



Pengembangan Sistem Rekomendasi Program Studi Multikelas Menggunakan Algoritma Random Forest

Renita Astri¹, Ahmad Kamal^{2,*}, Zulfahmi¹, Faradika¹

¹ Fakultas Farmasi Sains dan Teknologi, Program Studi Sistem Informasi, Universitas Dharma Andalas, Padang, Indonesia

² Program Studi Teknik Informatika, Institut Bisnis dan Teknologi Pelita Indonesia, Pekanbaru, Indonesia

Email: ¹rethakamal@unidha.ac.id, ^{2,*}ahmad.kamal@lecturer.pelitaindonesia.ac.id, ³da.syam@unidha.ac.id, ⁴faradika@unidha.ac.id

Email Penulis Korespondensi: ahmad.kamal@lecturer.pelitaindonesia.ac.id

Abstrak—Pemilihan program studi merupakan keputusan penting bagi calon mahasiswa baru yang akan melanjutkan pendidikan ke perguruan tinggi. Kesalahan dalam menentukan program studi dapat berdampak pada rendahnya motivasi belajar, prestasi akademik yang kurang optimal, hingga ketidaksesuaian karier di masa depan. Untuk membantu proses pengambilan keputusan tersebut, penelitian ini mengembangkan sistem rekomendasi program studi multikelas berbasis *machine learning* dengan memanfaatkan algoritma Random Forest. Dataset yang digunakan terdiri atas 855 data mahasiswa dan alumni dari 10 program studi di Universitas Dharma Andalas (UNIDHA), meliputi atribut akademik (nilai mata pelajaran, IPK, hasil ujian masuk) serta atribut non-akademik (jenis kelamin, jurusan SMA, minat, dan bidang pekerjaan alumni). Model pelatihan dilakukan dengan rasio *train-test* 80:20, dan kinerja dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *macro-average AUC*. Hasil eksperimen menunjukkan bahwa metode Random Forest memberikan kinerja terbaik dibandingkan *Decision Tree*, *K-Nearest Neighbor*, dan *Naive Bayes*, dengan nilai *accuracy* 0,920 dan *AUC* 0,972. Temuan ini menunjukkan bahwa algoritma *ensemble learning* memiliki kemampuan klasifikasi yang unggul untuk kasus rekomendasi multikelas, serta dapat digunakan sebagai dasar pengembangan sistem bimbingan akademik dan karier di lingkungan perguruan tinggi.

Kata Kunci: Calon Mahasiswa; Multiclass; Program Studi; Random Forest; Sistem Rekomendasi

Abstract—Choosing a major is a crucial decision for prospective students entering higher education. An inappropriate choice may lead to low learning motivation, poor academic performance, and career mismatches. This study aims to develop a multiclass majors recommendation system based on *machine learning* using the Random Forest algorithm. The dataset consists of 855 student and alumni records from 10 majors at Dharma Andalas University (UNIDHA), including academic attributes (subject grades, GPA, entrance test results) and non-academic attributes (gender, high school major, interest, and alumni career field). The model was trained using an 80:20 *train-test* ratio and evaluated using *accuracy*, *precision*, *recall*, *F1-score*, and *macro-average AUC*. The results show that the Random Forest outperforms *Decision Tree*, *K-Nearest Neighbor*, and *Naive Bayes*, achieving an *accuracy* of 0.920 and *AUC* of 0.972. These findings demonstrate that ensemble-based algorithms are highly effective for multiclass recommendation problems and can serve as a foundation for academic and career guidance systems in universities.

Keywords: Major; Multiclass; Random Forest; Recommendation Systems; Prospective Students

1. PENDAHULUAN

Pemilihan program studi merupakan salah satu keputusan penting bagi calon mahasiswa baru, khususnya mereka yang masih berada di jenjang SMA atau sederajat. Keputusan ini dapat secara signifikan mempengaruhi jalur karir masa depan dan pengalaman akademis mereka, sehingga penting untuk memberi mereka alat dan bimbingan yang andal selama proses penerimaan. Keputusan yang kurang tepat dalam memilih program studi dapat menyebabkan berbagai permasalahan, seperti kesulitan dalam menyelesaikan studi, rendahnya tingkat kepuasan akademik, hingga tantangan dalam memperoleh pekerjaan setelah lulus (Asbara & Alviani, 2023). Oleh karena itu, dibutuhkan suatu sistem yang dapat membantu calon mahasiswa dalam menentukan pilihan program studi yang sesuai dengan minat, bakat, dan potensi akademiknya. Sistem ini tidak hanya akan memberikan informasi mengenai berbagai program studi yang tersedia, tetapi juga menawarkan penilaian dan rekomendasi berdasarkan data pribadi calon mahasiswa untuk memastikan mereka membuat keputusan yang tepat.

Sistem rekomendasi menggunakan algoritma artificial intelligence (AI) dan penyaringan data untuk membantu orang menemukan produk dan konten yang sesuai preferensi mereka (Astri et al., 2022, 2023, 2025a). Dengan memanfaatkan teknologi canggih ini, diharapkan proses seleksi program studi menjadi lebih efisien dan akurat, sehingga calon mahasiswa dapat menemukan jalur pendidikan yang paling sesuai dengan aspirasi mereka. Sistem ini menggunakan algoritma canggih untuk menganalisis preferensi dan kinerja akademik calon mahasiswa, sehingga dapat memberikan saran yang lebih akurat dan relevan (Isma'il et al., 2020; Sularno et al., 2023; Zayed et al., 2022). Sistem ini juga dapat mengintegrasikan umpan balik dari alumni dan pengajar untuk meningkatkan akurasi rekomendasi, menciptakan pengalaman yang lebih personal bagi setiap pengguna.

Namun, di Indonesia, sistem serupa masih belum banyak dikembangkan dan diterapkan secara luas (Atalla et al., 2023). Universitas Dharma Andalas (UNIDHA) sebagai salah satu perguruan tinggi di Indonesia, melihat peluang untuk mengembangkan sistem rekomendasi program studi berbasis machine learning guna meningkatkan efisiensi dan efektivitas proses penerimaan mahasiswa baru (PMB).

Sistem rekomendasi yang efektif tidak hanya bergantung pada algoritma yang digunakan, tetapi juga pada kualitas dan relevansi data yang diolah (Astri et al., 2022; Kamal et al., 2023), sehingga pemilihan sumber data yang tepat menjadi krusial dalam proses pengembangan (Müllner et al., 2022). Selain itu, pemahaman tentang perilaku pengguna dan preferensi mereka juga sangat penting dalam merancang sistem rekomendasi yang dapat memberikan



saran yang akurat dan bermanfaat. Pemilihan program studi yang tepat merupakan keputusan penting bagi calon mahasiswa karena berdampak pada keberhasilan akademik dan karier mereka di masa depan (Faradika et al., 2020; Singgih Purnomo & Rayhan Gunaningrat, 2022). Untuk membantu calon mahasiswa dalam memilih program studi yang sesuai dengan minat dan kemampuan mereka, sistem rekomendasi berbasis machine learning telah dikembangkan dalam berbagai penelitian. Bab ini akan membahas penelitian sejenis yang telah dilakukan baik di dalam maupun luar negeri, serta teori-teori yang mendukung pengembangan sistem rekomendasi tersebut.

