

## ANALISIS POLA PERUBAHAN NILAI MAHASISWA MENGGUNAKAN METODE NAIVE BAYES DAN DECISION TREE

Akhsanul Khuluq<sup>1</sup>, Farid Fitriyadi<sup>2</sup>

<sup>1,2</sup>Program Studi Informatika, Universitas Sahid Surakarta

\*e-mail: [khuluqahsan237@gmail.com](mailto:khuluqahsan237@gmail.com)

Received: 12-12-2025

Revised: 14-01-2026

Approved: 10-02-2026

### ABSTRAK

Nilai akademik merupakan indikator penting dalam menilai keberhasilan proses pembelajaran di perguruan tinggi. Penelitian ini bertujuan untuk menganalisis pola perubahan nilai mahasiswa dengan memanfaatkan metode klasifikasi berbasis Naive Bayes dan Decision Tree. Permasalahan utama yang diangkat adalah bagaimana kedua algoritma tersebut dapat digunakan untuk mengidentifikasi kecenderungan perubahan nilai mahasiswa berdasarkan jalur ajuan perbaikan nilai, baik melalui program studi maupun dosen pengampu. Data penelitian berupa riwayat nilai mahasiswa dari tahun 2023 hingga 2025, mencakup catatan nilai KHS, nilai baru, serta jalur ajuan perbaikan nilai. Tahapan penelitian meliputi pra-pemrosesan data (normalisasi, pembersihan, dan pembagian data training-testing), pembangunan model klasifikasi, optimasi hyperparameter, serta evaluasi menggunakan metrik akurasi, presisi, recall, F1-score, dan confusion matrix. Hasil analisis menunjukkan bahwa kedua metode memiliki tingkat akurasi yang sangat baik, dengan nilai akurasi mencapai 97% untuk Naive Bayes dan 98% untuk Decision Tree. Model Decision Tree unggul dalam memberikan visualisasi pola perubahan nilai, khususnya pada jalur program studi yang menunjukkan konsistensi tinggi dengan precision dan recall sebesar 0,98–0,99. Sementara itu, Naive Bayes lebih efisien dalam proses komputasi dan tetap menunjukkan performa stabil dengan precision dan recall di atas 0,90 pada jalur dosen pengampu. Namun, kelas klaim nilai ke transkrip dan hapus nilai tidak muncul dalam hasil evaluasi, yang mengindikasikan adanya ketidakseimbangan data (class imbalance). Temuan penelitian ini menegaskan perlunya pengayaan data serta penerapan teknik penyeimbangan agar model dapat menggeneralisasi seluruh jenis perubahan nilai secara optimal. Secara praktis, hasil penelitian diharapkan dapat menjadi dasar bagi institusi pendidikan dalam merancang strategi pembelajaran yang lebih adaptif, meningkatkan transparansi dalam pengelolaan akademik, serta memperkuat sistem evaluasi berbasis data.

**Kata kunci:** Nilai akademik; Naive Bayes; Decision Tree; Klasifikasi; Perubahan nilai; Class imbalance; Evaluasi akademik; Sistem informasi pendidikan

### PENDAHULUAN

Latar belakang dan urgensi

Nilai akademik merupakan indikator utama keberhasilan pembelajaran di perguruan tinggi—merefleksikan pemahaman mahasiswa sekaligus efektivitas pengajaran, kurikulum, dan evaluasi. Memetakan pola perubahan nilai antarsemeseter (peningkatan, penurunan, stagnasi) penting untuk deteksi dini masalah akademik dan perancangan kebijakan pembelajaran yang adaptif dan berbasis data. Dalam konteks akuntabilitas modern, institusi perlu menilai efektivitas mekanisme ajuan perbaikan nilai (dosen pengampu vs program studi) agar keputusan lebih adil dan transparan.

Literatur terbaru yang relevan

- Efektivitas ML untuk prediksi akademik: Tinjauan empiris menunjukkan ML mampu mengolah data besar dan mengidentifikasi pola prediksi, namun performa sangat bergantung pada karakteristik dataset, pemilihan algoritma, dan fitur yang dilatih.

