

PENERAPAN ALGORITMA NAÏVE BAYES DALAM KLASIFIKASI TINGKAT KINERJA AKADEMIK SISWA SEKOLAH MENENGAH KEJURUAN (SMK) BERDASARKAN NILAI AKADEMIK

Tria Saputra, Sushanty Saleh

Institut Informatika dan Bisnis Darmajaya, Lampung Indonesia
Jalan Z.A. Pagar Alam, No.93 Gedong Meneng, Bandar Lampung, Lampung, Indonesia 35145
tria.2411050075P@mail.darmajaya.ac.id

ABSTRAK

Pemanfaatan data akademik dalam dunia pendidikan memiliki potensi besar untuk mendukung pengambilan keputusan yang lebih objektif dan berbasis data. Namun, data akademik siswa di lingkungan Sekolah Menengah Kejuruan (SMK) masih cenderung digunakan secara administratif tanpa analisis mendalam, sehingga pola kinerja siswa belum dapat diidentifikasi secara optimal. Penelitian ini bertujuan untuk mengklasifikasikan tingkat kinerja akademik siswa SMK menggunakan algoritma Naïve Bayes berdasarkan nilai akademik dan atribut pendukung, guna menghasilkan model klasifikasi yang akurat dan dapat digunakan sebagai dasar pengambilan keputusan berbasis data. Metode yang diterapkan meliputi preprocessing data, pembagian data dengan rasio 80:20, dan evaluasi model menggunakan confusion matrix, classification report, serta 10-fold cross validation. Dataset terdiri dari 253 siswa dengan atribut nilai Bahasa Indonesia, Bahasa Inggris, PPKn, kehadiran, usia, dan jenis kelamin. Hasil penelitian menunjukkan bahwa model Naïve Bayes mencapai akurasi sebesar 86,27% dengan hasil cross validation sebesar 93,69%, yang mengindikasikan model memiliki stabilitas dan kemampuan generalisasi yang baik serta berpotensi diterapkan sebagai alat bantu pengambilan keputusan di bidang pendidikan.

Kata kunci : Naïve Bayes, klasifikasi, kinerja akademik, data mining, machine learning, pendidikan

1. PENDAHULUAN

Perkembangan teknologi informasi telah mendorong transformasi signifikan dalam berbagai sektor, termasuk dalam bidang pendidikan. Sekolah sebagai institusi pendidikan menghasilkan berbagai data yang merepresentasikan aktivitas dan capaian belajar siswa, seperti nilai akademik, tingkat kehadiran, serta partisipasi dalam kegiatan pembelajaran. Data tersebut memiliki potensi yang besar untuk diolah menjadi informasi bernilai guna mendukung pengambilan keputusan yang lebih efektif, objektif, dan berbasis data [1], [2].

Namun demikian, dalam praktiknya pemanfaatan data akademik di lingkungan pendidikan masih cenderung bersifat deskriptif dan administratif. Data yang tersedia umumnya hanya digunakan sebagai arsip atau laporan tanpa dilakukan analisis lebih lanjut untuk mengidentifikasi pola kinerja siswa. Kondisi ini menyebabkan potensi data yang dimiliki belum dimanfaatkan secara optimal dalam mendukung peningkatan kualitas pembelajaran maupun evaluasi kinerja akademik siswa secara komprehensif. Pada lingkungan Sekolah Menengah Kejuruan (SMK), keberagaman jurusan menjadi tantangan tambahan karena perbedaan atribut data antar jurusan dapat menghambat konsistensi analisis kinerja akademik secara menyeluruh [2], [3]. Selain itu, pada lingkungan Sekolah Menengah Kejuruan (SMK), keberagaman jurusan juga menjadi tantangan tersendiri dalam pemanfaatan data akademik, khususnya dalam menjaga konsistensi atribut yang digunakan untuk analisis.

Seiring dengan perkembangan teknologi, pendekatan berbasis *machine learning* mulai banyak digunakan untuk mengatasi permasalahan tersebut. *Machine learning* merupakan cabang dari kecerdasan buatan yang mampu melakukan analisis data secara otomatis serta menghasilkan prediksi atau klasifikasi berdasarkan pola yang ditemukan dalam data. Dalam konteks pendidikan, metode ini dapat dimanfaatkan untuk mengklasifikasikan tingkat kinerja akademik siswa berdasarkan data yang tersedia, sehingga membantu pihak sekolah dalam mengidentifikasi siswa dengan kategori kinerja tertentu secara lebih akurat dan sistematis [1], [4].

Salah satu algoritma yang banyak digunakan dalam proses klasifikasi adalah Naïve Bayes. Algoritma ini dikenal memiliki keunggulan dalam hal kesederhanaan, efisiensi komputasi, serta kemampuan dalam menangani data dengan jumlah yang relatif terbatas. Selain itu, Naïve Bayes juga memiliki performa yang baik dalam berbagai kasus klasifikasi, termasuk pada data pendidikan yang bersifat kategorikal maupun numerik. Karakteristik tersebut menjadikan algoritma Naïve Bayes sebagai metode yang relevan untuk diterapkan dalam analisis kinerja akademik siswa [3], [5].

