

Klasifikasi Keparahan Kecelakaan Lalu Lintas Menggunakan Machine Learning

Darusman^{1,*}, Achmad Pahrul Rodji²

¹ Program Studi Magister Ilmu Komputer; Universitas Nusa Mandiri Jakarta; Jl. Raya Jatiwaringin Cipinang Melayu, Kec. Makasar, Kota Jakarta Timur, Daerah Khusus Ibukota Jakarta, No.telpon (021)28534471; e-mail: 14230029@nusamandiri.ac.id

²Program Studi Teknik Sipil; Fakultas Teknik; Universitas Krisnadwipayana; Jl. Kampus UNKRIS Jatiwaringin, Pondok Gede, Kota Bekasi, No.Telpon (021) 8462230/846223; e-mail: ²achmadpahrulrodji@unkris.ac.id

* Korespondensi: e-mail: 14230029@nusamandiri.ac.id

Diterima: ... ; Review: ...; Disetujui: ...

Cara sitasi: Darusman, Rodji AP. 2025. Klasifikasi Keparahan Kecelakaan Lalu Lintas Menggunakan Machine Learning. Informatics for Educators and Professionals : Journal of Informatics. Vol.10 (1): 82-92.

Abstrak: Kecelakaan lalu lintas merupakan salah satu penyebab utama cedera dan kematian di berbagai negara. Berbagai faktor seperti jumlah kendaraan yang terlibat, kondisi pencahayaan, jenis persimpangan, dan penyebab utama kecelakaan berkontribusi terhadap tingkat keparahan kecelakaan. Penelitian ini bertujuan untuk mengklasifikasikan tingkat keparahan kecelakaan lalu lintas dengan menggunakan algoritma Random Forest, Decision Tree, Naïve Bayes, dan Support Vector Machine (SVM). Dataset yang digunakan diperoleh dari kaggle dengan berbagai fitur kategorikal dan numerik yang relevan. Metodologi penelitian meliputi pengumpulan data, sampai evaluasi model. Evaluasi model dilakukan dengan *akurasi, precision, recall, dan F1-score*. Hasil penelitian menunjukkan bahwa Random Forest memberikan akurasi tertinggi sebesar 84%, diikuti oleh Naïve Bayes (82%), Decision Tree (77%), dan SVM (71%). Teknik SMOTE meningkatkan performa beberapa model dengan memperbaiki keseimbangan data, tetapi juga meningkatkan risiko *overfitting*. Sementara itu, penerapan PCA membantu meningkatkan efisiensi model dengan mengurangi dimensi tanpa kehilangan informasi penting. Dengan model yang telah dikembangkan, sistem prediksi ini berpotensi digunakan dalam analisis keselamatan jalan raya dan mendukung pengambilan keputusan dalam mitigasi kecelakaan lalu lintas

Kata kunci: Kecelakaan Lalu Lintas; Machine Learning; Klasifikasi Keparahan;

Abstract: Traffic accidents are one of the main causes of injury and death in various countries. Various factors such as the number of vehicles involved, lighting conditions, type of intersection, and the underlying cause of the accident contribute to the severity of the accident. This research aims to classify the severity of traffic accidents using Random Forest, Decision Tree, Naïve Bayes, and Support Vector Machine (SVM) algorithms. The dataset used was obtained from Kaggle with various relevant categorical and numerical features. The research methodology includes data collection and model evaluation. Model evaluation is carried out using accuracy, precision, recall, and F1-score. The research results show that Random Forest provides the highest accuracy of 84%, followed by Naïve Bayes (82%), Decision Tree (77%), and SVM (71%). The SMOTE technique improves the performance of some models by improving data balance, but also increases the risk of overfitting. Meanwhile, applying PCA helps improve model efficiency by reducing dimensions without losing important information. With the model

that has been developed, this prediction system has the potential to be used in road safety analysis and to support decision making in mitigating traffic accidents


Keywords: Traffic accident; Machine Learning; Severity Classification;

1. Pendahuluan

Kecelakaan lalu lintas merupakan permasalahan serius yang terjadi di berbagai negara dan memiliki dampak signifikan terhadap keselamatan manusia serta perekonomian. Berbagai faktor dapat mempengaruhi tingkat keparahan kecelakaan, seperti jumlah kendaraan yang terlibat, kondisi pencahayaan, jenis persimpangan, serta penyebab utama kecelakaan [1][2][3]. Seiring dengan meningkatnya jumlah kendaraan di jalan raya, risiko kecelakaan juga semakin tinggi, sehingga diperlukan upaya mitigasi berbasis teknologi untuk mengurangi jumlah dan tingkat keparahan kecelakaan [4][5][6]. Dalam beberapa tahun terakhir, teknologi kecerdasan buatan, khususnya machine learning, telah banyak diterapkan dalam analisis data kecelakaan lalu lintas guna mengidentifikasi pola dan faktor yang mempengaruhi tingkat keparahan kecelakaan. Metode konvensional dalam menganalisis kecelakaan sering kali mengandalkan model statistik sederhana, yang memiliki keterbatasan dalam menangkap hubungan kompleks antar variable [7][8][9]. Oleh karena itu, penerapan algoritma machine learning dapat meningkatkan akurasi dalam mengklasifikasikan tingkat keparahan kecelakaan berdasarkan faktor-faktor yang ada dalam dataset [10][11][12]. Salah satu tantangan utama dalam penelitian ini adalah ketidakseimbangan data, di mana jumlah kecelakaan ringan jauh lebih banyak dibandingkan dengan kecelakaan serius atau fatal. Ketidakseimbangan ini dapat menyebabkan bias pada model machine learning, sehingga model lebih cenderung memprediksi kelas mayoritas [13][14][15]. Selain itu, data kecelakaan lalu lintas sering kali memiliki banyak fitur dengan tingkat kepentingan yang bervariasi, sehingga diperlukan metode seleksi fitur untuk meningkatkan efisiensi model dan mengurangi dimensi data tanpa kehilangan informasi penting [16][17][18].

