

# Klasifikasi Risiko Bencana di Indonesia Menggunakan SVM dan Random Forest

Erland Adhe Sharendra<sup>1</sup>, Tri Widodo<sup>2\*</sup>, Damayanti<sup>1</sup>, Okma Arnilia<sup>3</sup>

<sup>1</sup> Fakultas Teknik dan Ilmu Komputer, Sistem Informasi, Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia

<sup>2</sup> Fakultas Teknik dan Ilmu Komputer, Teknik Komputer, Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia

<sup>3</sup> Fakultas Ilmu Tarbiyah dan Keguruan, Informatika, Universitas Islam Negeri Siber Syekh Nurjati, Cirebon, Indonesia

Email: <sup>1</sup>erland\_adhe\_sharendra@teknokrat.ac.id, <sup>2\*</sup>tri\_widodo@teknokrat.ac.id, <sup>3</sup>damayanti@teknokrat.ac.id,

<sup>4</sup>okmaarnilia@uinss.ac.id

Email Penulis Korespondensi: tri\_widodo@teknokrat.ac.id

Submitted: 02/05/2026; Accepted: 02/06/2026; Published: 05/06/2026

**Abstrak**—Indonesia merupakan negara dengan tingkat kerawanan bencana yang tinggi, sehingga diperlukan metode yang efektif untuk mengklasifikasikan tingkat risiko bencana secara akurat. Penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja algoritma *Support Vector Machine* dan *Random Forest* dalam klasifikasi tingkat risiko bencana. Data yang digunakan berupa data kejadian bencana periode 2019–2024 yang mencakup jenis bencana, wilayah, jumlah korban, serta kepadatan penduduk. Tingkat risiko diklasifikasikan menjadi tiga kategori, yaitu rendah, sedang, dan tinggi, berdasarkan total dampak yang dihitung dari jumlah korban. Metode yang digunakan meliputi tahap preprocessing data, normalisasi, serta pembagian data latih dan data uji. Hasil penelitian menunjukkan bahwa kedua model memiliki kinerja yang tinggi, dengan *Random Forest* memperoleh akurasi sebesar 95,66% dan *Support Vector Machine* sebesar 95,28%, serta nilai ROC-AUC masing-masing sebesar 0,9823 dan 0,9769. *Random Forest* menunjukkan kinerja yang sedikit lebih baik dengan selisih akurasi sebesar 0,38% serta hasil prediksi yang lebih konsisten. Tingginya kinerja model menunjukkan bahwa model mampu mengenali pola utama pada data, meskipun hasil tersebut juga dipengaruhi oleh karakteristik data yang digunakan. Secara keseluruhan, *Random Forest* lebih sesuai digunakan dalam klasifikasi tingkat risiko bencana pada data dengan karakteristik kompleks.

**Kata Kunci:** Klasifikasi Bencana; Machine Learning; Random Forest; Risiko Bencana; Support Vector Machine

**Abstract**—Indonesia is a country with a high level of disaster vulnerability, requiring effective methods to accurately classify disaster risk levels. This study aims to analyze and compare the performance of Support Vector Machine (SVM) and *Random Forest* algorithms in disaster risk classification. The dataset used consists of disaster event data from 2019–2024, including disaster type, region, number of victims, and population density. Disaster risk levels were classified into three categories, namely low, medium, and high, based on the total impact calculated from the number of victims. The proposed method includes data preprocessing, normalization, and train-test data splitting. The results show that both models achieved high performance, where Random Forest obtained an accuracy of 95.66% and SVM achieved 95.28%, with ROC-AUC values of 0.9823 and 0.9769, respectively. Random Forest demonstrated slightly better performance with an accuracy difference of 0.38% and more consistent prediction results. The high performance indicates that the models were able to recognize the main patterns within the dataset, although the results were also influenced by the characteristics of the data used. Overall, Random Forest is more suitable for disaster risk classification on data with complex characteristics.

**Keywords:** Disaster Classification; Machine Learning; Random Forest; Disaster Risk; Support Vector Machine

## 1. PENDAHULUAN

Tingginya frekuensi kejadian bencana di Indonesia dipengaruhi oleh kondisi geografisnya yang berada pada pertemuan beberapa lempeng tektonik aktif serta termasuk dalam kawasan cincin api dunia [1]. Kondisi tersebut menyebabkan berbagai jenis bencana, seperti banjir, tanah longsor, dan gempa bumi, sering terjadi di berbagai wilayah dengan dampak yang cukup besar [2]. Dampak yang ditimbulkan tidak hanya terbatas pada kerugian material, tetapi juga meliputi korban jiwa, kerusakan infrastruktur, serta terganggunya aktivitas sosial dan ekonomi masyarakat dalam jangka pendek maupun jangka panjang [3], [4]. Selain itu, efek lanjutan seperti penurunan stabilitas ekonomi daerah dan kualitas hidup masyarakat juga sering terjadi, sehingga diperlukan upaya mitigasi yang lebih terarah dan berbasis analisis yang akurat [5].

Pengelompokan tingkat risiko bencana menjadi langkah penting dalam mendukung proses pengambilan keputusan, khususnya dalam menentukan prioritas mitigasi pada suatu wilayah berdasarkan indikator yang relevan [2]. Meskipun demikian, penerapannya masih menghadapi berbagai kendala, terutama yang berkaitan dengan kompleksitas serta kualitas data yang digunakan [6]. Data kejadian bencana cenderung memiliki karakteristik yang beragam, mulai dari variasi jumlah kejadian, perbedaan kondisi antar wilayah, hingga distribusi data yang tidak seimbang pada setiap kelas risiko [7]. Jika data tersebut tidak diolah secara optimal, maka hasil klasifikasi berpotensi kurang akurat dan dapat memengaruhi penentuan prioritas penanganan, seperti ketidaktepatan distribusi bantuan, keterlambatan respons, serta kurang efektifnya strategi mitigasi [8]. Oleh karena itu, diperlukan pemanfaatan teknologi yang mampu mengelola data secara lebih sistematis agar hasil analisis dapat mencerminkan kondisi lapangan secara lebih akurat [9], [10].

Kemajuan teknologi, khususnya dalam bidang *machine learning*, membuka peluang baru dalam pengolahan data bencana karena kemampuannya dalam menangani data dalam jumlah besar serta mengenali pola yang kompleks [11], [12]. Pendekatan ini dinilai lebih unggul dibandingkan metode konvensional dalam meningkatkan akurasi dan objektivitas proses klasifikasi, terutama pada data dengan karakteristik non-linear [13], [14]. Dalam penerapannya,

pemilihan algoritma menjadi aspek penting dalam membangun model yang optimal [8]. Dua algoritma yang sering digunakan adalah *Support Vector Machine* (SVM) dan *Random Forest*, yang masing-masing memiliki keunggulan dalam menangani data non-linear serta meminimalkan risiko *overfitting* melalui pendekatan yang berbeda [5], [15]. SVM bekerja dengan membentuk batas keputusan yang optimal menggunakan fungsi kernel, sedangkan *Random Forest* memanfaatkan pendekatan *ensemble* untuk mengakomodasi variasi data dan meningkatkan stabilitas prediksi [13], [16]. Dengan karakteristik tersebut, kedua algoritma dinilai sesuai untuk diterapkan pada data bencana yang cenderung kompleks dan tidak selalu dapat dipisahkan secara linear [4].