- Prediksi nilai dan intervensi dini: Studi 2023 menegaskan model ML/Deep Learning dapat memprediksi nilai dan mengidentifikasi mahasiswa berisiko lebih awal, sehingga dukungan dapat diberikan tepat waktu.
- Pemilihan algoritma dan konteks data: SLR 2025 membandingkan KNN, Naive Bayes, dan Decision Tree—menekankan bahwa algoritma optimal bergantung pada sifat data dan tujuan analisis.
- Interpretabilitas untuk kebijakan: Literatur menekankan pentingnya model yang dapat dijelaskan (interpretable) agar hasil analisis dapat diadopsi oleh pengambil kebijakan pendidikan.

#### Masalah penelitian

- **Ketidakseimbangan kelas (class imbalance):** Distribusi tidak merata pada kategori “klaim nilai ke transkrip” dan “hapus nilai” berpotensi menurunkan akurasi dan generalisasi model, terutama pada kelas minor.
- **Efektivitas jalur ajuan perbaikan nilai:** Belum ada evaluasi sistematis perbandingan jalur dosen pengampu vs program studi dalam memengaruhi pola perubahan nilai.
- **Kebutuhan interpretabilitas untuk kebijakan:** Model prediktif harus tidak hanya akurat, tetapi juga mudah dijelaskan agar dapat diintegrasikan ke proses pengambilan keputusan akademik.

#### Tujuan penelitian

1. **Menganalisis pola perubahan nilai** mahasiswa berdasarkan jalur ajuan perbaikan nilai (dosen pengampu vs program studi).
2. **Membandingkan performa Naive Bayes dan Decision Tree** dalam mendeteksi pola perubahan nilai, menilai trade-off efisiensi komputasi vs interpretabilitas.
3. **Mengidentifikasi dampak class imbalance** dan mengevaluasi teknik penyeimbangan (mis. resampling) untuk meningkatkan generalisasi model pada kelas minor.
4. **Menyusun rekomendasi kebijakan akademik** berbasis temuan ML yang dapat dioperasionalkan oleh program studi dan dosen pengampu.

#### Metode dan alasan pemilihan algoritma

- **Naive Bayes:** Efisien secara komputasi, berbasis probabilistik dengan asumsi independensi antar fitur—cocok untuk dataset besar dan baseline cepat.
- **Decision Tree:** Mudah diinterpretasikan, dapat divisualisasikan sebagai pohon keputusan—memudahkan analisis pola dan komunikasi hasil ke pemangku kebijakan.

Kedua algoritma dipilih untuk menyeimbangkan kebutuhan efisiensi (Naive Bayes) dan interpretabilitas (Decision Tree), sejalan dengan rekomendasi literatur terbaru.

#### Kontribusi yang diharapkan

- **Kerangka evaluasi jalur ajuan nilai** yang terukur dan transparan, berbasis analitik ML.
- **Perbandingan komprehensif NB vs DT** pada konteks perubahan nilai, termasuk dampak penyeimbangan kelas.
- **Model yang dapat dijelaskan** untuk mendukung keputusan akademik dan intervensi dini—meningkatkan kepercayaan institusional.

## LANDASAN TEORI

### Pola Perubahan Nilai Mahasiswa

Nilai akademik mahasiswa merupakan indikator utama dalam menilai keberhasilan proses pembelajaran. Pola perubahan nilai dapat menunjukkan kecenderungan peningkatan, penurunan, atau stabilitas prestasi akademik. Analisis pola ini penting untuk mendeteksi masalah sejak dini, seperti penurunan motivasi belajar atau kesulitan memahami materi, sehingga institusi pendidikan dapat melakukan intervensi yang tepat.

Machine Learning dalam Analisis Pendidikan

*Machine learning* adalah cabang kecerdasan buatan yang berfokus pada pengembangan algoritma untuk belajar dari data dan membuat prediksi. Dalam konteks pendidikan, *machine learning* digunakan untuk:

- Memprediksi prestasi akademik mahasiswa.
- Mengidentifikasi faktor-faktor yang memengaruhi keberhasilan belajar.
- Memberikan rekomendasi strategi pembelajaran yang lebih personal.

### Algoritma Naive Bayes

Naive Bayes adalah algoritma klasifikasi berbasis probabilitas yang menggunakan Teorema Bayes dengan asumsi independensi antar atribut.

- Kelebihan:
  - Sederhana dan cepat dalam komputasi.
  - Efektif pada data berukuran besar dengan distribusi sederhana.
- Kelemahan:
  - Asumsi independensi sering tidak realistis pada data nyata.
  - Akurasi menurun jika terdapat korelasi kuat antar atribut.
- Aplikasi: Digunakan dalam analisis teks, prediksi akademik, dan sistem rekomendasi.