Meskipun demikian, penelitian terkait klasifikasi kinerja akademik siswa masih memiliki keterbatasan, terutama dalam pemilihan atribut yang belum mempertimbangkan konsistensi data antar jurusan pada lingkungan SMK. Oleh karena itu, diperlukan pendekatan yang mampu mengakomodasi keberagaman tersebut dengan tetap menjaga

keseragaman atribut yang digunakan dalam proses klasifikasi.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan model klasifikasi kinerja akademik siswa SMK menggunakan algoritma Naïve Bayes dengan memanfaatkan atribut nilai mata pelajaran umum serta atribut pendukung seperti jenis kelamin, usia, dan kehadiran. Untuk mengatasi tantangan keberagaman jurusan, penelitian ini menggunakan atribut dari mata pelajaran umum yang bersifat lintas jurusan sehingga menjaga konsistensi data. Pendekatan ini diharapkan menghasilkan model klasifikasi yang representatif dan dapat digunakan sebagai dasar pengambilan keputusan berbasis data di lingkungan pendidikan, sekaligus menjadi referensi bagi penelitian selanjutnya dalam penerapan *machine learning* dalam analisis data pendidikan [2], [6].

2. TINJAUAN PUSTAKA

2.1. Data Mining dalam Pendidikan

Data mining merupakan proses ekstraksi pengetahuan dari kumpulan data dalam jumlah besar untuk menemukan pola, hubungan, maupun informasi tersembunyi yang dapat digunakan dalam pengambilan keputusan. Dalam konteks pendidikan, data mining berkembang menjadi Educational Data Mining (EDM) yang berfokus pada analisis data siswa untuk meningkatkan kualitas pembelajaran dan manajemen pendidikan. Penerapan data mining dalam pendidikan memungkinkan institusi untuk mengidentifikasi pola kinerja siswa, mendeteksi potensi permasalahan akademik, serta memberikan rekomendasi berbasis data [7], [8].

Seiring meningkatnya volume data pendidikan, pemanfaatan teknik data mining menjadi semakin penting, khususnya dalam mengolah data akademik seperti nilai, kehadiran, dan aktivitas belajar siswa. Data tersebut jika dianalisis dengan tepat dapat memberikan wawasan yang signifikan dalam mendukung pengambilan keputusan yang lebih objektif dan akurat.

2.2. Machine Learning dalam Analisis Kinerja Akademik

Machine learning merupakan cabang dari kecerdasan buatan yang memungkinkan sistem untuk belajar dari data dan membuat prediksi atau keputusan tanpa diprogram secara eksplisit. Dalam bidang pendidikan, machine learning telah banyak digunakan untuk memprediksi kinerja akademik siswa, mengidentifikasi risiko kegagalan belajar, serta mengelompokkan siswa berdasarkan tingkat pencapaian akademiknya [1], [9].

Salah satu pendekatan yang umum digunakan dalam *machine learning* adalah klasifikasi, yaitu proses pengelompokan data ke dalam kategori tertentu berdasarkan pola yang telah dipelajari. Dalam penelitian ini, klasifikasi digunakan untuk menentukan tingkat kinerja akademik siswa berdasarkan atribut yang tersedia, seperti nilai akademik dan kehadiran.

2.3. Algoritma Naïve Bayes

Naïve Bayes merupakan salah satu algoritma klasifikasi berbasis probabilitas yang didasarkan pada Teorema Bayes dengan asumsi independensi antar fitur. Algoritma ini banyak digunakan karena kesederhanaannya, efisiensi komputasi, serta kemampuannya dalam menangani data dengan jumlah terbatas maupun data berdimensi tinggi [7], [8].

$$P(C | X) = \frac{P(X | C) \cdot P(C)}{P(X)} \quad (1)$$

di mana:

- $P(C | X)$ adalah probabilitas posterior (kelas berdasarkan data),
- $P(X | C)$ adalah probabilitas likelihood,
- $P(C)$ adalah probabilitas prior,
- $P(X)$ adalah probabilitas evidence.

Dalam implementasinya, Naïve Bayes menghitung probabilitas setiap kelas berdasarkan atribut yang dimiliki, kemudian memilih kelas dengan probabilitas tertinggi sebagai hasil klasifikasi. Algoritma ini telah terbukti efektif dalam berbagai studi klasifikasi, termasuk dalam analisis data pendidikan yang melibatkan variabel numerik dan kategorikal [8], [10].

2.4. Klasifikasi Kinerja Akademik Siswa

Kinerja akademik siswa merupakan indikator penting dalam menilai keberhasilan proses pembelajaran. Klasifikasi kinerja akademik bertujuan untuk mengelompokkan siswa ke dalam kategori tertentu, seperti sangat baik, baik, dan cukup, berdasarkan nilai akademik serta faktor pendukung lainnya.

