



Klasifikasi Persepsi Mahasiswa terhadap Penggunaan Artificial Intelligence dalam Kegiatan Akademik Menggunakan Metode Naïve Bayes

Muhammad Wendy Martadiansyah, Haryanto, Harun Al Rasyid

Program Studi Sistem Informasi, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika

wendy.martadiandsyah75@gmail.com*, haryanto.hyt@bsi.ac.id, harun.har@bsi.ac.id

Abstrak

Pemanfaatan Artificial Intelligence (AI) dalam kegiatan akademik mahasiswa semakin berkembang, mulai dari pencarian referensi hingga pemahaman materi perkuliahan. Namun, penggunaan AI dapat menimbulkan persepsi yang beragam, sehingga diperlukan metode untuk mengklasifikasikan persepsi tersebut dan mengidentifikasi atribut yang informatif dalam membedakan kategori. Penelitian ini bertujuan mengklasifikasikan persepsi mahasiswa di Kecamatan Serpong terhadap penggunaan AI dalam kegiatan akademik ke dalam kategori Tinggi dan Rendah, mengevaluasi kinerja model, serta mengidentifikasi atribut yang paling informatif terhadap kategori persepsi. Penelitian menggunakan pendekatan kuantitatif dengan kerangka Cross Industry Standard Process for Data Mining (CRISP-DM). Data dikumpulkan melalui kuesioner berskala Likert yang terdiri atas 19 pernyataan dari 120 mahasiswa yang dipilih menggunakan teknik purposive sampling. Label kelas dibentuk berdasarkan median skor rata-rata jawaban responden. Pemodelan dilakukan menggunakan algoritma Naïve Bayes pada RapidMiner dan dievaluasi dengan teknik 10-fold cross validation menggunakan metrik accuracy, precision, recall, dan F1-score. Analisis atribut dilakukan menggunakan operator Weight by Information Gain. Hasil pengujian menunjukkan nilai rata-rata accuracy sebesar 95,00%, precision 98,33%, recall 91,67%, dan F1-score 94,36%. Analisis Information Gain menunjukkan bahwa Q18, yaitu pernyataan bahwa AI telah menjadi bagian penting dalam kegiatan akademik, memperoleh bobot tertinggi sebesar 0,321, sedangkan Q11 tentang kemampuan belajar mandiri meskipun menggunakan AI memperoleh bobot terendah sebesar 0,076. Hasil ini menunjukkan bahwa Naïve Bayes dapat digunakan untuk mengklasifikasikan persepsi responden pada dataset penelitian, sementara pembobotan atribut membantu mengidentifikasi butir yang paling informatif dalam membedakan kategori persepsi.

Kata kunci: Persepsi Mahasiswa, Artificial Intelligence, Naïve Bayes, Klasifikasi, Information Gain

Abstract

The use of Artificial Intelligence (AI) in students' academic activities is increasing, from finding references to understanding course materials. However, students may have different perceptions of AI, creating a need for a method to classify these perceptions and identify attributes that provide useful information for distinguishing categories. This study aims to classify students' perceptions of AI use in academic activities in Serpong District into High and Low categories, evaluate model performance, and identify the attributes most informative for distinguishing perception categories. The study adopted a quantitative approach guided by the Cross-Industry Standard Process for Data Mining (CRISP-DM). Data were collected through a Likert-scale questionnaire containing 19 statements from 120 students selected using purposive sampling. Class labels were established using the median of respondents' average scores. The Naïve Bayes algorithm was implemented in RapidMiner and evaluated using 10-fold cross-validation with accuracy, precision, recall, and F1-score as performance metrics. Attribute analysis was conducted using the Weight by Information Gain operator. The results showed average accuracy of 95.00%, precision of 98.33%, recall of 91.67%, and F1-score of 94.36%. The Information Gain analysis indicated that Q18, the statement that AI has become an important part of academic activities, had the highest weight at 0.321, while Q11, concerning the ability to study independently while using AI, had the lowest weight at 0.076. These findings indicate that Naïve Bayes can classify respondents' perceptions within the study dataset, while attribute weighting helps identify questionnaire items that are most informative for distinguishing perception categories.

Keywords: Student Perceptions, Artificial Intelligence, Naïve Bayes, Classification, Information Gain

1. Pendahuluan

Perkembangan *Artificial Intelligence* yang pesat telah mengubah cara kerja di berbagai bidang menjadi lebih efektif, cepat, dan efisien, serta diperkirakan akan terus menghadirkan tantangan dan peluang baru (Rozali et al., 2024). Di lingkungan pendidikan tinggi, AI mulai dimanfaatkan mahasiswa untuk menyelesaikan tugas, mencari referensi pembelajaran, dan memahami materi yang kompleks. Seperti penerapan teknologi baru pada umumnya, pemanfaatan ini dapat berdampak positif maupun negatif (Zahara et al., 2023), sehingga memunculkan persepsi yang beragam di kalangan mahasiswa.

