

Penerapan Data Mining untuk Prediksi Minat Jurusan Mahasiswa Baru dengan Pendekatan Algoritma Naive Bayes

Niken Harsanti¹, Arief Wibowo²

¹Budiluhur University Master computer science Student

²Department of Information System, Budiluhur University

Article Info

Article history:

Received Oct 10, 2023

Revised Jun 08, 2024

Accepted Jun 24, 2024

Keywords:

Data Mining, Prediction, Student Interest, Naive Bayes algorithm

ABSTRACT

This research makes a positive contribution to the development of data mining applications in the field of higher education, which has the potential to help students and universities improve the efficiency of major selection. The aim of this research is to apply data mining techniques using the Naive Bayes algorithm to predict new students' majors. Accurate predictions can help new students make better decisions. Data obtained is based on historical data about past students, including information about academic grades, interests, and other factors that influence major selection. The Naive Bayes algorithm is used to process this data and produce a prediction model that can identify majors that best suit the characteristics of new students. The method using the Naive Bayes algorithm forms a grouping model using the Confusion Matrix table and classifies positive and negative values. The Naive Bayes algorithm model obtained can be implemented in the form of an application designed to predict new students' majors in determining the study program they will take. The Naive Bayes algorithm is able to provide quite accurate predictions, so it can be used as a guide for new students in choosing their major. The results of data processing for new students obtained accuracy values with the Naive Bayes algorithm model of 98.55%, precision of 99.97%, and recall of 98.55%.

Copyright © 2024 Universitas Indraprasta PGRI.
All rights reserved.

Corresponding Author:

Niken Harsanti,
Budiluhur University Master computer science Student
Jl. Ciledug Raya, Petukangan Utara Jakarta Selatan.
Email: 2211600271@student.budiluhur.ac.id

1. PENDAHULUAN

Tingkat perguruan tinggi menjadi langkah pemikiran dan berpola pikir yang tumbuh dikalangan siswa, khususnya selesai jenjang pendidikan tingkat atas menyiapkan bekal sedini mungkin untuk melanjutkan perguruan tinggi. Mahasiswa baru bersiap menentukan pilihan dengan melihat kesesuaian yang diinginkan dengan melihat rambu rambu aturan yang berlaku untuk mengambil jurusan yang mampu ditempuhnya. Fakultas diperguruan tinggi yang peminatnya digandrungi siswa biasanya yang praktis dan tren dikalangan siswa tingkat atas. [1]. Sistem penerimaan mahasiswa baru dilingkup perguruan tinggi beragam model penerapan serta ketentuan yang berlaku di kampusnya masing masing. Penelitian serupa di STMIK Royal dengan memberikan reward pada mahasiswa baru yang diprediksi masuk dalam program studi dengan peminatan tertentu dengan menggunakan naive bayes, dimana di perguruan tinggi tersebut melihat semakin menurunnya peminat pada program studitertentu.[2]. Profil mahasiswa dalam pemetaan peminatan studi tugas akhir juga diteliti dengan menggunakan naive bayes dan Term frequency invers document frequency, hasilnya sebagai rekomendasi berdasarkan profil siswa tersebut.[3]. Penelitian serupa juga dilakukan latifa dengan menggunakan metode naive bayes sebagai penunjang promosi program studi diperguruan tinggi UPGRIIS dengan klasifikasi data mining [4]. Penelitian dengan membandingkan antara algoritma naive bayes dan SVM juga dilakukan untuk prediksi mahasiswa yang belum registrasi dimana jumlah tersebut dikelompokkan

menjadi beberapa kelompok, terbentuk kluster yang akan dijadikan solusi akhir perbandingan tersebut pada fakultas ilmu komputer diteliti oleh megira.[5]. Penelitian yang dilakukan mirza penerapan algoritma naïve bayes dalam upaya menentukan strategi promosi mahasiswa baru , dimana hasil penelitian ini didapat peminat yang paling banyak jumlahnya sebagai program studi tren dan menjadi ketertarikan di bidang promosi.[6] Penelitian ini dilakukan dengan melihat dalam setiap tahunnya perubahan dan minimnya peminat prodi tertentu yang dirasa kurang diminati, maka diperlukan pemetaan konsep kebutuhan dari berbagai atribut program studi yang banyak peminatnya dengan prediksi peminatan mahasiswa baru .

