

## Prediksi Performa Akademik Mahasiswa untuk Kelulusan Predikat *Cum Laude* dengan Pendekatan *Machine Learning*

### *Predicting Academic Performance of Students for Graduating with Cum Laude Honors using Machine Learning Approach*

FIRGIAWAN INDRA KUSUMA BUDIYANTO<sup>1</sup>, IRMAN HERMADI<sup>1</sup>, MEDRIA  
KUSUMA DEWI HARDHIENATA<sup>1\*</sup>

#### Abstrak

Penelitian ini bertujuan untuk mengembangkan model yang dapat memprediksi jumlah mahasiswa yang lulus dengan predikat *cum laude* pada perguruan tinggi. Penelitian ini menggunakan algoritma *machine learning* untuk klasifikasi sehingga dapat dilakukan prediksi. Hasil dari penelitian ini menunjukkan efektivitas model dalam memprediksi kelulusan *cum laude* agar dapat memberikan kesempatan bagi universitas untuk meningkatkan kualitas lulusan secara keseluruhan dan mengatasi penurunan standar kelulusan yang mungkin terjadi. Prediksi jumlah mahasiswa *cum laude* dilakukan pada penelitian ini, untuk membantu proses pengambilan keputusan oleh pemangku kebijakan pada perguruan tinggi. Dengan memanfaatkan teknik *machine learning*, institusi dapat mengantisipasi dan mendukung mahasiswa dalam mencapai predikat *cum laude*, sehingga diharapkan dapat meningkatkan kualitas lulusan secara keseluruhan. Dalam penelitian ini, dibandingkan tiga algoritma *machine learning* yakni algoritma Naïve Bayes, Random Forest, dan C4.5 untuk melakukan prediksi kelulusan mahasiswa dengan predikat *cum laude*. Hasil penelitian menunjukkan bahwa dalam kasus ini kinerja terbaik dicapai oleh algoritma Naïve Bayes dengan nilai akurasi 87.60%, *precision* 86.70%, *recall* 92.10% dan *F1-score* 89.30%. Selain itu, algoritma Naïve Bayes juga menghasilkan nilai waktu komputasi terendah pada kasus yang diujikan dibandingkan dengan algoritma lainnya.

Kata Kunci: *cum laude*, kelulusan, *machine learning*, model prediktif.

#### Abstract

*This research aims to develop a predictive model using machine learning techniques to forecast cum laude graduations within a university. Machine learning algorithms are utilized for classification to enable such predictions. The research results demonstrate the effectiveness of the model in predicting cum laude graduation, thereby providing opportunities for the university to enhance the overall quality of graduates and address potential declines in graduation standards. Predictions regarding the number of cum laude students are made in this study to assist decision-making processes among university stakeholders. By leveraging machine learning techniques, institutions can anticipate and support students in achieving cum laude honours, ultimately leading to an improvement in the overall quality of graduates. In this study, three machine learning algorithms—Naïve Bayes, random forest, and C4.5—are compared for predicting student graduation with cum laude honours. The results of the study show that, for the considered case, the best performance was achieved by the Naïve Bayes algorithm with 87.60% accuracy, 86.70% precision, 92.10% recall, and 89.30% F1-score. In addition, the Naïve Bayes algorithm also obtained the lowest computational time compared to other algorithms.*

*Keywords: cum laude, graduation, machine learning, predictive model.*

## PENDAHULUAN

Melalui pendidikan pada perguruan tinggi, mahasiswa dapat memperoleh kualifikasi akademik yang dibutuhkan, yang dapat membantu menghadapi persaingan kerja di masa depan. Predikat *cum laude* adalah pencapaian akademik yang menunjukkan bahwa mahasiswa tersebut

<sup>1</sup> Departemen Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Institut Pertanian Bogor, Bogor 16680

\* Penulis Korespondensi: Tel/Faks: +62 858-9280-8513; Surel: medria.hardhienata@apps.ipb.ac.id

telah mencapai prestasi akademik yang tinggi. Meski demikian, tidak semua mahasiswa dapat mencapai prestasi ini karena beberapa faktor, seperti kemampuan akademik, lingkungan sosial, dan faktor pribadi.

Kata *cum laude*, yang berasal dari bahasa latin yang berarti “dengan pujian”, adalah salah satu predikat yang diberikan di perguruan tinggi (Merriam-Webster Dictionary 2023). Dalam buku pedoman akademik UIN Syarif Hidayatullah Jakarta, predikat *cum laude* diberikan pada lulusan dengan rentang Indeks Prestasi Kumulatif (IPK) antara 3.51 sampai 4.00 (UIN Syarif Hidayatullah 2019). Predikat *cum laude* merupakan salah satu bentuk penghargaan akademik yang diberikan kepada lulusan dengan pencapaian akademik yang tinggi. Arti harfiah dari *cum laude* adalah "Dengan Pujian" atau "Dengan Penghargaan". Istilah ini secara khusus digunakan untuk menggambarkan penghargaan yang diberikan kepada mahasiswa prestasi akademik yang sangat tinggi dalam gelar sarjananya. *Cum laude* dalam konteks pendidikan tinggi, biasanya merujuk pada kategori penghargaan tertinggi yang diberikan pada saat kelulusan. Persyaratan untuk lulus dengan predikat *cum laude* bervariasi bergantung pada kebijakan institusi. Persyaratan ini umumnya berhubungan dengan Indeks Prestasi Kumulatif (IPK) yang tinggi, dengan batas yang berbeda untuk setiap predikat.