Persepsi mahasiswa terhadap penggunaan AI dapat berbeda bergantung pada pengalaman, tingkat pemahaman, dan intensitas penggunaannya. Persepsi tersebut dapat diukur dengan skala Likert dan dinyatakan dalam tingkat tertentu, sehingga diperlukan metode yang mampu mengelompokkan persepsi secara sistematis berdasarkan pola jawaban responden. Oleh karena itu, diperlukan metode klasifikasi yang mampu mengidentifikasi pola jawaban responden secara sistematis untuk menentukan kategori persepsi mahasiswa. Salah satu metode yang dapat digunakan adalah algoritma *Naïve Bayes*, yaitu metode klasifikasi berbasis probabilitas yang memiliki proses perhitungan sederhana dan efisien sehingga dapat diterapkan dalam pengolahan data klasifikasi (Tanti et al., 2026).

Sejumlah penelitian telah mengkaji topik yang berdekatan. (Endraswari et al., 2025) menerapkan *Naïve Bayes* untuk mengklasifikasikan tingkat ketergantungan 58 mahasiswa terhadap ChatGPT dan memperoleh akurasi 83,3%, dengan sikap mahasiswa sebagai faktor yang paling berpengaruh. (Febrianti & Fitriani, 2024) memprediksi ketergantungan mahasiswa pada ChatGPT dari data survei skala Likert terhadap 254 mahasiswa; kinerja terbaik diperoleh pada pembagian data 70:30 dengan skor F1 sebesar 86,6%. Sementara itu, (Ole et al., 2026) mengkaji persepsi mahasiswa terhadap penggunaan ChatGPT dalam mengerjakan tugas melalui wawancara dengan analisis deskriptif kualitatif dan menemukan persepsi yang umumnya positif, disertai kekhawatiran terhadap ketergantungan, berkurangnya berpikir kritis, dan pelanggaran etika akademik.

Ketiga penelitian tersebut memperlihatkan bahwa penelitian klasifikasi cenderung berfokus pada tingkat ketergantungan terhadap ChatGPT, sedangkan penelitian tentang persepsi bersifat deskriptif tanpa membangun model klasifikasi. Dalam kajian ini belum ditemukan penelitian yang mengklasifikasikan persepsi mahasiswa terhadap penggunaan AI secara umum dalam kegiatan akademik menggunakan *Naïve Bayes* berdasarkan data primer kuesioner. Kebaruan penelitian ini terletak pada klasifikasi persepsi tersebut dan pada analisis *Weight by Information Gain* yang menunjukkan atribut pertanyaan dengan kontribusi terbesar dalam membedakan kategori persepsi.


Tujuan penelitian ini adalah mengklasifikasikan persepsi mahasiswa di wilayah Kecamatan Serpong terhadap penggunaan AI dalam kegiatan akademik ke dalam kategori Rendah dan Tinggi menggunakan *Naïve Bayes*, mengevaluasi kinerja model dengan *10-fold cross validation* berdasarkan *accuracy*, *precision*, *recall*, dan *F1-Score*, serta mengidentifikasi atribut yang paling berpengaruh terhadap kategori persepsi. Hasil penelitian diharapkan memberikan gambaran persepsi mahasiswa yang memenuhi kriteria responden dan menjadi rujukan bagi institusi pendidikan dalam memahami pemanfaatan AI di lingkungan akademik.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode data mining untuk mengklasifikasikan persepsi mahasiswa terhadap penggunaan *Artificial Intelligence* dalam kegiatan akademik. Pendekatan kuantitatif dipilih karena data berupa angka hasil kuesioner skala likert sehingga dapat dianalisis secara sistematis dan objektif. Algoritma *Naïve Bayes* digunakan sebagai metode klasifikasi, dan kontribusi setiap atribut terhadap kelas persepsi dianalisis menggunakan *Weight by Information gain*.

2.1. Tahapan Penelitian

Pengolahan data mengikuti kerangka CRISP-DM (*Cross Industry Standard Process for Data Mining*) pada Gambar 1, yang terdiri atas *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*. Pada tahap *business understanding*, permasalahan dirumuskan sebagai bagaimana mengklasifikasikan persepsi mahasiswa dan mengevaluasi kinerja algoritma tersebut.



Gambar 1 Tahapan Crisp-dm (Navisa et al., 2021)

Tahap *data understanding* mencakup pengumpulan data kuesioner dan pengenalan atribut yang diuraikan pada sub bab 2.2. Tahap *data preparation* meliputi pemeriksaan missing value menggunakan python, seleksi atribut, dan pembentukan label dengan Microsoft Excel pada sub bab 2.3 Tahap *modeling* membangun model menggunakan naive bayes dengan 10-fold cross validation pada RapidMiner, Sedangkan tahap *evaluation* menggunakan *confusion matrix*. Sebagai analisis pendukung dilakukan pembobotan atribut dengan *weight by information gain*, dan tahap *deployment* berupa penyajian hasil dalam laporan penelitian serta artikel ini.

2.2. Instrumen Penelitian

“Populasi dalam suatu penelitian mencakup seluruh kelompok atau elemen yang memiliki karakteristik tertentu sesuai dengan fokus penelitian yang dilakukan, baik berupa individu, objek, maupun kejadian yang relevan”(Asrulla et al., 2023).Populasi dalam penelitian ini adalah seluruh mahasiswa yang berada di wilayah Kecamatan Serpong yang menggunakan *Artificial Intelligence* dalam kegiatan akademik.“Sampel adalah bagian kecil dari suatu kelompok yang diambil dari seluruh populasi untuk dipelajari secara detail. Ukurannya biasanya lebih kecil, tapi tetap bisa mencerminkan karakteristik utama dari seluruh populasi.” (Mushofa et al., 2024). Penelitian ini menggunakan teknik pengambilan sampel purposive sampling, yaitu pemilihan responden berdasarkan kriteria yang telah ditentukan sesuai dengan tujuan penelitian.