Penelitian ini bertujuan untuk mengembangkan model klasifikasi tingkat keparahan kecelakaan lalu lintas dengan menggunakan algoritma Random Forest, Decision Tree, Naïve Bayes, dan Support Vector Machine (SVM). Dataset yang digunakan diperoleh dari kaggle *road traffic severity classification*, yang mencakup berbagai variabel terkait kecelakaan lalu lintas. Selain itu, penelitian ini juga mengevaluasi berbagai teknik penanganan ketidakseimbangan data, seperti SMOTE (*Synthetic Minority Over-sampling Technique*), serta metode reduksi dimensi menggunakan *Principal Component Analysis* (PCA) untuk meningkatkan kinerja model [19][20][21]. Dengan mengimplementasikan sistem prediksi berbasis machine learning yang optimal, diharapkan penelitian ini dapat memberikan kontribusi dalam meningkatkan keselamatan lalu lintas dengan mengidentifikasi faktor risiko utama kecelakaan. Selain itu, hasil penelitian ini juga dapat digunakan sebagai referensi dalam pengembangan kebijakan keselamatan jalan raya serta perencanaan infrastruktur transportasi yang lebih baik.

2. Metode Penelitian

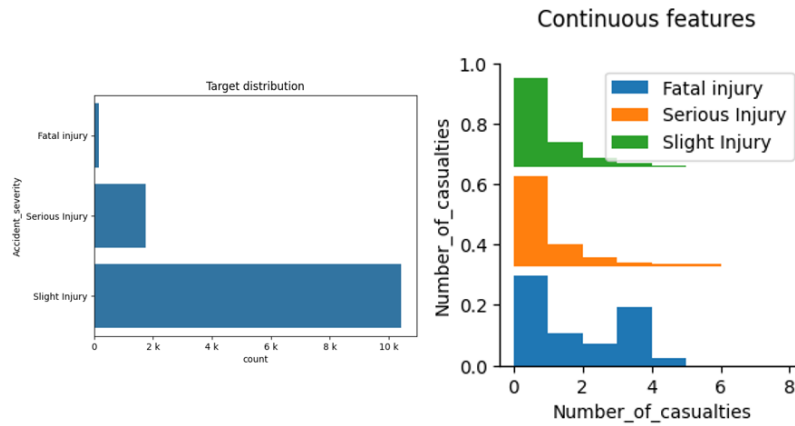


Sumber : Hasil Penelitian (2025)

Gambar 1. Tahap Penelitian

2.1. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini diperoleh dari kaggle <https://www.kaggle.com/datasets/avikumart/road-traffic-severity-classification>. Dataset ini berisi informasi detail mengenai kecelakaan lalu lintas, mencakup berbagai fitur kategorikal dan numerik yang dapat mempengaruhi tingkat keparahan kecelakaan. Beberapa fitur penting dalam dataset ini meliputi jumlah korban, jumlah kendaraan yang terlibat, kondisi pencahayaan, jenis persimpangan, serta penyebab utama kecelakaan.



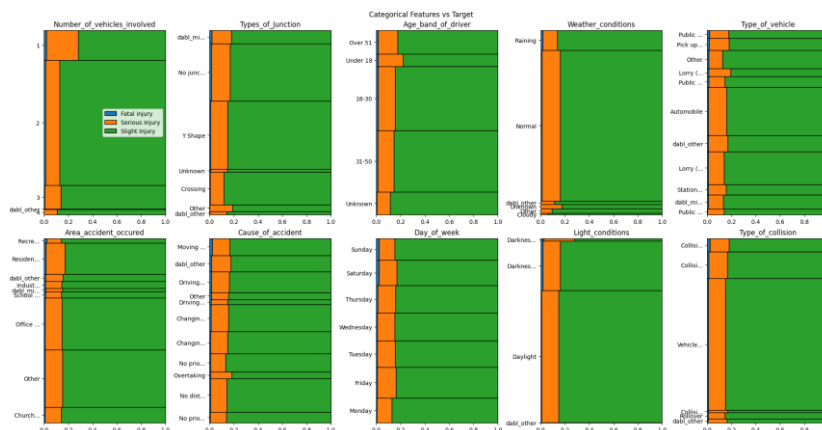
Sumber : Hasil Penelitian (2025)

Gambar 2. Distribusi Kecelakaan dan Jumlah Korban

Gambar 2 distribusi tingkat keparahan kecelakaan lalu lintas serta hubungan antara jumlah korban dengan tingkat keparahan kecelakaan. Diagram sebelah kiri menggambarkan bahwa kecelakaan ringan (*Slight Injury*) jauh lebih banyak dibanding kecelakaan serius (*Serious Injury*) dan fatal (*Fatal Injury*), menunjukkan adanya ketidakseimbangan kelas dalam data. Diagram di sebelah kanan memperlihatkan bahwa semakin tinggi jumlah korban, semakin besar kemungkinan kecelakaan masuk ke kategori serius atau fatal.

