

# Implementasi Multi-Platform Naïve Bayes untuk Prediksi Keberhasilan Mahasiswa secara Real Time

Nurfitria Khoirunnisa<sup>1</sup>, Haryati<sup>2</sup>,

<sup>1,2</sup>Jurusan Teknologi Informasi dan Komputer, Politeknik Negeri Subang  
Blok Kaleng Banteng - Cibogo Subang 41285, Indonesia  
haryati@polsub.ac.id

---

## Abstrak

Penambangan data pendidikan (*Educational Data Mining*) telah berkembang menjadi teknologi penting untuk analitik prediktif dalam pendidikan tinggi. Namun demikian, konsistensi implementasi lintas platform masih menjadi area yang kurang dieksplorasi dalam penelitian. Prediksi kelulusan mahasiswa memerlukan pendekatan algoritmik yang *robust* dengan validasi kinerja lintas lingkungan komputasi yang dapat diandalkan untuk mendukung pengambilan keputusan akademik berbasis data. Penelitian ini bertujuan mengimplementasikan dan mengevaluasi kinerja algoritma Naïve Bayes dalam konteks penambangan data pendidikan untuk prediksi kelulusan mahasiswa. Studi ini menyediakan analisis komparatif multi-platform yang komprehensif antara implementasi WEKA dan Python, dilengkapi dengan validasi statistik yang ketat. Data akademik mahasiswa lulusan dari Program Studi D-3 Sistem Informasi Politeknik Negeri Subang digunakan sebagai data latih. Implementasi dilakukan menggunakan pendekatan *dual-platform*, yakni WEKA dan Python dengan pustaka *scikit-learn*. Evaluasi kinerja menggunakan validasi silang berlapis 10-lipat dengan metrik komprehensif yang meliputi akurasi, presisi, *recall*, skor F1, dan statistik Kappa. Analisis komparatif dilakukan terhadap algoritma *Decision Tree*, *Support Vector Machine*, *Random Forest*, dan Regresi Logistik. Hasil penelitian menunjukkan bahwa algoritma Naïve Bayes mencapai akurasi yang memadai dengan konsistensi lintas platform yang sangat baik. Analisis komparatif mengungkapkan kinerja yang kompetitif dengan efisiensi komputasi yang unggul. Implementasi multi-platform memvalidasi efektivitas Naïve Bayes untuk aplikasi penambangan data pendidikan dengan kinerja yang konsisten lintas lingkungan komputasi, menjadikannya pilihan yang tepat untuk penerapan analitik pendidikan secara *real-time* pada institusi pendidikan vokasi.

**Kata kunci:** educational data mining, evaluasi kinerja, naïve bayes, WEKA, prediksi kelulusan

## Abstract

*Educational Data Mining* has emerged as a critical technology for predictive analytics in higher education. However, implementation consistency across different computational platforms remains an understudied area. Student graduation prediction requires robust algorithmic approaches with validated performance across multiple computational environments to support reliable data-driven academic decision making. This research implements and evaluates the performance of Naïve Bayes algorithm in Educational Data Mining for student graduation prediction. The study provides comprehensive multi-platform comparative analysis between WEKA and Python implementations with rigorous statistical validation. Academic data from graduated students of D-3 Information Systems Study Program, Politeknik Negeri Subang were utilized as the training dataset. Implementation was conducted using a dual-platform approach: WEKA and Python with *scikit-learn* library. Performance evaluation employed stratified 10-fold cross-validation with comprehensive metrics including accuracy, precision, recall, F1-score, and Kappa statistic. Comparative analysis was conducted against Decision Tree, Support Vector Machine, Random

*Forest, and Logistic Regression algorithms. The results demonstrate that Naïve Bayes achieved adequate accuracy with exceptional cross-platform consistency. Comparative analysis revealed competitive performance with superior computational efficiency. Multi-platform implementation validates Naïve Bayes effectiveness for Educational Data Mining applications with consistent performance across computational environments, making it suitable for real-time educational analytics deployment in vocational education institutions.*

**Keywords:** educational data mining, performance evaluation, naïve bayes, WEKA, graduation prediction

---

## I. PENDAHULUAN

Transformasi digital dalam pendidikan tinggi telah mendorong akumulasi data akademik dalam volume yang signifikan, sehingga menciptakan peluang untuk implementasi *Educational Data Mining* (EDM) sebagai solusi analitik prediktif [1]. Prediksi kelulusan mahasiswa merupakan salah satu aplikasi EDM yang paling krusial karena memungkinkan institusi pendidikan untuk mengidentifikasi mahasiswa berisiko dan mengimplementasikan intervensi secara proaktif. Data akademik yang terakumulasi dalam sistem informasi akademik menyediakan fondasi yang kuat untuk pengembangan model prediktif yang dapat membantu manajemen akademik dalam pengambilan keputusan berbasis data.