Data dikumpulkan melalui kuesioner daring menggunakan Google Form pada periode pengumpulan data. Instrumen terdiri atas 19 butir pernyataan dengan skala Likert numerik 1 sampai 5 yang mewakili lima indikator, sebagaimana ditunjukkan pada Tabel 1.

Tabel 1 Atribut Penelitian

Kode	Pernyataan	Indikator
Q1	Penggunaan AI memudahkan saya dalam memahami materi perkuliahan.	Kemudahan penggunaan
Q2	AI membantu saya dalam mencari referensi akademik.	Kemudahan penggunaan
Q3	AI mempermudah saya dalam menyelesaikan tugas kuliah.	Kemudahan penggunaan
Q4	AI mudah digunakan dalam validasi materi mata kuliah.	Kemudahan penggunaan
Q5	Penggunaan AI membuat proses belajar menjadi lebih efisien.	Efektivitas penggunaan
Q6	AI membantu meningkatkan produktivitas saya dalam belajar.	Efektivitas penggunaan
Q7	AI membantu saya memahami materi yang sulit dengan lebih cepat.	Efektivitas penggunaan
Q8	AI memberikan solusi yang relevan terhadap persoalan materi kuliah.	Efektivitas penggunaan
Q9	Penggunaan AI membuat saya lebih bergantung dalam mengerjakan tugas.	Dampak terhadap proses belajar
Q10	AI mempengaruhi cara saya dalam berpikir dan belajar.	Dampak terhadap proses belajar
Q11	Saya tetap mampu belajar mandiri meskipun menggunakan AI.	Dampak terhadap proses belajar
Q12	AI membantu meningkatkan kemampuan berpikir kritis saya.	Dampak terhadap proses belajar
Q13	AI merupakan teknologi yang bermanfaat dalam kegiatan akademik.	Persepsi terhadap AI
Q14	AI memberikan dampak positif dalam proses pembelajaran.	Persepsi terhadap AI
Q15	AI dapat meningkatkan kualitas pembelajaran mahasiswa.	Persepsi terhadap AI

Kode	Pernyataan	Indikator
Q16	Saya sering menggunakan AI dalam mengerjakan tugas kuliah.	Penggunaan AI dalam akademik
Q17	Saya menggunakan AI sebagai alat bantu belajar.	Penggunaan AI dalam akademik
Q18	AI sudah menjadi bagian penting dalam kegiatan akademik saya.	Penggunaan AI dalam akademik
Q19	Saya akan terus menggunakan AI dalam kegiatan akademik saya.	Penggunaan AI dalam akademik

Jumlah responden yang memenuhi kriteria adalah 120 orang, sehingga data primer penelitian terdiri atas 120 data. Karena sampel dipilih secara purposif dan secara tidak acak, hasil penelitian dibatasi pada karakteristik responden dan tidak digeneralisasi terhadap seluruh mahasiswa. Selain 19 pertanyaan tersebut, kuesioner memuat data jenis kelamin, Usia, semester, dan Jenis AI yang digunakan responden.

2.3. Pembentukan Label

Sebelum pemodelan, dilakukan pemeriksaan missing value menggunakan python untuk memastikan tidak ada data kosong. Atribut Q1-Q19 ditetapkan sebagai atribut masukan, sedangkan atribut identitas dan semester tidak dipakai sebagai prediktor. Label kelas dibentuk Microsoft Excel dari rata-rata skor jawaban setiap responden pada 19 pertanyaan, sebagaimana dinyatakan pada persamaan 1

Label dibentuk di Microsoft Excel dalam tiga langkah. Pertama, rata-rata skor setiap responden dihitung dengan Persamaan 1

$$\bar{X}_i = \frac{Q_1 + Q_2 + \dots + Q_{19}}{19} \quad (1)$$

Dengan X_i adalah rata-rata skor persepsi responden ke-i dan Q_{ij} adalah skor responden ke-i pada pernyataan ke-j. Kedua, median dari 120 nilai rata-rata ditetapkan sebagai batas (cutt-off) agar batas kategori tidak ditentukan secara kategori tidak ditentukan secara subjektif.

$$M_e = \text{Median}(X_1, X_2, \dots, X_{120}) \quad (2)$$

dengan M_e adalah nilai median dan X_1 sampai X_{120} adalah rata-rata skor persepsi dari 120 responden. Median yang diperoleh sebesar 4,105263. Responden dengan rata-rata skor kurang dari atau sama dengan median dikategorikan Rendah, sedangkan responden dengan rata-rata skor di atas median dikategorikan Tinggi. Perhitungan dan pelabelan dilakukan menggunakan *Microsoft Excel* dan menghasilkan 61 data kelas Rendah (50,8%) serta 59 data kelas Tinggi (49,2%), sehingga distribusi kelas relatif seimbang.