2.2. Analisis Data

Eksplorasi data mengungkap bahwa jumlah korban, jumlah kendaraan, dan kondisi pencahayaan berpengaruh terhadap keparahan kecelakaan [22][23]. Data menunjukkan ketidakseimbangan kelas, dengan kecelakaan ringan lebih dominan dibanding kecelakaan berat. Selain itu, fitur-fitur utama yang berkorelasi dengan tingkat keparahan berhasil diidentifikasi untuk digunakan dalam proses pemodelan.




Sumber : Hasil Penelitian (2025)

Gambar 3. Distribusi Kecelakaan Fitur Kategorikal

Gambar 3 distribusi keparahan kecelakaan lalu lintas berdasarkan berbagai fitur kategorikal, seperti jumlah kendaraan yang terlibat, jenis persimpangan, kondisi cuaca, jenis kendaraan, waktu kecelakaan, penyebab kecelakaan, dan kondisi pencahayaan. Warna hijau menunjukkan kecelakaan ringan (*Slight Injury*), oranye untuk kecelakaan serius (*Serious Injury*), dan biru untuk kecelakaan fatal (*Fatal Injury*). Distribusi ini menunjukkan bahwa sebagian besar kecelakaan yang terjadi bersifat ringan, sementara kecelakaan serius dan fatal memiliki proporsi yang lebih kecil di semua kategori.

2.3. Visualisasi Data

Visualisasi menggunakan *seaborn* dan *matplotlib* menunjukkan pola hubungan antar fitur, di mana area kecelakaan dan penyebab kecelakaan memiliki korelasi tinggi terhadap keparahan kecelakaan [24][25]. Analisis visual ini membantu memahami distribusi data sebelum memasuki tahap pemodelan.



Sumber : Hasil Penelitian (2025)

Gambar 4. Distribusi Kecelakaan Berdasarkan Jam Kejadian

Gambar 4 jumlah kecelakaan berdasarkan waktu kejadian dalam sehari. Kecelakaan ringan (*Slight Injury*) ditampilkan dalam warna biru, kecelakaan serius (*Serious Injury*) dalam warna oranye, dan kecelakaan fatal (*Fatal Injury*) dalam warna hijau. Mayoritas kecelakaan terjadi pada jam sibuk, yaitu antara pukul 7-9 pagi dan 15-18 sore, yang kemungkinan besar bertepatan dengan waktu berangkat dan pulang kerja. Proporsi kecelakaan fatal dan serius juga meningkat pada jam-jam tertentu, meskipun jumlahnya jauh lebih kecil dibanding kecelakaan ringan.

2.4. Pra-pemrosesan Data

Langkah pra-pemrosesan dilakukan dengan menangani nilai yang hilang menggunakan teknik imputasi, serta mengonversi fitur kategorikal dengan *one-hot encoding* dan target variabel dengan *label encoding* [26][27]. Selain itu, standarisasi dan normalisasi diterapkan jika diperlukan untuk meningkatkan kinerja model.

2.5. Seleksi Fitur

Seleksi fitur dilakukan menggunakan *SelectKBest*, *Chi-square*, dan *Mutual Information* untuk menentukan fitur yang paling berpengaruh. PCA diterapkan guna mengurangi dimensi data tanpa kehilangan informasi penting [28][29]. Hasilnya menunjukkan bahwa jenis persimpangan dan kondisi cahaya memiliki dampak signifikan dalam klasifikasi keparahan kecelakaan.

2.6. Data Tidak Seimbang

Dataset menunjukkan ketidakseimbangan kelas, dengan kecelakaan ringan lebih dominan dibanding kecelakaan berat. Untuk mengatasi hal ini, digunakan *smotenc* guna menyeimbangkan distribusi kelas dalam target variabel [30][31][32]. Teknik ini membantu meningkatkan akurasi model dengan memperkuat representasi data minoritas.

2.7. Pemodelan dan Hyperparameter

Pemodelan dilakukan menggunakan algoritma *Random Forest*, *Decision Tree*, *Naïve Bayes*, dan *SVM* [33][34][35]. Data dibagi dengan rasio *train-test* (80:20) untuk pelatihan dan pengujian. Evaluasi model dilakukan melalui *cross-validation*, serta hyperparameter tuning diterapkan untuk meningkatkan kinerja dan akurasi model.

