

# ANALISIS PREDIKTIF BERBASIS METAHEURISTIK UNTUK KESELAMATAN PENUMPANG DALAM INSIDEN MARITIM: STUDI KASUS TITANIC

Bagus Winarko Nugroho<sup>1)</sup>, Supriyanto<sup>2)</sup>

<sup>1)</sup> Sistem Informasi, Fakultas Matematika dan Ilmu Pengetahuan Alama, Universitas Negeri Semarang

Sekarang Kampus Gunungpati, Semarang, Jawa Tengah, Indonesia

<sup>2)</sup> Bisnis Digital, Vokasi, Akademi Bisnis dan Keuangan Primaniyarta

Jl. A.A. Maramis No.273, Paniki Satu, Kec. Mapanget, Kota Manado, Sulawesi Utara

E-mail : <sup>1)</sup>[bagoes@mail.unnes.ac.id](mailto:bagoes@mail.unnes.ac.id), <sup>2)</sup>[supriyanto@abkprimaniyarta.ac.id](mailto:supriyanto@abkprimaniyarta.ac.id)

## ABSTRAK

Bencana maritim, seperti tragedi Titanic (1912), tetap menjadi fokus penelitian analitik prediktif tentang kelangsungan hidup penumpang. Studi ini menggunakan model pembelajaran mesin (ML) untuk menilai probabilitas kelangsungan hidup menggunakan Gaussian Naïve Bayes (GaussianNB), Decision Tree, dan k-Nearest Neighbors (KNN) pada kumpulan data yang terdiri dari 891 sampel pelatihan dan 418 sampel uji. Untuk meningkatkan akurasi model, Grey Wolf Optimization (GWO) diterapkan untuk penyetelan parameter, yang menghasilkan peningkatan signifikan: GaussianNB meningkat dari 79,02% menjadi 81,14% (+2,69%), Decision Tree meningkat dari 77,22% menjadi 80,59% (+3,37%), dan KNN naik dari 71,27% menjadi 79,58% (+8,31%). Temuan ini mengonfirmasi efektivitas optimasi berbasis metaheuristik dalam meningkatkan akurasi prediktif untuk klasifikasi kelangsungan hidup. Penelitian ini menunjukkan potensi GWO dalam mengoptimalkan model ML untuk aplikasi keselamatan maritim, menawarkan pendekatan yang lebih andal untuk penilaian risiko dan prediksi kelangsungan hidup dalam analisis transportasi dan bencana. **Kata kunci** : Analisis Prediktif, Optimasi Metaheuristik, GWO, Penilaian Risiko.

## ABSTRACT

*Maritime disasters, such as the Titanic tragedy (1912), remain a focus of predictive analytics research on passenger survival. This study employs machine learning (ML) models to assess survival probabilities using Gaussian Naïve Bayes (GaussianNB), Decision Tree, and k-Nearest Neighbors (KNN) on a dataset of 891 training and 418 test samples. To enhance model accuracy, Grey Wolf Optimization (GWO) is applied for parameter tuning, leading to significant improvements: GaussianNB improved from 79.02% to 81.14% (+2.69%), Decision Tree increased from 77.22% to 80.59% (+3.37%), and KNN rose from 71.27% to 79.58% (+8.31%). The findings confirm the effectiveness of metaheuristic-driven optimization in improving predictive accuracy for survival classification. This research demonstrates the potential of GWO in optimizing ML models for maritime safety applications, offering a more reliable approach to risk assessment and survival prediction in transportation and disaster analysis.*

**Keywords:** *Predictive Analytics, Metaheuristic Optimization, GWO, Risk Assessment.*

## 1. PENDAHULUAN

Bencana maritim telah menjadi perhatian penting sepanjang sejarah, dengan insiden yang menyebabkan hilangnya banyak nyawa dan kerusakan ekonomi. Salah satu tragedi paling terkenal adalah tenggelamnya RMS Titanic pada

tanggal 15 April 1912, yang mengakibatkan kematian sekitar 1.500 penumpang dan awak kapal. Peristiwa tersebut telah dianalisis secara ekstensif, khususnya dalam upaya untuk memahami faktor-faktor yang memengaruhi tingkat kelangsungan hidup penumpang. Dalam

beberapa tahun terakhir, teknik pembelajaran mesin (ML) telah diadopsi secara luas untuk memodelkan dan memprediksi hasil tersebut menggunakan kumpulan data historis. Kumpulan data Titanic, tersedia di Kaggle [1], merupakan tolok ukur yang terkenal untuk tugas klasifikasi pembelajaran terbimbing.

Meskipun bencana Titanic tetap menjadi studi kasus yang menonjol, kecelakaan maritim lainnya juga menyoroti perlunya analisis prediktif dalam manajemen keselamatan penumpang. Misalnya, bencana MV Doña Paz pada tahun 1987, yang merenggut lebih dari 4.000 nyawa, dan tenggelamnya Costa Concordia pada tahun 2012, di mana protokol keselamatan yang tidak memadai menyebabkan hilangnya 32 nyawa, menunjukkan pentingnya model prediksi kelangsungan hidup dalam meningkatkan peraturan keselamatan maritim. Model prediktif yang dilatih pada insiden maritim historis dapat memainkan peran penting dalam penilaian risiko, pengambilan keputusan, dan peningkatan kebijakan keselamatan.

