

# PENERAPAN ALGORITMA NAIVE BAYES UNTUK PREDIKSI KELAYAKAN PENERIMA KREDIT PADA KOPERASI KASIH INDONESIA

Wahyudin<sup>1</sup>, Rizky Tahara Shita<sup>2\*</sup>

<sup>1,2</sup>Teknik Informatika, Fakultas Teknologi Informasi, Universitas Budi Luhur, Jakarta, Indonesia

Email: <sup>1</sup>2011510878@student.budiluhur.ac.id, <sup>2\*</sup>rizky.taharashita@budiluhur.ac.id  
(\* : *corresponding author*)

**Abstrak-**Koperasi Kasih Indonesia merupakan lembaga keuangan yang bertujuan untuk memberdayakan ekonomi masyarakat berpenghasilan rendah dan menengah melalui penyediaan layanan kredit. Namun, salah satu masalah utama yang dihadapi oleh Koperasi Kasih Indonesia adalah memastikan bahwa kredit yang diberikan dapat dikembalikan dengan baik oleh penerima. Meskipun saat ini Koperasi Kasih Indonesia sudah memiliki indikator penilaian kelayakan secara konvensional untuk memastikan calon anggota penerima kredit, tetapi masih ditemukan ada anggota yang layak menerima kredit, namun tidak dapat memenuhi kewajiban untuk membayar kredit yang telah diberikan, sehingga dari hal tersebut menyebabkan terjadinya risiko kredit macet. Penerapan teknologi dalam penilaian kelayakan kredit menjadi sangat penting untuk mengurangi risiko kredit macet dan meningkatkan efisiensi proses pemberian kredit. Melalui teknik penambangan data dan penerapan algoritma *Naive Bayes*, Koperasi Kasih Indonesia dapat meningkatkan akurasi dalam penilaian kelayakan penerima kredit dan mengurangi risiko kredit macet. Berdasarkan hasil pengujian yang dilakukan pada penelitian ini, model *Naive Bayes* yang diterapkan mampu memberikan prediksi yang memadai terhadap data calon anggota penerima kredit yang diberikan, model ini menunjukkan kemampuan yang baik dalam mengidentifikasi calon anggota penerima kredit. Hasil evaluasi kinerja model mendapatkan tingkat akurasi sebesar 68.33% dari prediksi model adalah benar, hasil rata-rata dari nilai *precision* sebesar 72%, *recall* sebesar 80%, dan *f1-score* sebesar 69%. Ini menunjukkan bahwa model algoritma ini dapat membantu Koperasi Kasih Indonesia dalam menilai kelayakan calon anggota penerima kredit dengan cukup baik, sehingga proses kredit yang diberikan lebih efisien dan tepat sasaran.

**Kata Kunci:** Koperasi Kasih Indonesia, Kredit, Efisiensi, Akurasi, *Naive Bayes*

## ***APPLICATION OF NAIVE BAYES ALGORITHM FOR PREDICTION OF CREDIT RECIPIENTS ELIGIBILITY AT KOPERASI KASIH INDONESIA***

**Abstract-***Koperasi Kasih Indonesia is a financial institution that aims to empower the economy of low and middle-income communities through the provision of credit services. However, one of the main problems faced by Koperasi Kasih Indonesia is ensuring that the credit provided can be returned properly by the recipient. Although currently Koperasi Kasih Indonesia already has conventional eligibility assessment indicators to ensure prospective credit recipients, there are still members who are eligible to receive credit, but cannot fulfill their obligations to pay the credit that has been given, so that this causes the risk of bad credit. The application of technology in credit eligibility assessment is very important to reduce the risk of bad credit and increase the efficiency of the credit granting process. Through data mining techniques and the application of the Naive Bayes algorithm, Koperasi Kasih Indonesia can increase the accuracy in assessing the eligibility of credit recipients and reduce the risk of bad credit. Based on the results of the tests carried out in this study, the Naive Bayes model applied is able to provide adequate predictions of the data of prospective credit recipients given, this model shows good ability in identifying prospective credit recipients. The results of the model performance evaluation obtained an accuracy level of 68.33% of the model predictions were correct, the average result of the precision value was 72%, recall was 80%, and f1-score was 69%. This shows that this algorithm model can help the Koperasi Kasih Indonesia in assessing the eligibility of prospective credit recipients quite well, so that the credit process provided is more efficient and on target.*