Table 1. Hasil Pelatihan Model

Model		Precision	Recall	F1-Score	Support
Random Forest	0	0.77	0.62	0.68	2085
	1	0.63	0.64	0.64	2100
	2	0.84	1.00	0.91	2064
	Accuracy			0.75	6249
	Macro Avg	0.75	0.75	0.74	6249
	Weighted Avg	0.75	0.75	0.74	6249
Decision Tree	0	0.78	0.74	0.76	2085
	1	0.70	0.63	0.66	2100
	2	0.84	0.97	0.90	2064
	Accuracy			0.78	6249
	Macro Avg	0.77	0.78	0.77	6249
	Weighted Avg	0.77	0.78	0.77	6249
Naïve Bayes	0	0.61	0.67	0.63	2085
	1	0.53	0.40	0.46	2100
	2	0.83	0.96	0.89	2064
	Accuracy			0.67	6249
	Macro Avg	0.66	0.68	0.66	6249
	Weighted Avg	0.66	0.67	0.66	6249
SVM	0	0.68	0.57	0.62	2085
	1	0.58	0.56	0.57	2100
	2	0.84	1.00	0.91	2064
	Accuracy			0.71	6249
	Macro Avg	0.70	0.71	0.70	6249
	Weighted Avg	0.70	0.71	0.70	6249

Sumber : Hasil Penelitian (2025)

Tabel 1 hasil pelatihan dan pengujian menggunakan algoritma *Random Forest*, *Decision Tree*, *Naïve Bayes*, dan *SVM* dengan rasio data 80:20. *Random Forest* dan *Decision Tree* menunjukkan performa terbaik dengan akurasi masing-masing 75% dan 78%, sedangkan *Naïve Bayes* memiliki akurasi lebih rendah, yaitu 67%. *SVM* mencapai akurasi 71%, menunjukkan keseimbangan antara presisi dan recall. Hasil ini menjadi dasar untuk tuning hyperparameter dan pemilihan model terbaik sebelum deployment.

2.8. Evaluasi Model

Evaluasi model dilakukan menggunakan metrik *Akurasi*, *Precision*, *Recall*, dan *F1-score* untuk mengukur performa klasifikasi. Metrik ini membantu dalam menilai keseimbangan antara prediksi benar dan kesalahan, memastikan model mampu mengklasifikasikan keparahan kecelakaan dengan baik.

3. Hasil dan Pembahasan

Hasil analisis model machine learning yang digunakan dalam penelitian ini memiliki kemampuan prediksi yang cukup baik dalam mengklasifikasikan keparahan kecelakaan lalu lintas jalan. Evaluasi model dilakukan menggunakan beberapa metrik utama, yaitu *akurasi*, *precision*, *recall*, dan *F1-score* untuk memastikan keandalan prediksi. Berdasarkan hasil akurasi dari berbagai model, *Random Forest* dan *Naïve Bayes* menunjukkan performa terbaik dengan

akurasi mencapai 84% dan 82% pada dataset dengan pembagian 80:20. Hal ini menunjukkan bahwa model ini mampu menangkap pola data dengan baik dan memberikan prediksi yang andal. Sebaliknya, model Decision Tree memiliki akurasi lebih rendah, yaitu 77%, yang menunjukkan bahwa pendekatan probabilistik kurang efektif dalam menangani karakteristik dataset ini. SVM mencapai akurasi 71%, menunjukkan keseimbangan antara *precision* dan *recall*. Pada eksperimen menggunakan teknik *oversampling* dengan pembagian data 80:20, performa model seperti Decision Tree meningkat, menunjukkan bahwa penambahan sampel pada kelas minoritas dapat membantu model memahami pola data dengan lebih baik. Namun, teknik ini tidak memberikan hasil optimal untuk Naive Bayes, yang mengalami penurunan akurasi menjadi 0.67. Hal ini dapat terjadi karena *oversampling* berpotensi menyebabkan *overfitting*, terutama pada model yang lebih sensitif terhadap distribusi data. Sementara itu, teknik *undersampling* dengan rasio 0.78 menunjukkan hasil yang lebih stabil untuk model Decision Tree dan Random Forest, dengan akurasi mencapai 0.75. Namun, metode ini berdampak negatif pada Naive Bayes, yang mengalami penurunan signifikan hingga 0.67, menunjukkan bahwa metode ini kurang optimal untuk dataset yang telah dikurangi sampelnya.

Setelah menerapkan *Principal Component Analysis* (PCA) untuk reduksi dimensi fitur, Decision Tree menunjukkan peningkatan akurasi menjadi 0.78, yang berarti model ini lebih efektif dalam menangani data setelah fitur yang kurang relevan dihilangkan. Model Random Forest dan Decision Tree tetap mempertahankan performa yang cukup baik setelah PCA diterapkan, sementara Naive Bayes meningkat menjadi 0.67, yang menunjukkan bahwa reduksi dimensi dapat membantu meningkatkan kinerja model berbasis probabilistik dengan mengurangi *noise* dalam fitur. PCA juga membantu menghilangkan redundansi antar fitur, yang dapat meningkatkan kecepatan komputasi tanpa mengorbankan akurasi prediksi. Analisis visualisasi menggunakan *heatmap* korelasi fitur menunjukkan bahwa beberapa fitur dalam dataset memiliki korelasi tinggi, yang dapat menyebabkan redundansi informasi jika tidak diatasi. Korelasi yang tinggi antar fitur dapat menyebabkan multikolinearitas, yang dapat mengurangi efektivitas model machine learning. Oleh karena itu, dilakukan seleksi fitur dengan menggunakan F-score, yang mengukur tingkat kepentingan masing-masing fitur dalam proses prediksi. Hasil analisis menunjukkan bahwa beberapa fitur memiliki pengaruh yang lebih besar terhadap hasil prediksi, yang berarti seleksi fitur dapat membantu meningkatkan efisiensi model dengan hanya menggunakan fitur yang paling relevan. Model seperti Random Forest dan Decision Tree sangat bergantung pada fitur penting dalam melakukan klasifikasi, sehingga seleksi fitur dapat meningkatkan performa model tersebut.