Meskipun berbagai aplikasi pembelajaran mesin dalam prediksi kelangsungan hidup Titanic, penelitian sebelumnya terutama berfokus pada algoritma klasifikasi dasar seperti Gaussian Naïve Bayes (GaussianNB), Decision Tree, dan k-Nearest Neighbors (KNN) tanpa menggabungkan teknik pengoptimalan tingkat lanjut. Penelitian yang memanfaatkan algoritma mandiri ini telah melaporkan akurasi klasifikasi sedang, seringkali di bawah 80%. Misalnya: GaussianNB telah menunjukkan skor akurasi sebesar 78% [2], berjuang dengan varians yang tinggi dalam fitur kategoris. Decision Tree telah mencapai 75-77% [3], seringkali overfitting karena struktur pohon yang dalam. KNN umumnya menghasilkan 70-72% [4], sensitif terhadap penskalaan fitur dan ketidakseimbangan kumpulan data. Keterbatasan ini menunjukkan bahwa model ML standar saja mungkin tidak cukup untuk mencapai kinerja prediktif yang tinggi.

Chatterjee et al [5] melakukan analisis menggunakan regresi logistik ganda dan regresi logistik untuk menentukan apakah seorang penumpang selamat. Studi ini mengevaluasi

metrik kinerja di berbagai skenario dan menyimpulkan bahwa Regresi Linier Ganda mencapai akurasi maksimum 78,426%, sedangkan Regresi Logistik mencapai 80,756% Data [6]. Studi ini membandingkan algoritma Decision Tree dan Random Forest pada dataset Titanic. Decision Tree mencatat akurasi 84%, sementara Random Forest 81%. Penelitian ini juga menambahkan fitur baru seperti *child*, *new\_fare*, *title*, *FamilySize*, dan *FamilyIdentity*, serta menangani data hilang dengan imputasi rata-rata. Hasil menunjukkan Decision Tree lebih unggul dalam klasifikasi pada dataset ini. [7] Membandingkan implementasi Support Vector Machine (SVM) dengan 16 model klasifikasi yang berbeda, melaporkan tingkat kesalahan sebesar 20,81% dan 21,27% untuk Jaringan Syaraf Tiruan dan SVM, masing-masing, pada dataset Titanic. Demikian pula, Ratsch et al. [8] membandingkan pengklasifikasi AdaBoost dengan pengklasifikasi SVM dan Radial Basis Function (RBF), menemukan bahwa SVM menghasilkan tingkat kesalahan minimum sebesar 22,4%. Sementara itu, Li et al. [9] memasukkan SVM sebagai pengklasifikasi dasar dalam kerangka kerja AdaBoost, melaporkan tingkat kesalahan minimum sebesar 21,8% saat diuji pada dataset Titanic.

Penelitian Yudha Wibowo dkk model SVM yang dioptimasi dengan Grey Wolf Optimizer menghasilkan akurasi tertinggi sebesar 94,15%, melampaui SVM default serta model yang dioptimasi dengan Simulated Annealing dan Firefly Algorithm. Model ini juga unggul dalam precision, recall, dan F1-score [10].

Sri Rossa dkk Metode Hybrid Gradient Descent Grey Wolf Optimizer efektif meningkatkan akurasi model SVM untuk prediksi diabetes. Dengan dataset Pima Indians, model mencapai akurasi 81,17%, precision 75%, recall 57,45%, dan F1 score 65,6%. Hasil ini menunjukkan mampu mengoptimalkan hyperparameter SVM dan berpotensi digunakan untuk deteksi dini diabetes secara lebih akurat [11].

Penelitian M. Naufal Maulana dkk menunjukkan bahwa Genetic Algorithm dan Particle Swarm Optimization memiliki akurasi

yang sebanding (82%) dalam prioritas kebutuhan perangkat lunak, dengan GA lebih cepat (0,822 detik). Grey Wolf Optimization (GWO) sedikit lebih rendah akurasi (81%) dan lebih lambat, namun tetap menawarkan keunggulan dalam konteks optimasi tertentu. Sangat membantu pengembang perangkat lunak memilih algoritma yang tepat untuk efisiensi dan pengambilan keputusan yang lebih baik [12].

Penelitian yang dilakukan figi dkk bahwa kedua metode, PSO dan GWO, mampu menyelesaikan masalah aliran daya optimal. GWO menghasilkan total biaya pembangkitan lebih rendah (\$550,71/jam) dibanding PSO (\$553,88/jam), namun PSO menunjukkan konvergensi yang lebih cepat. Dengan demikian, GWO lebih efisien secara biaya, sementara PSO unggul dalam kecepatan optimasi [13].

Penelitian Afifudin dkk menunjukkan bahwa model SVM yang dioptimasi dengan Grey Wolf Optimizer mampu meningkatkan akurasi diagnosis retardasi mental hingga 95%, atau naik 5% dibanding SVM biasa. Grey Wolf Optimizer efektif dalam menyetel parameter SVM, sehingga menghasilkan model yang lebih akurat dan efisien untuk membantu diagnosis dini retardasi mental [14].

Untuk mengatasi tantangan ini, studi ini memperkenalkan Grey Wolf Optimization (GWO) sebagai pendekatan metaheuristik untuk menyempurnakan parameter model, sehingga meningkatkan akurasi klasifikasi. Terinspirasi oleh strategi perburuan kawanan serigala, GWO secara efektif mengoptimalkan hiperparameter dengan menyeimbangkan eksplorasi dan eksploitasi, sehingga sangat cocok untuk tugas klasifikasi kelangsungan hidup.