Dalam berbagai penelitian, atribut nilai akademik banyak digunakan sebagai indikator utama dalam klasifikasi kinerja siswa karena mampu merepresentasikan capaian pembelajaran secara kuantitatif. Selain itu, penggunaan atribut yang bersifat umum juga penting untuk menjaga konsistensi data, terutama pada lingkungan pendidikan yang memiliki keberagaman karakteristik siswa.

2.5. Penelitian Terkait

Beberapa penelitian sebelumnya menunjukkan bahwa penerapan machine learning, khususnya algoritma klasifikasi, memiliki peran penting dalam analisis kinerja akademik siswa. Penelitian menunjukkan bahwa pendekatan berbasis pembelajaran mesin mampu meningkatkan akurasi dalam memprediksi keberhasilan akademik siswa [11]. Selain itu, pemanfaatan data mining dalam pendidikan dapat membantu institusi dalam mengidentifikasi pola belajar dan meningkatkan kualitas pembelajaran [9].

Penelitian lain juga menunjukkan bahwa algoritma Naïve Bayes memiliki performa yang baik dalam klasifikasi data pendidikan karena kesederhanaan dan efisiensinya [12], [13]. Namun demikian, sebagian penelitian masih memiliki

keterbatasan dalam pemilihan atribut yang belum mempertimbangkan konsistensi antar jurusan, sehingga diperlukan pendekatan yang lebih adaptif dalam pemodelan data.

2.6. Kerangka Pemikiran

Berdasarkan tinjauan pustaka yang telah diuraikan, dapat disimpulkan bahwa pemanfaatan data akademik siswa melalui pendekatan *machine learning* dapat memberikan kontribusi signifikan dalam analisis kinerja akademik. Penelitian ini mengusulkan penggunaan algoritma Naïve Bayes untuk mengklasifikasikan kinerja siswa berdasarkan atribut nilai dan atribut pendukung.

Secara konseptual, alur penelitian dapat dijelaskan sebagai berikut:

- Pengumpulan data akademik siswa
- Preprocessing data
- Penerapan algoritma Naïve Bayes
- Evaluasi model
- Interpretasi hasil klasifikasi

Dengan pendekatan tersebut, diharapkan model yang dihasilkan mampu memberikan klasifikasi kinerja akademik yang akurat dan dapat digunakan sebagai dasar dalam pengambilan keputusan di lingkungan pendidikan.

3. METODE PENELITIAN

3.1. Kerangka Pemikiran

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen dalam bidang data mining. Pendekatan ini dipilih karena mampu mengolah data numerik secara sistematis serta menghasilkan model klasifikasi yang dapat digunakan untuk menganalisis kinerja akademik siswa secara objektif dan terukur. Fokus utama penelitian adalah penerapan algoritma Naïve Bayes untuk mengklasifikasikan tingkat kinerja akademik siswa berdasarkan data yang tersedia [14], [15].

3.2. Sumber dan Deskripsi Data

Data yang digunakan dalam penelitian ini merupakan data akademik siswa Sekolah Menengah Kejuruan (SMK) kelas XII yang diperoleh dari beberapa jurusan, yaitu Akuntansi, Teknik Komputer dan Jaringan, Desain Komunikasi Visual, Teknik Kendaraan Ringan, dan Teknik Sepeda Motor. Penggunaan data lintas jurusan bertujuan untuk menghasilkan model klasifikasi yang lebih representatif terhadap kondisi nyata di lingkungan pendidikan.

Dataset terdiri dari 253 data siswa, yang mencakup atribut akademik dan atribut pendukung. Atribut yang digunakan dalam penelitian ini disajikan pada Tabel 1.

Tabel 1. Atribut dan Deskripsi Data Penelitian

Atribut	Deskripsi
Jenis Kelamin	Kategori (L/P)
Usia	Umur siswa (tahun)
Kehadiran	Persentase kehadiran (%)
Nilai Bahasa Indonesia	Nilai akademik siswa
Nilai Bahasa Inggris	Nilai akademik siswa
Nilai PPKn	Nilai akademik siswa
Nilai Rata-rata	Rata-rata nilai dari tiga mata pelajaran
Kategori	Label kinerja (Sangat Baik, Baik, Cukup)

Atribut nilai yang digunakan berasal dari mata pelajaran umum guna menjaga konsistensi data antar siswa dari berbagai jurusan.

3.3. Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan yang terstruktur, mulai dari pengolahan data hingga evaluasi model. Secara konseptual, tahapan penelitian meliputi pengumpulan data, preprocessing data, pembagian data, penerapan algoritma, serta evaluasi model. Setiap tahapan dilakukan secara sistematis untuk memastikan kualitas hasil klasifikasi yang diperoleh.