Penelitian ini dilakukan untuk memprediksi jumlah mahasiswa yang berpotensi mendapatkan predikat *cum laude* dengan menggunakan teknik *machine learning*. Sebelumnya, proses prediksi ini pada umumnya masih dilakukan secara manual sehingga memerlukan waktu analisis yang relatif lama. Kelebihan dari memprediksi jumlah mahasiswa yang berpotensi untuk mendapatkan predikat *cum laude* adalah perguruan tinggi dapat memanfaatkan hasil prediksi sebagai sarana promosi untuk menunjukkan kepada calon mahasiswa mengenai prediksi jumlah tingkat kelulusan mahasiswa dengan predikat *cum laude*. Selain itu diharapkan hasil prediksi dapat mendorong semangat para calon lulusan untuk mempertahankan prestasi akademiknya agar kelak dapat memiliki peluang besar terserap di dunia kerja. Hasil prediksi ini juga diharapkan dapat mendorong perguruan tinggi untuk terus meningkatkan kualitas pengajaran agar mahasiswa dapat memahami materi yang diajarkan dengan lebih baik dan memperoleh nilai yang tinggi.

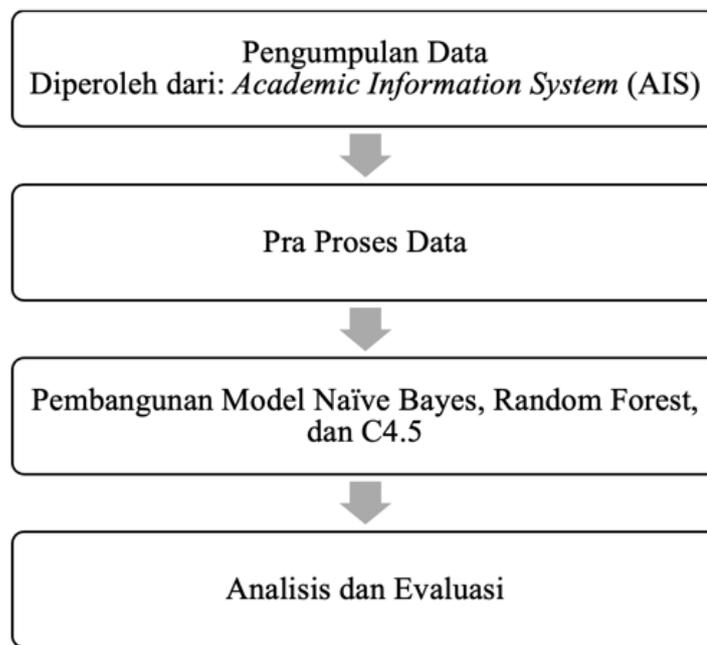
Beberapa penelitian terdahulu yang telah menggunakan teknik *machine learning* dalam mengevaluasi aktivitas akademik mahasiswa adalah penelitian Budiman *et al.* (2018). Budiman *et al.* (2018) menggunakan algoritma C4.5 untuk melakukan klasifikasi terhadap evaluasi aktivitas akademik mahasiswa. Hasilnya adalah algoritma C4.5 dengan rasio data 90% data latih, dan 10% data uji memiliki tingkat akurasi sebesar 78.58%, dan nilai *True Positive Rate* sebesar 76.72%. Penelitian lain yang relevan juga dilakukan oleh Galopo dan Eugene (2021). Dalam penelitian ini dilakukan prediksi mahasiswa yang akan lulus atau gagal pada suatu universitas dengan menggunakan algoritma Naïve Bayes. Tingkat akurasi yang dihasilkan adalah sebesar 83.77%, dengan presisi sebesar 80.46%, dan *recall* sebesar 83.33%. Penelitian Aman *et al.* (2019) meneliti performa akademik mahasiswa dengan menggunakan algoritma *Logistic Model Trees* (LMT), *random forest*, dan J48. Hasil penelitian menunjukkan masing – masing algoritma memiliki presisi sebesar 83.8%, 83.3%, dan 79.4%, nilai *recall* sebesar 83.5%, 83.1%, 79.1%, dan nilai *F-Measure* masing – masing sebesar 83.5%, 83.1%, dan 79.0%. Penelitian Karo *et al.* (2022) yang memprediksi kandidat penerima beasiswa menggunakan algoritma ID3 mendapat akurasi sebesar 83%, presisi sebesar 71.5%, dan *recall* sebesar 68%. Dalam kasus yang sama, algoritma pembandingnya yakni algoritma Naïve Bayes mendapatkan akurasi sebesar 89%, presisi sebesar 74%, dan *recall* sebesar 69%. Penelitian Ghosh dan Janan (2021) memprediksi performa mahasiswa dengan menggunakan algoritma *random forest* menunjukkan tingkat akurasi yang didapat sebesar 96%.

Meski beberapa penelitian pendahulu telah dilakukan untuk memprediksi performa akademik mahasiswa, penelitian untuk memprediksi kelulusan mahasiswa predikat *cum laude* dengan membandingkan beberapa algoritma *machine learning*, khususnya pada perguruan tinggi di Indonesia, saat ini masih belum banyak dilakukan. Prediksi kelulusan mahasiswa dengan

predikat *cum laude* dapat digunakan oleh universitas, salah satunya untuk memperkirakan jumlah mahasiswa yang berpotensi mendapatkan beasiswa studi lanjut. Oleh karena itu, penelitian ini bertujuan untuk membangun model terbaik dalam memprediksi kelulusan mahasiswa dengan predikat *cum laude*. Pencarian model terbaik dilakukan dengan membandingkan kinerja dari tiga algoritma yaitu C4.5, Naïve Bayes, dan *random forest* dengan menggunakan studi kasus data pada Universitas Islam Negeri Syarif Hidayatullah Jakarta. Kedepannya, model hasil penelitian ini diharapkan dapat diintegrasikan dalam sistem informasi akademik milik universitas yang bersangkutan dalam memprediksi mahasiswa yang akan meraih kelulusan predikat *cum laude*.