Hasil perbandingan model menunjukkan bahwa Random Forest dan Decision Tree adalah model terbaik untuk dataset dengan pembagian 80:20, dengan akurasi tinggi tanpa perlu *preprocessing* tambahan. Sementara itu, PCA terbukti membantu meningkatkan performa Random Forest, yang menandakan bahwa reduksi dimensi dapat meningkatkan efisiensi model. *Oversampling* bermanfaat bagi Decision Tree dengan meningkatkan akurasi, tetapi dapat menyebabkan *overfitting* pada model seperti SVM. *Undersampling* lebih efektif untuk Decision Tree, tetapi dapat menurunkan kinerja model berbasis margin seperti SVM. SVM tetap menjadi model dengan performa terendah di semua skenario, yang menunjukkan bahwa model ini kurang cocok untuk dataset kecelakaan lalu lintas karena pola distribusi data yang kompleks dan tidak sepenuhnya dapat direpresentasikan dengan pendekatan probabilistik. Selama proses evaluasi model, terdeteksi beberapa *outlier* dalam dataset, yang dapat mengindikasikan adanya faktor eksternal atau variasi dalam data yang tidak sepenuhnya tercakup dalam fitur yang digunakan. *Outlier* ini dapat menyebabkan kesalahan prediksi dan mengurangi akurasi model. Oleh karena itu, disarankan untuk menerapkan teknik tambahan seperti *anomaly detection* untuk mengidentifikasi dan menangani data yang menyimpang dari pola umum. Selain itu, eksplorasi lebih lanjut dapat dilakukan dengan menambahkan fitur yang lebih representatif atau menggunakan teknik *feature engineering* untuk meningkatkan kualitas dataset. Untuk penelitian selanjutnya, pendekatan dapat diperluas dengan eksplorasi model deep learning atau *ensemble methods* yang lebih kompleks untuk meningkatkan akurasi prediksi. Model seperti *Neural Networks* atau *Hybrid Ensemble Model* dapat menjadi alternatif yang menjanjikan untuk menangani dataset yang lebih kompleks dan besar. Selain itu, penggunaan dataset yang lebih besar dan lebih beragam akan membantu model meningkatkan kemampuan generalisasi, sehingga dapat diterapkan dalam berbagai skenario klasifikasi keparahan kecelakaan lalu lintas. Dengan adanya perbaikan pada teknik machine learning dan

pemilihan fitur yang lebih optimal, prediksi keparahan kecelakaan lalu lintas dapat semakin akurat dan andal untuk digunakan dalam analisis keselamatan transportasi.

Table 2. Hasil Model Random Forest

Model		Precision	Recall	F1-Score	Support
Random Forest	0	0.00	0.00	0.00	37
	1	0.00	0.00	0.00	363
	2	0.84	1.00	0.91	2064
	Accuracy			0.84	2464
	Macro Avg	0.28	0.33	0.30	2464
	Weighted Avg	0.70	0.84	0.76	2464

Sumber : Hasil Penelitian (2025)

Tabel 2 hasil evaluasi model Random Forest berdasarkan precision, recall, dan F1-score pada masing-masing kelas target. Model memiliki akurasi 84%, tetapi menunjukkan ketidakseimbangan dalam klasifikasi, di mana kelas 0 (kecelakaan ringan) dan 1 (kecelakaan sedang) memiliki precision dan recall 0.00, menunjukkan model gagal mengklasifikasikan kedua kelas ini dengan baik. Sebaliknya, model bekerja sangat baik pada kelas 2 (kecelakaan fatal) dengan F1-score 0.91. Hal ini menunjukkan bahwa model perlu diperbaiki, terutama dalam menangani ketidakseimbangan data.

Table 3. Hasil Model Decision Tree

Model		Precision	Recall	F1-Score	Support
Decision Tree	0	0.37	0.35	0.36	37
	1	0.28	0.29	0.28	363
	2	0.87	0.86	0.87	2064
	Accuracy			0.77	2464
	Macro Avg	0.51	0.50	0.50	2464
	Weighted Avg	0.77	0.77	0.77	2464

Sumber : Hasil Penelitian (2025)

Tabel 3 hasil evaluasi model Decision Tree pada klasifikasi tingkat keparahan kecelakaan. Model mencapai akurasi 77%, dengan performa terbaik pada kelas 2 (kecelakaan fatal) yang memiliki F1-score 0.87. Namun, model masih mengalami kesulitan dalam mengklasifikasikan kelas 0 (kecelakaan ringan) dan 1 (kecelakaan sedang), dengan F1-score masing-masing 0.36 dan 0.28. Meskipun lebih baik dibandingkan Random Forest dalam mengenali kelas minoritas, model ini tetap memerlukan perbaikan, seperti penanganan ketidakseimbangan data untuk meningkatkan akurasi pada semua kelas.