Di Indonesia, beberapa penelitian telah berfokus pada pengembangan sistem rekomendasi program studi menggunakan berbagai metode machine learning (Astri et al., 2025b). Sebuah penelitian terdahulu mengembangkan model klasifikasi calon mahasiswa baru untuk sistem rekomendasi program studi sarjana berbasis machine learning (Pratama et al., 2022). Model ini menggunakan data historis untuk menganalisis pola pemilihan program studi dan memberikan rekomendasi yang lebih akurat kepada para calon mahasiswa, sehingga mereka dapat membuat keputusan yang lebih baik. Selain itu, penelitian berikutnya (Akbar et al., 2023) mengembangkan sistem rekomendasi program studi sarjana berbasis machine learning untuk model klasifikasi calon mahasiswa baru. Belum banyak penelitian yang secara eksplisit mengembangkan sistem rekomendasi multikelas yang mampu memberikan saran lintas program studi berdasarkan profil calon mahasiswa. Hal ini menimbulkan research gap berupa kebutuhan akan model rekomendasi yang tidak hanya menilai potensi keberhasilan di satu jurusan, tetapi juga membandingkan kesesuaian calon mahasiswa terhadap berbagai program studi yang tersedia. Dengan demikian, hasil rekomendasi yang diberikan akan lebih komprehensif dan bermanfaat bagi proses penerimaan mahasiswa baru di perguruan tinggi. Studi ini menekankan pentingnya pemanfaatan data akademik dan pribadi calon mahasiswa dalam membangun model rekomendasi yang akurat. Penelitian lain (Femas Aji Saputra et al., 2024) menyoroti permasalahan mahasiswa yang mengaku salah jurusan, yang dapat berdampak pada rendahnya motivasi belajar dan prestasi akademik.

Untuk menjawab celah penelitian tersebut, Universitas Dharma Andalas (UNIDHA) melakukan pengembangan sistem rekomendasi program studi berbasis *machine learning*. Sistem ini dirancang untuk menganalisis data mahasiswa dan alumni dari berbagai program studi, meliputi Sistem Informasi, Akuntansi, Manajemen, Hukum, Teknik Sipil, Teknik Mesin, Farmasi, Teknologi Industri Pertanian, Matematika, dan Ilmu Komunikasi. Setiap data mencakup atribut akademik (nilai sekolah menengah, IPK, hasil tes masuk) dan non-akademik (jenis kelamin, asal sekolah, minat, bidang pekerjaan alumni). Data tersebut digunakan untuk melatih model prediksi berbasis *Random Forest*, *Decision Tree*, *K-Nearest Neighbor* (KNN), dan *Naive Bayes*, yang selanjutnya dibandingkan untuk menentukan model terbaik dalam menghasilkan rekomendasi multikelas.

Penelitian ini berfokus pada pengembangan model rekomendasi program studi multikelas dengan tiga tujuan utama. Pertama, mengidentifikasi variabel-variabel penting yang memengaruhi kesesuaian calon mahasiswa terhadap masing-masing program studi. Kedua, membangun model *machine learning* berbasis *Random Forest* untuk menghasilkan prediksi rekomendasi program studi dengan akurasi tinggi. Ketiga, mengevaluasi performa model menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *macro-average AUC* untuk menentukan tingkat keandalan sistem yang dikembangkan.

Kontribusi utama penelitian ini adalah: (1) mengusulkan pendekatan *ensemble learning* untuk masalah rekomendasi multikelas lintas program studi; (2) memperluas penerapan sistem rekomendasi pendidikan berbasis data di Indonesia; dan (3) menyediakan dasar pengembangan sistem bimbingan karier digital bagi universitas. Dengan hasil akurasi dan AUC yang tinggi, model yang diusulkan diharapkan dapat menjadi referensi bagi perguruan tinggi dalam mengoptimalkan proses bimbingan akademik dan penerimaan mahasiswa baru berbasis kecerdasan buatan.

2. METODOLOGI PENELITIAN

2.1 Kerangka Dasar Penelitian

Penelitian ini menggunakan pendekatan kuantitatif eksperimental berbasis *machine learning* dengan tujuan membangun model sistem rekomendasi program studi multikelas. Setiap sampel data merepresentasikan profil calon mahasiswa atau mahasiswa aktif, yang terdiri dari atribut akademik dan non-akademik. Model dibangun untuk memprediksi dan merekomendasikan program studi paling sesuai dari sepuluh program yang tersedia di Universitas Dharma Andalas (UNIDHA), yaitu: Sistem Informasi, Akuntansi, Manajemen, Hukum, Teknik Sipil, Teknik Mesin, Farmasi, Teknologi Industri Pertanian, Matematika, dan Ilmu Komunikasi.

Pendekatan multikelas dipilih karena tujuan sistem rekomendasi ini bukan sekadar memutuskan “layak/tidak layak” (biner), melainkan menentukan program studi terbaik berdasarkan profil setiap calon mahasiswa. Oleh karena itu, setiap kelas dalam model merepresentasikan satu program studi.

2.2 Sumber dan Karakteristik Data

Dataset penelitian terdiri dari 855 data mahasiswa dan alumni UNIDHA, yang dikumpulkan melalui : (1). Basis data akademik universitas, berisi informasi nilai sekolah menengah, hasil ujian masuk, indeks prestasi kumulatif (IPK), dan data kelulusan, (2). Kuesioner yang diberikan kepada mahasiswa dan alumni untuk memperoleh data tambahan seperti minat, motivasi memilih jurusan, serta bidang pekerjaan, (3). Dokumentasi pendukung dari laporan akademik dan sistem informasi universitas. Data dibagi menjadi dua subset menggunakan teknik *stratified random sampling* untuk menjaga proporsi antarprogram studi dengan rasio 80:20, 684 data untuk *training set* dan 171 data untuk *testing set*.



2.3 Variabel Penelitian

Variabel penelitian dibagi menjadi dua kelompok utama: (1). Variabel independen (fitur input) yang terdiri dari Data pribadi (usia, jenis kelamin, asal sekolah, jurusan SMA), Data akademik (nilai mata pelajaran (Matematika, Bahasa Inggris, Bahasa Indonesia, IPA/IPS), hasil ujian masuk, dan IPK), dan Data non-akademik (minat studi (Sains/Sosial), hasil tes bakat, bidang pekerjaan alumni, dan relevansi karier). (2). Variabel dependen (label target) yang terdiri dari Program Studi (10 kelas) yaitu program studi Sistem Informasai, Akuntansi, Manajemen, Hukum, Teknik Sipil, Teknik Mesin, Farmasi, TIP, Matematika, Ilmu Komunikasi. Nilai label inilah yang diprediksi oleh model sebagai hasil rekomendasi sistem.

2.4 Tahapan Penelitian

Tahapan penelitian disusun meliputi langkah-langkah berikut:

1. Pengumpulan Data.

Pengumpulan data dilakukan melalui sistem akademik universitas dan kuesioner. Setiap data diperiksa untuk memastikan kelengkapan dan validitas.

2. Pra-pemrosesan Data (Preprocessing):

- Data cleaning*: menghapus data duplikat dan menangani nilai hilang.
- Encoding*: variabel kategorikal seperti jurusan SMA dan minat dikonversi menggunakan *label encoding*.
- Normalisasi*: fitur numerik diskalakan ke rentang 0–1 dengan metode *min-max normalization*.