## METODE

Tahapan dalam penelitian ini adalah pengumpulan data, pra proses data, pembuatan dan pelatihan model prediksi, pengujian model, dan evaluasi. Tahapan penelitian ini bisa dilihat pada Gambar 1.



Gambar 1 Tahapan penelitian

### Pengumpulan Data

Dataset yang digunakan dalam penelitian ini diperoleh dari *Academic Information System (AIS)* yang dimiliki oleh UIN Jakarta, perguruan tinggi yang menjadi objek penelitian. Sampel data terdiri atas data mahasiswa yang lulus dari tahun angkatan 2017 – 2019 yang dipilih secara acak. Sampel dipilih secara acak untuk memastikan bahwa setiap anggota populasi memiliki kesempatan yang sama untuk dipilih sebagai bagian dari sampel, dan juga membantu menghindari bias yang mungkin muncul jika sampel dipilih secara tidak acak, misalnya hanya terpaku pada suatu fakultas saja, atau suatu jurusan saja. Aplikasi WEKA digunakan pada saat proses pembangunan model.

### Pra proses Data

Pertama, dilakukan proses normalisasi data dengan cara melakukan pembersihan, integrasi, dan transformasi data. Pada tahap pra proses data, digunakan metode *handling missing values* dengan cara menghapus baris data yang mengandung nilai yang hilang (Kantardzic 2003). Hal ini dilakukan untuk menghindari bias karena kekhawatiran input data yang kurang tepat. Data awal yang diperoleh berjumlah 1801 baris kemudian dilakukan pembersihan data dengan

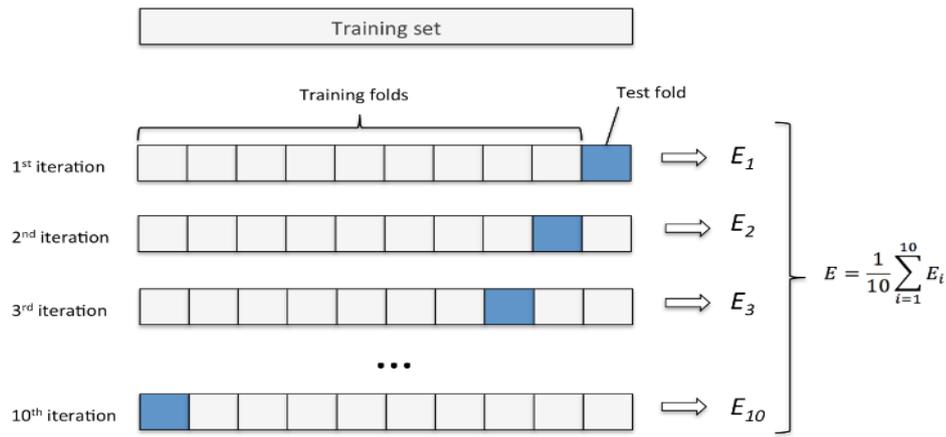
menghapus 8 baris data yang mengandung *missing values*. Data yang digunakan berjumlah 1793 baris data. Selanjutnya dilakukan proses integrasi, dan transformasi. Total atribut awal berjumlah 19 buah. Berdasarkan diskusi dengan ahli dan referensi yang sudah diteliti, dilakukan integrasi beberapa atribut dengan atribut lain, juga dilakukan penghapusan atribut yang tidak diperlukan. Dalam hal ini, peneliti menyesuaikan pemilihan atribut berdasarkan referensi dari penelitian yang sudah dilakukan sebelumnya pada penelitian Karo *et al.* (2022), Galopo dan Eugene (2021), dan Khan (2021). Penelitian Karo *et al.* (2022) mencantumkan beberapa atribut seperti jenis domisili, jenis transportasi, beasiswa yang pernah didapat, pekerjaan ayah, penghasilan ayah, pekerjaan ibu, pendapatan ibu, dan jenis kelas. Galopo dan Eugene (2021) mencantumkan beberapa atribut yang digunakan, seperti usia, jenis kelamin, jenis sekolah, IPK/nilai, rata-rata nilai matematika, IP semester 1 dan 2, pendapatan orang tua, pendidikan ayah, pendidikan ibu, dan kelulusan tepat waktu. Penelitian Khan (2021) mencantumkan beberapa atribut yaitu absensi, pendidikan ibu, pendidikan ayah, pekerjaan ibu, pekerjaan ayah, jumlah kegagalan tes sebelumnya, dan IPK. Setelah dilakukan analisis terhadap atribut yang sering digunakan dan menyesuaikan dengan objek penelitian, ditentukan 14 atribut untuk digunakan dalam penelitian ini. Atribut penelitian yang digunakan dapat dilihat pada Tabel 1.