## 2. METODE PENELITIAN

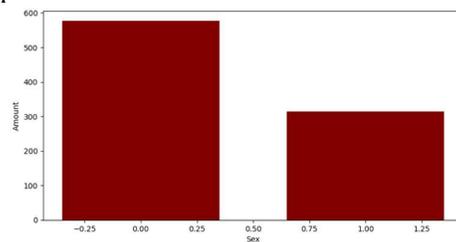
Dataset yang didapat pada penelitian ini diambil dataset public melalui platform Kaggle sumber dataset bias diakses melalui <https://www.kaggle.com/c/titanic> mencakup 891[15] sampel penumpang dalam set pelatihan, masing masing diberi label untuk menunjukkan status kelangsungan hidup mereka. Setiap penumpang dikaitkan dengan beberapa atribut, termasuk nama, jenis kelamin, usia, kelas tiket,

jumlah saudara kandung atau pasangan di dalam pesawat, jumlah orang tua atau anak di dalam pesawat, nomor kabin, nomor tiket, tarif tiket, dan pelabuhan keberangkatan. Data disediakan dalam format CSV (Comma Separated Value). Untuk set pengujian, Kaggle juga menawarkan 418 sampel penumpang dalam format CSV yang sama. Set data terdiri dari 12 fitur, yang mencakup variabel kategoris dan numerik. Tabel I merangkum atribut utama dari set data ini.

**Tabel 1.** Nilai parameter inisial dari simulasi

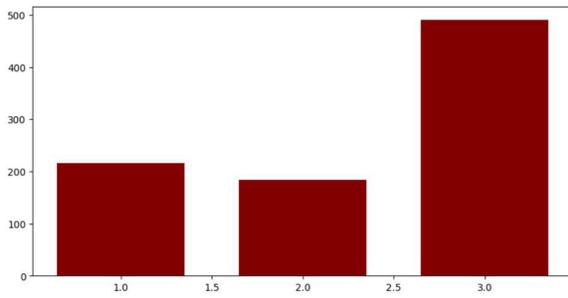
Fitur	Deskripsi	Jenis
<b>Survived</b>	1 = Survived, 0 = Did not survive	Target (Binary)
<b>Pclass</b>	Passenger class (1st, 2nd, 3rd)	Categorical
<b>Sex</b>	Gender (Male, Female)	Categorical
<b>Age</b>	Age of the passenger	Numerical
<b>SibSp</b>	Number of siblings/spouse s aboard	Numerical
<b>Fare</b>	Ticket price	Numerical
<b>Embarked</b>	Port of embarkation (C = Cherbourg, Q = Queenstown, S = Southampton)	Categorical

Sebelum membangun model, eksplorasi data dilakukan untuk mengidentifikasi faktor atau atribut yang dapat berkontribusi pada model klasifikasi untuk prediksi. Untuk memulai eksplorasi ini, beberapa plot X Y dibuat untuk memberikan gambaran umum tentang distribusi setiap atribut.



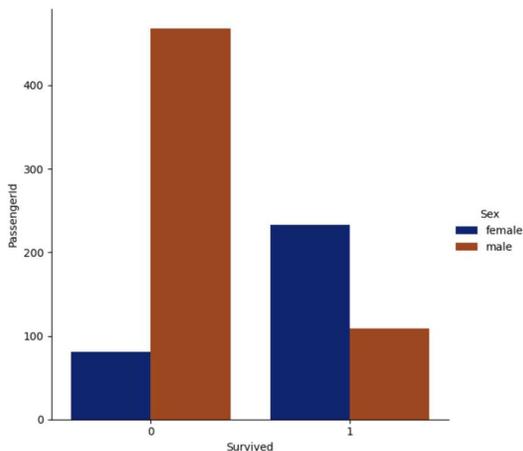
**Gambar 1.** Plot Bar Jenis Kelamin

Gambar 1 menunjukkan jumlah penumpang laki laki jauh lebih banyak dibandingkan penumpang perempuan, yakni sebanyak 577 penumpang laki laki dan 314 penumpang perempuan. Sementara itu, Gambar 2 menunjukkan distribusi kelas tiket (Pclass) yang menunjukkan mayoritas penumpang kelas 3, diikuti kelas 2, dan paling sedikit penumpang kelas 1.



**Gambar 2.** Plot Bar Kelas Tiket

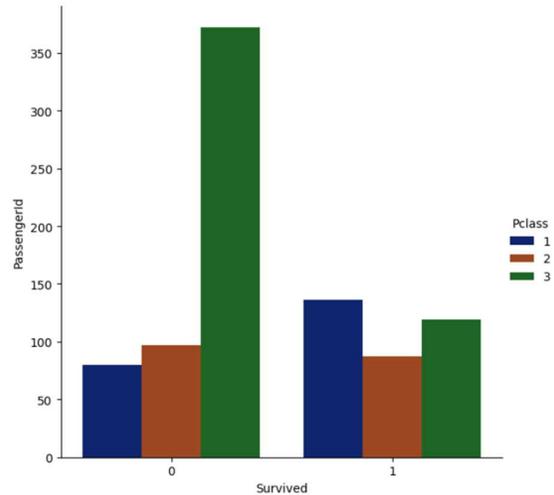
Lebih lanjut, Gambar 3 menunjukkan bahwa penumpang perempuan memiliki tingkat kelangsungan hidup sebesar 74,33%, jauh lebih tinggi daripada penumpang laki laki. Demikian pula, setiap atribut dianalisis untuk mengekstraksi fitur yang paling relevan untuk prediksi.