Ragam model peminatan mahasiswa baru yang digunakan ditingkat perguruan tinggi dengan melihat tren serta kekinian yang dapat diprediksi dengan beberapa pendekatan. Data mining bagian dari konsep data dengan tujuan menggali data menjadi informasi yang digunakan dalam basis data dan merupakan bagian dari Knowledge Discovery in Databases (KDD) agar memperoleh model informasi serta pola keterkaitan yang dapat digunakan dalam penambangan data. [7]. Data mining menggali data untuk memperoleh informasi yang diinginkan, bernilai serta manfaat untuk pengelompokan data dimana unsur lain terlibat didalamnya seperti pengguna dan perangkat yang saling terkoneksi secara online.[8]

Penambangan data bagian dari proses yang diperoleh dari data mining cluster atau pengelompokan yang dibutuhkan para peneliti diambil dari pola relation di database dalam jumlah yang sangat besar. Lingkup informatika sangat tertantang tentang data mining untuk mengkaji secara mendalam apa yang ingin diteliti di berbagai informasi data yang ingin diambil. Pengambilan dalam penambangan data mendapatkan informasi knowledge yang baru di kelompokkan ke dalam kumpulan data.[9] Pengelompokan data mining terdiri dari beberapa metode yang dimiliki dengan tujuan dapat memanfaatkan ragam himpunan data diantaranya durasi, perkiraan, pengklasifikasian, klusterisasi serta asosiasi.[10]

Bagian yang paling khusus dalam teknik data mining dan wajib diperhatikan ialah penerapan aturan agar mendapatkan model terpola frekuensi tertinggi diantara himpunan dari atribut ,item set biasa disebut sebagai Association Rule (Aturan Asosiasi).[11]. Diantara ragam penggunaan dalam algoritma masuk kedalam aturan asosiasi ialah AIS Algorithm, DHP Algorithm, Partition Algorithm, dan Naivebayes Algorithm. Jenis jenis algoritma itu terdapat satu algoritma yang sangat tepat dan valid saat digunakan dan cocok dengan data mining dalam menganalisa prediksi peminatan mahasiswa baru dalam mengambil program studi yang sesuai dengan talenta yang dimiliki sejak awal yaitu algoritma Naivebayes . [12]



Gambar 1. Peminatan Mahasiswa Baru 2022

Peminatan mahasiswa baru dalam setiap semesternya mengalami perubahan yang agak sulit diprediksi dengan kasat mata , disebabkan dalam mengambil jurusan mahasiswa dihadapkan pada keadaan yang sulit dipahami peminatannya dengan kealhilan yang dimiliki. Calon mahasiswa baru dalam memilih jurusan terkadang melihat opini dari kakak kelas dan iklan yang bertaburan di media online yang memikat calon mahasiswa baru dalam mengambil jurusan.[13]

Algoritma Naive Bayes bagian dari klasifikasi algoritma biasa digunakan dengan teorema Bayes diasumsikan naïf (naive) dimana semua fitur yang ada didalam data disebut independen antara satu dengan yang lainnya. Walaupun terkait asumsi tersebut adakalanya tidak terpenuhi berdasarkan hasilnya, Naive Bayes bagian dari algoritma paling miniati pada data sains untuk pembelajaran mesin inferensi karena kecepatan serta keakuratannya terjamin. [14]

Cara kerja algoritma Naive Bayes adalah sebagai berikut:

1. Estimasi Probabilitas Kelas: Pertama, algoritma Naive Bayes menghitung probabilitas masing-masing kelas dalam dataset. Ini dilakukan dengan menghitung frekuensi kemunculan setiap kelas dalam data pelatihan dan membaginya dengan jumlah total sampel.
2. Estimasi Probabilitas Fitur: Selanjutnya, algoritma Naive Bayes mengestimasi probabilitas setiap fitur (variabel independen) untuk setiap kelas. Ini melibatkan menghitung frekuensi kemunculan setiap nilai fitur dalam setiap kelas dan membaginya dengan jumlah total sampel dalam kelas tersebut.
3. Asumsi Independensi Fitur: Asumsi independensi adalah asumsi kunci dalam Naive Bayes. Algoritma menganggap bahwa semua fitur dalam data adalah independen satu sama lain, meskipun asumsi ini sering kali tidak realistis di dunia nyata.
4. Menghitung Probabilitas Posterior: Setelah probabilitas kelas dan probabilitas fitur telah diestimasi, Naive Bayes menggunakan teorema Bayes untuk menghitung probabilitas posterior. Probabilitas posterior adalah probabilitas bahwa sampel tertentu termasuk dalam suatu kelas berdasarkan fitur-fiturnya.
5. Klasifikasi: Setelah probabilitas posterior dihitung, algoritma Naive Bayes dapat digunakan untuk memprediksi kelas (variabel dependen) dari sampel yang tidak diketahui. Algoritma akan memilih kelas dengan probabilitas posterior tertinggi sebagai prediksi kelasnya.
6. Naive Bayes memiliki keuntungan dalam kecepatan komputasi dan kebutuhan data pelatihan yang relatif sedikit. Namun, asumsi independensi fitur dapat menjadi keterbatasan jika ada dependensi yang signifikan antar fitur dalam data. Meskipun demikian, Naive Bayes tetap efektif dalam banyak kasus dan sering digunakan dalam klasifikasi teks, pengenalan pola, dan banyak aplikasi lainnya.

Naive Bayes bagian dari salah satu algoritma yang memiliki akurasi baik dalam teknik pengklasifikasian serta perhitungan untuk menilai cluster tertinggi yang menjadi skala pengukur dalam prediksi berbagai penentu penilaian.[15] Teorema Bayes dengan rumus sebagai berikut :

Rumus Teorema Bayes

$$P(C | X) = \frac{P(X|C).P(C)}{P(X)}$$

Keterangan.

X = Sampel data yang memiliki class (label) yang tidak diketahui.

C = Hipotesis bahwa X adalah data class (label).

P(C) = Probabilitas hipotesis C.

P(X) = Peluang dari data sampel yang diamati (probabilitas C).

P(X|C) = Probabilitas berdasarkan kondisi pada hipotesis.

Konsep kerja dari alur metode naive bayes antara lain.

1. Menghitung nilai peluang kasus baru dari setiap hipotesa dengan class (label) yang ada di P(Ci).
2. Menghitung nilai akumulasi peluang dari setiap kelas P(X|Ci).
3. Menghitung nilai P(X|Ci) x P(Ci).
4. Menentukan class dari kasus baru tersebut.

Dalam menentukan mahasiswa baru dipilih peminatan program studi dan dihimpun dalam 10 aturan data yang berlaku. Terdiri dari 4 atribut yang akan digunakan

Jumlah pendaftar mahasiswa pada program studi di Fakultas Teknik (C1).

Tingkat kelulusan tes masuk program studi peminatan (C2).