Berbagai penelitian sebelumnya telah menunjukkan bahwa algoritma *machine learning* seperti *Support Vector Machine* (SVM) dan *Random Forest* memiliki performa yang baik dalam klasifikasi bencana [9]. Secara umum, *Random Forest* cenderung memberikan hasil yang lebih unggul dibandingkan SVM pada beberapa studi [17]. Sebagai contoh, penelitian oleh Mar'ah et al. (2025) menunjukkan bahwa *Random Forest* mampu mencapai akurasi sebesar 89%, lebih tinggi dibandingkan SVM sebesar 69% pada kasus banjir rob [18]. Temuan serupa juga dilaporkan oleh Santosa et al. (2024), di mana *Random Forest* memperoleh akurasi 78%, sedangkan SVM hanya mencapai 52% pada klasifikasi berbasis data teks [19]. Selain itu, Nurkhaliza dan Wijayanto (2022) mengungkapkan bahwa *Random Forest* tidak hanya unggul dalam akurasi sebesar 78,22%, tetapi juga memiliki nilai *precision* dan *recall* yang lebih baik [5]. Di sisi lain, Purwati dan Pristyanto (2024) menunjukkan bahwa kedua algoritma memiliki performa yang relatif seimbang, meskipun *Random Forest* dinilai lebih stabil [15]. Penelitian oleh Ageenko et al. (2022) juga mendukung temuan tersebut dengan menunjukkan bahwa *Random Forest* memiliki tingkat *robustness* yang lebih tinggi dalam pemetaan kerentanan bencana [4].

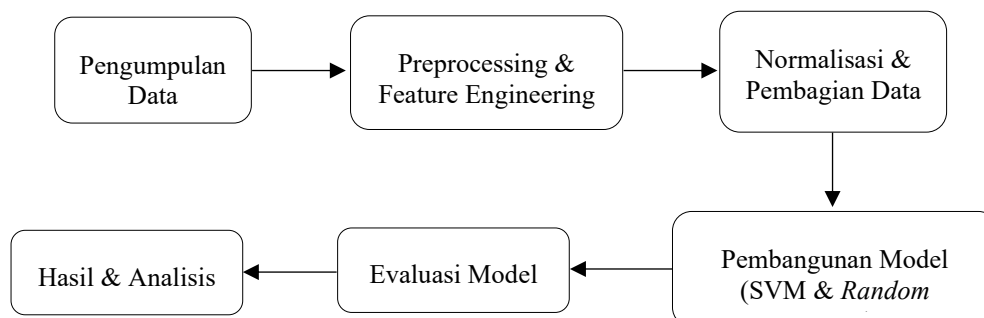
Meskipun demikian, sebagian besar penelitian sebelumnya masih memiliki keterbatasan, seperti fokus yang hanya pada satu jenis bencana atau penggunaan data yang belum sepenuhnya terstruktur [9], [19]. Selain itu, pemanfaatan indikator dampak korban dalam pembentukan kelas risiko, serta integrasi variabel kepadatan penduduk sebagai representasi tingkat paparan, masih belum dilakukan secara optimal [18]. Padahal, kedua aspek tersebut berperan penting dalam menghasilkan klasifikasi risiko yang lebih komprehensif [9]. Di sisi lain, data bencana memiliki karakteristik yang sangat beragam, baik dari jumlah kejadian, jenis bencana, maupun kondisi wilayah, sehingga distribusi data antar kelas cenderung tidak seimbang [7]. Kondisi ini dapat menimbulkan bias pada model klasifikasi terhadap kelas tertentu apabila tidak ditangani dengan baik [8]. Oleh karena itu, diperlukan pendekatan klasifikasi yang mampu mengakomodasi keragaman data sekaligus menjaga kestabilan performa pada setiap kelas [4].

Berdasarkan permasalahan yang telah diuraikan, penelitian ini bertujuan untuk melakukan klasifikasi tingkat risiko bencana di Indonesia dengan memanfaatkan algoritma *Support Vector Machine* (SVM) dan *Random Forest*, serta menganalisis perbandingan kinerja kedua algoritma dalam menangani data dengan karakteristik yang kompleks. Penelitian ini diharapkan dapat menghasilkan model klasifikasi yang lebih representatif terhadap kondisi di lapangan, sekaligus memberikan kontribusi sebagai referensi dalam pengembangan metode klasifikasi risiko bencana berbasis *machine learning* [9].

## 2. METODOLOGI PENELITIAN

### 2.1 Tahapan Penelitian

Penelitian ini menerapkan pendekatan kuantitatif berbasis *machine learning* dengan metode eksperimen untuk mengevaluasi kinerja algoritma dalam klasifikasi tingkat risiko bencana [9]. Seluruh tahapan penelitian disusun secara sistematis, dimulai dari proses pengumpulan data hingga evaluasi model menggunakan metrik kinerja seperti *accuracy*, *precision*, *recall*, dan *F1-score* [7], [20]. Alur penelitian tersebut disajikan dalam bentuk diagram pada Gambar 1.



Gambar 1. Tahapan Penelitian

Berdasarkan Gambar 1, tahapan penelitian diawali dengan pengumpulan data yang mencakup data kejadian bencana serta data kepadatan penduduk sebagai variabel pendukung. Selanjutnya dilakukan proses pengolahan data melalui tahap *preprocessing* dan *feature engineering*, yang meliputi pembersihan data, penyeragaman format

penulisan wilayah, serta ekstraksi informasi temporal berupa tahun kejadian dari data tanggal bencana [6]. Setelah itu, dilakukan penggabungan dataset berdasarkan kesesuaian wilayah dan waktu.

Data yang telah diproses kemudian dinormalisasi untuk menyamakan skala antar variabel, sebelum dilakukan pembagian data menjadi data latih dan data uji menggunakan metode *hold-out validation* dengan rasio 80:20 [13]. Tahap berikutnya adalah pembangunan model klasifikasi menggunakan algoritma *Support Vector Machine* (SVM) dan *Random Forest* [5], [15]. Model yang dihasilkan kemudian dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix* untuk memperoleh gambaran performa secara menyeluruh [7], [8]. Tahap akhir dilakukan analisis perbandingan guna menentukan algoritma dengan kinerja terbaik dalam klasifikasi tingkat risiko bencana.

## 2.2 Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari dua jenis data utama, yaitu data kejadian bencana dan data kepadatan penduduk sebagai variabel pendukung. Data kejadian bencana diperoleh dari Badan Nasional Penanggulangan Bencana (BNPB) melalui portal resmi Indonesia *Disaster Risk Index* (InaRISK), yang memuat informasi terkait waktu kejadian, lokasi, jenis bencana, serta indikator dampak seperti jumlah korban meninggal, luka-luka, dan hilang [2]. Data yang digunakan mencakup periode tahun 2019 hingga 2024 untuk merepresentasikan kondisi kejadian bencana dalam rentang waktu tersebut. Sementara itu, data kepadatan penduduk digunakan untuk menggambarkan tingkat paparan risiko pada masing-masing wilayah [18]. Kedua dataset tersebut kemudian diselaraskan berdasarkan kesamaan wilayah agar dapat digabungkan dan digunakan dalam proses analisis lebih lanjut [6]. Penggabungan kedua jenis data ini bertujuan untuk menghasilkan representasi yang lebih komprehensif dalam klasifikasi tingkat risiko bencana, karena mempertimbangkan aspek kejadian serta kondisi demografis wilayah [4], [9]. Atribut yang digunakan dalam penelitian ini ditampilkan pada Tabel 1, yang mencakup informasi terkait waktu kejadian, wilayah, jenis bencana, indikator dampak, serta kepadatan penduduk. Atribut-atribut tersebut menjadi dasar dalam proses pemodelan karena mampu merepresentasikan karakteristik kejadian bencana dan kondisi wilayah secara bersamaan.