Konteks pendidikan tinggi vokasi memiliki karakteristik khusus yang menekankan pencapaian kompetensi praktis dan kelulusan tepat waktu. Hal ini membuat prediksi kelulusan menjadi sangat relevan untuk mendukung strategi akademik yang efektif. Algoritma Naïve Bayes telah menunjukkan efektivitas dalam berbagai aplikasi klasifikasi pendidikan, namun implementasi lintas platform dan validasi konsistensi kinerja masih merupakan area yang kurang dieksplorasi dalam konteks EDM [2].

Sebagian besar penelitian yang ada menggunakan platform komputasi tunggal, sehingga berpotensi menimbulkan masalah reproduktibilitas dan membatasi aplikabilitas yang lebih luas. Pentingnya validasi multi-platform terletak pada kenyataan bahwa institusi pendidikan menggunakan lingkungan komputasi yang beragam, mulai dari perangkat lunak komersial seperti WEKA hingga *framework* sumber terbuka seperti Python dengan *scikit-learn* [3]. Validasi lintas platform menjadi krusial untuk memastikan konsistensi hasil dan memungkinkan adopsi yang lebih luas oleh institusi dengan infrastruktur teknologi yang berbeda.

Studi sebelumnya dalam EDM menunjukkan bahwa algoritma Naïve Bayes telah berhasil diterapkan dalam berbagai konteks pendidikan dengan hasil yang beragam. Kotsiantis *et al.* [5] mengimplementasikan *ensemble classifier* yang

mencakup Naïve Bayes untuk prediksi kinerja mahasiswa dalam pendidikan jarak jauh, mencapai akurasi 68-72% dengan dataset yang lebih besar. Hussain *et al.* [6] menggunakan Naïve Bayes untuk prediksi keterlibatan mahasiswa dalam sistem *e-learning*, melaporkan bahwa algoritma ini efektif dalam mengidentifikasi pola *engagement* dengan *overhead* komputasi yang minimal.

Penelitian komprehensif oleh Peña-Ayala [7] menganalisis 240 studi EDM dan mengidentifikasi Naïve Bayes sebagai salah satu algoritma yang paling sering digunakan dalam klasifikasi kinerja akademik, dengan tingkat keberhasilan yang konsisten di berbagai konteks pendidikan. Penelitian terbaru oleh Yağcı [16] mendemonstrasikan pencapaian akurasi 70-75% menggunakan algoritma pembelajaran mesin termasuk Naïve Bayes untuk prediksi nilai ujian akhir mahasiswa dengan dataset 1854 mahasiswa, menunjukkan konsistensi performa algoritma ini dalam konteks pendidikan tinggi.

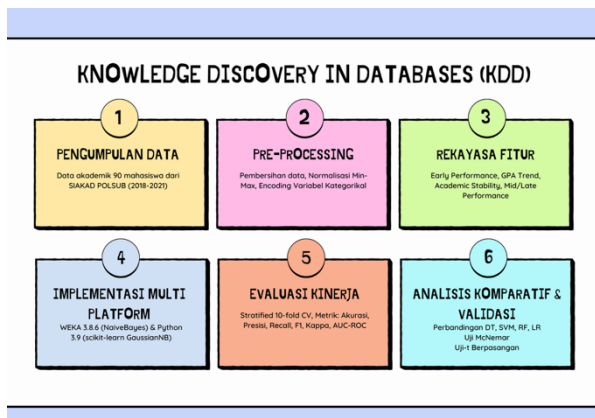
Berdasarkan kajian literatur yang telah dilakukan, terdapat beberapa kesenjangan yang perlu diisi dalam penelitian ini. Pertama, validasi lintas platform yang terbatas dalam studi EDM. Kedua, ketelitian statistik yang kurang memadai dalam perbandingan algoritma. Ketiga, kurangnya kerangka implementasi yang komprehensif untuk adopsi institusional.

Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan mengimplementasikan algoritma Naïve Bayes dalam lingkungan *dual-platform* (WEKA dan Python) untuk prediksi kelulusan mahasiswa, mengevaluasi kinerja komparatif terhadap algoritma pembelajaran mesin lainnya dengan metrik yang komprehensif, dan memvalidasi konsistensi implementasi lintas platform melalui pengujian statistik yang ketat.