### Algoritma Decision Tree

Decision Tree adalah algoritma klasifikasi berbasis aturan yang membangun model dalam bentuk pohon keputusan.

- Kelebihan:
  - Mudah dipahami karena hasil klasifikasi divisualisasikan dalam bentuk pohon.
  - Dapat menangani data dengan atribut kategorikal maupun numerik.
- Kelemahan:
  - Rentan terhadap *overfitting* jika pohon terlalu kompleks.
  - Sensitif terhadap perubahan kecil pada data.
- Aplikasi: Digunakan dalam analisis perilaku, prediksi akademik, dan sistem pendukung keputusan.

### Perbandingan Naive Bayes dan Decision Tree

- Naive Bayes unggul dalam kecepatan dan efisiensi komputasi.
- Decision Tree unggul dalam interpretabilitas dan visualisasi pola.
- Kombinasi keduanya dapat memberikan hasil yang lebih komprehensif: Naive Bayes untuk prediksi cepat, Decision Tree untuk analisis mendalam.

## METODE PENELITIAN

### Data Penelitian

- Sumber Data: Sistem Informasi Akademik perguruan tinggi.
- Periode: Tahun 2023–2025.
- Unit Analisis: Nilai KHS mahasiswa (semester sebelumnya) dan nilai baru (semester berikutnya).
- Variabel Utama:

- NILAI\_KHS → nilai mahasiswa pada semester sebelumnya.
- NILAI\_BARU → nilai mahasiswa pada semester berikutnya.
- JALUR\_AJUAN → kategori ajuan perbaikan nilai (Dosen Pengampu / Program Studi).

### Pra-pemrosesan Data

Tahapan ini dilakukan untuk memastikan kualitas data sebelum digunakan dalam model klasifikasi:

- Normalisasi Data: Nilai dinormalisasi ke skala 0–1 agar bobot antar atribut seimbang.
- Pembersihan Data: Menghapus data duplikat, tidak lengkap, atau salah input.
- Pembagian Data: Dataset dibagi menjadi training set (70%) dan testing set (30%).

### Algoritma Klasifikasi

#### Naive Bayes

- Menghitung probabilitas prior tiap kelas.
- Menghitung likelihood tiap atribut terhadap kelas.
- Menggabungkan probabilitas untuk menentukan kelas dengan posterior tertinggi.
- Kelebihan: cepat, sederhana, efisien pada dataset besar.
- Kelemahan: asumsi independensi antar atribut sering tidak sesuai kondisi nyata.

#### Decision Tree

- Menentukan atribut terbaik dengan *information gain* atau *Gini index*.
- Membagi dataset ke cabang sesuai nilai atribut.
- Mengulang hingga terbentuk pohon keputusan lengkap.
- Kelebihan: mudah dipahami, hasil dapat divisualisasikan.
- Kelemahan: rentan overfitting jika pohon terlalu kompleks.

### Evaluasi Model

Metrik evaluasi yang digunakan:

- Akurasi: persentase prediksi benar.
- Presisi: ketepatan prediksi positif.
- Recall (Sensitivitas): kemampuan menemukan semua data positif.
- Confusion Matrix: distribusi kesalahan klasifikasi antar kelas.

### Tujuan Analisis

Mengetahui efektivitas dan kecenderungan hasil perbaikan nilai berdasarkan jalur ajuan (dosen pengampu vs program studi), serta membandingkan performa Naive Bayes dan Decision Tree.

### Gambar Alur Penelitian



- Sumber Data: Diambil dari sistem informasi akademik tahun 2023–2025.
- Pra-pemrosesan: Meliputi normalisasi nilai, pembersihan data, dan pembagian data menjadi training (70%) dan testing (30%).
- Build Model: Dua algoritma digunakan: Naive Bayes dan Decision Tree.
- Evaluasi Model: Menggunakan metrik akurasi, presisi, recall, dan confusion matrix.
- Tujuan Akhir: Prediksi pola ajuan perbaikan nilai berdasarkan jalur (dosen pengampu vs program studi).