3.4. Preprocessing Data

Tahap preprocessing bertujuan untuk meningkatkan kualitas data sebelum digunakan dalam proses klasifikasi. Tahapan ini meliputi:

- Data Cleaning, yaitu proses pembersihan data dari nilai yang tidak valid atau duplikat
- Transformasi Data, yaitu konversi data kategorikal ke dalam bentuk numerik agar dapat diproses oleh algoritma
- Perhitungan Nilai Rata-rata, sebagai representasi kinerja akademik siswa

Nilai rata-rata dihitung menggunakan persamaan berikut:

$$\text{Rata-rata} = \frac{BI + BIng + PPKn}{3} \quad (2)$$

di mana:

- BI= Nilai Bahasa Indonesia
- BIng= Nilai Bahasa Inggris
- PPKn= Nilai Pendidikan Pancasila dan Kewarganegaraan

3.5. Pembagian Data

Dataset dibagi menjadi dua bagian, yaitu data pelatihan (*training data*) dan data pengujian (*testing data*). Pembagian dilakukan dengan proporsi:

- 80% data training (202 data)
- 20% data testing (51 data)

Pembagian ini bertujuan untuk melatih model menggunakan sebagian data dan menguji kemampuan generalisasi model terhadap data yang belum pernah dipelajari sebelumnya.

3.6. Penerapan Algoritma Naïve Bayes

Algoritma Naïve Bayes digunakan untuk melakukan klasifikasi terhadap data siswa berdasarkan atribut yang telah ditentukan. Dalam penelitian ini, setiap data siswa direpresentasikan sebagai sekumpulan atribut, kemudian dihitung probabilitas masing-masing kelas berdasarkan atribut tersebut.

Secara matematis, probabilitas kelas dihitung menggunakan Teorema Bayes:

$$P(C | X) = \frac{P(X | C) \cdot P(C)}{P(X)} \quad (3)$$

Dalam implementasinya, algoritma akan menghitung probabilitas posterior untuk setiap kategori kinerja, kemudian menentukan kategori dengan nilai probabilitas tertinggi sebagai hasil klasifikasi.

3.7. Evaluasi Model

Evaluasi model dilakukan untuk mengukur tingkat kinerja algoritma dalam mengklasifikasikan data siswa. Metode evaluasi yang digunakan meliputi:

- Accuracy, untuk mengukur tingkat ketepatan prediksi model
- Confusion Matrix, untuk melihat distribusi kesalahan klasifikasi
- Precision, Recall, dan F1-Score, untuk mengevaluasi performa masing-masing kelas
- Cross Validation (10-fold), untuk menguji stabilitas model

Akurasi model dihitung menggunakan persamaan berikut:

$$Accuracy = \frac{Prediksi\ Benar}{Total\ Data} \quad (4)$$

3.8. Perangkat dan Lingkungan Implementasi

Penelitian ini diimplementasikan menggunakan bahasa pemrograman Python dengan bantuan beberapa pustaka pendukung, yaitu:

- Pandas, untuk pengolahan data
- NumPy, untuk komputasi numerik
- Scikit-learn, untuk implementasi algoritma Naïve Bayes
- Matplotlib dan Seaborn, untuk visualisasi data

Penggunaan perangkat lunak ini memungkinkan proses analisis data dilakukan secara efisien dan terstruktur.

4. HASIL DAN PEMBAHASAN

4.1. Statistik Deskriptif Data

Berdasarkan hasil pengolahan data, diperoleh gambaran statistik deskriptif dari dataset yang digunakan dalam penelitian. Statistik ini mencakup nilai rata-rata, standar deviasi, nilai minimum, dan maksimum dari setiap atribut.

	Usia	Kehadiran (%)	Nilai Bahasa Indonesia	Nilai Bahasa Inggris	Nilai PPKn	Nilai Rata-rata
count	253.00	253.00	253.00	253.00	253.00	253.00
mean	16.48	87.17	88.71	88.17	78.82	79.90
std	0.52	7.57	9.73	9.09	8.68	5.26
min	16.00	75.00	65.00	65.00	65.00	67.67
25%	16.00	88.00	72.00	73.00	72.00	76.00
50%	16.00	87.00	81.00	80.00	78.00	80.00
75%	17.00	94.00	89.00	88.00	86.00	83.67
max	15.00	100.00	95.00	95.00	95.00	93.67

Gambar 1. Statistik Deskriptif Data Siswa

Gambar 1 menunjukkan hasil analisis statistik deskriptif terhadap data siswa yang digunakan dalam penelitian. Berdasarkan hasil tersebut, rata-rata usia siswa adalah sebesar 16,48 tahun, dengan rata-rata tingkat kehadiran mencapai 87,17%. Sementara itu, nilai rata-rata akademik siswa berada pada angka 79,90, yang mengindikasikan bahwa secara umum kinerja akademik siswa berada pada kategori baik. Selain itu, rentang nilai minimum dan maksimum yang tidak terlalu jauh menunjukkan bahwa distribusi data relatif stabil dan tidak terdapat penyimpangan ekstrem (*outlier*) yang signifikan.

4.2. Sampel Data Penelitian

Sebagai representasi struktur dataset yang digunakan, ditampilkan sebagian data siswa yang mencerminkan atribut penelitian.