**Keywords:** *Koperasi Kasih Indonesia, Credit, Efficiency, Accuracy, Naive Bayes*

---

## 1. PENDAHULUAN

Koperasi Kasih Indonesia merupakan lembaga keuangan yang bertujuan untuk memberdayakan ekonomi masyarakat berpenghasilan rendah dan menengah melalui penyediaan layanan kredit. Dalam rangka meningkatkan kesejahteraan anggotanya, Koperasi Kasih Indonesia menyediakan layanan kredit yang dapat dimanfaatkan oleh anggotanya untuk berbagai kebutuhan, seperti modal usaha, pendidikan, dan kebutuhan mendesak lainnya. Namun, salah satu masalah utama yang dihadapi oleh Koperasi Kasih Indonesia adalah memastikan bahwa kredit yang diberikan dapat dikembalikan dengan baik oleh penerima. Meskipun saat ini Koperasi Kasih Indonesia sudah

memiliki indikator penilaian kelayakan secara konvensional untuk memastikan calon anggota penerima kredit, tetapi masih ditemukan ada anggota yang layak menerima kredit, namun tidak dapat memenuhi kewajiban untuk membayar kredit yang telah diberikan, sehingga dari hal tersebut menyebabkan terjadinya risiko kredit macet.

Penerapan teknologi sangat diperlukan untuk mengidentifikasi informasi tersembunyi dalam data calon peminjam, sehingga memungkinkan koperasi dapat memprediksi kemampuannya dalam membayar kembali pinjaman [1]. Karena hal itu Koperasi Kasih Indonesia perlu memiliki sistem yang efektif untuk menilai kelayakan calon penerima kredit. Penerapan teknologi dalam penilaian kelayakan kredit menjadi sangat penting untuk mengurangi risiko kredit macet dan meningkatkan efisiensi proses pemberian kredit. Pengelolaan risiko kredit adalah proses identifikasi, pengukuran, dan pengelolaan risiko terkait pemberian kredit. Tujuan utama dari pengelolaan risiko kredit adalah meminimalkan kerugian yang timbul akibat ketidakmampuan peminjam untuk membayar kembali pinjaman. Kondisi kredit yang bermasalah dan nilai kredit yang buruk seringkali disebabkan oleh kurangnya analisis lanjutan dalam proses pemberian pinjaman [2]. Salah satu cara yang bisa digunakan adalah dengan menerapkan algoritma pembelajaran mesin dalam proses prediksi kelayakan penerima kredit. Pembelajaran mesin merupakan bagian dari kecerdasan buatan yang berfokus pada pengembangan algoritma agar komputer bisa belajar dari data serta membuat prediksi berdasarkan data.

Teknik penambangan data digunakan untuk proses menemukan pola, korelasi, atau pemahaman mendalam dari himpunan data besar dengan memanfaatkan teknik pembelajaran mesin, tujuan utama dari penambangan data adalah untuk mengubah data mentah menjadi informasi yang dapat digunakan untuk pengambilan keputusan di masa depan. Penambangan data memiliki beberapa tujuan, seperti fungsi deskriptif yang bertujuan untuk memperoleh pemahaman mendalam tentang data yang diamati. Ini dilakukan dengan menganalisis perilaku data untuk mengidentifikasi pola-pola yang relevan. Di sisi lain, fungsi prediktif bertujuan untuk menemukan pola atau hubungan di antara variabel tertentu dalam data guna membuat prediksi mendatang [3]. Penambangan data juga dikenal sebagai bagian dari *Knowledge Discovery in Database* (KDD) yaitu proses menemukan pengetahuan yang berguna dari data [4]. Penambangan data bisa digunakan untuk mengevaluasi risiko kredit dengan kemampuannya dalam memprediksi hasil observasi di masa mendatang [5]. Penambangan data dipandang sebagai cara untuk mengakses informasi tersembunyi dalam himpunan data, dengan mengungkap pola dan hubungan untuk tujuan klasifikasi, dan berperan penting dalam analisis data [6]. Dalam penambangan data, algoritma *Naive Bayes* sering dipakai untuk mengklasifikasikan data, membuat prediksi, atau mengidentifikasi pola tertentu [7].