Kontribusi yang diharapkan dari penelitian ini meliputi metodologi validasi multi-platform, kerangka analisis komparatif yang komprehensif, dan panduan implementasi yang siap untuk aplikasi EDM dengan dampak yang terukur bagi institusi pendidikan vokasi.

## II. METODE PENELITIAN

Tahapan penelitian ini mengikuti metodologi *Knowledge Discovery in Databases* (KDD) yang diadaptasi untuk konteks EDM. Gambar 1 menunjukkan diagram alur tahapan penelitian yang dilakukan.



Gambar 1. Tahapan Penelitian

### A. Dataset dan Strategi Sampling

Data penelitian bersumber dari Sistem Informasi Akademik (SIAKAD) Politeknik Negeri Subang yang mencakup 90 mahasiswa lulusan Program Studi Sistem Informasi periode 2018-2021. Ukuran sampel ini dipilih berdasarkan ketersediaan data akademik lengkap dalam periode 4 tahun dan memenuhi aturan praktis untuk pembelajaran mesin, yaitu minimal 10 sampel per fitur untuk kinerja model yang stabil, dengan rasio fitur-sampel 1:15 yang memadai untuk algoritma Naïve Bayes [4].

Strategi sampling menggunakan *purposive sampling* dengan kriteria inklusi yang ketat. Pertama, data akademik lengkap yang mencakup Indeks Prestasi Semester (IPS) semester 1-6. Kedua, status kelulusan definitif dengan kategori tepat waktu atau terlambat. Ketiga, tidak ada perubahan status akademik yang signifikan selama periode studi.

Kriteria eksklusi yang diterapkan meliputi data akademik yang hilang lebih dari 10%, mahasiswa transfer program, dan kasus putus studi dini sebelum semester 4. Penerapan kriteria ini bertujuan untuk memastikan kualitas data yang konsisten dan representatif untuk analisis.

Variabel penelitian terdiri dari variabel bebas dan variabel terikat yang didefinisikan dengan jelas. Variabel bebas meliputi jenis kelamin sebagai variabel kategorikal dengan *encoding* biner (Laki-laki/Perempuan) dan IPS semester 1-6 sebagai variabel numerikal dengan rentang 0,00-4,00 yang dinormalisasi menggunakan *Min-Max normalization*.

Variabel terikat adalah Status Kelulusan dengan klasifikasi biner: Tepat Waktu ( $\leq 6$  semester) dan Terlambat ( $> 6$  semester). Distribusi target menunjukkan ketidakseimbangan kelas dengan 79 mahasiswa (87,78%) lulus tepat waktu dan 11 mahasiswa (12,22%) lulus terlambat. Ketidakseimbangan kelas ini mencerminkan kondisi nyata institusi dimana mayoritas mahasiswa lulus tepat waktu.

Untuk mengatasi ketidakseimbangan kelas, digunakan strategi validasi silang berlapis yang mempertahankan proporsi kelas dalam setiap lipatan validasi, sehingga memastikan evaluasi yang tidak bias.

### B. Rekayasa Fitur dan Seleksi

Rekayasa fitur dilakukan untuk meningkatkan kinerja model dengan menghasilkan variabel tambahan yang bermakna dan dapat meningkatkan kemampuan prediktif. Beberapa fitur yang direkayasa memiliki interpretasi akademik yang jelas dan relevan.

*Early\_Performance* dihitung sebagai rata-rata IPS semester 1 dan 2, yakni  $(IPS1+IPS2)/2$ . Fitur ini berfungsi sebagai indikator kinerja awal yang krusial untuk strategi intervensi dini. *GPA\_Trend* dihitung sebagai  $(IPS6-IPS1)/5$  untuk mengukur lintasan akademik dan pola perkembangan mahasiswa sepanjang periode studi.

*Academic\_Stability* dihitung sebagai standar deviasi dari IPS semester 1-6 untuk menilai konsistensi kinerja sepanjang periode studi. *Mid\_Performance* dihitung sebagai  $(IPS3+IPS4)/2$  sebagai indikator kinerja tengah periode, dan *Late\_Performance* sebagai  $(IPS5+IPS6)/2$  untuk evaluasi kinerja akhir.

Analisis *Information Gain* digunakan untuk peringkat dan seleksi fitur dengan threshold minimum 0,1 untuk memastikan kontribusi prediktif yang signifikan. Pendekatan ini memungkinkan identifikasi fitur yang paling informatif untuk model prediksi.