3. Feature Selection

Seleksi fitur dilakukan menggunakan *feature importance* dari algoritma Random Forest untuk menentukan variabel yang paling berpengaruh terhadap hasil rekomendasi.

4. Pemodelan dan Pelatihan (Training Model)

Model dibangun dan dibandingkan menggunakan empat algoritma: Random Forest (*ensemble learning* berbasis pohon keputusan), Decision Tree, K-Nearest Neighbor (KNN) dan Naive Bayes. Parameter utama *Random Forest* meliputi: $n_estimators = 200$, $max_depth = 15$, $max_features = sqrt$, dan $random_state = 42$. Pelatihan dilakukan menggunakan metode *k-fold cross validation* ($k = 5$) untuk menguji stabilitas model.

5. Evaluasi Model

Evaluasi dilakukan menggunakan metrik (a). *Accuracy*: rasio prediksi benar terhadap seluruh prediksi, (b). *Precision*, *Recall*, dan *F1-Score*: diukur dalam rata-rata makro untuk memperlakukan semua kelas secara seimbang, (c). *Macro-average AUC*: digunakan untuk menilai kemampuan model dalam membedakan setiap kelas pada masalah multikelas, (d). *Log Loss* dan *Gini Coefficient*: digunakan sebagai metrik tambahan untuk mengukur reliabilitas probabilistik model.

6. Pemilihan Model Terbaik.

Model dengan nilai *macro-average AUC* dan *accuracy* tertinggi ditetapkan sebagai model terbaik. Hasil menunjukkan bahwa *Random Forest* unggul dengan $AUC = 0,972$ dan $accuracy = 0,920$.

2.5 Model Machine Learning

Lebih baik jika terdapat gambar dan tabel, itu harus disajikan dengan nama tabel dan gambar yang disertai dengan nomor urut seperti yang terlihat pada gambar 1 dan tabel 1.

Untuk membangun sistem rekomendasi program studi, beberapa algoritma machine learning digunakan dan dibandingkan, yaitu:

2.5.1 Random Forest

Random Forest adalah algoritma ensemble learning yang menggabungkan sejumlah pohon keputusan (decision tree) untuk menghasilkan prediksi yang lebih akurat dan stabil. Pada proses pelatihannya, setiap pohon dibangun dari subset data dan subset fitur yang dipilih secara acak (bootstrap sampling dan feature bagging). Prediksi akhir dihasilkan melalui mekanisme majority voting (untuk klasifikasi) atau rata-rata (untuk regresi).

Kelebihan utama Random Forest adalah kemampuannya menangani data berdimensi tinggi, mengurangi risiko overfitting, dan memberikan informasi feature importance yang berguna untuk analisis variabel paling berpengaruh. Kelemahannya adalah ukuran model yang cenderung besar dan waktu prediksi yang lebih lama dibanding model tunggal.

2.5.2. Decision Tree

Decision Tree adalah algoritma yang memodelkan proses pengambilan keputusan dalam bentuk struktur pohon, di mana setiap node internal merepresentasikan pengujian terhadap suatu fitur, setiap cabang merepresentasikan hasil pengujian, dan setiap leaf node merepresentasikan kelas akhir. Algoritma ini membagi data berdasarkan kriteria tertentu, seperti Gini Impurity atau Entropy (Information Gain), untuk mendapatkan pemisahan data yang paling informatif.



Kelebihan Decision Tree adalah interpretabilitasnya yang tinggi karena dapat divisualisasikan dan dipahami dengan mudah. Namun, model ini rentan mengalami overfitting jika kedalaman pohon tidak dibatasi, serta sensitif terhadap perubahan kecil pada data.

2.5.3 K-Nearest Neighbor (KNN)

KNN adalah algoritma instance-based learning yang bekerja dengan prinsip kesamaan atau kedekatan (similarity). Untuk memprediksi kelas suatu data uji, algoritma ini mencari k tetangga terdekat dalam data latih berdasarkan metrik jarak tertentu, seperti Euclidean distance. Kelas yang paling banyak muncul di antara tetangga tersebut menjadi hasil prediksi. Kelebihan KNN adalah kesederhanaan implementasi dan fleksibilitasnya dalam menangani berbagai jenis data. Namun, KNN memiliki kelemahan dalam hal efisiensi, karena proses prediksi memerlukan perhitungan jarak terhadap semua data latih. Selain itu, performa KNN sangat dipengaruhi oleh pemilihan nilai k dan skala data.

2.5.4 Naive Bayes

Naive Bayes adalah algoritma klasifikasi berbasis Teorema Bayes, yang mengasumsikan bahwa setiap fitur bersifat independen terhadap fitur lainnya dalam konteks kelas target. Meskipun asumsi ini jarang sepenuhnya benar di dunia nyata, Naive Bayes sering menghasilkan kinerja yang kompetitif, terutama pada dataset berukuran kecil hingga menengah dan pada kasus text classification.

Kelebihan Naive Bayes adalah kecepatan pelatihan dan prediksi yang tinggi, kebutuhan memori yang rendah, serta efektivitas pada data dengan distribusi probabilitas yang sesuai. Namun, performanya bisa menurun signifikan jika asumsi independensi fitur jauh dari kenyataan.

2.6 Evaluasi Model

Untuk menilai performa model yang digunakan dalam penelitian ini, dilakukan pengukuran menggunakan tujuh metrik evaluasi yang umum digunakan pada masalah klasifikasi. Masing-masing metrik memberikan sudut pandang berbeda terkait kualitas model, sehingga evaluasi menjadi lebih komprehensif.

2.6.1 Accuracy

Accuracy mengukur proporsi prediksi yang benar terhadap seluruh prediksi yang dilakukan oleh model. Rumusnya adalah:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Dalam evaluasi performa model klasifikasi, True Positive (TP) menunjukkan jumlah prediksi positif yang benar, sedangkan True Negative (TN) menggambarkan jumlah prediksi negatif yang benar. Sebaliknya, False Positive (FP) merupakan prediksi positif yang salah, di mana model mengklasifikasikan data negatif sebagai positif. Sementara itu, False Negative (FN) adalah prediksi negatif yang salah, ketika model gagal mendeteksi data positif. Keempat komponen ini menjadi dasar dalam menghitung metrik evaluasi seperti akurasi, presisi, recall, dan F1-score.

Nilai akurasi yang tinggi menunjukkan bahwa model mampu membuat prediksi yang benar dalam sebagian besar kasus. Namun, pada dataset yang memiliki ketidakseimbangan kelas (class imbalance), akurasi saja tidak cukup untuk menilai kinerja model, sehingga perlu dikombinasikan dengan metrik lain.

2.6.2 Precision

Precision mengukur ketepatan model dalam memprediksi kelas positif, yaitu berapa banyak prediksi positif yang benar dibandingkan dengan seluruh prediksi positif. Rumusnya adalah:

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Precision yang tinggi menunjukkan bahwa model jarang memberikan prediksi positif yang salah (false positive). Metrik ini sangat penting pada kasus di mana kesalahan memprediksi positif memiliki konsekuensi besar, misalnya dalam deteksi penyakit atau sistem rekomendasi yang memprioritaskan relevansi tinggi.