### Pembangunan Model

Pada tahap pembangunan model dalam *machine learning*, beberapa proses yang dilakukan melibatkan pemilihan model, persiapan data, inisialisasi parameter/atribut, dan pelatihan model. Algoritma yang digunakan dalam penelitian ini adalah Naïve Bayes, Random Forest, dan C4.5. Parameter/atribut yang digunakan sudah disaring sedemikian rupa dengan mengacu pada referensi penelitian (Karo *et al.* 2022), (Galopo dan Eugene 2021), dan (Khan 2021), dan menyesuaikan dengan keadaan data yang dimiliki oleh universitas objek penelitian. Model dilatih dengan menggunakan metode *k-fold cross validation* dengan nilai  $k=10$ . Nilai  $k=10$  dipilih dalam penelitian ini karena dapat mengurangi bias jika dibandingkan dengan  $k=2$  (Rodríguez *et al.* 2010). Tes validasi pada penelitian ini menggunakan *k-fold cross validation*. Metode ini membagi data menjadi  $k$  kelompok. Data yang dibagi berjumlah sama banyaknya untuk masing-masing kelompok, kemudian satu kelompok data diambil sebagai data uji (*testing*), dan sisanya sebagai data latih (*training*). Setelah dicapai iterasi maksimum, maka akan diambil nilai rata-rata dari setiap elemen yang diperhitungkan. Ilustrasi proses iterasi pada *k-fold* menurut Sontakke *et al.* (2019) bisa dilihat pada Gambar 2. Contoh data penelitian yang digunakan dalam penelitian ini ditampilkan pada Tabel 2.

Tabel 1 Atribut data yang digunakan dalam penelitian

No	Atribut	Skala	Argumen
1	Pend. Ibu	Nominal	Tidak Tamat SD/MI, SD/MI, SLTP/MTS, SLTA/MA, Diploma/SM, S1, S2, S3.
2	Pend. Ayah	Nominal	Tidak Tamat SD/MI, SD/MI, SLTP/MTS, SLTA/MA, Diploma/SM, S1, S2, S3.
3	Pkr. Ibu	Nominal	PNS, Swasta, TNI, POLRI, Petani, Wiraswasta, Nelayan, Lain-Lain, Ibu Rumah Tangga, Tidak Bekerja, Pensiunan/Almarhum.
4	Pkr. Ayah	Nominal	PNS, Swasta, TNI, POLRI, Petani, Wiraswasta, Nelayan, Lain-Lain, Tidak Bekerja, Pensiunan/Almarhum.
5	Prestasi	Ordinal	jumlah prestasi yang dimiliki (angka).
6	Kelamin	Nominal	L / P
7	Usia	Ordinal	usia saat mendaftar
8	IP Semester 1	Ordinal	nilai ip semester 1 (angka)
9	IP Semester 2	Ordinal	nilai ip semester 2 (angka)
10	IP Semester 3	Ordinal	nilai ip semester 3 (angka)
11	IP Semester 4	Ordinal	nilai ip semester 4 (angka)
12	IP Semester 5	Ordinal	nilai ip semester 5 (angka)
13	IP Semester 6	Ordinal	nilai ip semester 6 (angka)
14	Predikat	Nominal	'cum laude', 'tidak cum laude'



Gambar 2 Ilustrasi proses *k-fold cross validation*

Tabel 2 Sampel data penelitian yang diambil dari repository Sistem AIS, UIN Syarif Hidayatullah Jakarta

usia	pkjrj_ayah	pkjrj_ibu	pend_ayah	pend_ibu	jml_prestasi	ips1	ips2	ips3	ips4	ips5	ips6	jk	Pre-dikat
16	Lain-Lain	IRT	SLTA/MA	SLTA/MA	6	3.26	3.38	3.71	3.48	3.45	3.82	P	Cum laude
16	Lain-Lain	IRT	SLTA/MA	SLTA/MA	8	3.1	3.48	3.57	3.25	3.29	3.69	L	Cum laude
16	Lain-Lain	IRT	SLTA/MA	SLTA/MA	9	3.6	3.7	3.83	3.79	3.6	3.67	P	Cum laude
16	Petani	IRT	SLTA/MA	SLTA/MA	6	3.15	3.65	3.9	4	3.7	3.08	P	Cum laude
16	Petani	IRT	SLTA/MA	SLTP/MTS	2	3.65	3.7	3.74	3.61	3.5	3.6	P	Cum laude
16	Petani	IRT	SLTP/MTS	S1	8	3.45	3.33	3.45	3.75	3.32	3.79	P	Cum laude
16	Petani	IRT	SD/MI	Tidak Tamat	7	3	3.59	3.27	3.64	3.48	3.83	P	Cum laude
16	PNS	IRT	S3	S1	9	4	4	3.88	4	4	4	P	Cum laude
16	PNS	PNS	S1	S1	8	3.32	3.36	3.5	3.36	3.43	4	L	Cum laude
16	POLRI	IRT	SLTA/MA	Diploma/SM	3	3.13	3.73	3.86	3.74	3.57	4	P	Cum laude
16	Swasta	IRT	SLTA/MA	S1	7	4	3.83	3.75	4	4	4	L	Cum laude
16	Swasta	IRT	SLTA/MA	SLTA/MA	6	3.2	3.65	3.48	3.4	3.7	3.63	P	Cum laude
16	Swasta	IRT	SLTA/MA	SLTA/MA	7	3.52	3.54	3.83	3.75	3.83	3.82	P	Cum laude
16	Swasta	Swasta	S1	S1	4	3.91	3.86	3.77	3.57	3.57	3.73	P	Cum laude
16	Swasta	Swasta	S1	S1	7	3.6	3.74	3.5	3.87	3.64	4	P	Cum laude
16	Tidak kerja	Lain 2	Diploma/SM	SLTA/MA	5	3.38	3.42	3.65	3.62	3.83	3.36	P	Cum laude
16	Wiraswasta	IRT	Diploma/SM	SLTA/MA	7	3.78	3.22	3.78	3.78	3.63	3.67	P	Cum laude
16	Wiraswasta	IRT	S1	S1	4	3.2	3.68	3.75	3.25	3.43	3.61	P	Cum laude
16	Wiraswasta	IRT	S1	S1	17	3.79	3.57	3.83	3.5	3.56	3.85	P	Cum laude
16	Wiraswasta	IRT	SD/MI	SLTP/MTS	13	3.11	3.85	3.83	3.8	3.81	4	P	Cum laude
16	Wiraswasta	IRT	SLTA/MA	SD/MI	13	3.92	3.83	3.83	3.8	3.91	4	P	Cum laude
16	Wiraswasta	IRT	SLTA/MA	SLTA/MA	3	3.35	3.68	3.63	3.88	3.71	3.74	P	Cum laude
17	Lain-Lain	IRT	Diploma/SM	S1	8	3.58	3.38	3.81	3.48	3.67	3.73	P	Cum laude
17	Lain-Lain	IRT	S1	Diploma/SM	3	3.3	3.26	3.18	3.55	3.63	3.92	P	Cum laude

