

Identifikasi Dini Mahasiswa Berpotensi *Drop-Out* dengan Metode *Machine Learning* (Studi Kasus: Universitas Pembangunan Nasional “Veteran” Jakarta)

Salsabila Faiha Puteri¹, Bambang SarasYulistiawan², M. Octaviano Pratama³
S1 Sistem Informasi / Fakultas Ilmu Komputer

Universitas Pembangunan Nasional “Veteran” Jakarta

Jalan RS. Fatmawati Raya, Pd. Labu, Kec. Cilandak, Kota Depok, Jawa Barat 12450

salsabilafaihap@gmail.com¹, bambangsarasyulistiawan@upnvj.ac.id², octaviano.pratma@upnvj.ac.id³

Abstrak. Jumlah mahasiswa drop out merupakan salah satu indikator penting terhadap penilaian kualitas sebuah perguruan tinggi. Oleh sebab itu, perlu adanya sistem untuk memprediksi mahasiswa berpotensi drop out pada suatu perguruan tinggi, dengan tujuan meningkatkan kualitas mahasiswa dan perguruan tinggi. Upaya yang dilakukan dalam identifikasi dini mahasiswa berpotensi drop out juga bermanfaat untuk mencegah lonjakan mahasiswa drop out yang terjadi pada tahun-tahun akademik berikutnya. Berdasarkan observasi yang dilakukan di Universitas Pembangunan Nasional “Veteran” Jakarta, terdapat sebanyak 565 mahasiswa drop out pada tahun 2015 hingga tahun 2022. Dengan demikian, pada penelitian ini dilakukan pembuatan sistem yang berfungsi untuk melakukan identifikasi dini mahasiswa berpotensi drop out pada Universitas Pembangunan Nasional “Veteran” Jakarta. Penelitian dilakukan dengan menggunakan metode machine learning yaitu dengan menggunakan algoritma KNN dan Naïve Bayes. Pada penelitian ini juga dibangun sebuah sistem dashboard sebagai wadah untuk menyajikan visualisasi data terhadap data identifikasi dini mahasiswa berpotensi drop out yang informatif

Kata Kunci: *drop out, machine learning, KNN, Naïve Bayes*


1 Pendahuluan

Keberhasilan dalam masa perkuliahan merupakan tolok ukur utama untuk pencapaian akademik mahasiswa dan perolehan gelar di perguruan tinggi. Salah satu indikator kualitas perguruan tinggi adalah performa mahasiswa dalam menyelesaikan studi tepat waktu [1]. Masalah yang sering terjadi adalah mahasiswa mengalami *drop-out*, yang menunjukkan perlunya sistem prediksi untuk mendeteksi mahasiswa berpotensi *drop-out*. Sistem ini penting agar perguruan tinggi dapat melakukan intervensi yang tepat waktu, membantu mahasiswa meraih potensi maksimal mereka, dan meningkatkan kualitas pendidikan secara keseluruhan.

Dalam upaya efisiensi identifikasi dini mahasiswa berpotensi *drop-out*, pendekatan *machine learning* menjadi solusi yang efektif. *Machine learning*, sebagai cabang dari kecerdasan buatan, memungkinkan komputer untuk belajar dari data dan meningkatkan kemampuannya seiring waktu [2]. Penelitian ini mengaplikasikan dua algoritma *machine learning*, yaitu K-Nearest Neighbor (KNN) dan Naïve Bayes. KNN, algoritma yang sederhana namun efektif, melakukan prediksi dengan menggunakan nilai jarak dari data pelatihan [3]. Sementara itu, Naïve Bayes (NB) menggunakan probabilitas untuk mengelompokkan data, baik numerik maupun kategoris, dengan tingkat akurasi dan kecepatan tinggi pada dataset besar [4]. Berdasarkan penelitian relevan, dihasilkan akurasi oleh beberapa algoritma *machine learning*. Salah satu penelitian dengan judul “Student Dropout Prediction using Machine Learning Techniques” menggunakan beberapa algoritma *machine learning* dalam penelitiannya. Berdasarkan hasil penelitian tersebut, algoritma Naïve Bayes memiliki tingkat akurasi yang terbesar yaitu 98.29%.