**Tabel 1.** Keterangan Dataset

No	Atribut	Keterangan
1	Tanggal Kejadian	Waktu terjadinya bencana
2	Provinsi	Wilayah kejadian bencana
3	Jenis Bencana	Kategori bencana
4	Korban Meninggal	Jumlah korban meninggal
5	Korban Terluka	Jumlah korban luka
6	Korban Hilang	Jumlah korban hilang
7	Kepadatan Penduduk	Jumlah penduduk per wilayah

Berdasarkan atribut yang tersedia pada Tabel 1, dilakukan pembentukan label tingkat risiko bencana secara mandiri karena label tersebut tidak tersedia secara langsung dalam dataset. Label risiko ditentukan berdasarkan total dampak bencana yang dihitung dari jumlah korban, kemudian dikategorikan ke dalam tiga kelas, yaitu rendah, sedang, dan tinggi [7]. Pendekatan ini memungkinkan model untuk mengidentifikasi perbedaan tingkat risiko secara lebih terstruktur sesuai dengan distribusi data yang digunakan [8].

## 2.3 Data Preprocessing dan Feature Engineering

Tahap *data preprocessing* dan *feature engineering* dilakukan untuk mempersiapkan data agar dapat digunakan secara optimal dalam proses klasifikasi. Proses ini bertujuan untuk meningkatkan kualitas data, menjaga konsistensi format, serta menyesuaikan struktur data sesuai dengan kebutuhan algoritma *machine learning* [6]. Tahapan yang dilakukan meliputi pembersihan data serta penyeragaman format penulisan wilayah, khususnya pada atribut provinsi, sehingga data kejadian bencana dapat digabungkan secara konsisten dengan data kepadatan penduduk. Selain itu, dilakukan proses *feature engineering* dengan mengekstraksi informasi temporal berupa tahun dari data tanggal kejadian bencana untuk menyederhanakan representasi waktu dalam analisis [16]. Atribut kategorikal, seperti jenis bencana dan provinsi, kemudian ditransformasikan menggunakan metode *one-hot encoding* agar dapat diproses oleh algoritma *machine learning* [13].

Selanjutnya, dilakukan proses penggabungan (*merging*) antara dataset kejadian bencana dan data kepadatan penduduk berdasarkan kesesuaian wilayah dan tahun, sehingga diperoleh dataset yang lebih terintegrasi [9]. Indikator dampak bencana yang meliputi jumlah korban meninggal, luka-luka, dan hilang digunakan dalam pembentukan label risiko. Label tersebut ditentukan berdasarkan total dampak bencana dan dikategorikan ke dalam tiga kelas menggunakan metode berbasis kuantil (*quantile-based discretization*) [7]. Secara matematis, nilai kuantil dirumuskan sebagai berikut:

$$Q(p) = x[p \cdot n] \quad (1)$$

di mana  $Q(p)$  merupakan nilai quantile ke- $p$ ,  $n$  adalah jumlah data, dan  $x$  merupakan data yang telah diurutkan. Selanjutnya, fitur yang digunakan dalam model meliputi kepadatan penduduk, jenis bencana, wilayah, serta tahun

kejadian. Pemisahan antara atribut pembentuk label dan fitur dilakukan untuk menghindari penggunaan variabel yang sama dalam proses pelatihan model. Dataset yang telah terintegrasi kemudian digunakan pada tahap normalisasi serta pembagian data untuk proses pelatihan dan pengujian model [9].

## 2.4 Normalisasi dan Pembagian Data

Normalisasi data dilakukan untuk menyamakan skala antar variabel sehingga setiap fitur memiliki kontribusi yang seimbang dalam proses pembelajaran model *machine learning* [6]. Pada penelitian ini, metode yang digunakan adalah standarisasi (*Z-score normalization*) dengan bantuan *StandardScaler*, yang mengubah data sehingga memiliki rata-rata 0 dan standar deviasi 1 [16]. Metode ini dipilih karena mampu meningkatkan stabilitas model, terutama pada algoritma yang sensitif terhadap skala data seperti *Support Vector Machine* (SVM) [13]. Meskipun *Random Forest* tidak bergantung pada skala fitur, proses normalisasi tetap diterapkan untuk menjaga konsistensi dalam *pipeline* pemodelan serta memastikan bahwa perbandingan performa antar algoritma dilakukan pada kondisi data yang setara [15]. Secara matematis, proses normalisasi dengan metode standarisasi dirumuskan sebagai berikut:

$$z = \frac{x - \mu}{\sigma} \quad (2)$$

Pada persamaan (2),  $x$  merupakan nilai asli data,  $\mu$  adalah rata-rata data,  $\sigma$  merupakan standar deviasi, dan  $z$  adalah nilai hasil normalisasi. Dalam implementasinya, proses *fitting* hanya dilakukan pada data latih untuk memperoleh parameter  $\mu$  dan  $\sigma$ , yang kemudian digunakan untuk mentransformasikan data uji. Pendekatan ini bertujuan untuk menghindari terjadinya *data leakage*, sehingga model tidak memiliki informasi terhadap distribusi data uji selama proses pelatihan [6], [9].

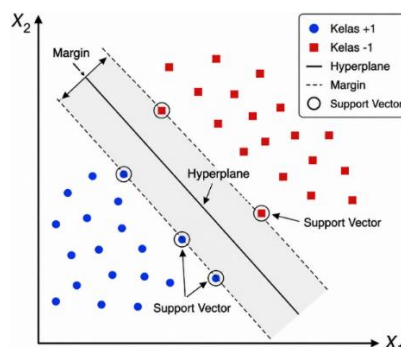
## 2.5 Pembangunan Model

Pada tahap ini dilakukan proses pembangunan model klasifikasi menggunakan algoritma *Support Vector Machine* (SVM) dan *Random Forest*. Kedua algoritma tersebut digunakan untuk mengklasifikasikan tingkat risiko bencana berdasarkan data yang telah melalui tahap *preprocessing*, normalisasi, serta pembagian data sebelumnya [5], [21].

### 2.5.1 Support Vector Machine (SVM)

Dalam penerapannya, data terlebih dahulu diproses melalui tahap normalisasi agar setiap fitur memiliki skala yang sebanding [6]. Selanjutnya, algoritma *Support Vector Machine* (SVM) bekerja dengan menentukan *hyperplane* optimal yang mampu memisahkan data antar kelas dengan margin maksimum [13]. *Hyperplane* berfungsi sebagai batas keputusan antar kelas, sedangkan margin merupakan jarak antara *hyperplane* dengan titik data terdekat dari masing-masing kelas. Titik-titik terdekat tersebut dikenal sebagai *support vector*, yang berperan penting dalam menentukan posisi *hyperplane* secara optimal [13].

Pada kondisi di mana data tidak dapat dipisahkan secara linear, fungsi kernel digunakan untuk memetakan data ke ruang berdimensi lebih tinggi sehingga proses pemisahan menjadi lebih efektif [9]. Dalam penelitian ini, kernel yang digunakan adalah *Radial Basis Function* (RBF) karena mampu menangani pola data yang bersifat non-linear dengan lebih baik [4]. Model yang telah dibangun kemudian digunakan untuk melakukan klasifikasi tingkat risiko bencana berdasarkan fitur yang telah diproses, dengan proses pelatihan menggunakan data latih dan pengujian menggunakan data uji guna mengevaluasi kemampuan model dalam mengklasifikasikan data baru. Ilustrasi pemisahan data menggunakan *hyperplane* pada metode SVM dapat dilihat pada Gambar 2.