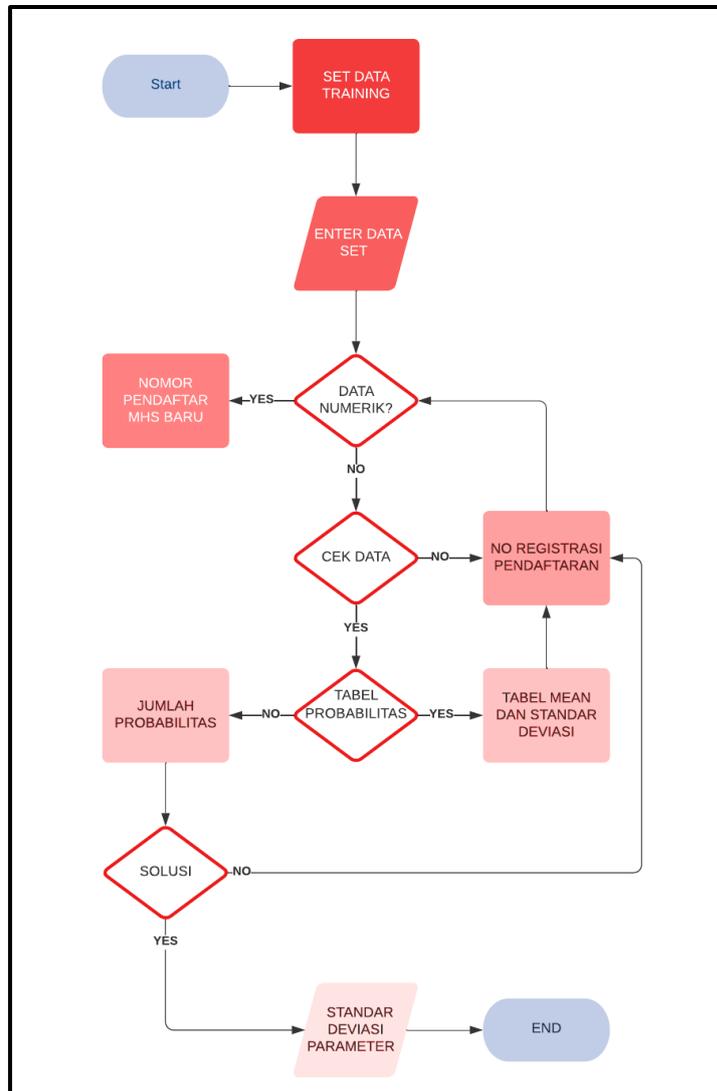
Daftar ulang dan registrasi mahasiswa baru (C3).

Keputusan memilih program studi yang diminati (C4).

Alur konsep metode Naive Bayes sebagai berikut:

- a. Baca data training
- b. Hitung jumlah data probabilitas, namun apabila data numerik maka:
- c. Cari nilai mean dan standar deviasi dari masing-masing parameter yang merupakan data numerik

- d. Cari nilai probabilitas dengan cara menghitung jumlah data yang sesuai dari kategori yang sama dibagi dengan jumlah data pada kategori tersebut.
- e. Mendapatkan nilai dalam table mean, standar deviasi dan probabilitas



Gambar 2. Alur Naïve Bayes Prediksi Jurusan Peminatan Mahasiswa Baru

2. METODE

Naïve bayes menggunakan metode Confusion Matrix yang mempresentasikan hasil setelah evaluasi model dengan menggunakan tabel matrik. Dataset terdiri dari 2 kelas, kelas pertama positif dan kelas kedua negatif. Evaluasi menggunakan confusion matrix menghasilkan nilai Akurasi, Precision, Recall, serta F-Measure. Akurasi mendapatkan klasifikasi presentasi ketepatan record data diklasifikasikan secara benar setelah dilakukan pengujian pada hasil klasifikasi. Precision merupakan proposikasi yang diprediksi positif yang juga positif benar pada data sebenarnya. Recall merupakan proporsi kasus positif yang sebenarnya diprediksi positif secara benar.

True Positive (TP) jumlah record positif dalam dataset yang diklasifikasikan positif. True Negative (TN) merupakan jumlah record negative dalam dataset yang diklasifikasikan positif. False Positive (FP) merupakan jumlah record negative dalam dataset yang diklasifikasikan positif. False Negative (FN) merupakan jumlah record positif dalam dataset yang diklasifikasikan negatif.

Rumus persamaan Confusion Matrix:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN}$$

3. HASIL DAN PEMBAHASAN

Data yang didapat sebanyak 2400 , namun dari data tersebut yang dapat digunakan sebanyak 680 data yang lengkap dan dapat diproses untuk berlanjut . Sebanyak 544 digunakan sebagai data training dan 236 digunakan sebagai data testing. Atribut yang didapatkan ada 8 terdiri dari , asal sekolah, jurusan, tahun lulus, pekerjaan, masa kerja, jenis kelamin, prodi pilihan, prodi alternatif.