## HASIL DAN PEMBAHASAN

Pada bagian ini disajikan hasil penelitian analisis pola perubahan nilai menggunakan algoritma *Naive Bayes* dan *Decision Tree*. Pembahasan dilakukan secara sistematis mulai dari hasil *preprocessing* data, pembangunan model *baseline*, proses optimasi *hyperparameter*, hingga evaluasi serta analisis perbandingan performa model sebelum dan sesudah dilakukan optimasi. Seluruh tahapan tersebut dipaparkan secara rinci untuk menunjukkan efektivitas pendekatan yang digunakan dalam meningkatkan akurasi dan stabilitas model klasifikasi.

### Pengumpulan dan *Preprocessing* data

Data yang digunakan berasal dari sistem informasi akademik perguruan tinggi, mencakup ajuan perubahan nilai mahasiswa dari tahun 2023 hingga 2025. Dataset terdiri dari **33.245 sampel** dengan lima kategori perubahan nilai:

Tabel 2. Jenis perubahan

Id_Jenis_Perubahan	Jumlah Data
0 – Lainnya/Tidak Teridentifikasi	4
1 – Perubahan Nilai melalui Program Studi	9586
2 – Perubahan Nilai melalui Dosen Pengampu	2572
3 – Klaim Nilai ke Transkrip	14621
4 – Hapus Nilai	6466

Tahapan pra-pemrosesan meliputi:

- Normalisasi nilai ke skala 0–1 agar bobot antar atribut seimbang.
- Pembersihan data dari duplikat dan nilai kosong.
- Pembagian data menjadi training set (70%) dan testing set (30%).

### Pembangunan Model dan Evaluasi

#### a. Naive Bayes

Model baseline dibangun menggunakan algoritma Naive Bayes dengan pendekatan probabilistik. Evaluasi dilakukan pada subset data yang memuat dua kelas dominan: program studi (kelas 1) dan dosen pengampu (kelas 2).

Confusion Matrix:

**Tabel 3.** Perhitungan dengan metode Naïve Bayes

True Label	Predicted 1.0	Predicted 2.0	Total
1.0 (Program Studi)	2.344	38	2.382
2.0 (Dosen Pengampu)	60	598	658
Total	2.404	636	3.040

#### Classification Report:

**Tabel 4.** Hasil Perhitungan dengan metode Naïve Bayes

	precision	recall	f1-score	support
1.0	0.98	0.98	0.98	2382
2.0	0.94	0.91	0.92	658
accuracy			0.97	3040
macro avg	0.96	0.95	0.95	3040
weighted avg	0.97	0.97	0.97	3040

Model menunjukkan performa sangat baik, terutama pada kelas program studi. Precision dan recall tinggi mengindikasikan bahwa pola perubahan nilai melalui program studi lebih konsisten dan mudah dipelajari. Kesalahan klasifikasi pada kelas dosen menunjukkan adanya overlap fitur antar jalur ajuan.

#### b. Decision Tree

Model kedua dibangun menggunakan algoritma Decision Tree dengan pemisahan atribut berdasarkan information gain. Evaluasi dilakukan pada subset data yang sama.

Confusion Matrix:

**Tabel 5.** Perhitungan dengan metode Decision Tree

True Label	Predicted 1.0	Predicted 2.0	Total
1.0 (Program Studi)	2.360	22	2.382
2.0 (Dosen Pengampu)	24	634	658
Total	2.384	656	3.040

#### Classification Report:

**Tabel 6.** Hasil Perhitungan dengan metode Decision Tree

	precision	recall	f1-score	support
1.0	0.99	0.99	0.99	2382

2.0	0.97	0.96	0.96	658
accuracy			0.98	3040
macro avg	0.98	0.98	0.98	3040
weighted avg	0.98	0.98	0.98	3040

---

Decision Tree menunjukkan akurasi lebih tinggi dibanding Naive Bayes, dengan keunggulan pada interpretabilitas dan visualisasi pola. Kesalahan klasifikasi dua arah tetap terjadi, namun jumlahnya kecil dan tidak berdampak signifikan terhadap stabilitas model.

#### Analisis Ketidakseimbangan Data

Kelas klaim nilai ke transkrip (kelas 3) dan hapus nilai (kelas 4) tidak muncul dalam hasil evaluasi. Hal ini menunjukkan adanya **class imbalance** atau keterbatasan sampel pada data uji. Model belum mampu mempelajari pola dari kelas-kelas tersebut secara optimal.