	Nama	Jenis Kelamin	usia	Kehadiran (%)	Nilai Bahasa Indonesia	Nilai Bahasa Inggris	Nilai PPKn	Nilai Rata-rata	kategori	Jurusan
0	ADELLA	P	17	99	95	94	78	79.00	Baik	AKUTANSI KEUANGAN
1	ARUL AGUS PRAMESTI	P	17	99	79	81	95	82.00	Baik	AKUTANSI KEUANGAN
2	ALYA PUTRI FADHANI	P	16	84	89	79	95	87.00	Sangat Baik	AKUTANSI KEUANGAN
3	AMANDA BERLIANA PUTRI	P	17	75	93	72	78	81.00	Baik	AKUTANSI KEUANGAN
4	JANDIRA AS	P	17	88	88	82	72	80.67	Baik	AKUTANSI KEUANGAN

Gambar 2. Contoh Dataset Siswa (5 Baris Pertama)

Gambar 2 menampilkan sebagian data siswa yang digunakan dalam penelitian sebagai representasi struktur dataset. Dataset tersebut terdiri dari beberapa atribut, yaitu nama siswa, jenis kelamin, usia, tingkat kehadiran, nilai mata pelajaran, nilai rata-rata, kategori kinerja akademik, serta jurusan. Struktur data ini menjadi dasar dalam proses klasifikasi menggunakan algoritma Naïve Bayes, di mana setiap atribut berperan sebagai variabel yang digunakan dalam menentukan kategori kinerja akademik siswa.

4.3. Distribusi Data dan Eksplorasi

Untuk memahami pola awal data, dilakukan visualisasi distribusi terhadap atribut utama.




Gambar 3. Distribusi Atribut Data Siswa

Gambar 3 menunjukkan hasil eksplorasi data melalui visualisasi distribusi beberapa atribut utama, yaitu kehadiran, nilai Bahasa Indonesia, Bahasa Inggris, PPKn, serta nilai rata-rata siswa. Berdasarkan visualisasi tersebut, sebagian besar siswa memiliki tingkat kehadiran di atas 85%, yang menunjukkan tingkat partisipasi yang baik dalam proses pembelajaran.

Selain itu, distribusi nilai pada masing-masing mata pelajaran cenderung berada pada rentang menengah hingga tinggi, yang mengindikasikan bahwa mayoritas siswa memiliki capaian akademik yang cukup baik. Distribusi nilai rata-rata juga menunjukkan pola yang relatif terpusat pada interval 75–85, yang menguatkan bahwa kategori kinerja akademik siswa didominasi oleh kategori baik.

4.4. Distribusi Kategori Kinerja Akademik

Distribusi kategori kinerja akademik dianalisis untuk mengetahui keseimbangan data.



Gambar 4. Distribusi Kategori Kinerja Akademik Siswa

Gambar 4 menunjukkan distribusi kategori kinerja akademik siswa yang terdiri dari tiga kelas, yaitu Baik, Sangat Baik, dan Cukup. Berdasarkan hasil visualisasi, kategori Baik mendominasi dengan jumlah 162 siswa (64,0%), diikuti oleh kategori Sangat Baik sebanyak 49 siswa (19,4%), dan kategori Cukup sebanyak 42 siswa (16,6%). Distribusi ini menunjukkan bahwa data tidak sepenuhnya seimbang (imbalanced), di mana kelas Baik memiliki jumlah data yang jauh lebih besar dibandingkan kelas lainnya. Kondisi ini berpotensi memengaruhi performa model klasifikasi, terutama dalam memprediksi kelas dengan jumlah data yang lebih sedikit, seperti kategori Cukup [16], [17].

4.5. Evaluasi Model Klasifikasi

Hasil pengujian model Naïve Bayes menunjukkan performa klasifikasi yang baik.

Akurasi Model: 86.27%
 Prediksi benar: 44 dari 51 data test

Classification Report:

	precision	recall	f1-score	support
Baik	0.88	0.91	0.90	33
Cukup	0.67	0.50	0.57	8
Sangat Baik	0.91	1.00	0.95	10
accuracy			0.86	51
macro avg	0.82	0.80	0.81	51
weighted avg	0.85	0.86	0.86	51

Gambar 5. Hasil Evaluasi Model (Classification Report)

Gambar 5 menunjukkan hasil evaluasi model menggunakan classification report. Berdasarkan hasil tersebut, model Naïve Bayes memperoleh tingkat akurasi sebesar 86,27%, dengan jumlah prediksi benar sebanyak 44 dari 51 data uji. Nilai precision, recall, dan f1-score pada masing-masing kelas menunjukkan performa yang cukup baik, terutama pada kategori Baik dan Sangat Baik yang memiliki nilai evaluasi tinggi. Namun, pada kategori Cukup, nilai recall yang lebih rendah menunjukkan bahwa model masih mengalami kesulitan dalam mengklasifikasikan kelas dengan jumlah data yang lebih sedikit [18].