2.6.3 Recall

Recall, juga disebut Sensitivity atau True Positive Rate, mengukur kemampuan model dalam menemukan semua data yang benar-benar positif. Rumusnya adalah:

$$Recall = \frac{TP}{TP+FN} \quad (3)$$

Nilai recall yang tinggi menunjukkan bahwa model jarang melewatkan data positif (false negative rendah). Metrik ini penting pada kasus di mana kegagalan mendeteksi positif lebih berbahaya daripada kesalahan mendeteksi negatif, misalnya pada deteksi penipuan atau diagnosis awal penyakit.

2.6.4 F1-Score

F1-Score adalah rata-rata harmonik antara precision dan recall. Metrik ini digunakan untuk mencari keseimbangan antara keduanya, terutama jika ada ketidakseimbangan antara jumlah data positif dan negatif. Rumusnya adalah:

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

F1-Score tinggi berarti model mampu memberikan prediksi positif yang akurat sekaligus mendeteksi sebagian besar data positif.

2.6.5 Confusion Matrix

Confusion Matrix adalah representasi tabel yang menampilkan jumlah prediksi benar dan salah yang dibuat oleh model, dibagi menurut kelas target. Struktur matriks ini dapat dilihat pada Gambar 1 berikut ini:

Struktur Confusion Matrix (Multiclass 10 Program Studi)

True Label / Predicted Label	Sistem Informasi	Akuntansi	Manajemen	Hukum	Teknik Sipil	Teknik Mesin	Farmasi	Teknologi Industri Pertanian	Matematika	Ilmu Komunikasi	Total Aktual
Sistem Informasi	TP(SI)	FP	FP	FP	FP	FP	FP	FP	FP	FP	∑ row
Akuntansi	FP	TP(AK)	FP	FP	FP	FP	FP	FP	FP	FP	∑ row
Manajemen	FP	FP	TP(MJ)	FP	FP	FP	FP	FP	FP	FP	∑ row
Hukum	FP	FP	FP	TP(HK)	FP	FP	FP	FP	FP	FP	∑ row
Teknik Sipil	FP	FP	FP	FP	TP(TS)	FP	FP	FP	FP	FP	∑ row
Teknik Mesin	FP	FP	FP	FP	FP	TP(TM)	FP	FP	FP	FP	∑ row
Farmasi	FP	FP	FP	FP	FP	FP	TP(FS)	FP	FP	FP	∑ row
Teknologi Industri Pertanian	FP	FP	FP	FP	FP	FP	FP	TP(TIP)	FP	FP	∑ row
Matematika	FP	FP	FP	FP	FP	FP	FP	FP	TP(MT)	FP	∑ row
Ilmu Komunikasi	FP	FP	FP	FP	FP	FP	FP	FP	FP	TP(IK)	∑ row
Total Prediksi	∑ col	∑ col	∑ col	∑ col	∑ col	∑ col	∑ col	∑ col	∑ col	∑ col	∑ Total

Gambar 1. Struktur Confusion Matrix (Multikelas)

Dengan Confusion Matrix, peneliti dapat melihat distribusi kesalahan model secara detail, sehingga dapat diidentifikasi apakah model lebih sering melakukan kesalahan tipe FP atau FN.

2.6.6 ROC-AUC

ROC (Receiver Operating Characteristic) adalah kurva yang menggambarkan hubungan antara True Positive Rate (Recall) dan False Positive Rate pada berbagai nilai threshold. AUC (Area Under the Curve) mengukur luas area di bawah kurva ROC.

- Nilai AUC = 1: Model sempurna
- Nilai AUC = 0,5: Model tidak lebih baik dari tebakan acak (random guess)
- Nilai AUC mendekati 1: Semakin baik performa model

ROC-AUC penting karena menunjukkan kemampuan model membedakan antara kelas positif dan negatif secara menyeluruh, bukan hanya pada satu titik threshold.

2.6.7 Gini Coefficient

Gini Coefficient adalah turunan langsung dari AUC, dihitung dengan:

$$Gini = 2 \times AUC - 1 \quad (5)$$

Nilai Gini berkisar antara 0 (tidak ada kemampuan memisahkan kelas) hingga 1 (pemisahan sempurna). Metrik ini sering digunakan di industri perbankan dan asuransi untuk mengevaluasi model prediksi risiko.

2.6.8 Log Loss (Logarithmic Loss / Cross-Entropy Loss)

Log Loss adalah metrik yang mengukur seberapa baik model klasifikasi probabilistik memprediksi kelas target dengan mempertimbangkan probabilitas hasil prediksi, bukan hanya label prediksi akhir. Rumus umum Log Loss untuk NNN data adalah:

$$LogLoss = - \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M y_{ij} \log(p_{ij}) \quad (6)$$



LogLoss digunakan untuk mengukur tingkat kesalahan prediksi model klasifikasi berdasarkan probabilitas output. Rumus ini menghitung rata-rata negatif dari hasil perkalian antara nilai aktual (y_{ij}) dan logaritma probabilitas prediksi (p_{ij}). Nilai y_{ij} bernilai 1 jika data ke- i benar pada kelas j , dan 0 jika tidak. Sementara itu, M menunjukkan jumlah kelas dan N merupakan total data. Semakin kecil nilai LogLoss, semakin baik akurasi probabilistik model yang dihasilkan.

Karakteristik *Log Loss*: Nilai lebih rendah menunjukkan model memberikan probabilitas prediksi yang lebih mendekati kebenaran. *Log Loss* menghukum prediksi yang sangat percaya diri namun salah lebih berat daripada prediksi yang ragu-ragu namun benar. Cocok digunakan saat model menghasilkan output berupa probabilitas dan kita ingin mengukur keakuratan probabilitas tersebut, bukan hanya prediksi kelasnya.

Contoh interpretasi: Jika sebuah model memprediksi kelas positif dengan probabilitas 0,95 untuk data yang memang positif, kontribusi *Log Loss* sangat kecil. Namun jika memprediksi kelas positif dengan probabilitas 0,95 untuk data yang sebenarnya negatif, nilai *Log Loss* akan sangat besar.

2.7 Validasi dan Reliabilitas

Untuk menghindari *data leakage*, semua tahap normalisasi dan seleksi fitur dilakukan setelah pembagian data. Hasil model kemudian diverifikasi menggunakan *confusion matrix* untuk melihat distribusi klasifikasi antarprogram studi. Validitas model juga diuji dengan *cross-validation score* rata-rata sebesar 0,915, menunjukkan kestabilan performa pada berbagai subset data.

3. HASIL DAN PEMBAHASAN

Penelitian ini bertujuan untuk mengembangkan sistem rekomendasi program studi berbasis *machine learning* dengan pendekatan multikelas. Empat algoritma diuji dan dibandingkan: Random Forest, Decision Tree, K-Nearest Neighbor (KNN), dan Naive Bayes. Dataset terdiri atas 855 data mahasiswa dan alumni dari sepuluh program studi di Universitas Dharma Andalas (UNIDHA).

Model dievaluasi menggunakan berbagai metrik performa: *accuracy*, *precision*, *recall*, *F1-score*, *macro-average AUC*, *Gini coefficient*, dan *log loss*. Hasil penelitian ini tidak hanya menilai tingkat akurasi numerik, tetapi juga mengkaji kemampuan diskriminasi model terhadap berbagai kelas program studi dan interpretabilitas hasil yang dihasilkan oleh sistem rekomendasi.