### Analisis dan Evaluasi

Pada tahapan ini dilakukan analisis dan evaluasi kinerja model untuk memastikan bahwa model dapat melakukan prediksi atau klasifikasi dengan baik. Kinerja algoritme diukur menggunakan *confusion matrix* (Manning *et al.* 2008).

### Naïve Bayes

Naïve Bayes adalah sebuah metode klasifikasi yang populer dalam statistika. Metode ini menggunakan teorema Bayes untuk membuat prediksi probabilistik terhadap kelas-kelas yang mungkin (Duda dan Hart 1973). Meskipun efektif, metode ini memiliki asumsi dasar yang dikenal sebagai "naïve" atau sederhana (Wickramasinghe dan Kalutarage 2021). Teorema Bayes menggambarkan probabilitas suatu peristiwa, berdasarkan kondisi yang mungkin relevan dengan peristiwa tersebut. Oleh karena itu, ketika diberikan suatu objek yang akan

diklasifikasikan, yang ditandai oleh beberapa variabel penjelas, Naïve Bayes memberikan probabilitas untuk setiap kelas yang mungkin bagi objek tersebut (Ledeboer 2019). Persamaan 1 adalah persamaan umum untuk algoritma Naïve Bayes.

$$Info(D) = -\sum_{j=1}^Y \frac{|D_j|}{D} \text{IxInfo}(D_j) \quad (1)$$

dengan  $P(A|B)$  = probabilitas untuk  $A$  jika  $B$  benar,  $P(B|A)$  = probabilitas untuk  $B$  jika  $A$  benar,  $P(A)$ ,  $P(B)$  = probabilitas independen untuk  $A$ , dan  $B$ .

### Random Forest

*Random forest* merupakan suatu model pembelajaran mesin yang berbasis pada pohon (*tree-based learning*) (Breiman 2001). Algoritma ini termasuk dalam kategori *ensemble learning*. *Ensemble learning* adalah konsep di mana beberapa model digabungkan untuk meningkatkan kinerja dan stabilitas prediksi dibandingkan dengan menggunakan satu model tunggal (Schonlau dan Zou 2020). Persamaan umum pada algoritma random forest untuk menentukan nilai *indeks gini* dan *gini split* dinyatakan dalam Persamaan 2.

$$GINI(D) = 1 - \sum_{i=1}^k p_i^2, \quad (2)$$

dengan  $D$  adalah dataset dengan sebanyak  $k$  kelas yang berbeda dan  $p_i$  adalah frekuensi relatif jika kelas  $i$  berada dalam dataset ( $D$ ). Persamaan untuk menghitung *gini split* dinyatakan dalam Persamaan 3.

$$GINI_{split} = \sum_{i=1}^m \frac{n_i}{n} GINI(D) \quad (3)$$

dengan  $m$  adalah jumlah *children*,  $n_i$  merupakan jumlah data dari *child*  $i$ ,  $n$  merupakan jumlah data dalam dataset, dan  $n_i$  adalah jumlah populasi dari *child*  $i$ .

### C4.5

Algoritma C4.5 merupakan salah satu algoritma klasifikasi dalam *data mining*, yang menggunakan model *decision tree* (Witten *et al.* 2017). Algoritma C4.5 merupakan penerus ID3 (*Iterative Dichotomiser*) yang mengadopsi *greedy/nonbacktracking* di mana pohon keputusan (*decision tree*) dibangun dengan cara atas ke bawah (*top down*), diulang (*recursive*), dan dibagi lalu diselesaikan (*divide and conquer*) (Han *et al.* 2022; Hssina *et al.* 2014). Algoritma ini mengembangkan pohon yang *overfit* (terlalu kompleks) dan kemudian dilakukan pemangkasan (*prune*) untuk membuat model yang lebih stabil (Berry dan Linoff 2004).

Persamaan umum dari Algoritma C4.5 untuk menentukan nilai *entropy* dan *information gain* dari masing – masing atribut untuk menentukan atribut *root* dinyatakan dengan Persamaan 4 dan Persamaan 5. Andaikan terdapat sebuah distribusi probabilitas sebagai berikut  $P = (p_1, p_2, \dots, p_n)$  dalam sampel  $S$ . Maka persamaan entropy  $P$  adalah sebagai berikut:

$$Entropy(P) = -\sum_{i=1}^n p_i \log_2 p_i, \quad (4)$$

Persamaan *gain* untuk sebuah test  $T$  dan sebuah posisi  $p$  adalah sebagai berikut:

$$Gain(p,T) = Entropy(p) - \sum_{j=1}^n p_j Entropy(p_j), \quad (5)$$

dengan  $p_j$  adalah himpunan semua kemungkinan nilai untuk atribut  $T$ .