RINGKASAN EVALUASI MODEL NAÏVE BAYES
 Klasifikasi Kinerja Akademik Siswa SMK XII


Dataset	: 253 siswa
Jumlah Fitur	: 6
Jumlah Kelas	: 3 (Baik, Cukup, Sangat Baik)
Data Training	: 202 (80%)
Data Testing	: 51 (20%)
Akurasi (Test Set)	: 86.27%
Presisi (Weighted)	: 85.38%
Recall (Weighted)	: 86.27%
F1-Score (Weighted)	: 85.58%
CV Akurasi (10-Fold)	: 93.69% ± 1.89%

Gambar 6. Ringkasan Evaluasi Model Naïve Bayes

Gambar 6 menyajikan ringkasan hasil evaluasi model secara keseluruhan, termasuk jumlah dataset, pembagian data training dan testing, serta nilai evaluasi utama. Selain itu, hasil 10-fold cross validation menunjukkan rata-rata akurasi sebesar 93,69% dengan standar deviasi yang relatif kecil, yang mengindikasikan bahwa model memiliki tingkat stabilitas dan konsistensi yang baik dalam melakukan klasifikasi pada berbagai subset data [12].

4.6. Confusion Matrix

Confusion matrix digunakan untuk mengevaluasi distribusi prediksi model.




Gambar 7. Confusion Matrix Model Naïve Bayes

Gambar 7 menunjukkan hasil evaluasi model menggunakan confusion matrix dalam bentuk jumlah dan persentase. Berdasarkan matriks tersebut, sebagian besar data berhasil diklasifikasikan dengan benar, terutama pada kategori Baik dan Sangat Baik. Hal ini terlihat dari nilai diagonal yang dominan pada kedua kelas tersebut. Namun demikian, masih terdapat kesalahan klasifikasi pada kategori Cukup, di mana beberapa data pada kelas tersebut diprediksi sebagai kategori Baik. Kondisi ini menunjukkan bahwa model

masih mengalami keterbatasan dalam membedakan kelas dengan jumlah data yang lebih sedikit. Selain itu, hasil dalam bentuk persentase memperlihatkan bahwa tingkat akurasi pada kelas Sangat Baik mencapai nilai yang sangat tinggi, sedangkan pada kelas Cukup distribusi prediksi masih belum optimal. Hal ini sejalan dengan distribusi data yang tidak seimbang, di mana kelas dengan jumlah data lebih besar cenderung memiliki performa klasifikasi yang lebih baik [13].

4.7. Korelasi Antar Fitur

Analisis korelasi dilakukan untuk melihat hubungan antar variabel.



Gambar 8. Heatmap Korelasi Antar Fitur Numerik

Gambar 8 menunjukkan hasil analisis korelasi antar fitur numerik yang digunakan dalam penelitian. Berdasarkan hasil tersebut, nilai rata-rata memiliki korelasi yang cukup kuat dengan nilai mata pelajaran, yaitu Bahasa Indonesia sebesar 0,63, Bahasa Inggris sebesar 0,51, dan PPKn sebesar 0,58. Hal ini menunjukkan bahwa nilai rata-rata sangat dipengaruhi oleh nilai masing-masing mata pelajaran. Sementara itu, atribut kehadiran memiliki nilai korelasi yang relatif rendah terhadap seluruh atribut nilai akademik, yang mengindikasikan bahwa kehadiran tidak memiliki pengaruh langsung yang signifikan terhadap hasil akademik siswa dalam dataset ini. Hasil ini memperkuat bahwa atribut nilai akademik merupakan faktor utama dalam proses klasifikasi kinerja siswa, sedangkan atribut pendukung seperti kehadiran berperan sebagai variabel tambahan yang tidak dominan [19].

4.8. Validasi Model


Validasi model dilakukan menggunakan metode 10-fold cross validation.

*** Probabilitas Posterior 10 Data Test Pertama:

No	Aktual	Prediksi	P(Baik)	P(Cukup)	P(Sangat B)
1	Sangat Baik	Sangat Baik	0.2386	0.0000	0.7614
2	Sangat Baik	Sangat Baik	0.1628	0.0000	0.8372
3	Baik	Baik	0.9998	0.0002	0.0000
4	Baik	Baik	0.9905	0.0095	0.0000
5	Baik	Baik	0.9772	0.0228	0.0000
6	Baik	Baik	0.9714	0.0000	0.0286
7	Cukup	Cukup	0.4719	0.5281	0.0000
8	Baik	Baik	0.9910	0.0000	0.0090
9	Baik	Baik	0.9967	0.0000	0.0033
10	Baik	Baik	0.7910	0.2090	0.0000

Gambar 9. Probabilitas Posterior Hasil Prediksi

Gambar 9 menunjukkan hasil perhitungan probabilitas posterior pada beberapa data uji. Berdasarkan hasil tersebut, setiap data memiliki nilai probabilitas untuk masing-masing kelas, yaitu Baik, Cukup, dan Sangat Baik. Kelas dengan nilai probabilitas tertinggi dipilih sebagai hasil prediksi akhir. Terlihat bahwa pada sebagian besar data, probabilitas pada kelas yang diprediksi memiliki nilai yang dominan dibandingkan kelas lainnya. Hal ini menunjukkan bahwa model memiliki tingkat keyakinan yang cukup tinggi dalam menentukan hasil klasifikasi [18].