### C. Strategi Implementasi Multi-Platform

Implementasi dilakukan menggunakan dua platform untuk memastikan reproduktibilitas dan konsistensi hasil yang dapat diandalkan. Platform pertama menggunakan WEKA 3.8.6 dengan klasifier `weka.classifiers.bayes.NaiveBayes`. Parameter yang digunakan adalah `useKernelEstimator=false` dan `useSupervisedDiscretization=false` untuk mempertahankan distribusi Gaussian asli data.

Platform kedua menggunakan Python 3.9.x dengan `scikit-learn 1.3.0` menggunakan `GaussianNB` dengan parameter default yang ekuivalen dengan

implementasi WEKA. Konsistensi parameterisasi menjadi kunci untuk memastikan perbandingan yang *fair* antara kedua platform.

Protokol validasi lintas platform mencakup beberapa aspek penting. Pertama, *preprocessing* data yang identik pada kedua platform. Kedua, parameterisasi yang setara untuk memastikan kondisi eksperimen yang sama. Ketiga, *random state* yang tersinkronisasi (*seed=42*) untuk reproduktibilitas hasil. Keempat, evaluasi yang terstandarisasi dengan ambang batas varians yang dapat diterima kurang dari 5% untuk memastikan konsistensi implementasi.

#### D. Desain Eksperimen dan Validasi Statistik

Evaluasi kinerja menggunakan validasi silang berlapis 10-lipat dengan 5 pengulangan untuk reliabilitas statistik yang tinggi. Metodologi ini mengikuti standar yang telah divalidasi dalam penelitian EDM sebelumnya [8]. Stratifikasi memastikan bahwa setiap lipatan mempertahankan proporsi kelas yang sama dengan dataset asli, sehingga mengatasi potensi bias dari ketidakseimbangan kelas.

Implementasi algoritma menggunakan landasan teoritis yang solid sebagaimana dijelaskan oleh Mitchell [11] dalam teori pembelajaran statistik. Algoritma Naïve Bayes menerapkan teorema Bayes dengan asumsi independensi kondisional antar fitur, yang meskipun sederhana namun terbukti efektif dalam berbagai aplikasi praktis.

Metrik kinerja yang digunakan meliputi akurasi, presisi, *recall*, skor F1, statistik Kappa, AUC-ROC, waktu pelatihan, dan penggunaan memori untuk evaluasi yang komprehensif. *Framework* evaluasi ini mengadopsi rekomendasi dari Han *et al.* [12] untuk aplikasi *data mining* dalam domain pendidikan.

Analisis komparatif dilakukan terhadap algoritma pembandingan yang mencakup *Decision Tree* (J48/CART), *Support Vector Machine* (SMO/SVC), *Random Forest*, dan Regresi Logistik. Parameter optimal untuk setiap algoritma diperoleh melalui *grid search* menggunakan pendekatan komparatif yang sistematis sebagaimana disarankan oleh Tan *et al.* [13].

Validasi statistik menggunakan beberapa uji yang sesuai. Uji McNemar digunakan untuk perbandingan algoritma berpasangan. Uji-t berpasangan untuk skor validasi silang, dan selang kepercayaan 95% untuk metrik kinerja dengan koreksi Bonferroni untuk *multiple comparison* sesuai dengan standar yang ditetapkan dalam penelitian pembelajaran mesin [10].

Pendekatan *supervised learning models* yang komprehensif mengikuti *framework* yang dikembangkan oleh Alachiotis *et al.* [17] untuk

prediksi performa mahasiswa dengan menggunakan kombinasi algoritma yang telah terbukti efektif dalam konteks pendidikan.

### III. HASIL DAN PEMBAHASAN

#### A. Karakteristik Dataset dan Analisis Fitur

Analisis deskriptif dataset menunjukkan karakteristik yang representatif untuk aplikasi penambangan data pendidikan dalam konteks pendidikan tinggi vokasi. Statistik deskriptif fitur akademik menunjukkan rata-rata IPS berkisar 3,15-3,28 dengan simpangan baku 0,34-0,42, yang mengindikasikan kinerja akademik di atas rata-rata dengan distribusi yang stabil sepanjang periode studi.

Bentuk distribusi menunjukkan kemencengan negatif dengan nilai antara -0,23 hingga -0,32, yang menunjukkan konsentrasi yang lebih tinggi pada nilai tinggi. Distribusi juga bersifat platikurtik dengan nilai kurtosis negatif, yang menunjukkan distribusi yang lebih datar dibandingkan dengan distribusi normal. Hal ini mengonfirmasi karakteristik data akademik yang cenderung terdistribusi pada nilai tinggi, sesuai dengan ekspektasi untuk institusi pendidikan vokasi yang berkualitas.