Gambar 2. Ilustrasi hyperplane pada *Support Vector Machine*

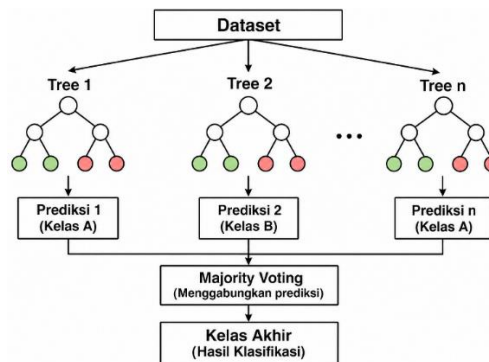
Gambar 2 tersebut menggambarkan bagaimana model menentukan batas keputusan yang optimal dengan memaksimalkan margin antar kelas, di mana *support vector* menjadi elemen kunci dalam pembentukan batas pemisah tersebut.

### 2.5.2 Random Forest

*Random Forest* merupakan metode berbasis *ensemble learning* yang mengombinasikan sejumlah *decision tree* untuk menghasilkan prediksi yang lebih akurat dan stabil [13], [22]. Pendekatan ini efektif dalam mengurangi risiko

*overfitting* serta mampu menangani data dengan tingkat kompleksitas yang tinggi [15]. Dalam proses pembentukannya, data dibagi menjadi beberapa subset menggunakan teknik *bootstrap sampling*, di mana setiap subset digunakan untuk membangun pohon keputusan yang berbeda. Selain itu, pemilihan fitur secara acak pada setiap pohon dilakukan untuk meningkatkan keberagaman model sehingga kemampuan generalisasi dapat ditingkatkan [9], [13].

Setiap *decision tree* menghasilkan prediksi secara independen, sehingga hasil antar pohon dapat berbeda. Untuk menentukan hasil akhir, digunakan metode *majority voting*, yaitu memilih kelas yang paling banyak diprediksi [13]. Pada penelitian ini, *Random Forest* diimplementasikan dengan jumlah pohon ( $n\_estimators$ ) sebanyak 200 untuk meningkatkan stabilitas model serta mengurangi variansi prediksi, dengan tetap mempertimbangkan efisiensi komputasi. Parameter lainnya menggunakan nilai *default* agar proses pemodelan tetap sederhana dan difokuskan pada perbandingan kinerja dasar tanpa melalui *hyperparameter tuning*. Ilustrasi proses klasifikasi menggunakan *Random Forest* ditunjukkan pada Gambar 3.



Gambar 3. Ilustrasi proses klasifikasi menggunakan *Random Forest*

Gambar 3 menggambarkan proses klasifikasi menggunakan *Random Forest*, di mana beberapa *decision tree* dibangun secara acak dan hasil prediksinya digabungkan melalui mekanisme *majority voting* untuk menentukan kelas akhir.

## 2.6 Evaluasi Model

Evaluasi model dilakukan untuk mengukur kinerja algoritma dalam mengklasifikasikan tingkat risiko bencana. Pada penelitian ini, digunakan beberapa metrik evaluasi, yaitu *accuracy*, *precision*, *recall*, dan *F1-score*, sehingga performa model dapat dinilai secara menyeluruh pada setiap kelas [16]. Penggunaan beberapa metrik ini bertujuan untuk memberikan gambaran yang lebih komprehensif, tidak hanya dari tingkat ketepatan secara keseluruhan, tetapi juga dari kemampuan model dalam mengenali setiap kelas dengan baik [5].

Selain itu, digunakan *confusion matrix* untuk menganalisis distribusi hasil prediksi dengan membandingkan nilai aktual dan hasil prediksi model, sehingga pola kesalahan klasifikasi dapat diidentifikasi [15]. Untuk melengkapi proses evaluasi, digunakan pula *ROC Curve* yang berfungsi untuk mengukur kemampuan model dalam membedakan antar kelas pada berbagai nilai *threshold* [7]. Nilai metrik evaluasi dihitung menggunakan persamaan berikut:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (6)$$

$$AUC = \sum_{i=1}^{n-1} (FPR_{i+1} - FPR_i) \cdot \frac{TPR_{i+1} + TPR_i}{2} \quad (7)$$

Keterangan: TP (*True Positive*) adalah jumlah data yang diprediksi benar sebagai kelas positif, TN (*True Negative*) adalah jumlah data yang diprediksi benar sebagai kelas negatif, FP (*False Positive*) adalah data yang diprediksi sebagai kelas positif tetapi sebenarnya negatif, dan FN (*False Negative*) adalah data yang diprediksi sebagai kelas negatif tetapi sebenarnya positif. Nilai AUC (*Area Under Curve*) merupakan luas area di bawah kurva ROC, dengan TPR dihitung sebagai  $TP/(TP+FN)$  dan FPR sebagai  $FP/(FP+TN)$ .

Metrik *accuracy* digunakan untuk mengukur tingkat ketepatan model secara keseluruhan. *Precision* menunjukkan ketepatan model dalam memprediksi suatu kelas, sedangkan *recall* menggambarkan kemampuan model dalam mendeteksi seluruh data pada kelas tersebut. *F1-score* merupakan rata-rata harmonik dari *precision* dan *recall*, yang memberikan ukuran performa yang lebih seimbang, terutama ketika distribusi data antar kelas tidak merata [5], [7].

*ROC Curve* digunakan untuk mengevaluasi kemampuan model dalam membedakan antar kelas pada berbagai nilai *threshold* [7]. Nilai AUC dihitung menggunakan metode trapezoidal, di mana nilai yang mendekati satu

menunjukkan performa model yang semakin baik. Dalam penelitian ini digunakan pendekatan *macro average*, karena mampu memberikan penilaian yang seimbang pada setiap kelas tanpa dipengaruhi oleh jumlah data pada masing-masing kelas, sehingga lebih sesuai untuk kasus klasifikasi multikelas [7].

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Analisis Data

Data yang digunakan dalam penelitian ini merupakan hasil penggabungan antara data kejadian bencana dan data kepadatan penduduk yang telah melalui tahap *preprocessing* [6]. Dataset yang dihasilkan berbentuk data tabular dengan kombinasi atribut numerik dan kategorikal. Atribut numerik meliputi jumlah korban meninggal, korban luka-luka, korban hilang, serta kepadatan penduduk yang memiliki rentang nilai berbeda pada setiap wilayah. Sementara itu, atribut kategorikal terdiri dari jenis bencana dan wilayah (provinsi). Perbedaan skala pada atribut numerik menunjukkan bahwa data perlu melalui proses normalisasi sebelum digunakan pada tahap pemodelan [16].

Setelah proses penggabungan dilakukan berdasarkan kesesuaian wilayah dan tahun, diperoleh dataset yang lebih lengkap dan terintegrasi sehingga dapat digunakan dalam proses klasifikasi tingkat risiko bencana. Untuk memberikan gambaran mengenai data yang digunakan, contoh dataset ditampilkan pada Tabel 2.

**Tabel 2.** Contoh Dataset

No	Tahun	Provinsi	Jenis Bencana	Korban Meninggal	Korban Luka	Korban Hilang	Kepadatan (Km <sup>2</sup> )
1	2019	Jawa Tengah	Banjir	4	2	0	1058
2	2019	Jawa Timur	Cuaca Ekstrem	1	0	0	831
3	2019	Maluku	Gempabumi	0	0	1	38
4	2019	Bali	Tanah Longsor	4	0	0	750

Berdasarkan Tabel 2, setiap baris data merepresentasikan satu kejadian bencana pada wilayah dan waktu tertentu. Data tersebut memuat atribut utama seperti jenis bencana, jumlah korban, dan kepadatan penduduk yang digunakan sebagai dasar dalam proses klasifikasi tingkat risiko bencana. Variasi nilai pada masing-masing atribut menunjukkan adanya perbedaan tingkat dampak bencana antar wilayah, sehingga dapat membantu model dalam mengenali pola risiko pada tahap pemodelan.