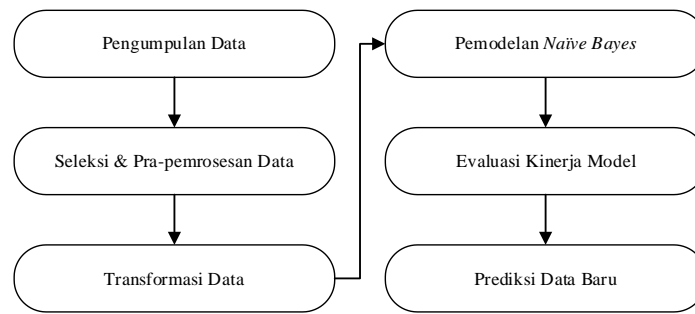
*Naive Bayes* adalah salah satu algoritma yang memiliki potensi besar untuk digunakan dalam kasus ini karena efektivitasnya dalam klasifikasi dan memiliki tingkat keakuratan yang lebih tinggi daripada algoritma yang lainnya [8]. *Naive Bayes* adalah algoritma pembelajaran mesin berbasis probabilitas dan statistik yang menggunakan *Teorema Bayes* untuk melakukan klasifikasi. Konsep *Teorema Bayes* merupakan dasar dari algoritma *Naive Bayes* untuk proses klasifikasi dalam penambangan data yang memberikan cara untuk memperbarui probabilitas hipotesis ketika mendapatkan bukti baru [9]. Teknik klasifikasi dalam penambangan data merupakan salah satu teknik yang bisa digunakan dalam menentukan risiko kredit [10].

Penelitian sebelumnya pada jurnal *Infortech*, dengan judul “Implementasi Algoritma Klasifikasi *Random Forest* Untuk Penilaian Kelayakan Kredit” peneliti melakukan pengujian dengan himpunan data sebanyak 481 data *record* kredit kendaraan bermotor dari PT. Buana Kredit Sejahtera, di mana pada data tersebut memiliki 13 variabel yang digunakan sebagai fitur input. Setelah melalui proses evaluasi menggunakan *confusion matrix*, data tersebut kemudian diklasifikasikan ke dalam 2 kelas target label: baik atau buruk. Hasil penelitian dari penerapan algoritma *Random Forest* menunjukkan tingkat akurasi sebesar 78,60% dan nilai area di bawah kurva (AUC) sebesar 0,907 maka model algoritma termasuk ke dalam klasifikasi baik sekali untuk mengklasifikasi kelayakan kredit [5].

Berbeda dengan penelitian sebelumnya, penelitian ini berjudul “Penerapan Algoritma *Naive Bayes* Untuk Prediksi Kelayakan Penerima Kredit Pada Koperasi Kasih Indonesia”, peneliti menggunakan 296 data historis peminjam koperasi dan 16 variabel sebagai fitur input. Proses evaluasi menggunakan *confusion matrix* dan diklasifikasi ke dalam 4 target label: dapat, tidak, tunda, kasus khusus. Hasil dari pengujian evaluasi model menunjukkan tingkat akurasi sebesar 68,33%, *precision* sebesar 72%, *recall* 80%, dan *f1-score* sebesar 69%. Dari hasil pengujian menunjukkan bahwa algoritma *Naive Bayes* dapat memberikan kinerja yang memadai dalam memprediksi kelayakan kredit dan menghasilkan matrik evaluasi yang baik.