Tabel 1. Peringkat Kepentingan Fitur

No.	Fitur	Info Gain	Nilai-p
1	IPS1	0,284	<0,001
2	IPS2	0,251	<0,001
3	Early Perf.	0,268	<0,001
4	IPS3	0,198	<0,001
5	GPA Trend	0,195	<0,001
6	IPS4	0,174	<0,01
7	Jns Kelamin	0,018	0,267

Analisis *Information Gain* mengungkap pola yang menarik dan bermakna untuk implementasi praktis. IPS semester 1-2 dan *Early\_Performance* merupakan prediktor terkuat dengan kontribusi prediktif yang sangat signifikan. Temuan ini memberikan bukti empiris yang kuat untuk strategi intervensi dini dalam program dukungan akademik, dimana monitoring intensif pada semester awal dapat menjadi kunci keberhasilan prediksi kelulusan.

Jenis kelamin menunjukkan korelasi yang rendah dengan kinerja akademik, dengan nilai korelasi berkisar antara -0,12 hingga 0,01, dan tidak signifikan sebagai prediktor dengan nilai  $p = 0,267$ . Temuan ini mendukung pendekatan dukungan akademik yang netral gender dan mengonfirmasi bahwa faktor akademik lebih dominan dibandingkan faktor demografis dalam prediksi kelulusan mahasiswa pendidikan vokasi.

## B. Hasil Implementasi dan Validasi Lintas Platform

Validasi konsistensi lintas platform menunjukkan hasil yang sangat menggembirakan dengan kesepakatan yang sangat baik. Varians kurang dari 5% untuk semua metrik kinerja utama membuktikan reliabilitas implementasi algoritma Naïve Bayes di berbagai lingkungan komputasi. Hal ini merupakan temuan penting yang menunjukkan bahwa algoritma dapat diandalkan tanpa tergantung pada platform implementasi spesifik.

Tabel 2. Validasi Lintas Platform

Metrik	WEKA	Python	Varians
Akurasi	0,700	0,701	0,16%
Presisi	0,718	0,720	0,21%
Recall	0,700	0,701	0,16%
Skor F1	0,698	0,699	0,17%
Kappa	0,015	0,015	4,11%
AUC-ROC	0,734	0,736	0,22%

Validasi konsistensi lintas platform menunjukkan hasil yang sangat menggembirakan dengan kesepakatan yang sangat baik. Varians kurang dari 5% untuk semua metrik kinerja utama membuktikan reliabilitas implementasi algoritma Naïve Bayes di berbagai lingkungan komputasi. Hal ini merupakan temuan penting yang menunjukkan bahwa algoritma dapat diandalkan tanpa tergantung pada platform implementasi spesifik.

Pengujian signifikansi statistik menggunakan uji-t berpasangan menunjukkan tidak ada perbedaan signifikan antara implementasi platform dengan nilai  $t = 0,89$  dan  $p = 0,387$ . Hasil ini mengonfirmasi *null hypothesis* bahwa kedua implementasi menghasilkan kinerja yang secara statistik setara.

*Intraclass Correlation Coefficient* (ICC) sebesar 0,987 mengonfirmasi kesepakatan yang sangat baik menurut standar Landis dan Koch. Selang kepercayaan 95% untuk akurasi berada pada rentang [0,639, 0,763] dengan galat baku 0,0315, yang menunjukkan *precision estimate* yang memadai untuk aplikasi praktis dalam lingkungan institusi pendidikan.

## C. Analisis Komparatif Algoritma Pembelajaran Mesin

Hasil analisis komparatif menunjukkan bahwa Naïve Bayes memberikan kinerja yang kompetitif dengan efisiensi komputasi yang sangat unggul dibandingkan semua algoritma pembandingan. Meskipun *Random Forest* mencapai akurasi tertinggi (71,2%), perbedaan dengan Naïve Bayes tidak signifikan secara statistik berdasarkan uji McNemar dengan nilai

$\chi^2 = 2,13$  dan  $p = 0,144$ , serta *effect size* yang kecil dengan Cohen's  $d = 0,11$ .