#### 3.2 Pengolahan Data

Pada tahap ini dilakukan proses pengolahan data sebelum digunakan dalam klasifikasi tingkat risiko bencana. Tahapan ini bertujuan untuk memastikan data yang digunakan telah sesuai dengan kebutuhan model. Dataset awal dalam penelitian ini berjumlah 12.983 data. Proses pengolahan diawali dengan tahap *preprocessing*, yaitu pembersihan data dengan menghapus data yang memiliki nilai kosong (*missing value*) pada beberapa atribut sehingga jumlah data berkurang menjadi 11.869 data. Selain itu, dilakukan penyeragaman format penulisan wilayah, khususnya pada atribut provinsi, agar data kejadian bencana dapat digabungkan secara konsisten dengan data kepadatan penduduk. Ekstraksi tahun dari data tanggal kejadian juga dilakukan untuk menyederhanakan representasi waktu dalam analisis. Setelah itu, kedua dataset digabungkan berdasarkan kesesuaian wilayah dan tahun sehingga menghasilkan data yang lebih lengkap dan terintegrasi.

Dataset yang telah digabungkan kemudian dibagi menjadi data latih dan data uji dengan rasio 80:20, di mana sebanyak 9.495 data digunakan sebagai data latih dan 2.374 data digunakan sebagai data uji. Pembagian ini dilakukan untuk melatih model sekaligus menguji performanya terhadap data yang belum pernah digunakan sebelumnya, sehingga kemampuan generalisasi model terhadap data baru dapat diketahui [16]. Selanjutnya, dilakukan normalisasi pada data latih untuk menyamakan skala antar variabel karena setiap fitur memiliki rentang nilai yang berbeda. Parameter normalisasi yang diperoleh dari data latih kemudian diterapkan pada data uji agar proses klasifikasi dapat dilakukan secara konsisten. Tahap ini menjadi penting terutama pada algoritma *Support Vector Machine* (SVM), yang sensitif terhadap perbedaan skala data [13].

#### 3.3 Pembangunan dan Evaluasi Model

Pada tahap ini dilakukan pembangunan model klasifikasi menggunakan algoritma *Support Vector Machine* (SVM) dan *Random Forest*. Kedua algoritma dilatih menggunakan data latih dan diuji menggunakan data uji untuk mengevaluasi kemampuannya dalam mengklasifikasikan tingkat risiko bencana [5], [15]. Proses pembangunan diawali dengan pelatihan algoritma SVM menggunakan data yang telah melalui tahap *preprocessing* dan normalisasi. Model yang terbentuk kemudian digunakan untuk melakukan prediksi terhadap data uji guna mengetahui kemampuannya dalam mengklasifikasikan data baru. Selanjutnya, dilakukan pelatihan menggunakan algoritma *Random Forest* dengan jumlah *decision tree* sebanyak 200, di mana hasil prediksi dari masing-masing pohon digabungkan untuk menentukan hasil klasifikasi akhir [13]. Model yang telah terbentuk kemudian digunakan untuk melakukan prediksi pada data uji sebagai bagian dari proses evaluasi performa.

Hasil pengujian menunjukkan bahwa kedua algoritma memiliki performa yang sangat baik. SVM memperoleh nilai *accuracy* sebesar 0,9528, sedangkan *Random Forest* mencapai nilai *accuracy* sebesar 0,9566, sehingga menunjukkan bahwa *Random Forest* memberikan performa yang sedikit lebih tinggi dibandingkan SVM. Perbedaan hasil tersebut menunjukkan bahwa pendekatan *ensemble learning* pada *Random Forest* mampu memberikan stabilitas prediksi yang lebih baik pada data dengan karakteristik kompleks [15]. Untuk melihat hasil evaluasi secara lebih rinci pada masing-masing kelas, hasil pengujian ditampilkan pada Tabel 3.

**Tabel 3.** Hasil Evaluasi Model per Kelas

Kelas	Metric	SVM	<i>Random Forest</i>
Rendah	Precision	0.959	0.960
	Recall	0.982	0.987
	F1-Score	0.971	0.973
Sedang	Precision	0.884	0.899
	Recall	0.892	0.895
	F1-Score	0.888	0.897
Tinggi	Precision	0.980	0.983
	Recall	0.940	0.943
	F1-Score	0.960	0.962

Berdasarkan Tabel 3, kedua model menunjukkan kemampuan yang baik dalam mengklasifikasikan data pada seluruh kelas. Perbedaan performa mulai terlihat pada kelas sedang dan tinggi, di mana *Random Forest* menghasilkan nilai yang sedikit lebih tinggi dibandingkan SVM. Selain itu, nilai *precision*, *recall*, dan *F1-score* pada *Random Forest* juga cenderung lebih konsisten.

Dataset dalam penelitian ini memiliki variasi nilai pada fitur kepadatan penduduk serta karakteristik wilayah dan jenis bencana yang cukup beragam. Kondisi tersebut menyebabkan distribusi data antar kelas tidak selalu terpisah secara jelas. Dalam situasi seperti ini, *Random Forest* memiliki keunggulan karena mampu menangani kombinasi fitur numerik dan kategorikal dengan distribusi yang tidak seragam, sehingga lebih efektif dalam menangkap pola lokal dibandingkan SVM yang bergantung pada satu batas pemisah global. Hal ini membuat *Random Forest* lebih adaptif dalam menangani data dengan pola yang saling beririsan.

Di sisi lain, performa yang relatif lebih rendah pada kelas sedang menunjukkan bahwa kelas tersebut memiliki tingkat kesulitan klasifikasi yang lebih tinggi dibandingkan kelas lainnya. Hal ini disebabkan oleh distribusi nilai pada fitur kepadatan penduduk, jenis bencana, dan wilayah yang cenderung saling beririsan antar kelas. Selain itu, pembentukan label risiko menggunakan pendekatan *quantile* menyebabkan batas antar kelas bersifat relatif, sehingga pemisahan pada kelas sedang menjadi kurang tegas. Kondisi tersebut menyebabkan model lebih sulit menentukan batas klasifikasi yang konsisten. Secara keseluruhan, kemampuan model dalam mengakomodasi variasi data sangat memengaruhi kestabilan hasil klasifikasi, terutama pada dataset dengan karakteristik yang tidak terpisah secara jelas. Untuk melihat perbandingan performa model secara lebih menyeluruh, hasil evaluasi selanjutnya ditampilkan pada Tabel 4.

**Tabel 4.** Perbandingan Performa Model

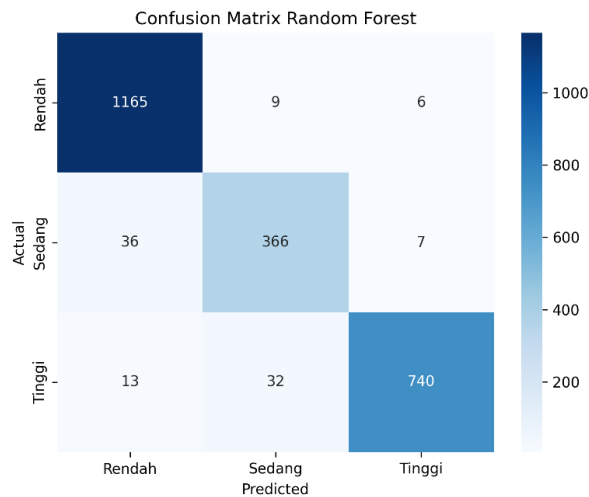
Model	Accuracy	Precision	Recall	F1-Score	ROC-AUC	Time (s)
SVM	0.9528	0.9532	0.9528	0.9528	0.9769	3.5688
<i>Random Forest</i>	0.9566	0.9569	0.9566	0.9565	0.9823	0.8837

Berdasarkan Tabel 4, *Random Forest* menunjukkan performa yang lebih tinggi dibandingkan SVM pada hampir seluruh metrik evaluasi. Nilai *accuracy* yang diperoleh sebesar 0,9566 lebih tinggi dibandingkan SVM sebesar 0,9528, diikuti oleh nilai *precision*, *recall*, dan *F1-score* yang juga menunjukkan hasil sedikit lebih baik. Selain itu, nilai ROC-AUC pada *Random Forest* sebesar 0,9823 lebih tinggi dibandingkan SVM sebesar 0,9769, yang mengindikasikan bahwa model memiliki kemampuan yang sangat baik dalam membedakan antar kelas. Dari sisi efisiensi, waktu komputasi *Random Forest* juga lebih cepat dibandingkan SVM, sehingga secara keseluruhan algoritma ini memberikan performa yang lebih unggul pada dataset yang digunakan dalam penelitian.

