasis proses hidrologi dan karakteristik geospasial memiliki peran penting dalam klasifikasi. Dengan demikian, penelitian ini memperlihatkan bahwa integrasi data hidrometeorologi dan geospasial dengan pendekatan *machine learning* dapat menjadi pendekatan yang relevan untuk menggambarkan kondisi wilayah terkait potensi banjir secara lebih menyeluruh.

Penelitian selanjutnya disarankan untuk memperluas representasi data kelas Banjir Bandang melalui pengumpulan data lapangan tambahan atau teknik augmentasi data guna mengatasi ketidakseimbangan kelas yang menjadi tantangan utama dalam penelitian ini. Selain itu, eksplorasi metode optimasi

metaheuristik lainnya seperti *Grey Wolf Optimizer* dapat dilakukan untuk membandingkan efektivitasnya terhadap PSO dalam konteks tuning hiperparameter model *boosting*. Pengembangan model ke arah prediksi berbasis spasial yang mempertimbangkan batas daerah aliran sungai dan dinamika aliran antarkawasan juga perlu dipertimbangkan untuk meningkatkan akurasi prediksi secara hidrologi.

DAFTAR PUSTAKA

- Abdel-Fattah, M., Saber, M., Kantoush, S. A., Khalil, M. F., Sumi, T., & Sefelnasr, A. M. (2023). Enhancing flood risk assessment through integration of ensemble learning approaches and physical-based hydrological modeling. *Geomatics, Natural Hazards and Risk*, 14(1), 2203798. <https://doi.org/10.1080/19475705.2023.2203798>
- Abedi, M., Mohammadzadeh, O., Mehrabani, G. V., Norouzi, H., Ahmadi, A., & Malekian, R. (2022). Flash-flood susceptibility mapping based on XGBoost, random forest and boosted regression trees. *Geocarto International*, 37(19), 5479–5496. <https://doi.org/10.1080/10106049.2021.1920636>
- Aydin, H. E., & Iban, M. C. (2023). Predicting and analyzing flood susceptibility using boosting-based ensemble machine learning algorithms with SHapley additive explanations. *Natural Hazards*, 116(3), 2957–2991. <https://doi.org/10.1007/s11069-022-05793-y>
- Badan Nasional Penanggulangan Bencana. (2024). *Banjir awal tahun 2024: Resiliensi Indonesia*. <https://bnpb.go.id>
- Costache, R., et al. (2025). Flood susceptibility assessment using multi-tier feature selection and ensemble boosting machine learning models. *Water*, 17(14), 2041. <https://doi.org/10.3390/w17142041>
- Elghouat, A., et al. (2024). Integrated approaches for flash flood susceptibility mapping: Spatial modeling and comparative analysis of statistical and machine learning models. *Journal of Water and Climate Change*, 15(8), 3624–3646. <https://doi.org/10.2166/wcc.2024.726>
- Kurniadi, A., et al. (2024). Future projections of extreme rainfall events in Indonesia. *International Journal of Climatology*, 44(4), 1502–1519. <https://doi.org/10.1002/joc.8321>
- Kurugama, A., et al. (2024). A comparative spatial analysis of flood susceptibility mapping using boosting machine learning algorithms in Rathnapura, Sri Lanka. *Journal of Flood Risk Management*, 17(2), e12980. <https://doi.org/10.1111/jfr3.12980>
- Nearing, G. S., Cohen, D., Dube, V., Gauch, M., Gilon, O., Harrigan, S., Hassidim, A., Klotz, D., Kratzert, F., Metzger, A., Nevo, S., Pappenberger, F., Prudhomme, C., Shalev, G., Shenzen, S., Tekalign, T. Y., Weitzner, D., & Matias, Y. (2024). Global prediction of extreme floods in ungauged watersheds. *Nature*, 627, 559–563. <https://doi.org/10.1038/s41586-024-07145-1>
- Nikhil, Y., et al. (2025). Identifying dominant river contributions to urban flooding: A scenario-based study of Makassar City. *Frontiers in Built Environment*, 11. <https://doi.org/10.3389/fbuil.2025.1612416>
- Painter, C. C., et al. (2025). Designing effective flood early warning systems: A review of barriers, best practices, and key characteristics. *Journal of Flood Risk Management*. <https://doi.org/10.1111/jfr3.70145>
- Priyambodoho, D., et al. (2022). Effects of urban development on regional climate change and flood inundation in Jakarta, Indonesia. *Journal of Disaster Research*, 17(4), 516–525. <https://doi.org/10.20965/jdr.2022.p0516>
- Rahayu, R., et al. (2025). *The influence of flood disasters on economic growth and poverty in Indonesia* [Preprint]. ResearchGate. <https://www.researchgate.net/publication/388624476>
- Saber, M., Boulmaiz, T., Guermoui, M., Abdrabo, K. I., Kantoush, S. A., Sumi, T., Boutaghane, H., Nohara, D., & Mabrouk, E. (2022). Examining LightGBM and CatBoost models for Wadi flash flood susceptibility prediction. *Geocarto International*, 37(25), 7462–7487. <https://doi.org/10.1080/10106049.2021.1974959>
- Saha, S., et al. (2024). SAR-driven flood inventory and multi-factor ensemble susceptibility modelling using machine learning frameworks. *Geomatics, Natural Hazards and Risk*, 15(1), 2409202. <https://doi.org/10.1080/19475705.2024.2409202>
- Saleh, R. A., et al. (2024). A novel voting ensemble model empowered by metaheuristic feature selection for accurate flash flood susceptibility mapping. *Geomatics, Natural Hazards and Risk*, 15(1). <https://doi.org/10.1080/19475705.2024.2360000>
- Saputra, H., Dasanto, B. D., Tarigan, S. D., Santikayasa, I. P., & Darmawan, Y. (2026). *Daily rainfall observations from 460 stations and flood event records across West Java, Indonesia (2020–2025)* [Data set]. Mendeley Data. <https://doi.org/10.17632/d7j3s64vvr.3>
- Siddiqui, A. Q., et al. (2025). Flood susceptibility mapping using machine learning and geospatial-Sentinel-1 SAR integration for enhanced early warning systems. *Remote Sensing*, 17(20), 3471. <https://doi.org/10.3390/rs17203471>
- Szczepanek, R. (2022). Daily streamflow forecasting in mountainous catchment using XGBoost, LightGBM and CatBoost. *Hydrology*, 9(12), 226. <https://doi.org/10.3390/hydrology9120226>

- Tian, Y., et al. (2019). *Towards global remote discharge estimation: Using the few to estimate the many* [Preprint]. arXiv. <https://arxiv.org/abs/1901.00786>
- Wang, Y., et al. (2024). Advancing flood susceptibility modeling using stacking ensemble machine learning: A multi-model approach. *Journal of Geographical Sciences*, 34(8), 1513–1536. <https://doi.org/10.1007/s11442-024-2259-2>
- Xu, Y., et al. (2024). Research on a hybrid model for flood probability prediction based on time convolutional network and particle swarm optimization algorithm. *Scientific Reports*, 14, 29876. <https://doi.org/10.1038/s41598-024-80100-2>
- Zhang, Q., et al. (2025). Machine learning-based identification of key factors and spatial heterogeneity analysis of urban flooding. *Scientific Reports*, 15, 23681. <https://doi.org/10.1038/s41598-025-08162-4>