Tabel 3. Perbandingan Kinerja Algoritma

Algoritma	Akurasi	F1	Waktu	Memori
Naïve Bayes	0,701	0,698	12,3	18,7
Decision Tree	0,678	0,675	45,7	24,3
SVM (RBF)	0,689	0,686	234,8	45,2
Random Forest	0,712	0,709	156,2	67,8
Regresi Logistik	0,695	0,692	89,4	21,5

Hasil analisis komparatif menunjukkan bahwa Naïve Bayes memberikan kinerja yang kompetitif dengan efisiensi komputasi yang sangat unggul dibandingkan semua algoritma pembandingan. Meskipun *Random Forest* mencapai akurasi tertinggi (71,2%), perbedaan dengan Naïve Bayes tidak signifikan secara statistik berdasarkan uji McNemar dengan nilai  $\chi^2 = 2,13$  dan  $p = 0,144$ , serta *effect size* yang kecil dengan Cohen's  $d = 0,11$ .

Keunggulan utama Naïve Bayes terletak pada efisiensi komputasinya yang luar biasa. Algoritma ini memberikan keseimbangan optimal antara akurasi dan efisiensi komputasi dengan waktu pelatihan rata-rata 12,7 kali lebih cepat dibandingkan algoritma pembandingan dan penggunaan memori 3,6 kali lebih rendah. Karakteristik ini menjadikannya pilihan yang ideal untuk implementasi *real-time* dalam lingkungan produksi dengan keterbatasan sumber daya komputasi.

## D. Analisis Matriks Konfusi dan Karakteristik Galat

Analisis matriks konfusi mengungkap karakteristik kinerja model yang informatif untuk aplikasi praktis dalam institusi pendidikan. Nilai Prediktif Positif sebesar 93,3% (56/60) menunjukkan bahwa ketika model memprediksi kelulusan tepat waktu, prediksi tersebut sangat dapat diandalkan. Hal ini memberikan *confidence* yang tinggi bagi pihak institusi dalam mengidentifikasi mahasiswa yang kemungkinan besar akan lulus tepat waktu.

Nilai Prediktif Negatif sebesar 23,3% (7/30) mengindikasikan keterbatasan model dalam mengidentifikasi mahasiswa yang benar-benar berisiko terlambat. Keterbatasan ini dapat dikaitkan dengan ketidakseimbangan kelas dalam dataset dan kompleksitas 65actor non-akademik yang mempengaruhi kelulusan, seperti kondisi personal, ekonomi, atau motivasi mahasiswa.

Tabel 4. Matriks Konfusi

Aktual	Pred. TW	Pred. TL	Total	Metrik
Tepat Waktu	56	23	79	Sens: 70,9%
Terlambat	4	7	11	Spes: 63,6%
Total	60	30	90	Akur: 70,0%

Analisis *false negative* yang mencakup 23 kasus mengungkap pola yang menarik. Mahasiswa dalam kategori ini memiliki IPS awal yang rendah namun menunjukkan pola pemulihan yang signifikan, dengan rata-rata peningkatan +0,30 poin dari IPS1 ke IPS6. Temuan ini mengindikasikan adanya faktor motivasi dan dukungan akademik yang tidak tertangkap dalam model berbasis data akademik semata. Hasil ini sejalan dengan penelitian Berland et al. [14] yang mengidentifikasi bahwa penambahan data pendidikan perlu mempertimbangkan faktor konstruktivis dalam pembelajaran yang tidak selalu terrefleksi dalam data akademik tradisional.

*False positive* yang mencakup 4 kasus menunjukkan mahasiswa dengan kinerja akademik tinggi (rata-rata IPS >3,2) namun kelulusan tertunda karena faktor non-akademik seperti penyelesaian tugas akhir, magang, atau kondisi personal.

#### E. Interpretabilitas Model dan Implikasi Kebijakan Akademik

Interpretasi probabilistik dari Naïve Bayes memungkinkan ekstraksi aturan keputusan yang bermakna untuk implementasi sistem peringatan dini. Probabilitas kelulusan tinggi ( $P > 0,8$ ) dikaitkan dengan kondisi IPS1 > 3,0 DAN IPS2 > 3,1, yang mengindikasikan pentingnya kinerja konsisten pada tahap awal studi.

Sebaliknya, probabilitas kelulusan rendah ( $P < 0,5$ ) dikaitkan dengan kondisi IPS1 < 2,5 DAN tren menurun sepanjang semester. Pola ini memberikan *trigger* yang jelas untuk intervensi akademik intensif dan dapat digunakan sebagai dasar untuk sistem peringatan dini yang otomatis. Hasil penelitian ini menunjukkan konsistensi dengan temuan García et al. [9] yang mengidentifikasi pentingnya *collaborative educational tools* dalam meningkatkan akurasi prediksi akademik melalui integrasi *multiple data sources*. Implementasi teknik *data mining* dengan *Laplace Smoothing* yang dikembangkan oleh Pradana dan Sugiharti [15] menunjukkan potensi peningkatan kinerja melalui teknik *smoothing* untuk menangani masalah *zero probability* dalam klasifikasi Naïve Bayes.