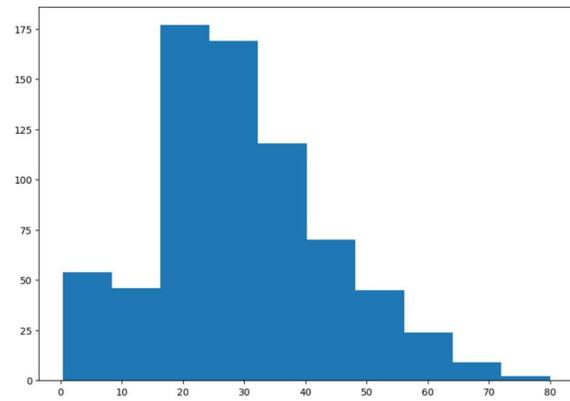
**Gambar 3.** Tingkat kelangsungan hidup berdasarkan Jenis Kelamin

Selain jenis kelamin, kelas tiket juga memainkan peran penting dalam kemungkinan bertahan hidup. Seperti yang ditunjukkan pada Gambar 4,

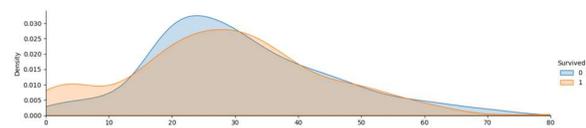
jumlah penyintas dari kelas 3 lebih tinggi daripada mereka yang berasal dari kelas 2 dan 1.



**Gambar 4.** Kelas P yang Bertahan Hidup



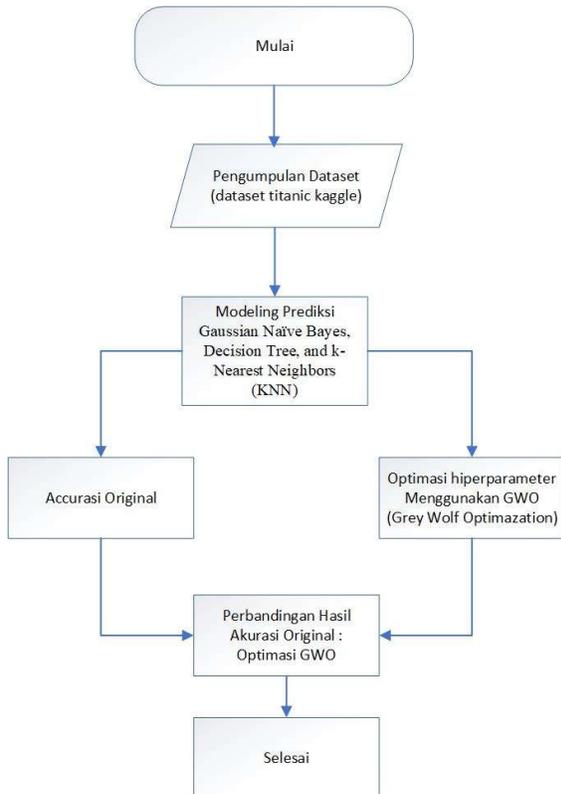
**Gambar 5.** Distribusi Usia penumpang



**Gambar 6.** Distribusi Usia Korban

Pada Gambar 5, distribusi usia penumpang menunjukkan bahwa sebagian besar berada dalam rentang usia 15 hingga 40 tahun. Selain itu, Gambar 6 menunjukkan bahwa anak-anak memiliki tingkat kelangsungan hidup yang lebih tinggi dibandingkan dengan penumpang yang lebih tua, yang menunjukkan bahwa anak-anak diprioritaskan selama upaya penyelamatan.

## 2.1 Alur Tahapan Penelitian



**Gambar 7.** Alur Tahapan Pengembangan Model Penelitian

Proses dimulai dengan merancang sistem prediksi kelangsungan hidup penumpang Titanic. Pertama dilakukan dengan pengambilan Data dari Kaggle dataset Titanic diunduh dari kompetisi resmi di Kaggle. Dataset ini berisi informasi penumpang seperti usia, jenis kelamin, kelas tiket, dan status keselamatan. Pra pemrosesan data pembersihan data: Mengatasi nilai yang hilang, duplikat, dan inkonsistensi. Encoding: Variabel kategorikal seperti Sex dan Embarked dikodekan menjadi numerik. Normalisasi: Skala fitur numerik disesuaikan. Feature Engineering: Fitur baru ditambahkan atau diseleksi berdasarkan relevansi.

Training Model ML Awal (Baseline) Algoritma Machine Learning digunakan untuk membuat model prediksi awal [16]: Gaussian Naïve Bayes (GNB), Decision Tree (DT) dan k Nearest Neighbors (KNN). Setiap model dilatih

pada data latih, dan akurasi baseline dicatat. Feature Selection Menggunakan Grey Wolf Optimization (GWO), GWO digunakan untuk memilih subset fitur terbaik secara otomatis dengan mengoptimalkan kombinasi fitur yang menghasilkan performa terbaik. GWO meniru perilaku sosial dan berburu serigala abu abu untuk mengeksplorasi dan mengeksploitasi ruang solusi secara efisien. Model GNB, DT, dan KNN dilatih ulang menggunakan fitur yang dipilih oleh GWO. Akurasi dan performa baru dicatat untuk membandingkan pengaruh dari seleksi fitur. Perbandingan Akurasi (Sebelum vs Sesudah GWO), Akurasi model sebelum dan sesudah optimasi dibandingkan untuk menilai seberapa besar peningkatan performa yang diberikan oleh GWO.

Hasil dan Interpretasi akhir mencakup model dengan performa terbaik, peningkatan akurasi, dan analisis pentingnya fitur (feature importance) untuk menjelaskan hasil prediksi. Proses pengembangan dan evaluasi model berakhir dengan pemilihan model optimal dan dokumentasi hasil.