Berdasarkan analisis dari UPT TIK dan AKPK, saat ini Universitas Pembangunan Nasional “Veteran” Jakarta belum memiliki sistem identifikasi dini untuk mahasiswa berpotensi drop-out, dengan pengelolaan masih bersifat manual. Data dari endpoint API akademik menunjukkan bahwa dari tahun 2015 hingga 2022, terdapat 565 mahasiswa aktif tingkat S1 yang mengalami drop-out. Untuk mengatasi masalah ini, meningkatkan kualitas pendidikan, mempercepat tindakan intervensi, dan mendukung visi perguruan tinggi, penelitian ini bertujuan untuk membangun sistem prediksi drop-out mahasiswa dengan visualisasi berbasis web, yang mencakup dashboard analitik untuk memberikan wawasan yang lebih baik dan intervensi yang lebih tepat.

2 Metodologi Penelitian



2.1 Identifikasi Masalah

Penelitian ini bertujuan mengidentifikasi mahasiswa yang berpotensi drop out di Universitas Pembangunan Nasional "Veteran" Jakarta dengan menganalisis tiga kriteria utama: IPK, SKS, dan Masa Studi. Kriteria ini ditetapkan berdasarkan Peraturan Rektor No. 15 Tahun 2020 tentang Evaluasi Kemajuan Studi dan Pedoman Akademik 2020/2021, serta hasil wawancara dengan pihak AKPK dan UPT TIK. IPK, yang mencerminkan prestasi akademik kumulatif dengan batas minimum 2.00, menjadi indikator utama. IPS, yang menentukan jumlah SKS yang dapat diambil, berpengaruh langsung terhadap IPK. Masa Studi, dengan batas minimal pada semester 2 dan maksimal pada semester 14, turut mempengaruhi potensi *drop-out*. Ketiga atribut ini saling terkait dan kritikal dalam prediksi drop out, mendukung Bidang Kemahasiswaan dalam pengambilan keputusan. Penelitian ini juga mengevaluasi penerapan Algoritma Naïve Bayes dan K-Nearest Neighbor (KNN) untuk mendeteksi mahasiswa berisiko *drop-out*.

2.2 Studi Literatur

Studi literatur merupakan tahapan dimana dilakukan sebuah pembelajaran serta pemahaman informasi untuk dijadikan sebuah referensi. Penulis menggunakan referensi-referensi yang relevan dengan penelitian-penelitian terdahulu. Penulis menggunakan pendekatan machine learning yaitu berisikan algoritma-algoritma seperti Algoritma Naïve Bayes dan Algoritma K-Nearest Neighbor (KNN). Penulis mendapatkan teori-teori tersebut dengan melakukan pemahaman melalui jurnal-jurnal, e-book, serta penelitian terdahulu yang relevan pada penelitian ini.

2.3 Pengumpulan Data

Pengumpulan data merupakan tahapan untuk mencari data yang relevan dan sesuai dengan tujuan penelitian. Penelitian ini dilakukan dengan menggunakan data akademik mahasiswa Universitas Pembangunan Nasional "Veteran" Jakarta. Data-data tersebut mewakili kriteria untuk menentukan mahasiswa terindikasi drop-out. Pengumpulan data dilakukan dengan melakukan observasi lapangan, dokumentasi, dan wawancara. Pengumpulan data dilakukan pada LP3M, AKPK, dan UPT TIK Universitas Pembangunan Nasional "Veteran" Jakarta

2.4 Preprocessing Data

Tahapan preprocessing merupakan tahapan penting sebelum melakukan modeling. Pada tahap preprocessing melibatkan data mentah yang belum di proses dan seleksi. Tahapan preprocessing memiliki 20 dampak pada kinerja serta kualitas model. Pada penelitian ini, tahapan yang dilakukan meliputi data cleaning, label encoding, feature engineering, dan data scalling.