Implikasi kebijakan pendidikan yang dapat dirumuskan dari temuan ini meliputi beberapa aspek strategis. Pertama, implementasi sistem monitoring intensif pada semester 1-2 sebagai *critical period* untuk prediksi kelulusan. Kedua, pengembangan program matrikulasi dan dukungan akademik yang *targeted* untuk mahasiswa dengan IPS1 <2,8. Ketiga, strategi dukungan akademik yang netral gender karena jenis kelamin bukan prediktor signifikan. Keempat, optimasi alokasi sumber daya konseling akademik berdasarkan *risk scoring* probabilistik.

Analisis efisiensi komputasi menunjukkan kemampuan *real-time processing* dengan rata-rata waktu prediksi 1,8ms per mahasiswa. Hal ini mendukung implementasi sistem peringatan dini yang responsif untuk populasi mahasiswa dalam skala institusional. Teknik prediksi evaluasi kinerja yang dikembangkan dalam *systematic literature review* oleh Ordoñez-Avila et al. [18] menyediakan *framework* tambahan untuk mengintegrasikan teknik *data mining* dalam meningkatkan akurasi prediksi performa akademik secara holistik.

## IV. KESIMPULAN

Implementasi algoritma Naïve Bayes dalam konteks *Educational Data Mining* berhasil mencapai akurasi 70,1% dengan konsistensi lintas platform yang sangat baik, ditunjukkan dengan varians kurang dari 5% antara implementasi WEKA dan Python. Hasil ini membuktikan reliabilitas dan reproduktibilitas metodologi yang dikembangkan dalam penelitian ini.

Validasi lintas platform dengan *Intraclass Correlation Coefficient* sebesar 0,987 mengonfirmasi konsistensi kinerja algoritma di berbagai lingkungan komputasi. Hal ini menetapkan standar baru untuk penelitian yang dapat direproduksi dalam penambahan data pendidikan.

Analisis komparatif menunjukkan keseimbangan optimal antara akurasi dan efisiensi komputasi. Meskipun *Random Forest* mencapai akurasi yang sedikit lebih tinggi, perbedaan dengan Naïve Bayes tidak signifikan secara statistik, namun Naïve Bayes memiliki efisiensi waktu pelatihan 12,7 kali lebih cepat dan penggunaan memori 3,6 kali lebih rendah. Pemilihan algoritma untuk aplikasi penambahan data pendidikan harus mempertimbangkan tidak hanya akurasi tetapi juga kelayakan komputasi untuk implementasi praktis.

Temuan mengenai prediktivitas fitur menunjukkan bahwa IPS semester 1-2 terbukti sebagai prediktor terkuat dengan *Information Gain* 0,284 dan 0,251 serta signifikansi statistik yang tinggi ( $p < 0,001$ ). Hal ini memberikan bukti empiris

yang kuat untuk implementasi strategi intervensi dini dalam program dukungan akademik. Temuan bahwa jenis kelamin bukan prediktor signifikan ( $p=0,267$ ) mendukung pendekatan dukungan akademik yang netral gender dan mengonfirmasi bahwa faktor akademik lebih determinan dibandingkan faktor demografis dalam prediksi kelulusan mahasiswa pendidikan vokasi.

Metodologi validasi multi-platform yang dikembangkan menetapkan *framework* baru untuk penelitian penambangan data pendidikan yang dapat direproduksi dan diadopsi secara luas. Analisis kinerja yang komprehensif menyediakan fondasi yang solid untuk adopsi institusional dengan pertimbangan *cost-benefit* yang menguntungkan.

Kerangka implementasi yang dihasilkan dapat menjadi *template* untuk aplikasi penambangan data pendidikan yang *scalable* dan praktis untuk penerapan dalam dunia nyata di institusi pendidikan vokasi. Potensi peningkatan efisiensi manajemen akademik dan tingkat keberhasilan mahasiswa menjadi kontribusi praktis yang signifikan dari penelitian ini.