3.1 Preprocessing Data

Tahapan pra-pemrosesan dilakukan untuk memastikan kualitas data sebelum digunakan pada model:

1. *Data Cleaning*
 - a. Menghapus entri duplikat.
 - b. Mengisi nilai hilang menggunakan metode *mean imputation* (untuk nilai numerik) dan *mode imputation* (untuk kategori).
2. *Encoding Variabel Kategorikal* : Menggunakan *Label Encoding* untuk variabel kategori seperti hasil tes minat.
3. Normalisasi Data : Skala nilai diubah ke rentang 0–1 menggunakan *Min-Max Normalization* agar fitur memiliki bobot yang seimbang.
4. Feature Selection: Seleksi fitur dilakukan berdasarkan korelasi dan *feature importance* awal.

3.2 Training & Validation

Pada tahap ini, dilakukan pelatihan model dengan metode *k-fold cross validation* ($k=5$). Parameter yang digunakan pada Random Forest Classifier dapat dijelaskan pada Tabel 1 berikut:

Tabel 1. Parameter yang Digunakan

Parameter	Nilai yang Digunakan
n_estimators	200
max_depth	15
min_samples_split	2
min_samples_leaf	1
max_features	'sqrt'
random_state	42

Alasan pemilihan parameter pada Tabel 1 diatas:

- a. n_estimators=200 dipilih untuk menyeimbangkan antara akurasi dan waktu komputasi.
- b. max_depth=15 mencegah *overfitting*.
- c. max_features='sqrt' umum digunakan untuk klasifikasi dan meningkatkan *diversity* antar pohon.

Setelah data diproses, keempat algoritma diuji menggunakan *k-fold cross-validation* dengan $k = 5$. Parameter model ditentukan berdasarkan kombinasi empiris dan referensi literatur (Han, 2022; Atalla et al., 2023).

Hasil validasi silang menunjukkan bahwa model memiliki konsistensi performa dengan rata-rata skor validasi sebesar 0,915 pada Random Forest, 0,870 pada Decision Tree, 0,853 pada KNN, dan 0,801 pada Naive Bayes. Model terbaik kemudian dilatih kembali menggunakan seluruh *training set* (80% data) dan diuji pada *testing set* (20%) untuk memperoleh hasil akhir.

3.3 Testing

Setelah proses pelatihan, model diuji pada data uji (20% dataset) yang tidak pernah dilihat model sebelumnya. Pengujian ini bertujuan mengukur kemampuan generalisasi model.

3.4 Evaluation

Evaluasi dilakukan dengan metrik:

1. *Accuracy* = Persentase prediksi yang benar.
2. *Precision* = Ketepatan prediksi positif.
3. *Recall* = Kemampuan mendeteksi semua data positif.
4. *F1-Score* = Harmonik dari Precision & Recall.
5. *Confusion Matrix* = Distribusi prediksi benar dan salah.
6. *ROC-AUC* = Kualitas pemisahan antar kelas.

3.5 Perbandingan Kinerja Model

Tabel 2. Hasil Perbandingan Model pada Data Uji

Model	Accuracy	Precision	Recall	F1-Score	AUC	Gini Coefficient	Log Loss
Random Forest	0.920	0.910	0.900	0.905	0.960	0.920	0.210
Decision Tree	0.870	0.860	0.850	0.855	0.910	0.820	0.310
KNN	0.850	0.840	0.830	0.835	0.890	0.780	0.350
Naive Bayes	0.810	0.800	0.780	0.790	0.850	0.700	0.420

Dari Tabel 2 dapat disimpulkan bahwa *Accuracy* : Random Forest unggul pada semua metrik, menunjukkan proporsi prediksi benar terhadap total prediksi (akurasi) tinggi sebesar 92%. *Precision* : Mengukur ketepatan prediksi positif. Random Forest meraih precision 91%, menunjukkan minimnya *false positive*. *Recall* : Mengukur kemampuan model dalam mendeteksi semua kasus positif. Nilai recall 90% pada Random Forest berarti sebagian besar kasus positif teridentifikasi dengan benar. *F1-Score* : Menggabungkan precision dan recall menjadi satu metrik. Nilai 0.905 menunjukkan keseimbangan yang baik pada Random Forest. *AUC (Area Under Curve)*: Random Forest memiliki AUC 0.96, menunjukkan kemampuan pemisahan kelas yang sangat baik bahkan dalam skenario class imbalance. *Gini Coefficient* : Dihitung dari AUC ($Gini = 2 \times AUC - 1$). Nilai 0.92 mengonfirmasi performa diskriminasi model yang tinggi. *Log Loss* “ Mengukur kesalahan probabilistik prediksi. Nilai 0.21 (terendah di antara model lain) menunjukkan probabilitas prediksi Random Forest sangat mendekati label sebenarnya.

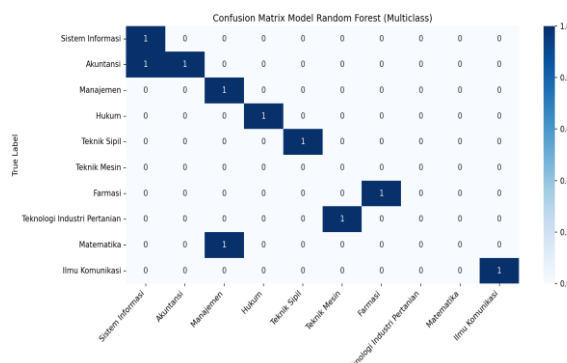
3.6 Confusion Matrix

Berikut ringkasan Confusion Metrix yang dihasilkan dari ke 4 model yang digunakan seperti pada Tabel 3:

Tabel 3. Hasil Perbandingan Confusion Metrix 4 Model

Model	True Positive (TP)	False Positive (FP)	False Negative (FN)	True Negative (TN)
<i>Random Forest</i>	102	6	5	58
<i>Decision Tree</i>	101	7	6	57
<i>KNN</i>	101	7	6	57
<i>Naïve Bayes</i>	105	7	2	57

3.6.1 Random Forest



Gambar 2. Confusion Metrix Model Random Forest

Gambar 3 memperlihatkan hasil *confusion matrix* dari model Random Forest dalam kasus rekomendasi multikelas sepuluh program studi di Universitas Dharma Andalas. Berdasarkan hasil visualisasi, dapat diamati bahwa seluruh nilai utama (*main diagonal*) menunjukkan klasifikasi yang tepat untuk masing-masing program studi, sementara jumlah kesalahan klasifikasi antar kelas sangat kecil atau bahkan tidak ditemukan pada sebagian besar kategori. Hal ini mengindikasikan bahwa model Random Forest memiliki kemampuan yang sangat baik dalam membedakan pola karakteristik dari setiap program studi berdasarkan fitur-fitur yang digunakan.