Table 4. Hasil Model Naive Bayes

Model		Precision	Recall	F1-Score	Support
Naive Bayes	0	0.07	0.11	0.09	37
	1	0.12	0.00	0.01	363
	2	0.84	0.97	0.90	2064
	Accuracy			0.82	2464
	Macro Avg	0.34	0.36	0.33	2464
	Weighted Avg	0.72	0.82	0.76	2464

Sumber : Hasil Penelitian (2025)

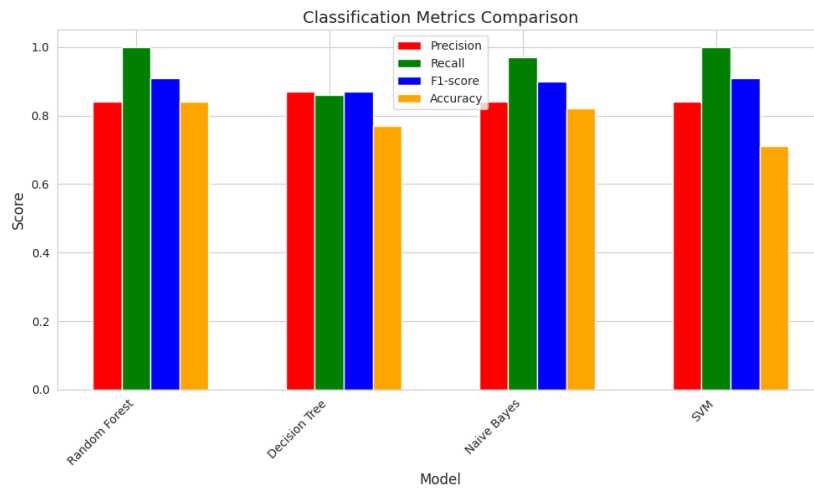
Tabel 4 hasil evaluasi model Naive Bayes dalam klasifikasi tingkat keparahan kecelakaan. Model memperoleh akurasi sebesar 82%, dengan performa terbaik pada kelas 2 (kecelakaan fatal) yang memiliki F1-score 0.90. Namun, model menunjukkan kelemahan signifikan dalam mengenali kelas 0 (kecelakaan ringan) dan 1 (kecelakaan sedang), dengan F1-score masing-masing hanya 0.09 dan 0.01. Hal ini menunjukkan bahwa model Naive Bayes kurang efektif dalam menangani ketidakseimbangan kelas, sehingga memerlukan teknik tambahan, seperti *oversampling* atau metode penyesuaian probabilitas, untuk meningkatkan performa pada semua kelas.

Table 5. Hasil Model SVM

Model		Precision	Recall	F1-Score	Support
SVM	0	0.68	0.57	0.62	2085
	1	0.58	0.56	0.57	2100
	2	0.84	1.00	0.91	2064
	Accuracy			0.71	6249
	Macro Avg	0.70	0.71	0.70	6249
	Weighted Avg	0.70	0.71	0.70	6249

Sumber : Hasil Penelitian (2025)

Tabel 5 hasil evaluasi model Support Vector Machine (SVM) dalam klasifikasi keparahan kecelakaan. Model memperoleh akurasi sebesar 71%, dengan performa terbaik pada kelas 2 (kecelakaan fatal) yang memiliki F1-score 0.91. Namun, untuk kelas 0 (kecelakaan ringan) dan 1 (kecelakaan sedang), model menunjukkan F1-score yang lebih rendah, yaitu 0.62 dan 0.57. Meskipun model SVM cukup baik dalam mengklasifikasikan kecelakaan fatal, performanya masih perlu ditingkatkan dalam mengenali kecelakaan ringan dan sedang, misalnya dengan optimasi parameter atau penggunaan teknik penyeimbangan data.



Sumber : Hasil Penelitian (2025)

Gambar 5 Perbandingan Metrik Evaluasi Model Klasifikasi

Gambar 5 perbandingan metrik evaluasi dari empat model klasifikasi yang digunakan dalam penelitian, yaitu Random Forest, Decision Tree, Naïve Bayes, dan Support Vector Machine (SVM). Metrik yang dibandingkan mencakup Precision, Recall, F1-score, dan Accuracy, yang ditampilkan dengan warna berbeda. Dari hasil yang diperoleh, Random Forest dan SVM memiliki recall tertinggi, menunjukkan kemampuan yang lebih baik dalam mendeteksi semua kategori kecelakaan, terutama kecelakaan fatal. Sementara itu, akurasi tertinggi dicapai oleh Random Forest, diikuti oleh Decision Tree dan Naïve Bayes, sedangkan SVM memiliki akurasi yang lebih rendah dibandingkan model lainnya. Dari segi F1-score, Random Forest dan Naïve Bayes menunjukkan keseimbangan yang lebih baik antara precision dan recall, sementara SVM memiliki F1-score yang cukup baik tetapi akurasinya lebih rendah. Secara keseluruhan, Random Forest merupakan model dengan performa terbaik, sementara SVM kurang optimal dalam hal akurasi meskipun memiliki nilai recall yang tinggi. Untuk meningkatkan performa klasifikasi kecelakaan lalu lintas, dapat dilakukan tuning hyperparameter atau penyeimbangan data guna memperoleh hasil yang lebih optimal.