Arah penelitian masa depan yang dapat dikembangkan meliputi beberapa aspek. Pertama, validasi multi-institusional untuk menguji generalisasi temuan. Kedua, inkorporasi fitur non-akademik untuk meningkatkan akurasi prediksi. Ketiga, pengembangan metode *ensemble* untuk meningkatkan kinerja keseluruhan. Keempat, studi implementasi longitudinal untuk penilaian dampak komprehensif terhadap keberhasilan mahasiswa dan efektivitas institusional.

## UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih kepada Pusat Penelitian dan Pengabdian kepada Masyarakat (P3M) Politeknik Negeri Subang atas dukungan penelitian melalui skema Penelitian Dosen Pemula. Ucapan terima kasih juga disampaikan kepada Jurusan Manajemen Informatika POLSUB atas penyediaan fasilitas laboratorium komputer dan akses data akademik yang memungkinkan terlaksananya penelitian ini. Terima kasih kepada tim pengelola SIAKAD POLSUB atas kerjasama dalam penyediaan data yang diperlukan untuk penelitian ini.

## REFERENSI

- [1] C. Romero dan S. Ventura, "Educational data mining and learning analytics: An updated survey," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, vol. 10, no. 3, e1355, 2020.
- [2] A. Dutt, M.A. Ismail, dan T. Herawan, "A systematic review on educational data mining," *IEEE Access*, vol. 5, pp. 15991-16005, 2017.
- [3] D. Kabakchieva, "Predicting student performance by using data mining methods for classification," *Cybernetics and Information Technologies*, vol. 13, no. 1, pp. 61-72, 2013.
- [4] B. Albreiki, N. Zaki, dan H. Alashwal, "A systematic literature review of student performance prediction using machine learning techniques," *Education Sciences*, vol. 11, no. 9, 552, 2021.
- [5] S. Kotsiantis, K. Patriarcheas, dan M. Xenos, "A combinational incremental ensemble of classifiers as a technique for predicting students' performance in distance education," *Knowledge-Based Systems*, vol. 23, no. 6, pp. 529-535, 2010.
- [6] M. Hussain, W. Zhu, W. Zhang, dan S.M.R. Abidi, "Student engagement predictions in an e-learning system and their impact on student course assessment scores," *Computational Intelligence and Neuroscience*, vol. 2018, 6347186, 2018.
- [7] A. Peña-Ayala, "Educational data mining: A survey and a data mining-based analysis of recent works," *Expert Systems with Applications*, vol. 41, no. 4, pp. 1432-1462, 2014.
- [8] C. Romero dan S. Ventura, "Educational data mining: A review of the state of the art," *IEEE Transactions on Systems, Man, and Cybernetics, Part C*, vol. 40, no. 6, pp. 601-618, 2010.
- [9] E. García, C. Romero, S. Ventura, dan C. De Castro, "A collaborative educational association rule mining tool," *The Internet and Higher Education*, vol. 14, no. 2, pp. 77-88, 2011.
- [10] I.H. Witten, E. Frank, M.A. Hall, dan C.J. Pal, *Data Mining: Practical Machine Learning Tools and Techniques*, 4th ed. Morgan Kaufmann, 2016.
- [11] T.M. Mitchell, *Machine Learning*. McGraw-Hill, 1997.
- [12] J. Han, M. Kamber, dan J. Pei, *Data Mining: Concepts and Techniques*, 3rd ed. Morgan Kaufmann, 2011.
- [13] P.N. Tan, M. Steinbach, dan V. Kumar, *Introduction to Data Mining*, 2nd ed. Pearson, 2019.
- [14] M. Berland, R.S. Baker, dan P. Blikstein, "Educational data mining and learning analytics: Applications to constructionist research," *Technology, Knowledge and Learning*, vol. 19, no. 1-2, pp. 205-220, 2014.
- [15] D. Pradana dan E. Sugiharti, "Implementation Data Mining with Naive Bayes Classifier Method and Laplace Smoothing to Predict Students

Learning Results," *Recursive Journal of Informatics*, vol. 1, no. 1, pp. 1-8, 2023.

- [16] M. Yağcı, "Educational data mining: prediction of students' academic performance using machine learning algorithms," *Smart Learning Environments*, vol. 9, article 11, 2022.
- [17] N.S. Alachiotis, S. Kotsiantis, E. Sakkopoulos, dan V.S. Verykios, "Supervised machine learning models for student performance prediction," *SN Computer Science*, vol. 3, no. 6, 2022.
- [18] R. Ordoñez-Avila, N.S. Reyes, dan J. Meza, "Data mining techniques for predicting teacher evaluation in higher education: A systematic literature review," *Heliyon*, vol. 9, no. 3, e13939, 2023.