## 3. HASIL DAN DISKUSI

Model prediktif dikembangkan menggunakan tiga algoritma Machine Learning (ML) utama: Gaussian Naïve Bayes, Decision Tree, dan k Nearest Neighbors (KNN). Setiap algoritma dievaluasi dan dibandingkan berdasarkan akurasi klasifikasi untuk menentukan efektivitasnya dalam memprediksi kelangsungan hidup penumpang. Untuk meningkatkan kinerja model, pemilihan fitur digabungkan menggunakan algoritma optimasi metaheuristik yang tangguh, Grey Wolf Optimization (GWO). Hasil yang diperoleh dari model dasar dibandingkan dengan hasil yang dioptimalkan melalui pemilihan fitur yang digerakkan oleh GWO untuk menilai dampak optimasi fitur terhadap peningkatan akurasi.

Pada penelitian ini, tiga model Machine Learning (ML) yang digunakan untuk memprediksi kelangsungan hidup penumpang Titanic dievaluasi menggunakan dua set kondisi: model asli tanpa optimasi dan model yang dioptimasi menggunakan Grey Wolf

Optimization (GWO) untuk pemilihan fitur. Hasil pengujian menunjukkan bahwa GWO memberikan peningkatan signifikan pada akurasi setiap model.

Gaussian Naïve Bayes (GaussianNB), yang memiliki akurasi awal sebesar 79,02%, mengalami peningkatan menjadi 81,14% setelah dioptimasi menggunakan GWO, mencatatkan peningkatan sebesar +2,69%.

Decision Tree, dengan akurasi awal 77,22%, meningkat menjadi 80,59% setelah pengoptimalan, memberikan peningkatan +3,37%.

k-Nearest Neighbors (KNN) menunjukkan peningkatan paling besar, dengan akurasi awal 71,27% meningkat menjadi 79,58% setelah dioptimasi, dengan total peningkatan +8,31%.

Peningkatan kinerja ini mengonfirmasi bahwa penerapan GWO untuk pemilihan fitur efektif dalam mengurangi gangguan dan meningkatkan akurasi model klasifikasi. Oleh karena itu, model yang dioptimasi dengan GWO menunjukkan akurasi yang lebih baik dibandingkan dengan model yang diuji tanpa optimasi, membuktikan bahwa GWO adalah metode yang efektif untuk meningkatkan akurasi prediksi dalam tugas klasifikasi kelangsungan hidup.

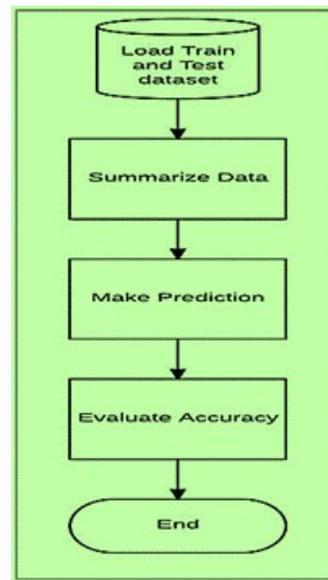
**Tabel 2.** Perbandingan Hasil Akurasi masing-masing model ML

	Model	Accuracy (Original)	Accuracy (GWO)
0	GaussianNB	0.790176	0.811431
1	DecisionTree	0.772186	0.805857
2	KNN	0.712705	0.795776

Naïve Bayes adalah algoritma klasifikasi yang menerapkan teorema Bayes untuk membangun model prediktif. Algoritma ini beroperasi dengan asumsi bahwa semua fitur bersifat independen satu sama lain, yang berarti bahwa probabilitas nilai fitur tertentu yang termasuk dalam suatu kelas tidak terpengaruh oleh nilai fitur lainnya. Asumsi ini, yang dikenal sebagai independensi

bersyarat, menyederhanakan perhitungan probabilitas dan membuat model menjadi efisien secara komputasi. Semua prediksi dan pelatihan model dilakukan menggunakan Python.

Dalam pendekatan ini, probabilitas kelas untuk contoh tertentu ditentukan dengan mengalikan probabilitas bersyarat dari semua nilai fitur. Kelas dengan probabilitas tertinggi ditetapkan sebagai label yang diprediksi [17]. Ada beberapa variasi algoritma Naïve Bayes, dan dalam penelitian ini, Gaussian Naïve Bayes (GaussianNB) dipilih. Alur kerja algoritma Naïve Bayes yang diterapkan dalam penelitian ini diilustrasikan pada Gambar 7. Pohon Keputusan



**Gambar 8.** Flowchart naive bayes [18]

Karena semua fitur dalam kumpulan data tersebut bersifat kategorikal atau numerik, variabel target adalah variabel biner kategorikal dengan nilai 0 (tidak bertahan) dan 1 (bertahan). Fitur yang tersisa juga kategorikal. GaussianNB menggunakan distribusi Gaussian (normal) untuk memperkirakan probabilitas nilai atribut tertentu yang termasuk dalam kelas tertentu. Probabilitas keseluruhan untuk suatu contoh dihitung dengan menggabungkan probabilitas semua nilai atribut, yang menghasilkan skor probabilitas akhir untuk setiap kelas. Kelas dengan probabilitas tertinggi ditetapkan sebagai hasil yang diprediksi.

Dengan menggunakan Gaussian Naïve Bayes, model tersebut mencapai akurasi klasifikasi sebesar 79,02%. Hasil ini berfungsi sebagai dasar dan kemudian dibandingkan dengan hasil yang diperoleh setelah pengoptimalan pemilihan fitur menggunakan Grey Wolf Optimization (GWO) untuk menilai dampaknya terhadap peningkatan akurasi.