2.5 Splitting Data

Data dibagi menjadi data training dan juga data testing. Data training digunakan untuk proses pelatihan pada modeling. Sedangkan data testing berguna untuk melakukan prediksi model yang sebelumnya telah dilakukan pelatihan menggunakan data training. Hal ini berguna untuk memberikan gambaran mengenai keakuratan model. Penentuan rasio pada data splitting akan ditetapkan pada saat proses pembuatan model dilakukan. Rasio dengan accuracy tertinggi akan dijadikan acuan dalam pembuatan model.

2.5 Membangun Model

Pada tahapan ini, dilakukan pemodelan menggunakan dua algoritma machine learning, yaitu K-Nearest Neighbor (KNN) dan Naïve Bayes, untuk menentukan model dengan akurasi terbaik. Proses dimulai dengan persiapan data, termasuk pengumpulan dan preprocessing. Model pertama yang diterapkan adalah Naïve Bayes, yang melibatkan pelatihan data untuk menghitung probabilitas kelas dan probabilitas kondisional fitur, serta evaluasi menggunakan metrik accuracy, precision, recall, dan F1-score. Selanjutnya, model KNN dibangun setelah preprocessing dan pemisahan data, dengan penentuan parameter k sebagai jumlah tetangga untuk prediksi. Evaluasi dilakukan untuk kedua model, dan hasil akurasi dibandingkan untuk memilih model dengan performa terbaik. Model yang memiliki akurasi tertinggi akan digunakan untuk prediksi dan visualisasi dalam penelitian selanjutnya.

2.6 Evaluasi Model

Berdasarkan pembuatan model yang telah dilakukan oleh algoritma Naïve Bayes dan KNN, selanjutnya adalah melakukan evaluasi model. Evaluasi model berfungsi untuk mengukur kinerja model serta melakukan pendeteksian apakah model tersebut mengalami overfitting atau underfitting. Uji model melibatkan melibatkan metrik evaluasi yaitu *accuracy*, *precision*, *recall*, dan *F1-Score*.

Tabel 1. Tabel Evaluasi Model

		<i>True Values</i>	
		TRUE	FALSE
<i>Prediction</i>	TRUE	TP	FP
	FALSE	FN	TN

2.7 Pemilihan Model Terbaik

Setelah dilakukan uji model, tahapan berikutnya adalah melakukan pemilihan model terbaik berdasarkan kedua algoritma yang telah dilakukan pemodelan. Model dengan kinerja terbaik dan akurasi yang terbaik adalah model yang akan digunakan dalam penelitian yaitu dalam pembuatan sistem prediksi mahasiswa berpotensi drop-out berbasis web.

2.8 Perancangan dan Pengujian Sistem

Dalam perancangan dan pengujian sistem, penulis menggunakan metode waterfall. Tujuan dari penggunaan metode waterfall yaitu karena metode ini terstruktur dan sistematis. Metode waterfall memiliki beberapa ciri seperti persyaratan yang stabil serta estimasi waktu yang akurat sehingga sesuai dengan penelitian ini. Metode waterfall berisi Requirements Analysis (Analisis Kebutuhan), System Design (Desain Sistem), Implementation (Implementasi), Integration and Testing (Integrasi dan Pengujian), Deployment (Penerapan), dan Maintenance (Pemeliharaan).

3 Hasil dan Pembahasan

3.1 Dataset

Pada penelitian ini data yang digunakan bersumber dari endpoint API yang meliputi data histori mahasiswa dan data list mahasiswa Universitas Pembangunan Nasional “Veteran” Jakarta. Jumlah data yang dihasilkan dari data histori mahasiswa yaitu 176.063 rows dan list mahasiswa yaitu 29.771 rows.

nim	int64	nim	int64
nama_mahasiswa	object	nama_mahasiswa	object
kode_program_studi	int64	jenis_kelamin	object
program_pendidikan	object	jalur_penerimaan	object
program_studi	object	tahun_angkatan	int64
ips	float64	semester_masuk	float64
sks_semester	int64	tanggal_mulai_masuk	object
status_mahasiswa_semester	object	kode_program_studi	int64
id_periode	int64	nama_program_studi	object
dtype: object		propinsi	object
		kota_kab	object
		kecamatan	object
		ipk	float64
		status_mahasiswa_terakhir	object
		penerimaan_basiswa_kipk	object
		penerimaan_basiswa_kjmu	object
		kelompok_ukt	object
		nominal_ukt	float64
		dtype: object	