#### Rekomendasi:

- Tambahkan data pada kelas 3 dan 4.
- Terapkan teknik penyeimbangan seperti SMOTE atau undersampling.
- Lakukan optimasi hyperparameter untuk meningkatkan generalisasi model.

#### Kesimpulan

- Kedua algoritma efektif dalam mengklasifikasikan perubahan nilai melalui program studi dan dosen.
- Decision Tree unggul dalam akurasi dan interpretabilitas, sedangkan Naive Bayes lebih efisien secara komputasi.
- Untuk membangun sistem klasifikasi perubahan nilai yang **komprehensif dan adil**, diperlukan pengayaan data dan pengembangan model lanjutan agar seluruh jenis perubahan nilai dapat terwakili secara utuh.

#### KESIMPULAN

Berdasarkan hasil evaluasi model klasifikasi menggunakan **Naive Bayes** dan **Decision Tree**, dapat disimpulkan beberapa hal penting sebagai berikut:

##### 1. Kinerja Model Secara Umum

Penelitian ini menunjukkan bahwa algoritma **Naive Bayes** dan **Decision Tree** sama-sama efektif dalam mengklasifikasikan pola perubahan nilai mahasiswa. Kedua model mencapai akurasi tinggi (97–98%) dengan nilai F1-score rata-rata di atas 0,95, sehingga dapat digunakan sebagai pendekatan berbasis data untuk mendukung sistem evaluasi akademik.

##### 2. Analisis Pola Perubahan Nilai Berdasarkan Jalur Ajuan

- **Program Studi (id\_jenis\_pengajuan 1):** Model mampu mengidentifikasi pola dengan sangat konsisten, ditunjukkan oleh precision dan recall sebesar 0,98–0,99. Hal ini menegaskan bahwa jalur program studi memiliki karakteristik yang lebih jelas dan mudah dipelajari oleh algoritma.
- **Dosen Pengampu (id\_jenis\_pengajuan 2):** Performa model juga tinggi (precision 0,94–0,97; recall 0,91–0,96), meskipun terdapat kesalahan klasifikasi

akibat overlap atribut dengan jalur program studi. Temuan ini menunjukkan adanya kemiripan pola yang perlu diperhatikan dalam kebijakan akademik.

### 3. Perbandingan Naive Bayes dan Decision Tree

- **Naive Bayes** unggul dalam efisiensi komputasi, sehingga cocok digunakan sebagai baseline model untuk dataset besar.
- **Decision Tree** unggul dalam akurasi dan interpretabilitas, karena hasil klasifikasi dapat divisualisasikan dalam bentuk pohon keputusan yang mudah dipahami oleh pembuat kebijakan.
- Perbandingan ini menegaskan bahwa pemilihan algoritma harus mempertimbangkan trade-off antara kecepatan komputasi dan kemudahan interpretasi.

### 4. Dampak Ketidakseimbangan Data (Class Imbalance)

Kelas klaim nilai ke transkrip (`id_jenis_pengajuan 3`) dan hapus nilai (`id_jenis_pengajuan 4`) tidak muncul dalam evaluasi. Hal ini menunjukkan keterbatasan jumlah sampel yang menyebabkan bias model. Untuk meningkatkan generalisasi, diperlukan pengayaan data dan penerapan teknik penyeimbangan (misalnya SMOTE, oversampling, atau undersampling).

### 5. Implikasi Penelitian dan Rekomendasi Kebijakan

- Model klasifikasi dapat digunakan sebagai **alat bantu evaluasi akademik berbasis data**, khususnya untuk mendeteksi pola perubahan nilai melalui jalur program studi dan dosen.
- Institusi pendidikan perlu memperkaya data pada kelas minor agar sistem klasifikasi lebih adil dan komprehensif.
- Penelitian lanjutan dapat mengembangkan model dengan strategi balancing dan optimasi hyperparameter, sehingga seluruh jenis perubahan nilai dapat terwakili secara utuh.
- Hasil penelitian ini dapat menjadi dasar bagi kampus dalam merancang kebijakan pembelajaran yang lebih adaptif, meningkatkan transparansi, serta memperkuat akuntabilitas sistem pendidikan tinggi.