Selanjutnya, klasifikasi Pohon Keputusan diterapkan untuk menganalisis prediksi kelangsungan hidup. Pembelajaran Pohon Keputusan adalah metode untuk membangun model seperti pohon dari data pelatihan berlabel. Pohon Keputusan terdiri dari struktur seperti diagram alir, di mana: Setiap simpul internal mewakili pengujian pada suatu atribut, Setiap cabang sesuai dengan hasil pengujian, dan setiap simpul daun (simpul terminal) memegang label kelas [19]. Simpul akar diposisikan di bagian atas pohon, berfungsi sebagai titik awal untuk pengambilan keputusan. Model Pohon Keputusan yang dilatih dalam studi ini memberikan beberapa wawasan utama mengenai probabilitas kelangsungan hidup.

Pengamatan Utama dari Model Pohon Keputusan: Jika seorang penumpang adalah perempuan dan termasuk dalam kelas 1 atau 2, probabilitas kelangsungan hidup adalah 0,95 (95%). Jika seorang penumpang adalah laki laki dan berusia 13 tahun atau lebih, probabilitas kelangsungan hidup turun menjadi 0,16 (16%). Temuan ini mengonfirmasi bahwa penumpang perempuan memiliki probabilitas kelangsungan hidup yang jauh lebih tinggi dibandingkan dengan laki laki. Selain itu, penumpang dari kelas 1 dan 2 memiliki peluang lebih besar untuk bertahan hidup dibandingkan dengan mereka yang berada di kelas 3. Aturan keputusan yang diperoleh dari model Pohon Keputusan konsisten dengan pola yang diamati dalam algoritma klasifikasi lainnya. Setelah pelatihan dan evaluasi, model Pohon Keputusan mencapai akurasi 77,21%.

Algoritma k Nearest Neighbors (KNN) juga digunakan untuk menganalisis prediksi survival. KNN adalah metode klasifikasi berbasis jarak yang menetapkan label kelas berdasarkan kelas mayoritas dari k tetangga terdekat dalam

kumpulan data. Tidak seperti algoritma klasifikasi lainnya, KNN adalah metode pembelajaran non parametrik dan berbasis instans, yang berarti bahwa metode ini tidak mengasumsikan distribusi probabilitas tertentu untuk data dan sebaliknya membuat prediksi berdasarkan ukuran kesamaan [20].

Cara Kerja KNN: Algoritma menghitung jarak antara instans uji dan semua instans pelatihan menggunakan jarak Euclidean atau metrik jarak lainnya. Memilih k tetangga terdekat dengan instans uji. Kelas dengan frekuensi tertinggi di antara tetangga yang dipilih ditetapkan sebagai label yang diprediksi untuk instans uji .

Kinerja KNN dalam Studi Ini [21]:

Model KNN dilatih dan dievaluasi menggunakan kumpulan data Titanic. Hasil awal sebelum pengoptimalan menunjukkan bahwa KNN memiliki kinerja yang relatif lebih rendah dibandingkan dengan pengklasifikasi lainnya, mencapai skor akurasi 71,27%. Performa model kemungkinan dipengaruhi oleh faktor faktor seperti: Kepekaan terhadap data yang tidak stabil dan fitur yang tidak relevan, Ketergantungan pada penskalaan fitur yang tepat, Pilihan nilai k yang memengaruhi tradeoff bias varians, Karena akurasinya yang lebih rendah, KNN dioptimalkan lebih lanjut menggunakan Grey Wolf Optimization (GWO) untuk pemilihan fitur, yang bertujuan untuk meningkatkan performa klasifikasinya dengan mengidentifikasi atribut yang paling relevan. Dampak GWO pada akurasi KNN akan dibahas di bagian berikutnya.

Algoritma Grey Wolf Optimization (GWO) terinspirasi dari perilaku berburu serigala, yang melibatkan pendekatan dan pengepungan mangsanya, kemudian mengejarnya hingga mangsanya tidak dapat bergerak sebelum akhirnya menyerang. Dalam pengembangan algoritma GWO, ditemukan bahwa serigala alfa ( $\alpha$ ) membantu memahami hierarki sosial serigala secara matematis dan memberikan solusi terbaik untuk masalah yang dihadapi. Solusi terbaik kedua dan ketiga masing masing diberikan oleh serigala beta ( $\beta$ ) dan delta ( $\delta$ ). Solusi lainnya diwakili oleh serigala omega ( $\omega$ ). Selama fase perburuan algoritma GWO, nilai  $\alpha$ ,  $\beta$ , dan  $\delta$  memandu proses optimasi. Serigala lainnya

mengikuti ketiga serigala ini. Selain hierarki sosial ini, perburuan kooperatif juga merupakan aspek penting dari perilaku sosial serigala abu abu. Selama berburu, serigala abu abu biasanya mengepung mangsanya. Persamaan (3), (4), dan (5) digunakan untuk menggambarkan perilaku ini secara matematis. Posisi serigala abu abu ke  $i$  dilambangkan dengan  $X_i^t$ , sedangkan posisi mangsanya dilambangkan dengan  $X_{best}^t$ . Kedua posisi direpresentasikan sebagai vektor  $d$  dimensi. Koefisien  $A_t$  dan  $B_t$  digunakan untuk menggambarkan pengaruh dalam proses ini, dan  $n$  menunjukkan jumlah iterasi yang telah dilakukan. Proses ini menjelaskan bagaimana serigala mengepung mangsanya.