Gambar 1. Dataset Mahasiswa

3.2 Preprocessing Data

a. Data Cleaning

Pada tahap ini, dilakukan pemilihan atribut-atribut yang diperlukan dan yang tidak diperlukan baik dalam pembuatan model maupun prediksi dan visualisasi. Implementasi proses *data cleaning* dalam penelitian ini meliputi pemilihan jenjang, *drop column*, penghapusan duplikasi data, penggabungan data, serta penanganan *missing values*. Setelah melewati tahap *data cleaning*, dataset berjumlah 23.420 rows.

b. Data Transformation

Pada tahap ini, dilakukan *label encoding* untuk mengonversi data kategori menjadi data numerik. Dalam penelitian ini, setiap data yang memiliki tipe data *object* akan dikonversi menjadi bernilai numerik.

c. Feature Engineering

Pada tahap ini, dilakukan pembuatan atribut baru yaitu adalah atribut status mahasiswa. Tahapan pada proses ini meliputi penghitungan kriteria atribut, selanjutnya adalah penentuan status mahasiswa. Hasil dari proses ini meliputi status mahasiswa ‘terprediksi dropout’ dan ‘tidak terprediksi dropout’.

d. Data Scalling

Data scalling digunakan untuk mengubah fitur ke dalam skala tertentu, dan akan memastikan bahwa seluruh fitur memiliki skala yang sama. *Data scalling* memiliki tujuan untuk meningkatkan kinerja model. Salah satu algoritma machine learning yang berbasis jarak adalah Algoritma KNN. Fitur yang memiliki skala yang lebih besar akan mendominasi dari fitur lainnya sehingga dapat menyebabkan kesalahan dalam membuat keputusan.

3.3 Membuat Model

a. Modeling KNN

Tabel 2. Tabel Parameter *k*

Parameter <i>k</i>	Mean Accuracy
<i>k</i> = 4	0.9786 (97.86%)
<i>k</i> = 5	0.9900 (99.00%)
<i>k</i> = 6	0.9773 (97.73%)

Pada Tabel 2. dilakukan penentuan parameter *k* dengan tiga kali percobaan. Berdasarkan tabel diatas, *mean accuracy* tertinggi yaitu parameter *k* = 5.

Tabel 3. Perbandingan Rasio

Perbandingan	Accuracy
Rasio 80:20	0.9977 (99.77%)
Rasio 70:30	0.9974 (99.74%)

Pada **Tabel 3.** dilakukan perbandingan rasio. Berdasarkan perbandingan rasio diatas, rasio 80:20 memiliki *accuracy* lebih tinggi yaitu 99.77%. Oleh karena itu, rasio 80:20 dijadikan acuan untuk melakukan *training model*.

Tabel 4. Perbandingan Metric

Metric	Accuracy
<i>Manhattan Distance</i>	0.9977 (99.97%)
<i>Chebyshev Distance</i>	0.9974 (99.74%)
<i>Minkowski p = 2 Distance /</i> <i>Euclidean Distance</i>	0.9977 (99.77%)

Pada **Tabel 4.** dilakukan perbandingan *metric* dilakukan pada tiga jenis *metric* yaitu Manhattan Distance, Chebyshev *metric*, dan Minkowski $p = 2$ atau Euclidean Distance. Pada tabel diatas, penggunaan *metric* Manhattan Distance dan Euclidean Distance memiliki hasil *accuracy* yang sama yaitu pada 0.9977, sedangkan untuk *metric* Chebyshev memiliki nilai *accuracy* 0.9974. Pemilihan Euclidean Distance atau setara dengan minkowski $p = 2$, sebagai atribut dilakukan karena data memiliki fitur yang hanya terbatas pada tiga atribut dan Euclidean Distance merupakan *metric* yang paling umum digunakan pada algoritma KNN.

```
#training model
classifier = KNeighborsClassifier(n_neighbors = 5, metric = 'minkowski', p = 2)
classifier.fit(X_train, y_train)
```