Keunggulan tersebut tidak hanya dipengaruhi oleh hasil evaluasi, tetapi juga berkaitan dengan karakteristik data dan kemampuan algoritma dalam memodelkan pola yang kompleks. Dataset memiliki variasi nilai pada fitur kepadatan penduduk, wilayah, dan jenis bencana, sehingga distribusi data antar kelas tidak selalu terpisah secara linear. Dalam kondisi tersebut, *Random Forest* memiliki keunggulan karena membangun banyak *decision tree* dari subset data dan fitur yang berbeda, sehingga mampu menangkap variasi pola hubungan antar variabel secara lebih fleksibel. Proses agregasi dari banyak pohon keputusan juga membuat hasil klasifikasi menjadi lebih stabil dan tidak terlalu sensitif terhadap variasi kecil pada data. Hal ini menyebabkan *Random Forest* lebih adaptif dalam menangani data dengan distribusi yang tidak seragam dan pola yang saling beririsan.

Sebaliknya, SVM bergantung pada pembentukan satu *hyperplane* optimal sebagai batas pemisah antar kelas. Ketika distribusi data tidak terpisah secara jelas, proses pembentukan batas tersebut menjadi lebih kompleks dan sensitif terhadap parameter yang digunakan, sehingga dapat memengaruhi performa model. Kondisi ini terlihat pada

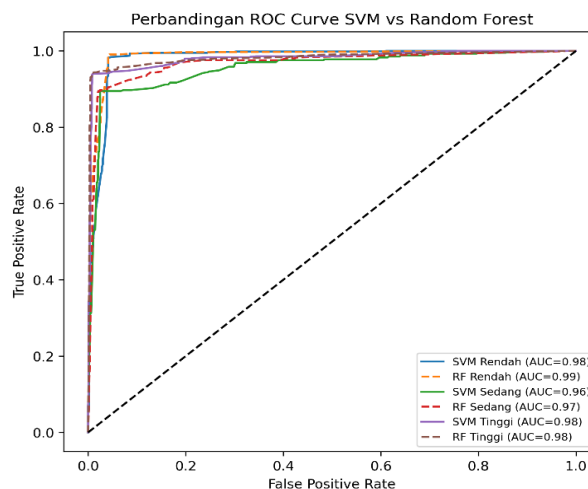
kelas sedang, yang menunjukkan performa lebih rendah dibandingkan kelas lainnya. Hal tersebut disebabkan oleh posisi kelas sedang yang berada pada rentang nilai tengah dari total dampak bencana, sehingga sebagian datanya memiliki karakteristik yang mendekati kelas rendah maupun kelas tinggi. Akibatnya, distribusi data pada kelas sedang menjadi kurang homogen dan batas antar kelas tidak terbentuk secara tegas, sehingga model mengalami kesulitan dalam melakukan klasifikasi secara konsisten. Untuk menganalisis distribusi kesalahan klasifikasi pada masing-masing kelas, digunakan *confusion matrix* yang ditampilkan pada Gambar 4.



Gambar 4. Confusion Matrix *Random Forest*

Berdasarkan Gambar 4 hasil *confusion matrix*, sebagian besar data berhasil diklasifikasikan dengan baik, yang ditunjukkan oleh dominasi nilai pada diagonal utama. Hasil tersebut menunjukkan bahwa model mampu mengenali pola utama pada data dengan cukup baik. Meskipun demikian, masih terdapat beberapa kesalahan prediksi yang mengindikasikan bahwa model belum sepenuhnya mampu membedakan seluruh data secara konsisten, terutama pada data yang memiliki karakteristik yang saling berdekatan.

Kesalahan klasifikasi paling banyak terlihat pada kelas sedang, di mana sejumlah data masih terprediksi ke kelas lain. Terdapat 36 data yang diprediksi sebagai kelas rendah dan 7 data diprediksi sebagai kelas tinggi. Kondisi ini menunjukkan bahwa sebagian data pada kelas sedang berada pada area yang beririsan dengan kelas lain, sehingga meningkatkan kemungkinan terjadinya kesalahan klasifikasi. Sebaliknya, pada kelas rendah dan tinggi jumlah kesalahan relatif lebih sedikit karena karakteristik datanya cenderung lebih ekstrem dan lebih mudah dibedakan oleh model. Hal ini menunjukkan bahwa tingkat kesulitan klasifikasi tidak merata pada setiap kelas, di mana kelas sedang memiliki tingkat kesalahan yang lebih tinggi dibandingkan kelas lainnya. Secara keseluruhan, hasil *confusion matrix* mendukung temuan sebelumnya bahwa perbedaan performa antar kelas dipengaruhi oleh karakteristik distribusi data. Selanjutnya, kemampuan model dalam membedakan antar kelas dianalisis menggunakan *ROC Curve* yang ditampilkan pada Gambar 5.



Gambar 5. Perbandingan ROC Curve SVM dan *Random Forest*

Berdasarkan grafik *ROC Curve* pada Gambar 5, kurva dari kedua model berada dekat dengan sudut kiri atas, yang menunjukkan bahwa model memiliki kemampuan yang sangat baik dalam membedakan antar kelas. Nilai *AUC* yang tinggi mengindikasikan bahwa tingkat kesalahan klasifikasi relatif rendah serta model mampu mengenali data dengan baik pada berbagai nilai *threshold*.

Jika dibandingkan, *Random Forest* menunjukkan performa yang sedikit lebih baik dibandingkan SVM, meskipun perbedaannya tidak terlalu signifikan. Hal ini sejalan dengan nilai *ROC-AUC* pada Tabel 4, di mana *Random Forest* memiliki nilai yang sedikit lebih tinggi sehingga menunjukkan kemampuan diskriminasi yang lebih baik dalam membedakan antar kelas. Secara keseluruhan, kedua model memiliki performa yang sangat baik dalam klasifikasi tingkat risiko bencana, dengan nilai *AUC* yang mendekati satu yang menunjukkan kemampuan generalisasi yang baik serta hasil prediksi yang cukup andal terhadap data baru.

Tingginya nilai *AUC* pada penelitian ini menunjukkan bahwa model mampu mempelajari pola berdasarkan karakteristik data yang digunakan. Hal ini berkaitan dengan adanya hubungan antara variabel input, seperti jenis bencana, wilayah, dan kepadatan penduduk, terhadap tingkat dampak bencana yang digunakan sebagai dasar pembentukan label. Kondisi tersebut menyebabkan pola antar kelas menjadi lebih terstruktur sehingga lebih mudah dikenali oleh model. Meskipun demikian, pada sebagian data yang berada di sekitar batas antar kelas masih terdapat pola yang saling beririsan, sehingga kemampuan model belum sepenuhnya konsisten pada seluruh kondisi data. Oleh karena itu, tingginya nilai *AUC* tidak hanya dipengaruhi oleh kemampuan model, tetapi juga oleh karakteristik data dan hubungan antar variabel yang digunakan dalam proses klasifikasi, sehingga hasil evaluasi tetap perlu diinterpretasikan secara hati-hati.