### Confusion Matrix

*Confusion matrix* (CM) adalah sebuah tabel yang umumnya digunakan dalam *machine learning* untuk mengevaluasi atau memvisualisasikan perilaku model dalam konteks klasifikasi terawasi (*supervised classification*) (Manning *et al* 2008). Matriks ini bersifat persegi dan digunakan untuk menganalisis performa model klasifikasi dengan membandingkan prediksi model dengan nilai aktual dari suatu dataset. Dataset pada CM terdiri atas dua kelas, di mana kelas pertama dianggap sebagai kelas positif dan kelas kedua dianggap sebagai kelas negatif. *True Positive (TP)* adalah nilai prediksi yang benar (*cum laude*), *False Negative (FN)* adalah nilai prediksi yang salah (tidak *cum laude*), *False Positive (FP)* adalah nilai prediksi yang salah (*cum laude*), dan *True Negative (TN)* adalah nilai prediksi yang benar (tidak *cum laude*) (Caelen 2017).

Tabel 3 *Confusion matrix*

Actual	Predicted	
	-	+
-	True Negative (TN)	False Positive (FN)
+	False Negative (FN)	True Positive (TP)

### Accuracy

*Accuracy (AC)* adalah metrik yang mengukur persentase prediksi yang benar oleh model. Metrik ini memberikan gambaran tentang sejauh mana model dapat membuat prediksi yang benar secara keseluruhan. Persamaan *accuracy* dinyatakan dalam Persamaan 6.

$$AC = \frac{tp + tn}{tp + tn + fp + fn} \quad (6)$$

### Precision

*Precision (PR)* adalah metrik yang mengevaluasi sejauh mana model dapat memprediksi label positif dengan tepat. Precision dihitung dengan membagi total jumlah *true positive* dengan jumlah *true positive* dan *false positive* secara keseluruhan. Persamaan 7 adalah persamaan untuk *precision*.

$$PR = \frac{tp}{tp + fp} \quad (7)$$

### Recall

*Recall (RC)* juga dikenal sebagai *true positive rate* atau *sensitivity* adalah metrik yang mengukur persentase positif sebenarnya yang diidentifikasi dengan benar oleh model. Persamaan *recall* dinyatakan dengan Persamaan 8.

$$RC = \frac{tp}{tp + fn} \quad (8)$$

### ***F-Measure***

*F-Measure* (juga dikenal sebagai *F1-Score*) adalah metrik yang merupakan kombinasi dari *precision* dan *recall*. Persamaan *F-Measure* dinyatakan dalam Persamaan 9.

$$F1 = \frac{2 \times RC \times PR}{RC + PR} \quad (9)$$

## **HASIL DAN PEMBAHASAN**

Jumlah data yang digunakan pada penelitian ini adalah 1793. Teknik *k-fold cross validation* digunakan untuk mengevaluasi kinerja model dengan  $k=10$ , sehingga terdapat 10 kelompok data. Langkah selanjutnya adalah memilih satu kelompok sebagai data uji, dan menggabungkan isi kelompok lainnya sebagai data latih. Langkah ini dilakukan terus menerus sampai setiap kelompok pada setiap iterasi pernah menjadi data uji. Kinerja algoritma diukur menggunakan *accuracy*, *precision*, *recall*, dan *F1-Score*.

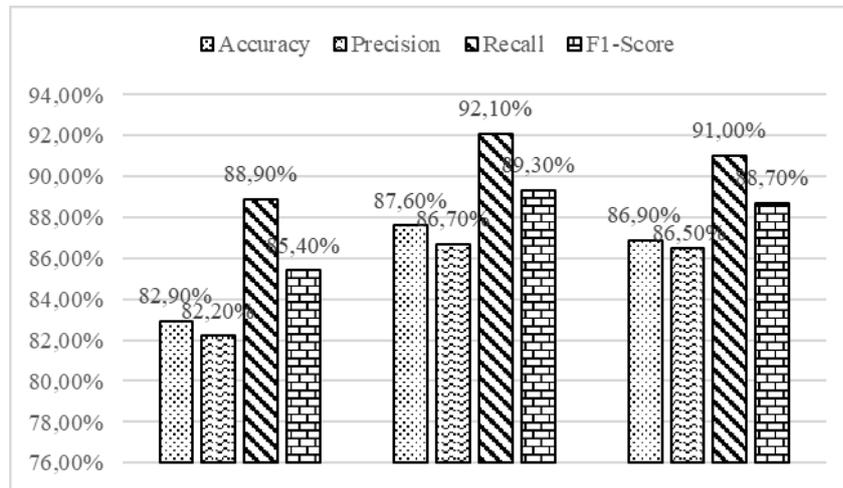
Hasil pengujian model menggunakan *confusion matrix* dari ketiga algoritma ditampilkan pada Tabel 4. Grafik perbandingan dari segi *accuracy*, *precision*, *recall*, dan *F1-score* pada masing – masing algoritma dapat dilihat pada Tabel 5 dan Gambar 3. Hasil pengujian menunjukkan bahwa algoritma Naïve Bayes pada kasus yang diujikan memiliki performa terbaik, baik dari segi *accuracy*, *precision*, *recall*, dan *F1-score*. *Random forest* menunjukkan performa yang cukup kompetitif dengan algoritma Naïve Bayes. Hasil pengujian mengindikasikan bahwa dalam hal akurasi, algoritma Naïve Bayes menunjukkan performa terbaik yaitu sebesar  $87.60 \pm 0.31\%$ , *random forest* mendapatkan akurasi yang sedikit lebih rendah yakni sebesar  $86.90 \pm 0.32\%$ , sedangkan C4.5 memiliki performa terendah dalam konteks penelitian ini yaitu  $82.90 \pm 0.38\%$  (Gambar 4). Algoritma Naïve Bayes juga menunjukkan *precision* dan *recall* yang tinggi yaitu 86.70% dan 92.10%, yang mencerminkan kemampuannya dalam mengidentifikasi dan mengklasifikasikan data positif secara efisien. Dalam konteks penelitian ini, artinya algoritma Naïve Bayes dapat memprediksi jumlah lulusan *cum laude* dengan baik dibandingkan kedua algoritma pembanding. Tingkat akurasi, *precision*, *recall*, dan *F1-Score* dari *random forest* mendekati nilai dari Naïve Bayes yang masing – masing sebesar 86.90%, 86.50%, 91.00%, dan 88.70%. Oleh karena itu, *random forest* dianggap sebagai alternatif unggulan dalam kasus ini. Dibandingkan dengan algoritma Naïve Bayes dan *random forest*, dalam kasus ini performa terendah diperoleh oleh algoritma C4.5.