Gambar 2. Implementasi Model KNN**Tabel 5.** Confusion Matrix Data Training KNN

		Predicted Label	
		Terprediksi <i>Dropout</i> (0)	Tidak Terprediksi <i>Dropout</i> (1)
Actual Label	Terprediksi <i>Dropout</i> (0)	1518 (TN)	35 (FP)
	Tidak Terprediksi <i>Dropout</i> (1)	7 (FN)	17176 (TP)

Tabel 6. Confusion Matrix Data Testing KNN

		Predicted Label	
		Terprediksi <i>Dropout</i> (0)	Tidak Terprediksi <i>Dropout</i> (1)
Actual	Terprediksi <i>Dropout</i> (0)	400 (TN)	6 (FP)

Label	Tidak Terprediksi <i>Dorpout (1)</i>	4 (FN)	4274 (TP)
--------------	---	--------	-----------

b. Modeling Naive Bayes

```
gnb = GaussianNB()
gnb.fit(x_train, y_train.ravel())
```

Gambar 3. Implementasi Model Naive Bayes

Tabel 6. Confusion Matrix Data Training Naive Bayes

		<i>Predicted Label</i>	
		Terprediksi <i>Dropout (0)</i>	Tidak Terprediksi <i>Dorpout (1)</i>
<i>Actual Label</i>	Terprediksi <i>Dropout (0)</i>	1091 (TN)	462 (FP)
	Tidak Terprediksi <i>Dorpout (1)</i>	274 (FN)	16909 (TP)

Tabel 7. Confusion Matrix Data Testing Naive Bayes

		<i>Predicted Label</i>	
		Terprediksi <i>Dropout (0)</i>	Tidak Terprediksi <i>Dorpout (1)</i>
<i>Actual Label</i>	Terprediksi <i>Dropout (0)</i>	298 (TN)	108 (FP)
	Tidak Terprediksi <i>Dorpout (1)</i>	64 (FN)	4214 (TP)

3.4 Pemilihan Model Terbaik

Tabel 8. Tabel Pemilihan Model Terbaik

Algoritma	Data	Evaluasi Model
KNN	Training	<i>Accuracy: 0.9978</i>
		<i>Precision: 0.9980</i>
		<i>Recall: 0.9995</i>
		<i>F1-Score: 0.9988</i>
	Testing	<i>Accuracy: 0.9978</i>
		<i>Precision: 0.9985</i>
		<i>Recall: 0.9990</i>
		<i>F1-Score: 0.9988</i>

Naive Bayes	<i>Training</i>	<i>Accuracy: 0.9658</i>
		<i>Precision: 0.9734</i>
		<i>Recall: 0.9840</i>
		<i>F1-Score: 0.9787</i>
	<i>Testing</i>	<i>Accuracy: 0.9633</i>
		<i>Precision: 0.9750</i>
		<i>Recall: 0.9849</i>
		<i>F1-Score: 0.9799</i>

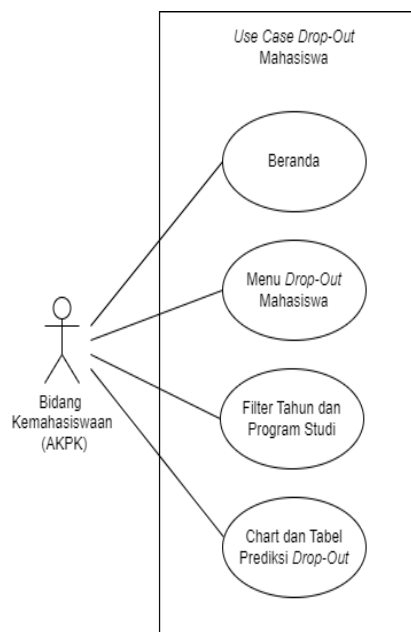
Berdasarkan **Tabel 8.** yaitu mengenai uji performa model oleh dua algoritma, KNN memiliki performa yang lebih baik dibandingkan dengan Naive Bayes. Oleh karena itu, model KNN akan digunakan dalam penelitian ini