2.4. Algoritma Naive Bayes

Klasifikasi merupakan teknik data mining untuk mengenali pola dalam data dan memprediksi kelas suatu objek berdasarkan objek lain yang kelasnya telah diketahui (Musa et al., 2024). Salah satu Algoritma yang dapat digunakan untuk proses klasifikasi adalah *Naïve Bayes*, yaitu algoritma machine learning berbasis probabilitas dan statistika yang menggunakan Teorema Bayes sebagai dasar perhitungannya (Susana & Suarna, 2022). Algoritma ini digunakan untuk memperkirakan probabilitas suatu kelas berdasarkan informasi atau atribut yang terdapat pada data (Kusuma & Nugroho, 2021).

Teorema Bayes digunakan untuk menghitung probabilitas suatu hipotesis berdasarkan informasi atau bukti yang diketahui. Dalam klasifikasi, perhitungan tersebut digunakan untuk menentukan probabilitas suatu data termasuk ke dalam kelas tertentu, sebagaimana ditunjukkan pada Persamaan (3).

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

Dengan (X) merupakan data yang kelasnya belum diketahui, (H) merupakan hipotesis bahwa data (X) termasuk dalam kelas tertentu, $P(H|X)$ merupakan probabilitas hipotesis setelah data diketahui, $P(H)$ merupakan probabilitas awal hipotesis, $P(X|H)$ merupakan probabilitas munculnya data (X) apabila hipotesis (H) benar, dan

($P(X)$) merupakan probabilitas kemunculan data (X). Dalam penelitian ini, atribut Q1 sampai Q19 digunakan sebagai prediktor, sedangkan atribut Kategori digunakan sebagai label klasifikasi. Untuk perhitungan manual, digunakan pendekatan Gaussian Naïve Bayes yang menghitung *likelihood* atribut numerik berdasarkan distribusi normal. Persamaan Gaussian tersebut ditunjukkan pada Persamaan (4).

$$P(x_i|C) = \frac{1}{\sqrt{2\pi}\sigma^2} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma^2}\right) \quad (4)$$


(x_i) merupakan nilai atribut ke-(i) pada data yang diuji, (C) merupakan kelas yang sedang dihitung, (μ) merupakan rata-rata nilai atribut pada kelas (C), dan (σ) merupakan standar deviasi nilai atribut pada kelas (C). Persamaan tersebut digunakan untuk memperoleh nilai *likelihood* setiap atribut berdasarkan distribusi Gaussian. Selanjutnya, probabilitas *prior* dan nilai *likelihood* dari seluruh atribut digunakan untuk menghitung skor setiap kelas. Perhitungan skor kelas ditunjukkan pada Persamaan (5).

$$\text{Skor}(C) = P(C) \prod_{i=1}^{19} P(X_i|C) \quad (5)$$

Dengan ($P(C)$) merupakan probabilitas *prior* kelas (C), sedangkan ($P(X_i|C)$) merupakan nilai *likelihood* atribut ke-(i) pada kelas (C). Simbol ($\prod$) menunjukkan perkalian nilai *likelihood* dari seluruh 19 atribut prediktor. Berdasarkan hasil perhitungan tersebut, data ditetapkan ke kelas yang memiliki skor terbesar.

Pemodelan dilakukan menggunakan perangkat lunak RapidMiner yang menyediakan antarmuka grafis untuk memudahkan pengguna dalam melakukan analisis data tanpa memerlukan keterampilan pemrograman secara mendalam (Sudarsono et al., 2021). Selain itu, RapidMiner menyediakan berbagai operator yang mendukung tahapan analisis secara menyeluruh, mulai dari pengolahan data, *preprocessing*, pemodelan menggunakan algoritma klasifikasi, hingga evaluasi kinerja model.

Data hasil prapemrosesan diimpor menggunakan operator *Read Excel*, sedangkan atribut Kategori ditetapkan sebagai label menggunakan operator *Set Role*. Selanjutnya, data diproses melalui operator *Cross Validation* untuk mengevaluasi kinerja model klasifikasi, sebagaimana ditunjukkan pada Gambar 2. Selain pengujian menggunakan RapidMiner, perhitungan *Naïve Bayes* dengan distribusi Gaussian juga dilakukan secara manual menggunakan Microsoft Excel untuk menelusuri tahapan perhitungan probabilitas *prior*, rata-rata, standar deviasi, *likelihood*, dan skor setiap kelas.



Gambar 2 Proses Klasifikasi Naive Bayes

2.5 Evaluasi Model

Model divalidasi menggunakan *10-fold cross validation*. Data dibagi menjadi sepuluh *fold* berukuran relatif sama. Pada setiap iterasi sembilan *fold* digunakan sebagai data latih oleh operator *Naïve Bayes* dan satu *fold* sebagai data uji melalui operator *Apply Model* dan *Performance*, seperti pada Gambar 2, sehingga setiap *fold* menjadi data uji tepat satu kali. Data diimpor dengan operator *Read Excel* dan atribut Kategori ditetapkan sebagai label dengan operator *Set Role*.



Gambar 3 Subproses pelatihan dan pengujian di dalam operator Cross Validation

Kinerja model dievaluasi menggunakan *confusion matrix*, yaitu tabel yang membandingkan hasil prediksi model dengan kelas sebenarnya. Melalui tabel tersebut, dapat diketahui jumlah prediksi yang benar maupun kesalahan klasifikasi berdasarkan empat komponen, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN) (Valerian et al., 2025). Berdasarkan komponen tersebut, evaluasi kinerja model dilakukan menggunakan empat metrik, yaitu *accuracy*, *precision*, *recall*, dan *F1-Score* (Negoro et al., 2023), sebagaimana ditunjukkan pada Persamaan (6) sampai (9).