4. Kesimpulan

Hasil penelitian ini berhasil menggunakan model machine learning dapat digunakan secara efektif untuk mengklasifikasikan keparahan kecelakaan lalu lintas. Dari hasil evaluasi, Random Forest menunjukkan performa terbaik dengan akurasi 84%, diikuti oleh Naïve Bayes (82%), Decision Tree (77%), dan SVM (71%). Teknik SMOTE membantu meningkatkan akurasi beberapa model tetapi meningkatkan risiko *overfitting*, sedangkan PCA membantu mengurangi dimensi tanpa kehilangan informasi penting. Pemilihan model dan teknik penyeimbangan data

sangat berpengaruh terhadap performa klasifikasi. Sebagai prospek pengembangan, penelitian selanjutnya dapat mengeksplorasi metode deep learning atau kombinasi *ensemble models* guna meningkatkan akurasi dan stabilitas prediksi. Selain itu, penggunaan dataset yang lebih besar dan lebih beragam dapat meningkatkan kemampuan generalisasi model. Dari sisi penerapan, model yang dikembangkan dalam penelitian ini berpotensi digunakan dalam sistem prediksi kecelakaan berbasis data *real-time* untuk mendukung kebijakan keselamatan jalan raya dan perencanaan infrastruktur transportasi yang lebih baik.

Referensi

- [1] G. Han, T. Bu, M. Wang, H. Zheng, X. Sun, and L. Jin, "Text Classification of Railway Traffic Accidents Based on Dual-channel Bidirectional Long Short Term Memory Network," *Tiedao Xuebao/Journal China Railw. Soc.*, vol. 43, no. 9, 2021, doi: 10.3969/j.issn.1001-8360.2021.09.010.
- [2] Y. Ling, Z. Ma, X. Dong, and X. Weng, "A deep learning approach for robust traffic accident information extraction from online chinese news," *IET Intell. Transp. Syst.*, 2024, doi: 10.1049/itr2.12493.
- [3] G.-H. Jo and Y.-J. Song, "Image Data Generation System for Classification of Traffic Accident Scenarios," *J. Korean Inst. Inf. Technol.*, vol. 20, no. 4, 2022, doi: 10.14801/jkiit.2022.20.4.31.
- [4] Manja Danova Putri, Dina Fitria, Yenni Kurniawati, and Zilrahmi, "Classification the Characteristics of Traffic Accident Victims in Pariaman Using the Chi-square Automatic Interaction Detection Algorithm," *UNP J. Stat. Data Sci.*, vol. 2, no. 1, 2024, doi: 10.24036/ujsds/vol2-iss1/127.
- [5] S. Çeven and A. Albayrak, "Traffic accident severity prediction with ensemble learning methods," *Comput. Electr. Eng.*, vol. 114, 2024, doi: 10.1016/j.compeleceng.2024.109101.
- [6] I. El Mallahi, J. Riffi, H. Tairi, A. Ez-Zahout, and M. A. Mahraz, "A Distributed Big Data Analytics Model for Traffic Accidents Classification and Recognition based on SparkMLlib Cores," *J. Autom. Mob. Robot. Intell. Syst.*, vol. 16, no. 4, 2022, doi: 10.14313/jamris/4-2022/34.
- [7] Y. Wang, H. Zhai, X. Cao, and X. Geng, "Cause Analysis and Accident Classification of Road Traffic Accidents Based on Complex Networks," *Appl. Sci.*, vol. 13, no. 23, 2023, doi: 10.3390/app132312963.
- [8] A. V. Vitianingsih, N. Suryana, and Z. Othman, "Spatial analysis model for traffic accident-prone roads classification: A proposed framework," *IAES Int. J. Artif. Intell.*, vol. 10, no. 2, 2021, doi: 10.11591/ijai.v10.i2.pp365-373.
- [9] C. Oh and Y. Ban, "Cross-Modality Interaction-Based Traffic Accident Classification," *Appl. Sci.*, vol. 14, no. 5, 2024, doi: 10.3390/app14051958.
- [10] X. H. Wang, "Traffic accident data classification algorithm based on decision tree," *Adv. Transp. Stud.*, vol. 1, no. Special issue, 2022, doi: 10.53136/97912599481134.
- [11] A. V. Vitianingsih, Z. Othman, S. S. K. Baharin, and A. Suraji, "Empirical Study of a Spatial Analysis for Prone Road Traffic Accident Classification based on MCDM Method," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 5, 2022, doi: 10.14569/IJACSA.2022.0130578.
- [12] P. Gong, Q. Wang, and J. Zhu, "Classification of Emergency Responses to Fatal Traffic Accidents in Chinese Urban Areas," *Comput. Mater. Contin.*, vol. 68, no. 1, 2021, doi: 10.32604/cmc.2021.016483.
- [13] D. A. Saputro, "Classification of Traffic Accident Information Using Machine Learning from Social Media," *Int. J. Emerg. Trends Eng. Res.*, vol. 8, no. 3, 2020, doi: 10.30534/ijeter/2020/04832020.
- [14] A. D. Putra and A. S. Girsang, "Analysis of named-entity effect on text classification of traffic accident data using machine learning," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 25, no. 3, 2022, doi: 10.11591/ijeecs.v25.i3.pp1672-1678.
- [15] H. H. Joni, A. A. Mohammed, and A. A. Shakir, "Classification of traffic accidents datasets between 2003–2017 in Iraq," *Data Br.*, vol. 28, 2020, doi: 10.1016/j.dib.2019.104902.
- [16] Y. Zhang and Y. Sung, "Hybrid Traffic Accident Classification Models," *Mathematics*, vol. 11, no. 4, 2023, doi: 10.3390/math11041050.