Tabel 4 *Confusion matrix* ketiga algoritma

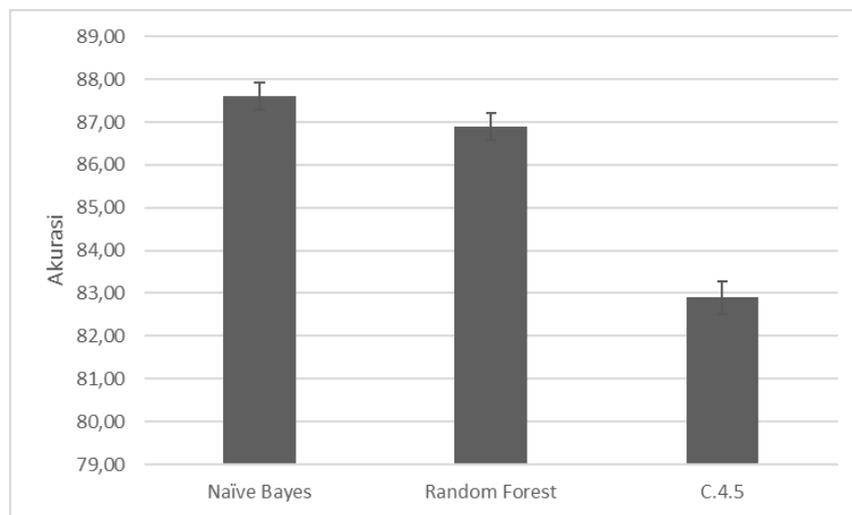
Algoritma		Predikat	
		Jumlah mahasiswa yang Tidak <i>Cum Laude</i>	Jumlah mahasiswa yang <i>Cum Laude</i>
C4.5	Tidak <i>Cum Laude</i>	592	194
	<i>Cum Laude</i>	112	895
Naïve Bayes	Tidak <i>Cum Laude</i>	644	142
	<i>Cum Laude</i>	80	927
Random Forest	Tidak <i>Cum Laude</i>	643	143
	<i>Cum Laude</i>	91	916

Tabel 5 Nilai *accuracy*, *precision*, *recall*, dan *f1-score* pada masing – masing algoritma

Algoritma	Metrik Pengujian			
	<i>Accuracy (AC)</i>	<i>Precision (PR)</i>	<i>Recall (RC)</i>	<i>F1-Score (F1)</i>
	$\frac{tp + tn}{tp + tn + fp + fn}$	$\frac{tp}{tp + fp}$	$\frac{tp}{tp + fn}$	$\frac{2 \times RC \times PR}{RC + PR}$
C4.5	82.90%	82.20%	88.90%	85.40%
Naïve Bayes	87.60%	86.70%	92.10%	89.30%
Random Forest	86.90%	86.50%	91.00%	88.70%



Gambar 3 Perbandingan hasil Algoritma C4.5, Naïve Bayes, dan random forest



Gambar 4 Grafik perbandingan akurasi ketiga algoritma (diurutkan dari akurasi tertinggi)

Selain melakukan evaluasi kinerja algoritma, dalam penelitian ini juga dihitung waktu komputasi dari ketiga algoritma yang dapat dilihat pada Tabel 6. Waktu komputasi untuk masing-masing algoritma dihitung menggunakan aplikasi WEKA. Dari perbandingan waktu eksekusi yang ditampilkan pada Tabel 6 dapat dilihat bahwa Algoritma Naïve Bayes memerlukan waktu paling singkat untuk kasus yang diujikan yakni sebesar 0.02 detik. Hal ini menunjukkan bahwa Naïve Bayes cocok digunakan pada kasus-kasus di mana efisiensi waktu eksekusi menjadi faktor penting. Algoritma C4.5 memerlukan waktu eksekusi sedikit lebih lama dibandingkan dengan Naïve Bayes (0.03 detik), tetapi masih lebih cepat daripada algoritma *random forest*. Algoritma *random forest* memerlukan waktu eksekusi paling lama (0.64 detik).