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (6)$$

$$Precision = \frac{TP}{TP+FP} \quad (7)$$

$$Recall = \frac{TP}{TP+FN} \quad (8)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (9)$$

dengan TP adalah jumlah data Tinggi yang diprediksi Tinggi, TN adalah jumlah data Rendah yang diprediksi Rendah, FP adalah jumlah data Rendah yang diprediksi Tinggi, dan FN adalah jumlah data Tinggi yang diprediksi Rendah. Sebagai analisis pendukung, operator *Weight by Information Gain* digunakan untuk meranking atribut yang paling berpengaruh terhadap kelas (Fajriyan et al., 2022).

3. Hasil dan Pembahasan

3.1. Karakteritik Responden

Sebanyak 120 mahasiswa menjadi responden penelitian. Tabel 2 menunjukkan bahwa komposisi jenis kelamin relatif seimbang, yaitu 62 laki-laki(51,7%) dan 58 perempuan (48,3). Dari sisi usia, responden didominasi kelompok 21-23 tahun(62,5%), dan dari sisi jenjang semester, lebih dari separuh responden berada pada semester 8 (58,3%). Komposisi ini menunjukkan bahwa data lebih banyak mewakili mahasiswa tingkat akhir, yaitu kelompok yang cenderung lebih sering menggunakan Artificial Inlligence dalam kegiatan akademik.

Tabel 2 Karakteristik Responden

Karakteristik	Kategori	Jumlah (orang)	Persentase
Jenis kelamin	Laki-laki	62	51,7%
	Perempuan	58	48,3%
Usia	18–20 tahun	25	20,8%
	21–23 tahun	75	62,5%
	24–26 tahun	17	14,2%
	27 tahun ke atas	3	2,5%
Semester	Semester 2	13	10,8%
	Semester 4	12	10,0%
	Semester 6	23	19,2%
	Semester 7	2	1,7%
	Semester 8	70	58,3%

Responden diperbolehkan memilih lebih dari satu aplikasi AI yang digunakan, sehingga jumlah persentase pada Tabel 3 melebihi 100%. Chat GPT merupakan aplikasi yang paling banyak digunakan (91,7%), diikuti oleh Google Gemini(83,3%) dan Claude(50,8%). Temuan ini menunjukkan bahwa sebagian besar mahasiswa menggunakan lebih dari satu aplikasi AI yang digunakan untuk menunjang kegiatan akademiknya.

Tabel 3 Aplikasi AI yang digunakan responden

Aplikasi AI	Jumlah responden	Persentase
ChatGPT	110	91,7%
Google Gemini	100	83,3%
Claude	61	50,8%
Perplexity AI	42	35,0%
Blackbox AI	41	34,2%
Microsoft Copilot	26	21,7%
Chatbot Kademangan	1	0,8%
KIRO AI	1	0,8%
Grok	1	0,8%

3.2. Hasil Prapemrosesan dan Pembentukan label

Pemeriksaan missing value menunjukkan bahwa seluruh atribut memiliki nilai kosong sebanyak nol, sehingga tidak diperlukan penanganan data hilang. Dataset akhir terdiri dari 120 baris data dengan 26 atribut, dan 19 diantaranya, yaitu Q1-Q19, digunakan sebagai prediktor.

Median skor rata-rata persepsi dari 120 responden adalah 4,105263. Berdasarkan nilai batas tersebut diperoleh 59 responden (49,2%) pada kategori Tinggi dan 61 responden (50,8%) pada kategori Rendah. Distribusi kedua kelas yang hampir seimbang ini penting karena pada data yang timpang nilai *accuracy* dapat didominasi oleh kelas mayoritas. Perlu dicatat bahwa median yang berada di atas skor 4 pada skala 1–5 menunjukkan bahwa responden secara umum menilai penggunaan AI secara positif, sehingga kategori Rendah dalam penelitian ini bermakna relatif terhadap responden lain dan bukan persepsi yang negatif.

3.3. Perhitungan Probabilitas pada Algoritma Naïve Bayes

Probabilitas *prior* kelas Tinggi adalah $59/120 = 0,4917$ dan kelas Rendah adalah $61/120 = 0,5083$. Rata-rata dan standar deviasi setiap atribut pada masing-masing kelas, yang menjadi parameter distribusi Gaussian, disajikan pada Tabel 4. Rata-rata seluruh atribut pada kelas Tinggi lebih besar daripada kelas Rendah, dengan selisih terbesar pada Q10, Q19, Q18, Q9, dan Q6, sedangkan selisih terkecil terdapat pada Q11.