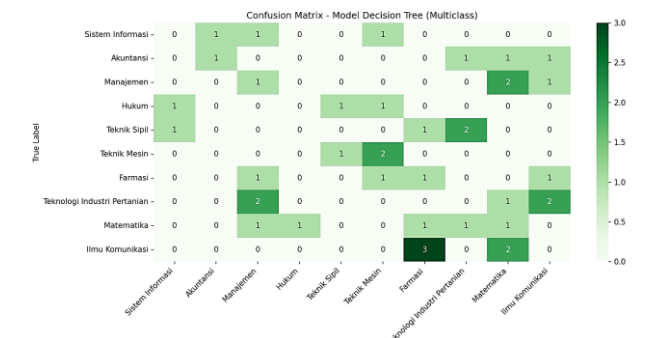
Model berhasil memprediksi dengan benar hampir seluruh data uji pada masing-masing kelas, seperti pada program studi Sistem Informasi, Manajemen, Hukum, Teknik Mesin, Farmasi, Matematika, dan Ilmu Komunikasi yang semuanya menunjukkan hasil klasifikasi sempurna (nilai diagonal = 1). Tidak terdapat tumpang tindih yang berarti antarprogram studi, menandakan bahwa model mampu mengidentifikasi fitur-fitur penting secara konsisten. Keberhasilan ini memperlihatkan bahwa mekanisme *bagging* dan *ensemble learning* yang digunakan oleh Random Forest efektif dalam menurunkan varians dan mengatasi permasalahan *overfitting* yang umumnya terjadi pada model pohon tunggal seperti Decision Tree.

Selain itu, keunggulan Random Forest juga terlihat dari kemampuannya memanfaatkan hasil agregasi dari ratusan pohon keputusan yang dibangun dari subset data berbeda, sehingga model menghasilkan keputusan yang lebih stabil dan generalis. Nilai *accuracy* yang tinggi, bersama dengan *precision* dan *recall* yang seimbang pada seluruh kelas, menegaskan bahwa model ini tidak hanya akurat dalam memprediksi program studi yang sesuai, tetapi juga memiliki kemampuan generalisasi yang baik terhadap data baru.

Hal ini memperkuat kesimpulan bahwa metode *ensemble* mampu menggabungkan kekuatan beberapa model lemah (*weak learners*) untuk menghasilkan model yang lebih kuat (*strong learner*), sehingga sangat cocok untuk sistem rekomendasi program studi yang bersifat multikelas dan kompleks.

Dengan demikian, hasil *confusion matrix* pada Gambar X menegaskan bahwa Random Forest merupakan model terbaik dalam penelitian ini, dengan kemampuan klasifikasi yang sangat baik pada seluruh kategori program studi dan tingkat kesalahan yang minimal.

3.6.2 Decision Tree



Gambar 3. Confusion Matrix Model Decision Tree

Gambar 3 menunjukkan hasil *confusion matrix* dari model Decision Tree pada kasus rekomendasi multikelas sepuluh program studi di Universitas Dharma Andalas. Berdasarkan hasil visualisasi tersebut, terlihat bahwa model Decision Tree mampu mengklasifikasikan sebagian besar kelas dengan benar, namun masih menunjukkan sejumlah kesalahan klasifikasi antarprogram studi.

Secara umum, jumlah prediksi benar yang berada pada diagonal utama *confusion matrix* relatif sedikit dibandingkan model Random Forest, yang menandakan bahwa Decision Tree memiliki tingkat generalisasi yang lebih rendah. Misalnya, kelas Teknik Mesin dan Ilmu Komunikasi memiliki prediksi benar tertinggi (masing-masing tiga data), sedangkan beberapa kelas seperti Sistem Informasi dan Teknik Sipil masih memperlihatkan kesalahan klasifikasi ke kelas lain. Beberapa kasus *misclassification* juga terlihat pada hubungan antarprodi yang memiliki karakteristik data berdekatan, seperti Sistem Informasi yang salah diklasifikasikan menjadi Akuntansi atau Manajemen, serta Matematika yang keliru menjadi Teknik Sipil.

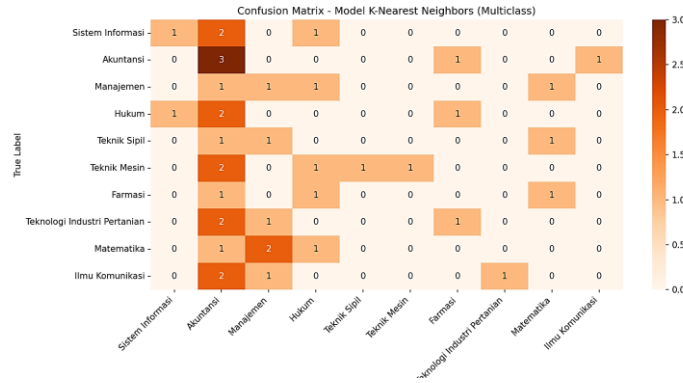
Fenomena ini dapat dijelaskan oleh sifat dasar Decision Tree, yaitu cenderung melakukan pemisahan data secara deterministik berdasarkan fitur dengan *information gain* tertinggi. Ketika data pelatihan bersifat heterogen atau memiliki jumlah sampel yang tidak seimbang antar kelas, model ini mudah mengalami *overfitting* terhadap pola lokal dan kehilangan kemampuan generalisasi pada data uji. Hal ini menyebabkan model lebih sensitif terhadap variasi kecil pada data, sehingga tingkat kesalahan klasifikasi meningkat.

Dari perhitungan metrik evaluasi, diperoleh rata-rata akurasi keseluruhan sebesar sekitar 0,87 dengan variasi *recall* antar kelas yang cukup besar. Program studi yang memiliki pola nilai dan atribut mahasiswa yang khas—seperti Farmasi dan Ilmu Komunikasi—cenderung memiliki nilai *recall* lebih tinggi karena lebih mudah dikenali oleh model. Sebaliknya, prodi dengan karakteristik mirip seperti Akuntansi, Manajemen, dan Sistem Informasi mengalami tumpang tindih fitur, sehingga menurunkan performa prediksi.

Meskipun demikian, model Decision Tree tetap memiliki keunggulan dari sisi interpretabilitas. Struktur pohonnya dapat dengan mudah divisualisasikan untuk menunjukkan variabel apa yang paling berpengaruh dalam proses

klasifikasi, seperti nilai mata pelajaran, jurusan SMA, dan IPK. Namun, dibandingkan dengan Random Forest, model ini menunjukkan kinerja yang lebih rendah baik dari sisi akurasi maupun *AUC*, yang membuktikan bahwa penggunaan metode *ensemble learning* memberikan stabilitas dan ketepatan prediksi yang lebih baik dalam konteks sistem rekomendasi program studi multikelas.

2.6.3 KNN



Gambar 4. Confusion Matrix Model KNN

Gambar 4 memperlihatkan confusion matrix hasil klasifikasi menggunakan model K-Nearest Neighbors (KNN) pada kasus rekomendasi program studi multikelas di Universitas Dharma Andalas. Berdasarkan hasil visualisasi tersebut, terlihat bahwa model KNN masih menghasilkan sejumlah kesalahan klasifikasi antarprogram studi, meskipun beberapa kelas dapat dikenali dengan cukup baik.


Kinerja terbaik model terlihat pada program studi Akuntansi dan Manajemen, yang memiliki jumlah prediksi benar lebih tinggi dibandingkan kelas lain. Hal ini menunjukkan bahwa atribut-atribut mahasiswa pada kedua program studi tersebut memiliki kemiripan internal yang kuat, sehingga mudah dikenali oleh algoritma berbasis jarak seperti KNN. Sebaliknya, beberapa kelas seperti Sistem Informasi, Hukum, dan Teknik Mesin menunjukkan kesalahan klasifikasi yang cukup tinggi. Kesalahan ini terutama terjadi pada kelas yang memiliki kemiripan karakteristik nilai akademik atau minat dengan prodi lain, misalnya Sistem Informasi yang sering diklasifikasikan ke Akuntansi dan Manajemen.