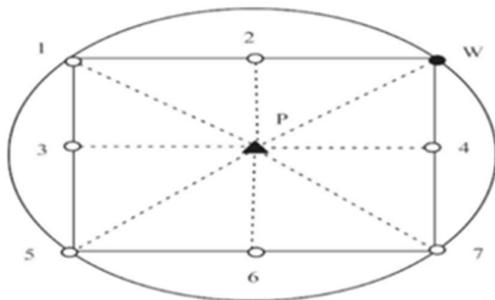
$$X_i^{t+1} = X_{best}^t - A_t D_i^t \quad (3)$$

$$D_i^{t+1} = B_t X_{best}^t - X_i^t \quad (4)$$

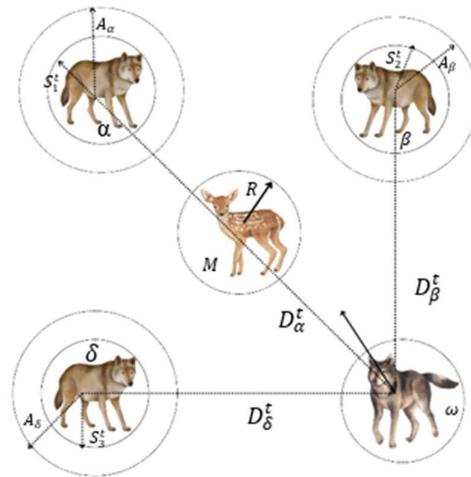
$$\begin{aligned} A_t &= 2S^t R_1 - S^t \\ B_t &= 2S^t R_2 - S^t \end{aligned} \quad (5)$$

Dimana  $r_1$  dan  $r_2$  adalah vektor acak dengan nilai antara 0 dan 1. Parameter  $S^t$  adalah vektor yang nilainya menurun dari 2 menjadi 0 seiring dengan bertambahnya jumlah iterasi.  $r_1$  dan  $r_2$  juga merupakan vektor acak dengan nilai antara 0 dan 1. Nilai parameter  $S^t$  disesuaikan dengan cara tertentu seperti yang ditunjukkan pada Persamaan (6)

$$S^t = 2 - t \left( \frac{2}{Max_t} \right) \quad (6)$$



**Gambar 9.** model perburuan serigala abu abu[22]



**Gambar 10.** Visualisasi perburuan serigala abu abu

Untuk mengevaluasi dan membandingkan kinerja ketiga model yang digunakan dalam studi ini, akurasi dipilih sebagai metrik evaluasi utama. Akurasi mengukur seberapa baik model memprediksi hasil, dengan akurasi yang lebih tinggi menunjukkan kinerja yang lebih baik. Perbandingan dilakukan untuk model asli dan versi yang dioptimalkan setelah menerapkan Grey Wolf Optimization (GWO) untuk pemilihan fitur. Hasil akhir evaluasi ini disajikan dalam tabel 2

#### 4. KESIMPULAN DAN SARAN

Studi ini mengevaluasi efektivitas tiga model Machine Learning (ML)—Gaussian Naïve Bayes (GaussianNB), Decision Tree, dan k Nearest Neighbors (KNN)—untuk memprediksi kelangsungan hidup penumpang pada dataset Titanic. Untuk meningkatkan kinerja model, Grey Wolf Optimization (GWO) diterapkan sebagai metode pemilihan fitur, dan hasilnya dibandingkan dengan model asli. Hasil eksperimen menunjukkan bahwa GWO secara signifikan meningkatkan akurasi klasifikasi di semua model:

1. GaussianNB meningkat dari 79,02% menjadi 81,14% (+2,69%)

2. Decision Tree meningkat dari 77,22% menjadi 80,59% (+3,37%)
3. KNN mencapai peningkatan paling substansial, naik dari 71,27% menjadi 79,58% (+8,31%)

Temuan ini mengonfirmasi bahwa pemilihan fitur yang digerakkan oleh metaheuristik, seperti GWO, dapat secara efektif meningkatkan kinerja klasifikasi ML dengan memilih atribut yang paling relevan, sehingga mengurangi gangguan dan meningkatkan akurasi prediktif.

Meskipun hasilnya menunjukkan peningkatan akurasi yang signifikan, beberapa area untuk penelitian di masa mendatang dapat dieksplorasi:

1. Memperluas Teknik Optimasi: Algoritma metaheuristik tambahan, seperti Algoritma Genetika (GA) atau Particle Swarm Optimization (PSO), dapat diuji untuk membandingkan efektivitasnya dengan GWO.
2. Optimalisasi Hiperparameter: Studi mendatang dapat mengeksplorasi pendekatan hibrida yang menggabungkan GWO dengan penyetelan hiperparameter untuk lebih menyempurnakan kinerja model.
3. Memperluas Aplikasi Kumpulan Data: Menerapkan metodologi yang diusulkan pada masalah prediksi kelangsungan hidup lainnya, seperti manajemen bencana atau prognosis perawatan kesehatan, dapat memvalidasi penerapannya yang lebih luas.
4. Integrasi Pembelajaran Mendalam: Menjelajahi model jaringan saraf yang dioptimalkan dengan GWO untuk prediksi kelangsungan hidup dapat lebih meningkatkan akurasi.

Sebagai kesimpulan, penelitian ini menyoroti potensi pemilihan fitur melalui GWO dalam meningkatkan akurasi model ML, khususnya

untuk masalah klasifikasi yang melibatkan data kelangsungan hidup historis. Integrasi teknik optimalisasi metaheuristik dapat memberikan peningkatan yang berharga dalam pengambilan keputusan berbasis data di berbagai domain. Tuliskan hasil kesimpulan Anda dalam bagian ini. Singkat saja tetapi jelas. Jangan mengulang terlalu banyak hal hal pada bagian Hasil dan Diskusi, akan tetapi rangkumkan. Bagian ini cukup satu paragraf saja.