Tabel 4 Rata-rata dan standar deviasi atribut pada setiap kelas

Atribut	Rata-rata (Tinggi)	Standar deviasi (Tinggi)	Rata-rata (Rendah)	Standar deviasi (Rendah)
Q1	4,763	0,425	4,049	0,638
Q2	4,712	0,584	4,082	0,836
Q3	4,847	0,360	4,066	0,827
Q4	4,678	0,502	3,869	0,819
Q5	4,644	0,479	3,820	0,800
Q6	4,576	0,764	3,541	0,985
Q7	4,814	0,389	3,918	0,795
Q8	4,593	0,641	3,656	0,744
Q9	4,034	1,119	2,984	0,932
Q10	4,373	0,757	3,197	1,005
Q11	4,390	0,824	3,967	0,789
Q12	4,322	0,999	3,443	0,779
Q13	4,729	0,481	4,033	0,746
Q14	4,576	0,527	3,836	0,751

Atribut	Rata-rata (Tinggi)	Standar deviasi (Tinggi)	Rata-rata (Rendah)	Standar deviasi (Rendah)
Q15	4,475	0,647	3,689	0,690
Q16	4,508	0,593	3,623	0,750
Q17	4,729	0,445	4,000	0,768
Q18	4,475	0,767	3,410	0,817
Q19	4,441	0,618	3,279	0,749

Sebagai ilustrasi, perhitungan dilakukan terhadap satu data responden. Hasil perkalian likelihood Gaussian ke-19 atribut beserta skor posteriornya ditunjukkan pada Tabel 5. Skor kelas Rendah jauh lebih besar daripada kelas Tinggi, dengan probabilitas posterior ternormalisasi sebesar 0,999966, sehingga data tersebut diklasifikasikan ke dalam kelas Rendah, sesuai dengan kelas aktualnya. Penerapan perhitungan manual yang sama terhadap seluruh data menghasilkan 114 prediksi benar dan 6 prediksi salah, konsisten dengan keluaran RapidMiner.

Tabel 5 Hasil perhitungan posterior pada satu data uji

Kelas	Prior	$P(X C)$	Skor	Posterior ternormalisasi
Tinggi	0,4917	$5,843812 \times 10^{-13}$	$2,873208 \times 10^{-13}$	0,000034
Rendah	0,5083	$1,678670 \times 10^{-8}$	$8,533240 \times 10^{-9}$	0,999966

3.4 Kinerja model klasifikasi

Confusion matrix hasil pengujian *10-fold cross validation* pada RapidMiner disajikan pada tabel 6 sebanyak 60 data kategori Rendah dan 54 data kategori Tinggi diklasifikasikan dengan benar, sedangkan 1 data kategori Rendah diprediksi sebagai Tinggi dan 5 data kategori Tinggi diprediksi sebagai Rendah. Dengan demikian, 114 dari 120 data (95,00%) terklasifikasi dengan benar.

Tabel 6 *Confusion matrix*

	Aktual Rendah	Aktual Tinggi	Class precision
Prediksi Rendah	60	5	92,31%
Prediksi Tinggi	1	54	98,18%
Class recall	98,36%	91,53%	

Nilai metrik evaluasi dirangkum pada Tabel 7. Hasil pengujian menggunakan RapidMiner menunjukkan nilai rata-rata dari sepuluh *fold*, yaitu *accuracy* sebesar 95,00%, *precision* sebesar 98,33%, *recall* sebesar 91,67%, dan *F1-Score* sebesar 94,36%, dengan kelas Tinggi sebagai kelas positif. Sementara itu, perhitungan berdasarkan *confusion matrix* gabungan menggunakan Persamaan (5) sampai (8) menghasilkan nilai *precision* sebesar 98,18%, *recall* sebesar 91,53%, dan *F1-Score* sebesar 94,74%. Perbedaan nilai antara kedua perhitungan tersebut terjadi karena hasil pertama merupakan rata-rata metrik dari setiap *fold*, sedangkan hasil kedua dihitung berdasarkan akumulasi prediksi dari seluruh *fold*.

Tabel 7 Kinerja model Naïve Bayes (kelas positif: Tinggi)


Metrik	Rata-rata 10 <i>fold</i> (RapidMiner)	Dihitung dari <i>confusion matrix</i> gabungan
<i>Accuracy</i>	95,00% ± 5,83%	95,00%
<i>Precision</i>	98,33% ± 5,27%	98,18%
<i>Recall</i>	91,67% ± 11,79%	91,53%
<i>F1-score</i>	94,36% ± 6,77%	94,74%

Hasil evaluasi pada Tabel 7 menunjukkan bahwa model Naïve Bayes memperoleh nilai *accuracy* sebesar 95,00% berdasarkan rata-rata sepuluh *fold*. Nilai *precision* sebesar 98,33% lebih tinggi dibandingkan *recall* sebesar 91,67%. Hal ini menunjukkan bahwa prediksi model terhadap kelas Tinggi memiliki ketepatan yang tinggi, meskipun model masih belum berhasil mengidentifikasi seluruh data yang sebenarnya termasuk dalam kelas tersebut. Sementara itu, nilai *F1-score* sebesar 94,36% menunjukkan keseimbangan yang baik antara *precision* dan *recall*. Perhitungan berdasarkan *confusion matrix* gabungan menghasilkan nilai *precision* sebesar 98,18%, *recall* sebesar 91,53%, dan *F1-score* sebesar 94,74%. Perbedaan nilai tersebut terjadi karena rata-rata metrik per-

fold dihitung dari hasil evaluasi setiap bagian data, sedangkan metrik dari *confusion matrix* gabungan dihitung berdasarkan akumulasi hasil prediksi seluruh *fold*.