3.1. Data Set

Gambar 3. Dataset yang digunakan

Terlihat dalam Gambar 3 ada data yang siap digunakan sebanyak data ada 544 baris, dan data yang disajikan tersebut akan dijadikan sebagai data training maupun data testing. Data tersebut selanjutnya akan melewati proses perhitungan untuk menentukan nilai dari setiap atribut yang sudah didapatkan, antara lain mean dan standar deviasi.

Tabel 1. Perhitungan Mean

Prodi Peminatan	Asal Sekolah	Jurusan	Tahun Lulus	Pekerjaan	Prodi pilihan	Prodi alternatif
Arsitek	77.678	76.793	77.324	77.123	76.346	70.321
Informatika	83.378	82.458	82.645	81.278	82.543	81.123
Visual	81.934	80.234	80.164	80.268	81.268	80.326

Terlihat dalam Pada Tabel 1 didapatkan hasil perhitungan mean dari data training yang telah disediakan.

Tabel 2. Perhitungan Standar Deviasi

Prodi Peminatan	Asal Sekolah	Jurusan	Tahun Lulus	Pekerjaan	Prodi pilihan	Prodi alternatif
Arsitek	4.011	3.893	3.734	3.586	3.044	4.246
Informatika	4.236	4.680	3.562	4.68	4.446	4.551
Visual	4.840	4.840	4.840	4.840	4.840	4.840

Terlihat dalam Pada Tabel 2 didapatkan hasil perhitungan standar deviasi dari data training yang telah disediakan.

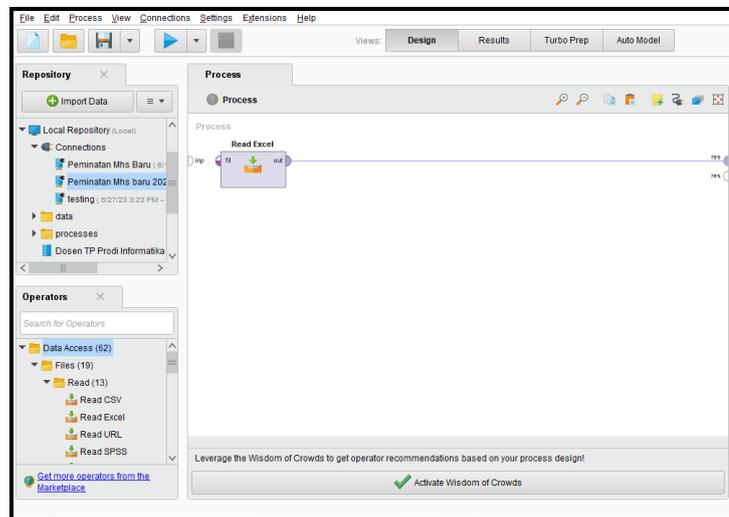
Tabel 3. Probabilitas

Prodi Peminatan	Nilai
Arsitek	0.3873434783443
Informatika	0.4273454795435
Visual	0.2542367881123

Terlihat dalam Pada Tabel 3 didapatkan hasil nilai probabilitas dari data training yang telah disediakan.