## DAFTAR PUSTAKA

1. Juniari, N. K., Suwirmayanti, N. L. G. P., & Setiawan, G. H. (2023). Analisis Perbandingan Metode Decision Tree dan Naive Bayes untuk Prediksi Kelulusan Tepat Waktu Mahasiswa. *Seminar & Publikasi ITB STIKOM Bali*.
2. Fauzan, A. S., Purnama Sari, A. I., & Ali, I. (2022). Analisis Perbandingan Algoritma Decision Tree dan Naive Bayes untuk Mengevaluasi Prestasi Belajar Siswa (Studi Kasus: SMK Al-Musyawirin). *JATI, ITN Malang*.
3. Salmawati, Y., & Hazriani. (2022). Klasifikasi Mahasiswa Berpotensi Drop Out Menggunakan Algoritma Naive Bayes dan Decision Tree. *Jurnal Ilmiah Ilmu Komputer*.
4. Febriyanto, E., & Wasilah. (2025). Optimization of Naive Bayes and Decision Tree Algorithms through Bagging and AdaBoost Techniques for Predicting Student Study Success. *Jurnal INFOTEL*, 17(1), 136-149.
5. Prayoga, R. A. S., Basatha, R., Akbar, M. S., Elfaiz, E. A., & Putra, C. D. (2025). Application of Naive Bayes Method for Student Performance Classification. *SISTEMASI*, 14(2).
6. Manzali, Y., Akhiat, Y., Barry, K. A., Akachar, E., & El Far, M. (2024). Prediction of Student Performance Using Random Forest Combined With Naive Bayes. *The Computer Journal*, 67(8), 2677-2689.

7. Sivasakthi, M., & Padmanabhan, K. R. A. (2022). Prediction of Students Programming Performance Using Naïve Bayesian and Decision Tree. *Soft Computing for Security Applications, Advances in Intelligent Systems and Computing*, 1428, 97–106. Springer.
8. Agustina, F. D., Arif, M., & Ahmad, S. (2025). Systematic Literature Review atas Kinerja Algoritma KNN, Naïve Bayes, dan Decision Tree pada Berbagai Studi Prediksi dan Klasifikasi. *Jurnal Jawara Sistem Informasi*, 3(1).
9. Tosun, S., & Kalaycıoğlu, D. B. (2024). Data Mining Approach for Prediction of Academic Success in Open and Distance Education. *Journal of Educational Technology & Online Learning*, 7(2), 168–176.
10. IEEE Explore. (2025). Exploring Weka and Python for Educational Data Mining: Naïve Bayes vs Decision Tree. *IEEE Transactions on Education*.
11. Nakhipova, V., Kerimbekov, Y., Umarova, Z., Suleimenova, L., Botayeva, S., Ibashova, A., & Zhumatayev, N. (2025). Use of the Naive Bayes Classifier Algorithm in Machine Learning for Student Performance Prediction. *International Journal of Information and Education Technology*, 14(1).
12. Orji, F. A., & Vassileva, J. (2024). Machine Learning Approach for Predicting Students' Academic Performance and Study Strategies. *arXiv preprint arXiv:2210.08186*.
13. Korchi, E., et al. (2023). Deep Learning Models for Predicting Student Academic Performance. *Education and Information Technologies*.
14. Buzducea, D., et al. (2026). Interpretability in Machine Learning Models for Education. *Journal of Educational Data Science*.
15. Agyemang, E., et al. (2024). Factors Influencing Academic Performance Prediction Using Machine Learning. *International Journal of Educational Technology*.
16. Zhang, Y., & Li, H. (2023). Comparative Study of Naive Bayes and Decision Tree in Educational Data Mining. *Journal of Computer Applications in Education*.
17. Chen, L., & Wang, J. (2023). Improving Student Grade Prediction Using Hybrid Naive Bayes and Decision Tree. *Applied Sciences*, 13(4).
18. Singh, R., & Kumar, P. (2024). Educational Data Mining: A Comparative Analysis of Naive Bayes and Decision Tree. *International Journal of Advanced Computer Science*.
19. Sari, A. I., & Nugroho, B. (2023). Predicting Student Performance Using Naive Bayes and Decision Tree. *Jurnal Teknologi Informasi dan Ilmu Komputer*.
20. Ahmad, S., & Arif, M. (2025). Comparative Performance of Naive Bayes and Decision Tree in Academic Prediction. *Jurnal Sistem Informasi Pendidikan*.