3.5 Perancangan dan Pengujian Sistem

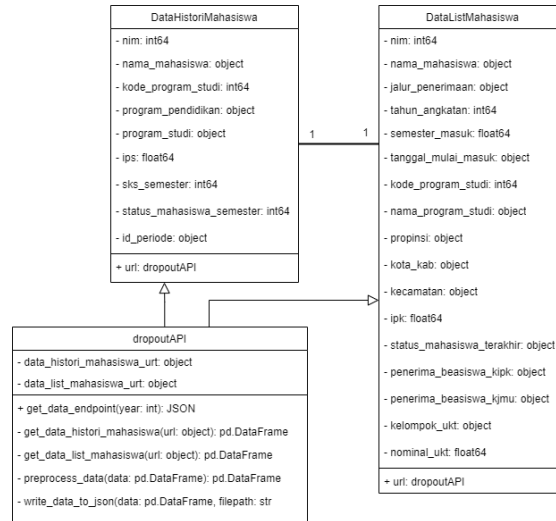
a. Analisis Kebutuhan

Pada tahapan ini, sistem memerlukan fungsionalitas dan spesifikasi teknis sebagai berikut. Kebutuhan fungsional meliputi kemampuan sistem untuk menarik dan menyimpan data periodik dari API, memproses data melalui preprocessing, mendukung pelatihan model machine learning, menyimpan model yang telah dilatih, melakukan prediksi, dan menyediakan visualisasi interaktif. Kebutuhan non-fungsional mencakup penggunaan sistem operasi Windows 11, backend dengan Python dan Flask, frontend dengan HTML, CSS, dan JavaScript, serta penggunaan library seperti numpy, pandas, matplotlib, scikit-learn, dan alat visualisasi ApexCharts.js.

b. Sistem Desain



Gambar 4. Use Case Diagram Drop-Out Mahasiswa



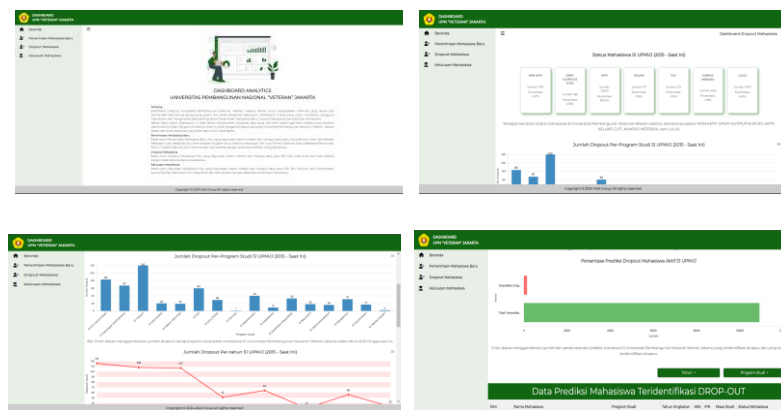
Gambar 5. Class Diagram Drop-Out Mahasiswa

c. Rancangan Wireframe



Gambar 6. Rancangan WireFrame Dashboard

d. Implementasi



Gambar 7. Tampilan Menu Drop-Out Mahasiswa

e. Pengujian Sistem

Pada tahap ini, dilakukan pengujian sistem. Penulis menggunakan Black Box Testing untuk melakukan testing dalam rangka memastikan bahwa sistem berjalan sesuai dengan kebutuhan.

f. Penerapan

Setelah dilakukan pengujian, sistem dapat diterapkan dan digunakan oleh pemangku kepentingan untuk membantu dalam melakukan pengambilan keputusan.

g. Pemeliharaan

Tahap pemeliharaan dan pembaruan sistem merupakan tahap terakhir dari alur proses pada sistem

perancangan dan pengujian sistem yang terdapat pada penelitian ini. Dalam tahap ini, perlu dilakukan maintenance system serta update system berdasarkan kebutuhan seperti pengecekan system error maupun pembaruan machine learning model maupun pembaruan konten visualisasi.