### 3.4 Pembahasan

Hasil pengujian menunjukkan bahwa kedua model, yaitu *Support Vector Machine (SVM)* dan *Random Forest*, mampu mengklasifikasikan tingkat risiko bencana dengan baik pada dataset yang digunakan. Perbedaan performa antara kedua model dipengaruhi oleh karakteristik masing-masing algoritma dalam memproses data. *Random Forest* memiliki keunggulan dalam menangani pola data yang kompleks karena menggunakan banyak *decision tree* yang digabungkan melalui mekanisme *majority voting* [13], [21]. Pendekatan tersebut membuat model lebih stabil serta mampu mengurangi pengaruh *noise* pada data. Sebaliknya, SVM cenderung lebih sensitif terhadap parameter dan distribusi data [4], sehingga performanya dapat menurun ketika terdapat data antar kelas yang memiliki karakteristik saling berdekatan. Selain faktor algoritma, karakteristik data yang digunakan juga berpengaruh terhadap tingkat keberhasilan proses klasifikasi.

Berdasarkan hasil *confusion matrix*, sebagian besar data berhasil diklasifikasikan dengan benar. Meskipun demikian, masih terdapat beberapa kesalahan klasifikasi, terutama pada kelas sedang yang terprediksi sebagai kelas rendah maupun tinggi. Kondisi tersebut menunjukkan bahwa karakteristik data pada kelas sedang memiliki kemiripan dengan kelas lainnya, sehingga model mengalami kesulitan dalam menentukan batas klasifikasi secara tegas. Selain itu, posisi kelas sedang yang berada di antara kelas rendah dan tinggi menyebabkan sebagian data memiliki nilai yang tidak berbeda secara signifikan, sehingga model cenderung mengelompokkan data ke kelas yang paling mendekati berdasarkan pola yang telah dipelajari. Hal ini menunjukkan bahwa tingkat kesulitan klasifikasi tidak hanya dipengaruhi oleh algoritma yang digunakan, tetapi juga oleh distribusi data yang tidak sepenuhnya terpisah secara jelas.

Evaluasi menggunakan *ROC Curve* menunjukkan bahwa kedua model memiliki kemampuan diskriminasi yang sangat baik, yang ditunjukkan oleh nilai *AUC* yang mendekati satu [7]. Hasil tersebut menunjukkan bahwa model mampu membedakan antar kelas dengan tingkat kesalahan yang relatif rendah pada berbagai nilai *threshold*. Perbedaan nilai *AUC* yang diperoleh juga menunjukkan bahwa *Random Forest* memiliki kemampuan yang sedikit lebih baik dibandingkan SVM dalam membedakan kelas risiko bencana, meskipun selisih performanya tidak terlalu signifikan. Kondisi ini mengindikasikan bahwa kedua model sebenarnya memiliki kemampuan yang hampir sebanding, namun *Random Forest* cenderung lebih stabil dalam menangani variasi data yang kompleks. Untuk memperkuat hasil penelitian, dilakukan perbandingan dengan beberapa penelitian terdahulu yang menggunakan metode serupa, yang disajikan pada Tabel 5.

**Tabel 5.** Perbandingan Penelitian Terdahulu

Peneliti	Metode	Dataset/Kasus	Hasil	Kesimpulan
Mar et al. (2025) [18]	RF vs SVM	Banjir Rob	RF: 89%, SVM: 69%	RF lebih unggul
Purwati & Pristyanto (2024) [15]	RF vs SVM	Klasifikasi Banjir	RF: 91%, SVM: 91%	RF lebih stabil
Penelitian ini	RF vs SVM	Risiko Bencana	RF: 95.66%, SVM: 95.28%	RF sedikit lebih unggul

Berdasarkan Tabel 5, hasil penelitian ini menunjukkan kecenderungan yang sejalan dengan penelitian sebelumnya, di mana *Random Forest* umumnya menghasilkan performa yang lebih baik dibandingkan SVM [5], [21]. Meskipun demikian, perbedaan performa yang tidak terlalu signifikan menunjukkan bahwa kedua algoritma memiliki kemampuan yang relatif sebanding dalam menangani permasalahan klasifikasi. Kondisi tersebut menunjukkan bahwa pemilihan algoritma tidak hanya dipengaruhi oleh nilai performa, tetapi juga perlu mempertimbangkan karakteristik data yang digunakan dalam proses pemodelan.

Perbedaan nilai akurasi antara penelitian ini dan penelitian terdahulu dapat dipengaruhi oleh beberapa faktor, seperti jenis dataset, jumlah data, serta variabel yang digunakan dalam proses klasifikasi. Pada penelitian ini, label risiko dibentuk berdasarkan indikator dampak bencana, sedangkan fitur yang digunakan meliputi kepadatan

penduduk, jenis bencana, dan karakteristik wilayah. Kombinasi variabel tersebut memungkinkan model mengenali pola risiko secara lebih komprehensif. Meskipun demikian, nilai akurasi yang tinggi tetap perlu diinterpretasikan secara hati-hati karena dipengaruhi oleh struktur data serta proses pembentukan label, sehingga belum sepenuhnya mencerminkan kemampuan model pada seluruh kondisi data.

#### 4. KESIMPULAN

Berdasarkan hasil penelitian, algoritma *Support Vector Machine* (SVM) dan *Random Forest* dapat digunakan untuk mengklasifikasikan tingkat risiko bencana dengan performa yang tinggi, di mana *Random Forest* memperoleh nilai akurasi sebesar 0,9566 dan SVM sebesar 0,9528, serta nilai ROC-AUC masing-masing sebesar 0,9823 dan 0,9769 yang menunjukkan kemampuan yang sangat baik dalam membedakan antar kelas. *Random Forest* menunjukkan performa yang lebih unggul, terutama dalam menangani data yang memiliki pola tidak linear dan cenderung saling beririsan, sehingga lebih adaptif dalam menangkap variasi hubungan antar fitur dibandingkan SVM yang bergantung pada satu batas pemisah global. Tingginya nilai akurasi yang diperoleh menunjukkan bahwa model mampu mengenali pola utama berdasarkan variabel yang digunakan, khususnya indikator dampak dan kepadatan penduduk. Namun demikian, performa tersebut tidak sepenuhnya mencerminkan kompleksitas kondisi risiko bencana di dunia nyata, karena pembentukan label dan keterbatasan variabel menyebabkan model lebih berfokus pada pola tertentu dalam data. Secara implementatif, model yang dihasilkan dapat dimanfaatkan oleh instansi seperti Badan Nasional Penanggulangan Bencana (BNPB) sebagai alat bantu dalam mengidentifikasi tingkat risiko secara cepat dan objektif, sehingga dapat mendukung penentuan prioritas penanganan dan perencanaan mitigasi yang lebih tepat sasaran. Oleh karena itu, penambahan variabel yang merepresentasikan karakteristik wilayah dan kondisi lingkungan diarahkan untuk memperkaya representasi risiko serta meningkatkan kemampuan generalisasi model, sehingga hasil klasifikasi dapat diterapkan secara lebih luas pada berbagai kondisi nyata.