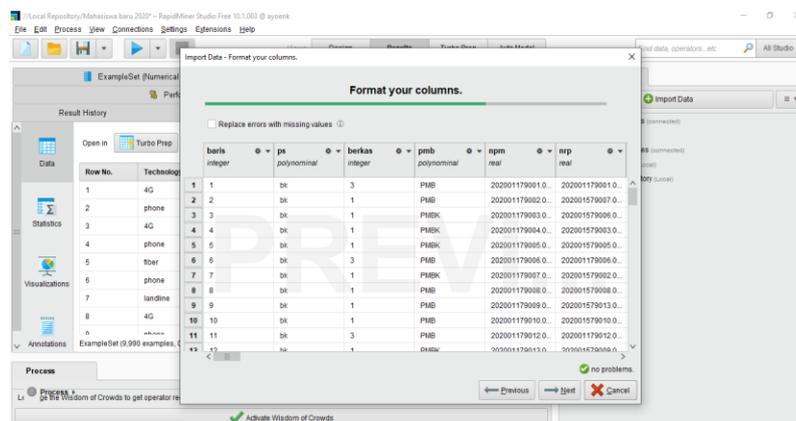
IMPLEMENTASI SISTEM

Setelah serangkaian perhitungan data mining dilakukan dan didapatkan sebuah hasil, maka dilanjutkan perhitungan tersebut dapat di uji dengan menggunakan aplikasi RapidMiner yang dibuat. Berikut bagian awal tampilan dari prediksi jurusan peminatan mahasiswa baru dengan menggunakan algoritma Naïve Bayes. Mulai dari testing koneksi RapidMiner, impor data, data training, data testing, data baru, perhitungan hasil prediksi, klasifikasi dan akurasi.



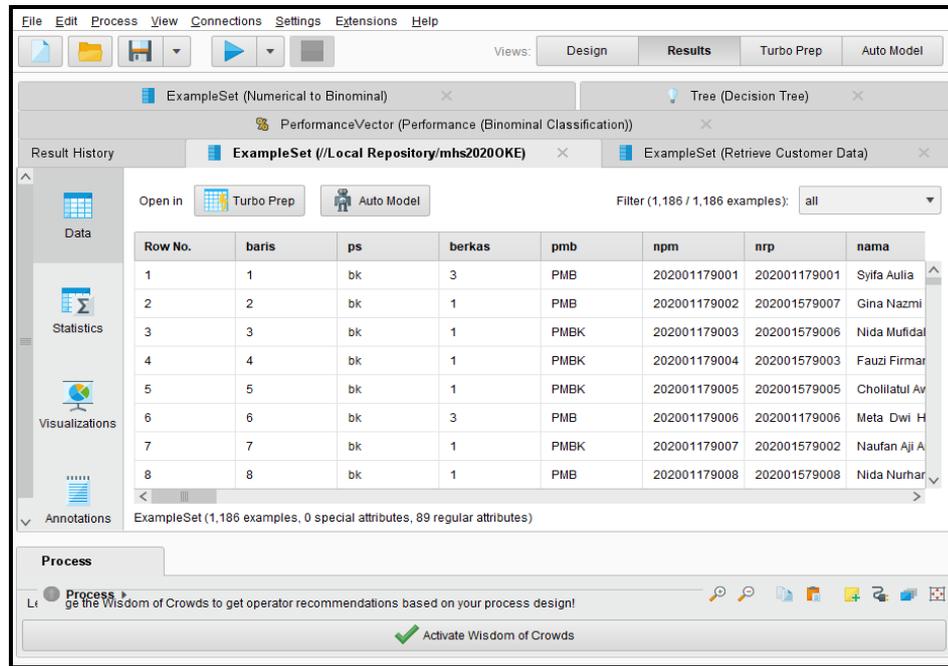
Gambar 4. Testing koneksi rapidminer

Pada gambar 4, tersebut diatas bagian tampilan dari Testing koneksi RapidMiner dimana terlihat fungsi, koneksi dapat dilanjutkan .Dilanjutkan untuk proses data tersebut nanti nya akan diproses untuk perhitungan Naïve Bayes.



Gambar 5. Import Data

Pada gambar 5, merupakan tampilan dari import data dimana terdapat fungsi untuk menambah data atau pun mengimport data training ulang, yang dimana data training tersebut nantinya akan diproses untuk perhitungan Naive Bayes.