3.5 Analisis Bobot Atribut Menggunakan *Weight by Information Gain*

Hasil pembobotan atribut menggunakan operator *Weight by Information Gain* ditunjukkan pada Gambar 4. Hasil tersebut menunjukkan bahwa pernyataan Q18, yaitu “AI sudah menjadi bagian penting dalam kegiatan akademik saya”, memperoleh bobot tertinggi, sekitar 0,32. Empat atribut berikutnya dengan bobot berkisar antara 0,26 hingga 0,30 adalah Q8 (AI memberikan solusi yang relevan terhadap persoalan materi kuliah), Q12 (AI membantu meningkatkan kemampuan berpikir kritis), Q19 (keinginan untuk terus menggunakan AI), dan Q7 (AI membantu memahami materi yang sulit dengan lebih cepat). Sementara itu, Q11, yaitu “Saya tetap mampu belajar mandiri meskipun menggunakan AI”, memperoleh bobot terendah, sekitar 0,076.



Gambar 4 Bobot Atribut Berdasarkan *Weight by Information Gain*

Hasil pembobotan tersebut menunjukkan bahwa Q18 merupakan atribut yang paling informatif dalam membedakan kategori persepsi mahasiswa pada dataset penelitian ini, sedangkan Q11 memiliki kemampuan pembeda yang relatif rendah. Tingginya bobot Q18, Q8, Q12, Q19, dan Q7 menunjukkan bahwa atribut terkait pentingnya AI dalam kegiatan akademik, relevansi manfaat, dukungan terhadap kemampuan berpikir kritis, niat penggunaan berkelanjutan, serta pemahaman materi memberikan informasi yang relatif besar dalam proses klasifikasi.

Untuk memperjelas hasil pembobotan tersebut, Tabel 8 menyajikan perbandingan bobot *Information Gain* dengan nilai rata-rata (*mean*) atribut pada kategori Tinggi dan Rendah. Perbandingan ini digunakan untuk melihat kesesuaian pola bobot atribut dengan perbedaan nilai rata-rata antarkelas.

Tabel 8 Bobot *information gain* dan *mean* atribut per kelas

Atribut	Bobot $\approx$	Mean Tinggi	Mean Rendah	Selisih
Q18	0,321	4,475	3,410	1,065
Q8	0,301	4,593	3,656	0,937
Q12	0,278	4,322	3,443	0,879
Q19	0,271	4,441	3,279	1,162
Q7	0,263	4,814	3,918	0,896
Q11	0,076	4,390	3,967	0,423

Berdasarkan Tabel 8, Q18 memiliki bobot *Information Gain* tertinggi sebesar 0,321, sedangkan Q11 memiliki bobot terendah sebesar 0,076. Selisih rata-rata terbesar terdapat pada Q19, yaitu 1,162, sedangkan Q11 memiliki

selisih terkecil sebesar 0,423. Hasil ini memberikan gambaran bahwa atribut yang dianalisis memiliki tingkat kemampuan pembeda yang berbeda dalam klasifikasi persepsi mahasiswa. Dengan demikian, analisis *Weight by Information Gain* membantu mengidentifikasi atribut yang paling informatif dalam membedakan kategori persepsi mahasiswa terhadap penggunaan *Artificial Intelligence* dalam kegiatan akademik.

4. Kesimpulan

Penelitian ini berhasil mengklasifikasikan persepsi 120 mahasiswa di Kecamatan Serpong terhadap penggunaan *Artificial Intelligence* dalam kegiatan akademik ke dalam kategori Tinggi dan Rendah menggunakan algoritma *Naïve Bayes*. Dengan label yang dibentuk berdasarkan median skor rata-rata sebesar 4,105263, diperoleh 59 responden berkategori Tinggi dan 61 responden berkategori Rendah. Pengujian dengan *10-fold cross validation* menghasilkan *accuracy* 95,00%, *precision* 98,33%, *recall* 91,67%, dan *F1-score* 94,36%, dengan 114 data terklasifikasi benar dan 6 data salah klasifikasi. Analisis *Weight by Information Gain* menunjukkan bahwa pernyataan mengenai AI yang telah menjadi bagian penting dalam kegiatan akademik merupakan atribut dengan kontribusi terbesar, sedangkan pernyataan mengenai kemampuan belajar mandiri meskipun menggunakan AI memiliki kontribusi terkecil. Hasil tersebut menunjukkan bahwa *Naïve Bayes* dapat digunakan untuk memetakan persepsi mahasiswa berdasarkan data kuesioner, dan bahwa tingkat keterlibatan AI dalam rutinitas akademik menjadi pembeda utama persepsi. Temuan ini dapat dimanfaatkan perguruan tinggi sebagai bahan pertimbangan dalam menyusun kebijakan dan program literasi penggunaan AI. Penelitian selanjutnya disarankan melibatkan responden yang lebih banyak dan beragam, menggunakan label yang diperoleh secara independen dari atribut prediktor, membandingkan *Naïve Bayes* dengan algoritma lain seperti *Decision Tree*, *Random Forest*, *K-Nearest Neighbor*, dan *Support Vector Machine*, serta melengkapi data kuesioner dengan wawancara agar persepsi mahasiswa dapat dijelaskan secara lebih mendalam.