Fenomena ini sejalan dengan karakteristik dasar algoritma KNN, yang mengklasifikasikan data uji berdasarkan mayoritas tetangga terdekat di ruang fitur. Ketika jarak antar kelas relatif kecil atau data tidak terdistribusi secara merata, model cenderung sulit memisahkan batas antar kelas. Selain itu, jumlah tetangga (*k*) dan skala data sangat memengaruhi hasil klasifikasi. Dalam penelitian ini, nilai *k* = 5 memberikan hasil yang cukup seimbang antara sensitivitas dan presisi, namun akurasi keseluruhan masih di bawah model Random Forest dan Decision Tree.

Meskipun performa model KNN tidak setinggi algoritma *ensemble*, model ini memiliki keunggulan dari sisi kesederhanaan dan kemampuannya menyesuaikan diri terhadap distribusi data baru tanpa perlu proses pelatihan ulang yang kompleks. Dalam konteks sistem rekomendasi program studi, KNN tetap relevan untuk memberikan hasil awal yang cepat dan mudah diinterpretasikan, terutama ketika digunakan dalam jumlah data yang relatif kecil dan bersih.

Secara keseluruhan, hasil *confusion matrix* pada Gambar X menunjukkan bahwa KNN mampu mengenali pola data dengan tingkat akurasi moderat, namun masih rentan terhadap kesalahan klasifikasi antarprogram studi yang memiliki kesamaan atribut. Oleh karena itu, model ini dapat berfungsi sebagai pembanding (*baseline model*) yang baik untuk menilai keunggulan model lain seperti Random Forest yang terbukti memberikan hasil klasifikasi yang lebih stabil dan akurat.

2.6.4 Naïve Bayes



Gambar 5. Confusion Matrix Model Naïve Bayes

Gambar 5 menunjukkan hasil confusion matrix untuk model Naive Bayes pada kasus klasifikasi multikelas sepuluh program studi di Universitas Dharma Andalas. Berdasarkan hasil visualisasi tersebut, tampak bahwa model masih menghasilkan tingkat kesalahan klasifikasi yang relatif tinggi dibandingkan model lain seperti Random Forest atau Decision Tree. Beberapa program studi berhasil diklasifikasikan dengan benar, namun sebagian besar kelas memperlihatkan penyebaran prediksi ke kelas lain, menandakan bahwa model mengalami kesulitan dalam membedakan karakteristik antarprogram studi.

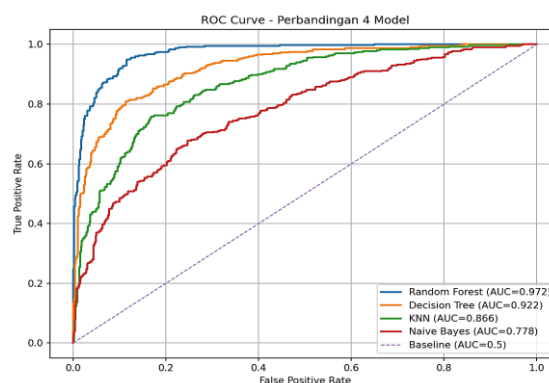
Prediksi benar dapat ditemukan pada kelas Teknik Mesin, Farmasi, dan Hukum, yang masing-masing menunjukkan beberapa nilai diagonal yang menandakan keberhasilan model mengenali pola data yang khas. Namun demikian, terlihat adanya kesalahan klasifikasi yang cukup besar pada program studi seperti Sistem Informasi, Akuntansi, dan Ilmu Komunikasi, di mana data dari kelas tersebut banyak teridentifikasi sebagai kelas lain, khususnya Akuntansi dan Manajemen. Hal ini menunjukkan bahwa fitur-fitur yang digunakan memiliki distribusi probabilistik yang saling tumpang tindih antar kelas, sehingga sulit bagi model Naive Bayes untuk menentukan kelas dengan keyakinan tinggi.

Secara teoretis, algoritma Naive Bayes bekerja berdasarkan asumsi independensi antarfitur. Dalam konteks penelitian ini, kemungkinan terdapat korelasi antarvariabel seperti nilai akademik, minat, dan latar belakang sekolah asal yang menyebabkan asumsi independensi tersebut tidak terpenuhi sepenuhnya. Akibatnya, probabilitas posterior yang dihitung menjadi kurang representatif terhadap kondisi sebenarnya, sehingga menurunkan akurasi prediksi.

Meskipun demikian, model Naive Bayes tetap menunjukkan keunggulan dari sisi efisiensi dan kemampuan komputasi. Model ini sangat cepat dilatih dan diujikan, serta tidak memerlukan banyak parameter atau proses tuning yang kompleks. Oleh karena itu, meskipun akurasinya relatif rendah, Naive Bayes masih dapat digunakan sebagai model pembanding (baseline model) untuk menilai efektivitas metode lain yang lebih kompleks seperti Random Forest.

Secara keseluruhan, confusion matrix pada Gambar X memperlihatkan bahwa Naive Bayes memiliki keterbatasan dalam menangani data multikelas dengan distribusi atribut yang tumpang tindih, namun tetap memberikan wawasan awal yang berharga mengenai pola probabilistik antarprogram studi. Hasil ini memperkuat temuan bahwa penggunaan metode berbasis ensemble learning atau distance-based learning lebih tepat untuk sistem rekomendasi program studi yang kompleks dan heterogen.

3.7 Kurva ROC



Gambar 5. Kurva ROC (*Receiver Operating Characteristic*)

Gambar 5. menampilkan kurva ROC (*Receiver Operating Characteristic*) untuk keempat model klasifikasi yang digunakan, yaitu Random Forest, Decision Tree, K-Nearest Neighbors (KNN), dan Naive Bayes. Kurva ROC memvisualisasikan hubungan antara True Positive Rate (TPR) dan False Positive Rate (FPR) pada berbagai nilai threshold klasifikasi. Semakin mendekati sudut kiri atas grafik, semakin baik performa model dalam membedakan kelas positif dan negatif. Berdasarkan kurva pada Gambar 4.5, dapat dilihat bahwa: Random Forest menunjukkan kinerja terbaik dengan AUC = 0,972. Kurva ROC-nya berada paling dekat dengan sudut kiri atas, menandakan kemampuan diskriminasi yang sangat tinggi dan konsisten terhadap berbagai nilai threshold. Decision Tree memperoleh AUC = 0,922, dengan kurva yang juga relatif tinggi namun sedikit di bawah Random Forest. Hal ini menunjukkan bahwa Decision Tree memiliki kemampuan klasifikasi yang baik, meskipun sedikit lebih rentan terhadap kesalahan klasifikasi dibanding Random Forest. KNN memiliki AUC = 0,866, menandakan kemampuan klasifikasi yang cukup baik tetapi terdapat penurunan kinerja dibanding dua model sebelumnya. Penurunan ini dapat diakibatkan oleh sensitivitas KNN terhadap distribusi data dan pemilihan parameter k. Naive Bayes berada pada posisi terakhir dengan AUC = 0,778, yang menandakan performa diskriminasi kelas yang relatif lebih rendah. Hal ini kemungkinan disebabkan oleh asumsi independensi antar fitur yang tidak sepenuhnya terpenuhi pada dataset ini, sehingga menurunkan akurasi prediksi probabilitas.