Gambar 6. Tampilan Data Testing

Pada gambar 6 merupakan tampilan dari data training dimana fungsi yang terdapat didalam tampilan data training ini hampir sama dengan gambar 2. Data testing ini nantinya akan digunakan untuk menentukan hasil prediksi dan klasifikasi yang tepat dengan menggunakan algoritma Naive Bayes. Pada gambar 5 diatas terlihat proses hasil perhitungan prediksi menggunakan algoritma Naive Bayes berdasarkan data training set yang sudah diimport. Setelah proses perhitungan selesai maka hasil akan terlihat prediksi tersebut. Tingkat accuracy : 98,52% +/- 0,58% (micro average : 98,52%)

	true false	true true	class precision
pred.false	9824	3	99,97%
pred.true	145	18	11,04%
class recall	98,55%	85,71%	

Gambar 7. Tampilan Uji Akurasi

Pada gambar 7 tampilan terlihat hasil dari pengolahan data testing maka akan diperoleh hasil pengujian menggunakan metode *Confusion Matrix* untuk melihat nilai dari akurasi, *class precision*, dan *class recall*.

UJI AKURASI

Setelah dilakukan pengolahan terhadap data training set maka akan diperoleh akurasi pada pelatihan data. Untuk perhitungan akurasi menggunakan *Confusion Matrix* dilakukan dengan cara menjumlah nilai True Positive dengan True Negative kemudian dibagi dengan total keseluruhan data yang ada. Perhitungan tersebut berdasarkan data didapat nilai sebagai berikut :

$$\frac{145 + 3}{145 + 3 + 2 + 0} * 100 = 98.52\%$$

Nilai presisi didapatkan dengan melihat data dan membagi *True false* dengan total penjumlah dari *False Positive* dan *True true* dari data yang ada menjadi data yang ada menjadi *class precision*

$$\frac{148}{145 + 1} * 100 = 99.97\%$$

Nilai *recall* didapat dengan cara menghitung nilai *True Positive* yang dibagi dengan total data yang dijumlahkan antara *False Negative* dengan *True Positive* dari data, yaitu sebesar

$$\frac{148}{148 + 1} * 100 = 98.55\%$$

PENUTUP

Berdasarkan perhitungan, prediksi hasil serta pembahasan tersebut diatas kesimpulan didapat prediksi jurusan peminatan mahasiswa baru dilakukan dengan menggunakan algoritma Naïve Bayes sangat akurat. Hasil pemrosesan data mahasiswa baru diperoleh nilai akurasi dengan model algoritma Naïve Bayes sebesar 98.55%, *precision* sebesar 99.97%, dan *recall* sebesar 98.55%. Model algoritma naive bayes yang diperoleh dapat diimplementasikan ke dalam bentuk aplikasi yang dirancang untuk prediksi peminatan jurusan mahasiswa baru dalam menentukan program studi yang akan diambil. Selain itu dapat disimpulkan algoritma naive bayes tingkat akurasinya sangat cocok digunakan untuk prediksi peminatan mahasiswa baru, dapat digunakan sebagai konsep peminatan jurusan di perguruan tinggi lain.

UCAPAN TERIMAKASIH

Terimakasih kepada Bapak Dr. Arief Wibowo Pengampu Mata kuliah Data Mining di program pasca sarjana ilmu komputer Universitas Budiluhur yang telah memberikan ilmunya, mensupport serta memberikan data, informasi yang valid dan terbaik dalam tulisan ini, serta rekan rekan seperjuangan.