4 Kesimpulan dan Penutup

Berdasarkan penelitian yang telah dilakukan dapat disimpulkan bahwa:

1. Adapun teknik atau tahapan yang digunakan dalam pembuatan sistem prediksi dan mengetahui presentase mahasiswa adalah sebagai berikut.
 - a. Melakukan pengumpulan data yang bersumber dari API data akademik mahasiswa Universitas Pembangunan Nasional “Veteran” Jakarta sehingga data menjadi dinamis dan prediksi model menjadi *real time*.
 - b. Menggunakan metode *machine learning* yaitu Algoritma KNN dan Naïve Bayes. Hasil akurasi yang diperoleh dari algoritma KNN yaitu sebesar 0.9977 atau 99,77% dan Naïve Bayes yaitu sebesar 0.9658 atau 96.58%. Berdasarkan akurasi yang diperoleh dari ke dua model, algoritma KNN memiliki akurasi lebih tinggi yaitu 99.77%. Oleh karena itu, algoritma KNN dijadikan acuan untuk pembuatan model dalam penelitian ini.
 - c. Berdasarkan hasil penelitian, jumlah mahasiswa terprediksi *drop-out* untuk jenjang S1 sebanyak 144 orang dengan presentase 1.30% pada tahun ajaran 2023-2024. Sementara mahasiswa tidak terprediksi *dropout* berjumlah 10.902 orang dengan presentase 98.70%.
2. Pembuatan *dashboard analytic* dibangun menggunakan *HTML*, *CSS*, *Javascript* dan *Python*. Visualisasi data pada *dashboard analytic* disajikan dengan menggunakan *Apexchart.js* yang dilengkapi dengan filter tahun dan program studi sehingga memudahkan *user* untuk melihat data prediksi mahasiswa teridentifikasi *dropout* sehingga dapat digunakan untuk membantu sistem pengambilan keputusan. Pada *dashboard analytic* juga dilengkapi oleh informasi tambahan pada yang disajikan dalam bentuk diagram yang menarik. Pengujian yang dilakukan pada sistem *dashboard analytic* dengan menggunakan *blackbox testing* menghasilkan keseluruhan *output* yang diharapkan (*accepted*).

Adapun saran yang diberikan oleh penulis berdasarkan penelitian ini adalah sebagai berikut

1. Memperbesar lingkup jenjang pendidikan untuk dilakukan prediksi mahasiswa teridentifikasi *dropout*. Pada penelitian ini, penulis menggunakan tingkat S1 sebagai batasan masalah penelitian, sehingga perlu dilakukan perberasan lingkup jenjang supaya sistem prediksi dapat dilakukan lebih maksimal.
2. Menggunakan perbandingan model dengan menggunakan algoritma-algoritma *machine learning* lainnya supaya didapatkan hasil yang lebih maksimal.
3. Memperbarui design *user interface* seperti menambahkan diagram-diagram yang lebih informatif supaya lebih menarik dan mudah dimengerti.
4. Melakukan penelitian lebih mendalam terhadap berbagai macam aspek penilaian yang mempengaruhi atribut-atribut mahasiswa seperti IPK, SKS, dan Masa Studi.

Referensi

- [1] U. M. Asmudi, Harlinda, and N. Kurniati, “Penentuan Tingkat Kelulusan Mahasiswa di Fakultas Ekonomi dan Bisnis Universitas Muslim Indonesia Berbasis Web,” *Buletin Sistem Informasi dan Teknologi Islam*, vol. 2, no. 3, pp. 208–212, 2021.
- [2] T. Wahyono, *Python for Machine Learning (Dasar-dasar Pemrograman Python untuk Machine Learning dan Kecerdasan Buatan)*. Gava Media Yogyakarta, 2018.
- [3] R. Primartha, *Algoritma Machine Learning*. Informatika Bandung, 2021.
- [4] E. Sutoyo and A. Almaarif, “Educational Data Mining for Predicting Student Graduation Using the Naïve Bayes Classifier Algorithm,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 4, pp. 95–101, Feb. 2020, doi: 10.29207/resti.v4i1.1502.