- [17] M. Guo, Z. Yuan, B. Janson, Y. Peng, Y. Yang, and W. Wang, "Older pedestrian traffic crashes severity analysis based on an emerging machine learning xgboost," *Sustain.*, vol. 13, no. 2, 2021, doi: 10.3390/su13020926.
- [18] J. Li, F. Guo, Y. Zhou, W. Yang, and D. Ni, "Predicting the severity of traffic accidents on mountain freeways with dynamic traffic and weather data," *Transp. Saf. Environ.*, vol. 5, no. 4, 2023, doi: 10.1093/tse/tdad001.
- [19] M. Mohanty, R. Panda, S. R. Gandupalli, R. R. Arya, and S. K. Lenka, "Factors propelling fatalities during road crashes: A detailed investigation and modelling of historical crash data with field studies," *Heliyon*, vol. 8, no. 11, 2022, doi: 10.1016/j.heliyon.2022.e11531.
- [20] S. Awan *et al.*, "Profiling Casualty Severity Levels of Road Accident Using Weighted Majority Voting," *Comput. Mater. Contin.*, vol. 71, no. 2, 2022, doi: 10.32604/cmc.2022.019404.
- [21] R. Vanitha and M. Swedha, "Prediction of Road Accidents Using Machine Learning Algorithms," *Middle East J. Appl. Sci. Technol.*, vol. 06, no. 02, 2023, doi: 10.46431/mejast.2023.6208.
- [22] H. Bhuiyan *et al.*, "Crash severity analysis and risk factors identification based on an alternate data source: a case study of developing country," *Sci. Rep.*, vol. 12, no. 1, 2022, doi: 10.1038/s41598-022-25361-5.
- [23] Z. Iqbal, M. I. Khan, S. Hussain, and A. Habib, "An Efficient Traffic Incident Detection and Classification Framework by Leveraging the Efficacy of Model Stacking," *Complexity*, vol. 2021, 2021, doi: 10.1155/2021/5543698.
- [24] S. Pourroostaei Ardakani *et al.*, "Road Car Accident Prediction Using a Machine-Learning-Enabled Data Analysis," *Sustain.*, vol. 15, no. 7, 2023, doi: 10.3390/su15075939.
- [25] S. Birfir, A. Elalouf, and T. Rosenbloom, "Building machine-learning models for reducing the severity of bicyclist road traffic injuries," *Transp. Eng.*, vol. 12, 2023, doi: 10.1016/j.treng.2023.100179.
- [26] S. Zhang, A. Khattak, C. M. Matara, A. Hussain, and A. Farooq, "Hybrid feature selection-based machine learning Classification system for the prediction of injury severity in single and multiple-vehicle accidents," *PLoS One*, vol. 17, no. 2 February, 2022, doi: 10.1371/journal.pone.0262941.
- [27] M. Papadimitriou-Olivgeris *et al.*, "Predictors of mortality of trauma patients admitted to the ICU: a retrospective observational study☆," *Brazilian J. Anesthesiol. (English Ed.)*, vol. 71, no. 1, 2021, doi: 10.1016/j.bjane.2020.12.006.
- [28] M. I. Basheer Ahmed *et al.*, "A Real-Time Computer Vision Based Approach to Detection and Classification of Traffic Incidents," *Big Data Cogn. Comput.*, vol. 7, no. 1, 2023, doi: 10.3390/bdcc7010022.
- [29] S. Dong, A. Khattak, I. Ullah, J. Zhou, and A. Hussain, "Predicting and Analyzing Road Traffic Injury Severity Using Boosting-Based Ensemble Learning Models with SHAPley Additive exPlanations," *Int. J. Environ. Res. Public Health*, vol. 19, no. 5, 2022, doi: 10.3390/ijerph19052925.
- [30] M. M. R. Komol, M. M. Hasan, M. Elhenawy, S. Yasmin, M. Masoud, and A. Rakotonirainy, "Crash severity analysis of vulnerable road users using machine learning," *PLoS One*, vol. 16, no. 8 August, 2021, doi: 10.1371/journal.pone.0255828.
- [31] S. Ahmed, M. A. Hossain, S. K. Ray, M. M. I. Bhuiyan, and S. R. Sabuj, "A study on road accident prediction and contributing factors using explainable machine learning models: analysis and performance," *Transp. Res. Interdiscip. Perspect.*, vol. 19, 2023, doi: 10.1016/j.trip.2023.100814.
- [32] I. Aldhari, M. Almoshaogeh, A. Jamal, F. Alharbi, M. Alinizzi, and H. Haider, "Severity Prediction of Highway Crashes in Saudi Arabia Using Machine Learning Techniques," *Appl. Sci.*, vol. 13, no. 1, 2023, doi: 10.3390/app13010233.
- [33] V. Astarita, S. S. Haghshenas, G. Guido, and A. Vitale, "Developing new hybrid grey wolf optimization-based artificial neural network for predicting road crash severity," *Transp. Eng.*, vol. 12, 2023, doi: 10.1016/j.treng.2023.100164.
- [34] M. Megnidio-Tchoukouegno and J. A. Adedeji, "Machine Learning for Road Traffic Accident Improvement and Environmental Resource Management in the Transportation Sector," *Sustain.*, vol. 15, no. 3, 2023, doi: 10.3390/su15032014.

- [35] P. Infante *et al.*, "Comparison of Statistical and Machine-Learning Models on Road Traffic Accident Severity Classification," *Computers*, vol. 11, no. 5, 2022, doi: 10.3390/computers11050080.