Gambar 10. Distribusi Probabilitas Posterior per Kelas

Gambar 10 menunjukkan distribusi probabilitas posterior untuk masing-masing kelas. Berdasarkan visualisasi tersebut, probabilitas pada kelas yang sesuai dengan label aktual cenderung berada pada nilai tinggi, sedangkan pada kelas lainnya berada pada nilai yang rendah. Pola ini menunjukkan bahwa model Naïve Bayes mampu memisahkan kelas dengan cukup baik berdasarkan distribusi probabilitas yang dihasilkan. Namun, pada beberapa kasus tertentu masih terdapat tumpang tindih distribusi, yang dapat menyebabkan kesalahan klasifikasi, terutama pada kelas dengan jumlah data yang lebih sedikit [15].

4.9. Pembahasan

Hasil penelitian menunjukkan bahwa algoritma Naïve Bayes memiliki kemampuan yang baik dalam mengklasifikasikan kinerja akademik siswa. Tingkat akurasi yang diperoleh menunjukkan bahwa model mampu mengidentifikasi pola hubungan antar atribut secara efektif, terutama pada data dengan karakteristik yang relatif homogen [14].

Dominasi kategori *Baik* dalam dataset memberikan pengaruh terhadap performa model, di mana model cenderung lebih optimal dalam mengklasifikasikan kelas dengan jumlah data yang lebih besar. Fenomena ini umum terjadi pada dataset yang tidak seimbang (*imbalanced data*), di mana model memiliki kecenderungan bias terhadap kelas mayoritas. Hal ini terlihat pada hasil confusion matrix yang menunjukkan bahwa kesalahan klasifikasi lebih banyak terjadi pada kategori *Cukup* [13], [17].

Berdasarkan analisis korelasi, atribut nilai akademik memiliki kontribusi yang lebih signifikan dibandingkan atribut lainnya dalam proses klasifikasi. Hal ini menunjukkan bahwa nilai akademik merupakan indikator utama dalam menentukan kinerja siswa, sementara atribut kehadiran berperan sebagai

faktor pendukung yang tidak secara langsung memengaruhi hasil klasifikasi secara dominan [12].

Selain itu, hasil validasi menggunakan metode *10-fold cross validation* menunjukkan bahwa model memiliki tingkat stabilitas yang tinggi, yang ditunjukkan oleh konsistensi nilai akurasi pada setiap fold. Hal ini mengindikasikan bahwa model tidak hanya memiliki performa yang baik pada data uji, tetapi juga mampu melakukan generalisasi terhadap data yang berbeda [16].

Secara keseluruhan, hasil penelitian ini menunjukkan bahwa algoritma Naïve Bayes efektif digunakan dalam klasifikasi kinerja akademik siswa, terutama dalam kondisi dataset dengan atribut numerik yang sederhana dan distribusi data yang relatif terstruktur. Model yang dihasilkan berpotensi untuk digunakan sebagai alat bantu dalam pengambilan keputusan berbasis data di lingkungan pendidikan, khususnya dalam mengidentifikasi tingkat kinerja akademik siswa secara lebih objektif dan sistematis

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan algoritma Naïve Bayes mampu mengklasifikasikan tingkat kinerja akademik siswa dengan tingkat akurasi yang baik, serta menunjukkan performa yang stabil dalam berbagai pengujian. Atribut nilai akademik terbukti menjadi faktor utama dalam menentukan kategori kinerja siswa, sementara atribut pendukung seperti kehadiran memberikan kontribusi tambahan meskipun tidak dominan. Selain itu, hasil evaluasi dan validasi menunjukkan bahwa model memiliki kemampuan generalisasi yang baik, sehingga berpotensi untuk diterapkan sebagai alat bantu dalam pengambilan keputusan berbasis data di lingkungan pendidikan. Adapun saran untuk penelitian selanjutnya adalah dengan mempertimbangkan penggunaan algoritma klasifikasi lain sebagai pembandingan, menambahkan variasi atribut yang lebih beragam seperti aspek non-akademik, serta melakukan pengujian pada dataset yang lebih besar dan beragam guna meningkatkan akurasi dan generalisasi model yang dihasilkan.