#### REFERENCES

- [1] United Nations Office for Disaster Risk Reduction (UNDRR), *Global Assessment Report on Disaster Risk Reduction 2022: Our World at Risk: Transforming Governance for a Resilient Future*. Geneva: United Nations, 2022. Accessed: May 10, 2026. [Online]. Available: <https://www.undrr.org/GAR2022>
- [2] Fitri Adi Setyorini, "Menakar Paradigma Penanggulangan Bencana Melalui Analisis Undang-Undang No. 24 Tahun 2007 Tentang Penanggulangan Bencana," *Journal of Social Politics and Governance (JSPG)*, vol. 5, no. 2, pp. 97–96, Dec. 2023, doi: 10.24076/jspg.v5i2.1339.
- [3] M. Ganjirad and M. R. Delavar, "Flood Risk Mapping Using Random Forest and Support Vector Machine," in *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Copernicus Publications, Jan. 2023, pp. 201–208. doi: 10.5194/isprs-annals-X-4-W1-2022-201-2023.
- [4] A. Ageenko, L. C. Hansen, K. L. Lyng, L. Bodum, and J. J. Arsanjani, "Landslide Susceptibility Mapping Using Machine Learning: A Danish Case Study," *ISPRS Int. J. Geoinf.*, vol. 11, no. 6, Jun. 2022, doi: 10.3390/ijgi11060324.
- [5] A. A. Nurkhaliza and A. W. Wijayanto, "Perbandingan Algoritma Klasifikasi Support Vector Machine dan Random Forest pada Prediksi Status Indeks Mitigasi dan Kesiapsiagaan Bencana (IMKB) Satuan Kerja BPS di Indonesia," *Jurnal Informatika Universitas Pamulang*, vol. 7, no. 1, pp. 54–59, 2022, doi: 10.32493/informatika.v7i1.16117.
- [6] A. Brijith, "Data Preprocessing for Machine Learning," CSIM, 2023, Accessed: May 10, 2026
- [7] J. S. Aguilar-Ruiz and M. Michalak, "Classification Performance Assessment for Imbalanced Multiclass Data," *Sci. Rep.*, vol. 14, no. 1, Dec. 2024, doi: 10.1038/s41598-024-61365-z.
- [8] A. Rajab *et al.*, "Flood Forecasting by Using Machine Learning: A Study Leveraging Historic Climatic Records of Bangladesh," *Water (Switzerland)*, vol. 15, no. 22, Nov. 2023, doi: 10.3390/w15223970.
- [9] M. Asif, M. M. Kuglitsch, I. Pelivan, and R. Albano, "Review and Intercomparison of Machine Learning Applications for Short-term Flood Forecasting," *Water Resources Management*, vol. 39, no. 5, pp. 1971–1991, Mar. 2025, doi: 10.1007/s11269-025-04093-x.
- [10] A. Faruq and A. Syaiful Amal, "Desain Sistem Prediksi Wilayah Terdampak Banjir dengan Machine Learning berbasis Data Sistem Informasi Geografis," *Seminar Keinsinyuran*, p. 1, 2024, Accessed: May 10, 2026. [Online]. Available: <https://research-report.umm.ac.id/index.php/psppi/article/view/362>
- [11] C. Zeng and D. Bertsimas, "Global Flood Prediction: a Multimodal Machine Learning Approach," *ArXiv*, vol. 2301.12548, Jan. 2023, [Online]. Available: <http://arxiv.org/abs/2301.12548>
- [12] E. Hermawan, S. Darmawan Panjaitan, and E. Faja Ripanti, "Sistem Prediksi Banjir Rob Kota Pontianak Berbasis Machine Learning Menggunakan Framework," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 10, no. 3, pp. 351–361, Dec. 2024, Accessed: May 10, 2026. [Online]. Available: <https://jurnal.untan.ac.id/index.php/jepin/article/view/79955?>
- [13] Parag Ghorpade, Hitesh Chordiya, Basavaraj Hooli, Aditya Gadge, Gita Gosavi, and Yashwant S. Ingle, "Flood Forecasting Using Machine Learning: A Review," *2021 8th International Conference on Smart Computing and Communications (ICSCC)*, 2021, doi: 10.1109/ICSCC51209.2021.9528099.
- [14] S. Triyanto, A. Sunyoto, and M. R. Arief, "Analisis Klasifikasi Bencana Banjir Berdasarkan Curah Hujan Menggunakan Algoritma Naïve Bayes," *JOISIE Journal Of Information System And Informatics Engineering*, vol. 5, no. 2, pp. 109–117, 2021, Accessed: May 10, 2026. [Online]. Available: <https://jurnalamikom.ac.id/index.php/joisie/article/view/687>
- [15] S. E. Purwati and Y. Pristyanto, "Model Random Forest and Support Vector Machine for Flood Classification in Indonesia," *sinkron*, vol. 8, no. 4, pp. 2261–2268, Oct. 2024, doi: 10.33395/sinkron.v8i4.13973.



- [16] M. Sinsirimongkhon, S. Arwatchananukul, and P. Temdee, “Multi-Class Classification Method with Feature Engineering for Predicting Hypertension with Diabetes,” *Journal of Mobile Multimedia*, vol. 19, no. 3, pp. 799–822, 2023, doi: 10.13052/jmm1550-4646.1937.
- [17] M. Fauzi, Muhsi, and Hozairi, “Analisis Penggunaan Model Random Forest dalam Memprediksi Resiko Banjir di Daerah Rawan Bencana Kabupaten Pamekasan,” *Seminar Nasional Humaniora dan Aplikasi Teknologi Informasi (SEHATI)*, vol. 11, no. 1, pp. 17–25, Oct. 2025, Accessed: May 10, 2026. [Online]. Available: <https://ejournalwiraraja.com/index.php/SEHATI/article/view/4669>
- [18] M. Mar, W. Aprizal Arifin, and A. Armelita Rosalia, “Perbandingan Random Forest Dan Support Vector Machine Dalam Memprediksi Banjir Rob di Teluk Lampung,” *Jurnal Algoritma*, vol. 22, no. 2, pp. 1116–1126, 2025, doi: 10.33364/algoritma/v.22-1.2145.
- [19] R. Santosa, A. Fariza, and F. Arifin, “Classification of Flood Disaster Level News Articles Using Machine Learning,” *Indonesian Journal of Computer Science Attribution*, vol. 13, no. 1, pp. 264–275, 2024, Accessed: May 10, 2026. [Online]. Available: <https://ijcs.stmikindonesia.ac.id/ijcs/index.php/ijcs/article/view/3550>
- [20] R. Hermawan, A. Maulana, and A. Zulianto, “Penyusunan Model Untuk Predkisi Bencana Banjir Menggunakan Machine Learning,” *Jurnal InfoSecure (JISEC)*, vol. 2, no. 1, pp. 1–10, Apr. 2021, Accessed: May 10, 2026. [Online]. Available: [https://jurnal-pasca.unla.ac.id/infosecure/article/view/v2n1\\_01](https://jurnal-pasca.unla.ac.id/infosecure/article/view/v2n1_01)
- [21] I. A. Purnomo, J. Indra, E. E. Awal, and T. Rohana, “Analisis Prediksi Banjir di Indonesia Menggunakan Algoritma Support Vector Machine dan Random Forest,” *Journal of Information System Research (JOSH)*, vol. 6, no. 1, pp. 219–228, Oct. 2024, doi: 10.47065/josh.v6i1.5958.
- [22] T. Prasetyo and Ardianto, “Analisis Prediksi Risiko Banjir Menggunakan Algoritma Random Forest,” *Jurnal Teknik Informatika Unika ST. Thomas (JTIUST)*, vol. 10, no. 02, pp. 314–319, 2025, Accessed: May 10, 2026. [Online]. Available: <https://ejournal.ust.ac.id/index.php/JTIUST/article/view/5944>