Tabel 6 Perbandingan waktu saat algoritma dijalankan pada aplikasi (diurutkan dari waktu tercepat)

Algoritma	Time (detik)
Naïve Bayes	0.02
C4.5	0.03
Random Forest	0.64

## SIMPULAN

Dalam penelitian ini dikembangkan model untuk memprediksi jumlah mahasiswa yang lulus dengan predikat *cum laude* pada perguruan tinggi. Dataset yang digunakan dalam penelitian ini diperoleh dari *Academic Information System (AIS)* yang dimiliki oleh UIN Jakarta. Hasil penelitian menunjukkan bahwa ketiga algoritma yaitu C4.5, Naïve Bayes, dan *random forest* menampilkan performa yang baik saat proses prediksi. Hal ini dapat dilihat dari

tingkat *accuracy*, *precision*, *recall*, dan *F1-score* yang tidak berbeda jauh di antara kategori-kategori tersebut. Hasil penelitian menunjukkan bahwa dalam kasus yang diujikan, performa terbaik dicapai oleh algoritma Naïve Bayes dengan nilai akurasi 87.60%, *precision* 86.70%, *recall* 92.10% dan *F1-score* 89.30%. Selain itu, algoritma Naïve Bayes juga menghasilkan nilai waktu komputasi terendah dibandingkan algoritma lainnya, yakni sebesar 0.02 detik untuk kasus yang diujikan.

Penelitian selanjutnya dapat difokuskan pada pengujian model dengan melakukan penambahan data uji serta melakukan evaluasi *feature importance* untuk menganalisis fitur yang paling penting dalam model prediksi. Selain itu dapat dilakukan implementasi model prediksi pada aplikasi komputer yang dapat mempermudah pengguna dalam melakukan prediksi kelulusan mahasiswa dengan predikat *cum laude*.

## DAFTAR PUSTAKA

- Aman F, Rauf A, Ali R, Iqbal F, Khattak AM. 2019. A predictive model for predicting students academic performance. Di dalam: *2019 10th International conference on information, intelligence, systems and applications (IISA)*. IEEE. hlm 1–4.
- Berry MJA, Linoff GS. 2004. *Data mining techniques: for marketing, sales, and customer relationship management*. John Wiley & Sons.
- Breiman L. 2001. Random forests. *Machine Learning*, 45:5–32.
- Budiman E, Haviluddin, Kridalaksana AH, Wati M, Purnawansyah. 2018. Performance of decision tree C4. 5 algorithm in student academic evaluation. Di dalam: *Computational Science and Technology: 4th ICCST 2017, Kuala Lumpur, Malaysia, 29–30 November, 2017*. Springer. hlm 380–389.
- Duda RO, Hart PE. 1973. Bayes Decision Theory. Chapter 2: Pattern Classification and Scene Analysis. hlm10–43.
- Caelen O. 2017. A Bayesian interpretation of the confusion matrix. *Ann Math Artif Intell*. 81(3):429–450.doi:10.1007/s10472-017-9564-8.
- Galopo JP, Eugene SP. 2021. Predicting Student Program Completion Using Naïve Bayes Classification Algorithm. *International Journal of Modern Education and Computer Science*. 13(3):57–67. doi:10.5815/ijmecs.2021.03.05.
- Ghosh SK, Janan F. 2021. Prediction of student’s performance using random forest classifier. Di dalam: *Proceedings of the 11th Annual International Conference on Industrial Engineering and Operations Management, Singapore*. hlm 7–11.
- Han J, Pei J, Tong H. 2022. *Data mining: concepts and techniques*. Morgan kaufmann.
- Hssina B, Merbouha A, Ezzikouri H, Erritali M. 2014. A comparative study of decision tree ID3 and C4. 5. *International Journal of Advanced Computer Science and Applications* 4, hlm 13–19.
- Karo IMK, Fajari MY, Fadhilah NU, Wardani WY. 2022. Benchmarking Naïve Bayes and ID3 Algorithm for Prediction Student Scholarship. *IOP Conf Ser Mater Sci Eng*. 1232(1):012002. doi:10.1088/1757-899x/1232/1/012002.
- Khan S. 2021. Study Factors for Student Performance Applying Data Mining Regression Model Approach. 188. 10.22937/IJCSNS.2021.21.2.21.
- Kantardzic M. 2003. *Data Mining – Concepts, Models, Methods, and Algorithms*. John Wiley & Sons. hlm 165-176.
- Ledeboer T. 2019. Interpretable Student Performance Prediction.: a case study in Dutch secondary education. [tesis]. Eindhoven University of Technology.
- Merriam-Webster Dictionary, “Cum laude.”. [diakses 18 November 2023]. <https://www.merriam-webster.com/dictionary/cum%20laude>.
- Manning CD, Raghavan P, Schütze H. 2008. *Introduction to Information Retrieval*. Cambridge (AU): Cambridge University Press.

- Rodríguez JD, Pérez A, Lozano JA. 2010. Sensitivity Analysis of k-Fold Cross Validation in Prediction Error Estimation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 32(3):569–575. doi:10.1109/TPAMI.2009.187.
- Schonlau M, Zou RY. 2020. The random forest algorithm for statistical learning. *Stata J*. 20(1):3–29.
- Sontakke SA, Lohokare J, Dani R, Shivagaje P. 2019. Classification of Cardiotocography Signals Using Machine Learning. In: Intelligent Systems and Applications. *IntelliSys 2018. Advances in Intelligent Systems and Computing, 869 Cham*. Springer. [https://doi.org/10.1007/978-3-030-01057-7\\_35](https://doi.org/10.1007/978-3-030-01057-7_35).
- UIN Syarif Hidayatullah. 2019. Pedoman Akademik Program Strata 1 2019/2020. Jakarta (ID): UIN Jakarta Press.
- Wickramasinghe I, Kalutarage H. 2021. Naive Bayes: applications, variations and vulnerabilities: a review of literature with code snippets for implementation. *Soft comput*. 25(3):2277–2293.
- Witten I, Frank E, Hall M, Kaufmann M. 2017. Practical machine learning tools and techniques. Data Mining. Fourth Edition. Amsterdam (NL): Elsevier Publishers.