DAFTAR PUSTAKA

- [1] M. N. Gul, M. Arif, S. Gulzar, G. Naveed, and W. Abbasi, "Deep Learning-Driven Student Performance Analysis: Detecting Anomalies and Predicting Academic Success," *IJSS*, vol. 4, no. 1, pp. 33–48, Mar. 2025, doi: 10.63544/ijss.v4i1.117.
- [2] Z. Khoshgoftar, M. Babaei, A. K. Rouzbahani, and M. Kalantarion, "Educational data mining in medical education: A five-level approach," *Journal of Education and Health Promotion*, vol. 14, no. 1, Jan. 2025, doi: 10.4103/jehp.jehp_1339_23.
- [3] T. Tiaht, B. Hanus, and J. C. Porter, "Transitioning a traditional introductory information systems course to a data analytics focused course," *Decision Sci J Innov Edu*, vol. 20, no. 4, pp. 176–189, Oct. 2022, doi: 10.1111/dsji.12275.
- [4] Y. Yuan *et al.*, "The strengths, weaknesses, opportunities, and threats of generative artificial intelligence: a qualitative study of undergraduate nursing students," *Front. Public Health*, vol. 13, p. 1672140, Sep. 2025, doi: 10.3389/fpubh.2025.1672140.
- [5] M.-H. Wu, C.-J. Chen, and H.-F. Lee, "Effectiveness of Mobile-Based Learning for Nasogastric Tube Intubation Among Medical Students: A Randomized Controlled Trial," *Healthcare*, vol. 13, no. 5, p. 546, Mar. 2025, doi: 10.3390/healthcare13050546.
- [6] M. M. D. L. Pontes *et al.*, "Evidence of the effectiveness of projects, programs, and/or strategies for curricular innovation in undergraduate health courses: systematic review and meta-analysis," *BMC Med Educ*, vol. 26, no. 1, p. 132, Dec. 2025, doi: 10.1186/s12909-025-08306-0.
- [7] M. Yağcı, "Educational data mining: prediction of students' academic performance using machine learning algorithms," *Smart Learn. Environ.*, vol. 9, no. 1, p. 11, Dec. 2022, doi: 10.1186/s40561-022-00192-z.
- [8] D. Khairy, N. Alharbi, M. A. Amasha, M. F. Areed, S. Alkhalaf, and R. A. Abougala, "Prediction of student exam performance using data mining classification algorithms," *Educ Inf Technol*, vol. 29, no. 16, pp. 21621–21645, Nov. 2024, doi: 10.1007/s10639-024-12619-w.
- [9] D. Jacob and R. Henriques, "Educational Data Mining to Predict Bachelors Students' Success," *Emerg Sci J*, vol. 7, pp. 159–171, Jul. 2023, doi: 10.28991/ESJ-2023-SIED2-013.
- [10] C. E. Murwaningtyas and M. F. D. D. Jesus, "Data Mining Analysis of Moodle Learning Data and Student Perceptions During and After the Covid-19 Pandemic," *j. nas. pendidik. teknik. inform.*, vol. 13, no. 3, pp. 506–519, Dec. 2024, doi: 10.23887/janapati.v13i3.84005.
- [11] Dr. A. Triayudi, R. T. Aldisa, and S. Sumiati, "New Framework of Educational Data Mining to Predict Student Learning Performance," *JOWUA*, vol. 15, no. 1, pp. 115–132, Mar. 2024, doi: 10.58346/JOWUA.2024.I1.009.
- [12] M. I. Termedi, A. M. Ma'rof, H. B. Ab. Jalil, and I. Ishak, "A Thematic Review on Predicting Student Performance Using Data Mining," *IJARBS*, vol. 13, no. 11, p. Pages 1814-1831, Nov. 2023, doi: 10.6007/IJARBS/v13-i11/19563.
- [13] A. Alfahid, "Algorithmic Prediction of Students On-Time Graduation from the University," *TEM Journal*, pp. 692–698, Feb. 2024, doi: 10.18421/TEM131-72.

-
- [14] D. Paramitha and N. Nugraheni, "Educational Data Mining in Accounting: Market Segmentation Strategy for Financial Management of New Student Admissions," *JASa*, vol. 9, no. 1, pp. 117–125, Apr. 2025, doi: 10.36555/jasa.v9i1.2799.
- [15] B. A. M. Claudio, "Application of Data Mining for the Prediction of Academic Performance in University Engineering Students at the National Autonomous University of Mexico, 2022," *LatIA*, vol. 2, p. 14, Jul. 2024, doi: 10.62486/latia202414.
- [16] M. H. B. Roslan and C. J. Chen, "Educational Data Mining for Student Performance Prediction: A Systematic Literature Review (2015-2021)," *Int. J. Emerg. Technol. Learn.*, vol. 17, no. 05, pp. 147–179, Mar. 2022, doi: 10.3991/ijet.v17i05.27685.
- [17] M. Nazir, A. Noraziah, and M. Rahmah, "Students' Performance Prediction in Higher Education Using Multi-Agent Framework-Based Distributed Data Mining Approach: A Review," *International Journal of Virtual and Personal Learning Environments*, vol. 13, no. 1, pp. 1–19, Aug. 2023, doi: 10.4018/IJVPLE.328772.
- [18] M. A. Betz, R. L. Sharples, and M. D. Ward, "The Data Mine model for accessible partnerships in data science," *WIREs Computational Stats*, vol. 16, no. 1, p. e1642, Jan. 2024, doi: 10.1002/wics.1642.
- [19] L. Krungkraipetch, K. Krungkraipetch, K. Usimat, and S. Bookaeaw, "Seeds of Scholarship: A Systematic Review of Research Engagement in Undergraduate Medical Education," *Perspect Med Educ*, vol. 15, no. 1, pp. 16–27, Jan. 2026, doi: 10.5334/pme.2199.