Reference

1. Asrulla, R., Jailani, M. S., & Jeka, F. (2023). Populasi dan sampling (kuantitatif), serta pemilihan informan kunci (kualitatif) dalam pendekatan praktis. *Jurnal Pendidikan Tambusai*, 7(3), 26320–26332. <https://doi.org/https://doi.org/10.31004/jptam.v7i3.10836>
2. Endraswari, P. M., Tou, N., & Zaliman, I. (2025). ANALISIS KETERGANTUNGAN MAHASISWA TERHADAP CHATGPT DALAM KONTEKS AKADEMIK : PEMODELAN KLASIFIKASI BERBASIS NAÏVE BAYES. *Jurnal Informasi Interaktif*, 10(3), 199–208. <https://doi.org/https://doi.org/10.37159/jii.v10i3>
3. Fajriyan, F. N., Ahsan, M., & Harianto, W. (2022). Komparasi Tingkat Akurasi Information Gain Dan Gain Ratio Pada Metode K-Nearest Neighbor. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 6(1), 386–391. <https://doi.org/10.36040/jati.v6i1.4694>
4. Febrianti, R., & Fitriani, S. (2024). *Artificial Intelligence in Educational Research*. 1(2), 10–21. <https://doi.org/10.5772/intechopen.113844>
5. Kusuma, A., & Nugroho, A. (2021). Analisa Sentimen Pada Twitter Terhadap Kenaikan Tarif Dasar Listrik Dengan Metode Naïve Bayes. *Jurnal Ilmiah Teknologi Informasi*, 15(2), 137–146. <https://doi.org/10.32815/jitika.v15i2.557>
6. Musa, D. M., Sakti, D., Shantiony, K. A., Zega, S. K. P., Hamzah, S., Zega, Y. J., & Lubis, B. O. (2024). Penerapan Data Mining Untuk Klasifikasi Data Penjualan Pakan Ternak Terlaris Dengan Algoritma C4.5. *Jurnal Teknologi Informatika Dan Komputer MH. Thamrin*, 10(1), 168–182. <https://doi.org/https://doi.org/10.37012/jtik.v10i1.1985>
7. Mushofa, M., Hermina, D., & Huda, N. (2024). Memahami Populasi dan Sampel: Pilar Utama dalam Penelitian Kuantitatif. *Jurnal Syntax Admiration*, 5(12), 5937–5948. <https://doi.org/10.46799/jsa.v5i12.1992>
8. Navisa, S., Luqman Hakim, & Aulia Nabilah. (2021). Komparasi Algoritma Klasifikasi Genre Musik pada Spotify Menggunakan CRISP-DM. *Jurnal Sistem Cerdas*, 4(2), 114–125. <https://doi.org/10.37396/jsc.v4i2.162>
9. Negoro, N. K., Utami, E., & Yaqin, A. (2023). Klasifikasi Deteksi Penggunaan Masker Menggunakan Metode Convolutional Neural Network. *JIIPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 8(2), 664–674. <https://doi.org/10.29100/jipi.v8i2.3748>
10. Ole, A. A., Supit, D., & Lotulung, M. (2026). PERSEPSI MAHASISWA TENTANG PENGGUNAAN AI (CHAT GPT) DALAM MENGERJAKAN TUGAS. *Jurnal Ilmiah Pendidikan Dasar*, 10(01), 1–15. <https://doi.org/https://doi.org/10.23969/jp.v11i01.44069>
11. Rozali, C., Zein, A., & Eriana, E. S. (2024). Artificial Intelligence (AI) Dimasa Depan : Tantangan Dan Peluang. *Jurnal Inovasi Pengabdian Masyarakat*, 2, 66–71. <https://doi.org/https://doi.org/10.55903/jitu.v2i1.177>
12. Sudarsono, B. G., Leo, M. I., Santoso, A., & Hendrawan, F. (2021). ANALISIS DATA MINING DATA NETFLIX MENGGUNAKAN APLIKASI RAPID MINER. *JBASE - Journal of Business and Audit Information Systems*, 4(1), 13–21. <https://doi.org/10.30813/jbase.v4i1.2729>
13. Susana, H., & Suarna, N. (2022). PENERAPAN MODEL KLASIFIKASI METODE NAIVE BAYES TERHADAP PENGGUNAAN AKSES INTERNET. *Jurnal Sistem Informasi Dan Teknologi Informasi*, 4(1), 1–8. <https://doi.org/https://doi.org/10.52005/jursistekni.v4i1.96>
14. Tanti, L., Alam, A., & Wanayumini. (2026). Analisis Pengaruh Seleksi Atribut Relief-F dan Gain Ratio Terhadap Performa Naïve Bayes Classifier. 15. <https://doi.org/10.33395/jmp.v15i2.16112>
15. Valerian, F. R., Syarief, M., Fatah, D. A., Informasi, S., Madura, U. T., Kamal, K., & Timur, J. (2025). Klasifikasi tingkat obesitas menggunakan metode gbm dan confusion matrix. *Jurnal Mahasiswa Teknik Informatika*, 9(2), 2242–2249. <https://doi.org/https://doi.org/10.36040/jati.v9i2.13062>
16. Zahara, S. L., Azkia, Z. U., & Chusni, M. M. (2023). Implementasi Teknologi Artificial Intelligence (AI) dalam Bidang Pendidikan. *Jurnal Penelitian Sains Dan Pendidikan*, 3, 15–20. <https://doi.org/doi.org/10.23971/jpsp.v3i1.4022>