DAFTAR PUSTAKA

- [1] A. Yobioktabera and A. W. Wibowo, "Penerapan Data Mining Untuk Memprediksi Penerimaan Calon Mahasiswa Baru Fakultas Kedokteran Menggunakan Algoritma K-NN," *JTET (Jurnal Tek. Elektro Ter., vol. 10, no. 1, 2021.*
- [2] W. Handoko and M. Iqbal, "PREDIKSI PEMINATAN PROGRAM STUDI PADA PENERIMAAN MAHASISWA BARU STMIK ROYAL MENGGUNAKAN NAÏVE BAYES," *J. Sci. Soc. Res., vol. 4, no. 2, 2021, doi: 10.54314/jssr.v4i2.661.*
- [3] H. Ar - Rasyid, S. F. Pane, and M. Y. H. Setyawan, "Pemetaan Profil Mahasiswa Untuk Memprediks i Peminatan Mahasiswa," *PETIR, vol. 16, no. 1, 2023, doi: 10.33322/petir.v16i1.1337.*
- [4] K. Latifah, "ANALISIS DAN PENERAPAN ALGORITMA C45 DALAM DATA MINING UNTUK MENUNJANG STRATEGI PROMOSI PRODI INFORMATIKA UPGRIS," *J. Tek. Inform., vol. 11, no. 2, 2018, doi: 10.15408/jti.v11i2.6706.*
- [5] S. Megira, Kusri, and E. T. Luthfi, "PERBANDINGAN KINERJA NAIVE BAYES DAN SUPPORT VECTOR MACHINE UNTUK PREDIKSI HERREGISTRASI | Jurnal Sistem Informasi Komputer dan Teknologi Informasi (SISKOMTI)," *J. Siskomti, vol. 3, no. 2, 2020.*
- [6] A. H. Mirza, "Application of Naive Bayes Classifier Algorithm in Determining New Student Admission Promotion Strategies Penerapan Algoritma Naive Bayes Classifier Dalam Menentukan Strategi Promosi Penerimaan Mahasiswa Baru," *J. Inf. Syst. Informatics, vol. 1, no. 1, 2019.*
- [7] Y. E. Fadrial, "Algoritma Naive Bayes Untuk Mencari Perkiraan Waktu Studi Mahasiswa," *INTECOMS J. Inf. Technol. Comput. Sci., vol. 4, no. 1, 2021, doi: 10.31539/intecom.v4i1.2219.*
- [8] J. Dongga, A. Sarungallo, N. Koru, and G. Lante, "Implementasi Data Mining Menggunakan Algoritma Apriori Dalam Menentukan Persediaan Barang (Studi Kasus: Toko Swapen Jaya Manokwari)," *G-Tech J. Teknol. Terap., vol. 7, no. 1, 2023, doi: 10.33379/gtech.v7i1.1938.*
- [9] A. Andika, S. Syarli, and C. R. Sari, "DATA MINING KLASIFIKASI KELULUSAN MAHASISWA MENGGUNAKAN METODE NAÏVE BAYES," *J. Pegguruang Conf. Ser., vol. 4, no. 1, 2022, doi: 10.35329/jp.v4i1.2358.*
- [10] M. Arifin, "Implementasi Data Mining Pada Prediksi Pemesanan Menggunakan Algoritma Apriori (Studi Kasus :Kimia Farma)," *J. Pelita Inform., vol. 8, no. 3, 2020.*
- [11] I. P. Astuti, "Algoritma Apriori Untuk Menemukan Hubungan Antara Jurusan Sekolah Dengan Tingkat Kelulusan Mahasiswa," *J. Tek. Inform., vol. 12, no. 1, 2019, doi: 10.15408/jti.v12i1.10525.*
- [12] A. Syahrul and A. Solichin, "Rekomendasi Pemilihan Mata Kuliah dalam Pengisian Rencana Studi Mahasiswa dengan Penerapan Algoritma Apriori," *J. Eltikom, vol. 6, no. 1, 2022, doi: 10.31961/eltikom.v6i1.522.*

- [13] “Implementasi Data Mining Menggunakan Algoritme Naive Bayes Classifier dan C4.5 untuk Memprediksi Kelulusan Mahasiswa,” *Telematika*, vol. 13, no. 1, 2020, doi: 10.35671/telematika.v13i1.881.
- [14] S. Raschka and Vahid Mirjalili, “Python Machine Learning Second Edition Machine Learning and Deep Learning with Python, Scikit-learn and TensorFlow,” *Taiwan Rev.*, vol. 69, no. 4, 2019.
- [15] Z. Zulfauzi and M. N. Alamsyah, “Penerapan Algoritma Naive Bayes Untuk Prediksi Penerimaan Mahasiswa Baru Studi Kasus Universitas Bina Insan Fakultas Komputer,” *J. Teknol. Inf. Mura*, vol. 12, no. 02, 2020, doi: 10.32767/jti.v12i02.1096.