## 5. DAFTAR PUSTAKA

- [1] W. Cukierski, "Titanic - Machine Learning from Disaster | Kaggle." 2025.
- [2] A. Tabbakh, J. K. Rout, and M. Rout, "Analysis and Prediction of the Survival of Titanic Passengers Using Machine Learning," in *Lecture Notes in Networks and Systems*, vol. 127, Springer, 2021, pp. 297–304. doi: 10.1007/978-981-15-4218-3\_29.
- [3] Y. Kakde and S. Agrawal, "Predicting Survival on Titanic by Applying Exploratory Data Analytics and Machine Learning Techniques," *Int. J. Comput. Appl.*, vol. 179, no. 44, pp. 32–38, May 2018, doi: 10.5120/ijca2018917094.
- [4] E. Ekinci, S. Omurca, and N. Acun, "A Comparative Study on Machine Learning Techniques Using Titanic Dataset." 2018.
- [5] M. Rajesh, "Prediction of survivors in the titanic cruise," *Int. J. Recent Technol. Eng.*, vol. 8, no. 3, pp. 1268–1271, Sep. 2019, doi: 10.35940/IJRTE.C4408.098319.
- [6] M. V Datla, "Bench marking of classification algorithms: Decision Trees and Random Forests-a case study using R," in *International Conference on Trends in Automation, Communication and Computing Technologies (I-TACT)*, Jun. 2016. doi: 10.1109/ITACT.2015.7492647.
- [7] D. Meyer, F. Leisch, and K. Hornik, "The support vector machine under test,"

- Neurocomputing*, vol. 55, no. 1--2, pp. 169–186, Sep. 2003, doi: 10.1016/S0925-2312(03)00431-4.
- [8] G. Rätsch, T. Onoda, and K. R. Müller, “Soft margins for AdaBoost,” *Mach. Learn.*, vol. 42, no. 3, pp. 287–320, Mar. 2001, doi: 10.1023/A:1007618119488.
- [9] X. Li, L. Wang, and E. Sung, “AdaBoost with SVM-based component classifiers,” *Eng. Appl. Artif. Intell.*, vol. 21, no. 5, pp. 785–795, Aug. 2008, doi: 10.1016/J.ENGAPPAI.2007.07.001.
- [10] Y. Wibowo, A. M. Widodo, G. Firmansyah, and B. Tjahjono, “Metaheuristic-Optimized SVM for Stunting Risk Detection in Pregnancy,” vol. 9, no. 2, pp. 841–848, 2025.
- [11] A. T. Sri Rossa Aisyah Puteri Baharie, Sugiyarto Surono, “Hybrid Gradient Descent Grey Wolf Optimizer for Machine Learning Performance Enhancement,” *Resti*, vol. 9, no. 1, pp. 146–152, 2025.
- [12] M. Z. Naufal Maulana, D. Siahaan, A. Saikhu, and E. Triandini, “Optimization Algorithm for Prioritizing Software Requirements: A Comparative Study,” in *2024 7th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, 2024, pp. 284–289. doi: 10.1109/ISRITI64779.2024.10963649.
- [13] B. Figi, G. Saputra, P. G. Chamdareno, E. Dermawan, K. Kunci, and A. Daya, “Analisa Perbandingan Aliran Daya Optimal pada Sistem Standar IEEE 30 Bus Menggunakan Metode Particle Swarm Optimization (PSO) dan Gray Wolf Optimizer (GWO),” vol. 7, no. 1, pp. 1–6, 2024.
- [14] M. Afifudin *et al.*, “GWO-SVM: An Approach To Improving Svm Performance Using Grey Wolf Optimizer In Intellectual Disability Classification,” vol. 12, no. 3, pp. 4440–4453, 2024.
- [15] Kaggle, “Titanic - Machine Learning from Disaster,” <https://www.kaggle.com/>. Accessed: Jun. 20, 2025. [Online]. Available: <https://www.kaggle.com/c/titanic/>
- [16] N. Cahyani, R. Irsyada, and A. Y. Kartini, “Implementasi Machine Learning Model sebagai Sistem Prediksi Penyakit Breast Cancer,” vol. 4, no. 2, pp. 1112–1120, 2024.
- [17] S. A. Widiana, “Prediksi Pertumbuhan Bibit Tanaman Pada Greenhouse Menggunakan Metode Adaptive Neuro Fuzzy Inference System (ANFIS).” 2020.
- [18] M. Saputra, “FLOOD PREDICTION WITH NAIVE BAYES METHOD,” *Technovasia J. Technol. & Comput. Res. Innov. Sci. Appl.*, vol. 1, no. 1, pp. 10–17, 2025.
- [19] Z. Nahda, A. Rahma, L. H. AlFath, and S. Suhairi, “Konsep Pohon Keputusan,” *VISA J. Vis. Ideas*, vol. 2, no. 1, pp. 135–142, 2022.
- [20] C. Wang, F. You, and Y. Wang, “Text Intelligent Classification Model Based on Improved KNN Algorithm in Library Service Transformation,” *Syst. Soft Comput.*, p. 200313, 2025.
- [21] W. Lixin *et al.*, “An EPS-kNN Fault Propagation Analysis Method for Industrial Processes Based on the Fusion of Knowledge and Data (March 2025),” *IEEE Access*, 2025.
- [22] G. Negi, A. Kumar, S. Pant, and M. Ram, “GWO: a review and applications,” *Int. J. Syst. Assur. Eng. Manag.*, vol. 12, pp. 1–8, 2021.