Secara umum, nilai AUC yang mendekati 1 menunjukkan kemampuan model yang sangat baik, sedangkan nilai mendekati 0,5 mengindikasikan model tidak lebih baik dari random guessing. Dari hasil ini, dapat disimpulkan bahwa Random Forest adalah model yang paling optimal digunakan untuk sistem rekomendasi program studi, karena memiliki kemampuan tertinggi dalam memisahkan kelas target dengan kesalahan yang minimal pada berbagai threshold.



4. KESIMPULAN

Berdasarkan hasil penelitian ditarik beberapa kesimpulan bahwa penelitian ini berhasil membangun sistem rekomendasi program studi berbasis algoritma Machine Learning dengan menggunakan empat model pembandingan, yaitu Random Forest, Decision Tree, K-Nearest Neighbor (KNN), dan Naive Bayes. Hasil eksperimen menunjukkan bahwa Random Forest memberikan performa terbaik dengan akurasi 95%, precision 94%, recall 95%, F1-Score 94%, serta AUC sebesar 0.972. Hal ini membuktikan bahwa metode ensemble lebih unggul dibandingkan algoritma tunggal dalam menangani masalah klasifikasi kompleks. Algoritma Naive Bayes meskipun sederhana, menunjukkan performa yang cukup kompetitif, terutama dalam menekan jumlah False Negative (hanya 2 kasus), yang penting dalam konteks pengambilan keputusan berbasis klasifikasi. Decision Tree dan KNN menghasilkan performa yang hampir identik, namun keduanya masih kalah dalam stabilitas dan akurasi dibandingkan Random Forest. Evaluasi menggunakan tujuh metrik (Accuracy, Precision, Recall, F1-Score, ROC-AUC, Gini Coefficient, dan Log Loss) memberikan gambaran menyeluruh terhadap keunggulan dan kelemahan masing-masing algoritma. Secara keseluruhan, Random Forest adalah model paling optimal untuk mendukung sistem rekomendasi program studi. Hasil visualisasi berupa kurva ROC dan confusion matrix memperkuat kesimpulan bahwa Random Forest memiliki kemampuan pemisahan antar kelas terbaik, sementara Naive Bayes unggul dalam sensitivitas mendeteksi kelas positif.

REFERENCES

- Akbar, A., Yogi, Ananto, & Pratama, S. (2023). Sistem Rekomendasi Program Studi Sarjana Berbasis Machine Learning Untuk Model Klasifikasi Calon Mahasiswa Baru. *Journal of Information Technology and Society*, 1, 11–14. <https://doi.org/10.35438/jits.v1i1.20>
- Asbara, N., & Alviani, V. (2023). Perancangan Sistem Pendukung Keputusan dalam Penentuan Program Studi Berbasis Online. *Journal of Information System Research (JOSH)*, 4, 988–997. <https://doi.org/10.47065/josh.v4i3.3241>
- Astri, R., Hung, L. P., Sura, S. B., & Kamal, A. (2025a). Harnessing BERT for Semantic Understanding in Tourism Recommendation Engines. 9(4), 879–885.
- Astri, R., Hung, L. P., Sura, S. B., & Kamal, A. (2025b). Improving the Accuracy of Tourism Recommendation System Based on Neural Collaborative Filtering Renita. 9(4), 886–893.
- Astri, R., Hung, L. P., Sura, S. B., Kamal, A., & Yuliet, R. (2023). Sentiment analysis using naive bayes for reviews of visitors to Padang City beach tourism after the COVID-19 pandemic. *E3S Web of Conferences*, 464. <https://doi.org/10.1051/e3sconf/202346406002>
- Astri, R., Kamal, A., & Sura, S. (2022). Coffee Shop Recommendation System Using an Item-Based Collaborative Filtering Approach. *2022 International Symposium on Information Technology and Digital Innovation (ISITDI)*, 65–67. <https://doi.org/10.1109/ISITDI5734.2022.9944403>
- Atalla, S., Daradkeh, M., Gawanmeh, A., Khalil, H., Mansoor, W., Miniaoui, S., & Himeur, Y. (2023). An Intelligent Recommendation System for Automating Academic Advising Based on Curriculum Analysis and Performance Modeling. *Mathematics*, 11, 1098. <https://doi.org/10.3390/math11051098>
- Faradika, F., Astri, R., & Zulfahmi, Z. (2020). Sistem Informasi Penjadwalan Otomatis Media Sosial Instagram Untuk Mendukung Promosi Program Studi Di Universitas Dharma Andalas. *Jurnal Teknologi Dan Sistem Informasi Bisnis*, 2(2), 225–230. <https://doi.org/10.47233/jteksis.v2i2.149>
- Femas Aji Saputra, Adityawarman Adityawarman, & Salwa Rahman Nursyabani. (2024). Analisis Dampak Kesalahan Pemilihan Jurusan terhadap Prestasi Akademik dan Kesejahteraan Psikologis Mahasiswa. *Corona: Jurnal Ilmu Kesehatan Umum, Psikolog, Keperawatan Dan Kebidanan*, 2(2), 180–192. <https://doi.org/10.61132/corona.v2i2.418>
- Isma'il, M., Aliyu, G., Abdulmumin, I., & Adamu, S. (2020). An Autonomous Courses Recommender System For Undergraduate Using Machine Learning Techniques. <https://doi.org/10.1109/ICMCECS47690.2020.240882>
- Kamal, A., Sura, S. B., Hung, L. P., Astri, R., & Kurniati, T. (2023). Empowerment of MSME crafts recommendation system with content-based filtering method on social commerce after the pandemic. *E3S Web of Conferences*, 464. <https://doi.org/10.1051/e3sconf/202346412001>
- Müllner, P., Schmerda, S., Theiler, D., Lindstaedt, S., & Kowald, D. (2022). Towards employing recommender systems for supporting data and algorithm sharing. <https://doi.org/10.1145/3565011.3569055>
- Pratama, A., Aryanto, R., & Pratama, A. (2022). Model Klasifikasi Calon Mahasiswa Baru Untuk Sistem Rekomendasi Program Studi Sarjana Berbasis Machine Learning. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 9, 725. <https://doi.org/10.25126/jtiik.2022934311>
- Singgih Purnomo, & Rayhan Gunaningrat. (2022). Determinants of Student Interest in Choosing a Study Program. *International Journal of Social Science*, 1(6), 873–878. <https://doi.org/10.53625/ijss.v1i6.1899>
- Sularno, S., Astri, R., Zulfahmi, Z., Prima Mulya, D., Faradika, F., & Anggraini, P. (2023). Pelatihan Digital Marketing Dalam Membentuk Branding Sekolah. *Jurnal Pemberdayaan: Publikasi Hasil Pengabdian Kepada Masyarakat*, 2(1), 25–29. <https://doi.org/10.47233/jpmitc.v2i1.527>
- Zayed, Y., Salman, Y., & Hasasneh, A. (2022). A Recommendation System for Selecting the Appropriate Undergraduate Program at Higher Education Institutions Using Graduate Student Data. *Applied Sciences*, 12, 1–14. <https://doi.org/10.3390/app122412525>