## 2. METODE PENELITIAN

Penerapan metode *naive bayes* yang digunakan untuk prediksi kelayakan penerima kredit pada penelitian ini melalui beberapa tahapan yang dilakukan secara sistematis untuk dapat mencapai tujuan yang diharapkan. Berikut pada gambar 1 merupakan gambaran dari tahapan metode yang diterapkan pada penelitian ini:



Gambar 1. Metode Penelitian

## 2.1 Pengumpulan Data

Tahap awal yang dipersiapkan dalam penelitian ini adalah menyiapkan data penelitian sebanyak 296 data historis peminjam Koperasi Kasih Indonesia untuk periode Mei 2023 hingga Juni 2024 yang berasal dari data historis peminjam yang dikelola dan disimpan oleh Koperasi Kasih Indonesia. Data-data yang disimpan tersebut masih dalam bentuk lembaran formulir layak tidak yang telah diambil oleh petugas koperasi di lapangan ketika ada anggota yang mengajukan pinjaman.

Data tersebut kemudian diolah agar dapat dilakukan pra-pemrosesan data karena format data sebelumnya masih menggunakan lembaran formulir, maka perlu dilakukan proses perubahan data menggunakan aplikasi *Microsoft Excel* supaya model prediktif dapat mengenali data untuk diolah dengan membuat data nya menjadi sebuah tabel data yang lebih terstruktur dan lebih mudah untuk dilakukan pengujian.

## 2.2 Seleksi dan Pra-pemrosesan Data

Pada tahapan ini, dilakukan pemilihan data yang relevan yaitu menentukan variabel-variabel yang dijadikan acuan sebagai analisis untuk memprediksi kelayakan penerima kredit dan menghapus informasi yang tidak diperlukan untuk penilaian kelayakan kredit. Variabel-variabel yang dijadikan acuan sebanyak 16 variabel yaitu: usia, jumlah anak, status pendidikan, status rumah, ukuran rumah, jenis lantai, bahan atap terluas, bahan dinding rumah, tipe sanitasi, sumber air bersih, sumber listrik, penghasilan anggota perbulan, jumlah keluarga ditanggung yang berusia 0-18 tahun, jumlah keluarga ditanggung yang sedang bersekolah, jumlah keluarga ditanggung yang berhenti sekolah karena tidak ada biaya, dan barang yang tidak dimiliki calon anggota. Variabel-variabel tersebut dipilih karena memiliki skor yang lebih terstruktur supaya dapat diproses oleh model prediktif.

## 2.3 Transformasi Data

Tahapan transformasi data melibatkan proses mengubah format data agar menjadi format yang sesuai untuk dapat diproses oleh penambahan data dan menyesuaikan dengan kebutuhan dalam penerapan model prediktif. Proses ini terjadi pada tahap transformasi data dari teks nominal ke numerik supaya lebih terstruktur dan menyederhanakan representasi data sehingga lebih mudah dianalisis dan diproses oleh algoritma *naïve bayes*. Selanjutnya pada lembaran formulir layak tidak tersebut, beberapa variabel sudah memiliki berbagai nilai skor numerik yang sudah ada untuk dijadikan sebagai acuan untuk transformasi data.

## 2.4 Pemodelan *Naïve Bayes*

Tahap pemodelan *naïve bayes*, melatih model menggunakan himpunan data yang sudah melewati tahap seleksi, pra-pemrosesan, dan transformasi data. Proses ini membagi data ke dalam dua kelompok data, yaitu: data pelatihan sebesar 80% dan data pengujian sebesar 20% secara acak untuk selanjutnya dapat dilakukan proses perhitungan terhadap probabilitas dengan menggunakan konsep *teorema bayes* yang merupakan dasar dari algoritma *naïve bayes* untuk proses klasifikasi dalam penambahan data. Persamaan *teorema bayes* adalah:

$$P(H|E) = \frac{P(E|H) \times P(H)}{P(E)} \quad (1)$$

Keterangan:

- P(H|E) = Probabilitas hipotesis H diberikan bukti E
- P(E|H) = Probabilitas bukti E diberikan hipotesis H
- P(H) = Probabilitas awal hipotesis H
- P(E) = Probabilitas bukti E

## 2.5 Evaluasi Kinerja Model

Tahap selanjutnya adalah menilai efektivitas kinerja model klasifikasi menggunakan *confusion matrix* dan mengevaluasi kinerja model dengan menggunakan matrik evaluasi *accuracy*, *precision*, *recall*, dan *f1-score* di mana tujuan dari tahap ini adalah untuk mengukur seberapa baik model bekerja dengan data yang belum pernah diolah sebelumnya, yaitu data pengujian. Berikut pada tabel 1 adalah tahapan awal untuk evaluasi kinerja model:

**Tabel 1.** *Confusion Matrix*

	<i>Predicted Positive</i>	<i>Predicted Negative</i>
<i>Actual Positive</i>	<i>True Positive</i>	<i>False Negative</i>
<i>Actual Negative</i>	<i>False Positive</i>	<i>True Negative</i>

Keterangan:

- True Positive* = Jumlah data yang sebenarnya positif dan diprediksi sebagai positif
- False Negative* = Jumlah data yang sebenarnya positif tetapi diprediksi sebagai negatif
- False Positive* = Jumlah data yang sebenarnya negatif tetapi diprediksi sebagai positif
- True Negative* = Jumlah data yang sebenarnya negatif dan diprediksi sebagai negatif

Untuk menghitung nilai *accuracy*, *precision*, *recall*, dan *f1-score* menggunakan persamaan berikut:

- a. *Accuracy*, mengukur proporsi prediksi yang benar dari keseluruhan dokumen. *Accuracy* dapat dihitung menggunakan persamaan berikut:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

- b. *Precision*, mengukur proporsi prediksi positif yang benar dari semua prediksi positif. *Precision* dapat dihitung menggunakan persamaan berikut:

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

- c. *Recall*, mengukur proporsi data aktual positif yang diprediksi dengan benar. *Recall* dapat dihitung menggunakan persamaan berikut:

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

- d. *F1-Score*, merupakan gambaran keseimbangan antara *precision* dan *recall* yang berguna ketika distribusi kelas tidak merata. *F1-Score* dapat dihitung menggunakan persamaan berikut:

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

## 2.6 Prediksi Data Baru

Tahap terakhir dari metode penelitian ini adalah prediksi data baru sebagai proses memasukan data calon anggota peminjam baru dari pengguna sesuai variabel yang digunakan untuk dapat dilakukan proses prediksi kelayakan penerima kredit berdasarkan probabilitasnya, di mana model yang telah dilatih digunakan untuk memprediksi kelayakan penerima kredit untuk calon anggota peminjam baru. Tujuan dari prediksi data baru adalah untuk memanfaatkan model yang telah dilatih dan dievaluasi untuk memberikan hasil prediksi berdasarkan variabel yang tersedia.

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Himpunan Data

Data yang digunakan pada penelitian ini sebanyak 296 data historis peminjam Koperasi Kasih Indonesia untuk periode Mei 2023 hingga Juni 2024, yang dikelola dan disimpan oleh Koperasi Kasih Indonesia. Berikut pada tabel 2 adalah ringkasan data historis yang berhasil dikumpulkan:

**Tabel 2.** Data Historis Peminjam Koperasi

No	Usia	Status Rumah	Ukuran Rumah	Penghasilan Anggota	JKD Sedang Sekolah	...	Status Kelayakan
1	27	Kontrak	< 21m <sup>2</sup>	> 1.5Juta	1-2	...	Dapat
2	27	Kontrak	30-36m <sup>2</sup>	> 1.5Juta	0	...	Dapat
3	27	Milik	30-36m <sup>2</sup>	> 1.5Juta	1-2	...	Dapat
4	27	Kontrak	30-36m <sup>2</sup>	900-1.5Juta	1-2	...	Dapat
5	46	Kontrak	21-30m <sup>2</sup>	900-1.5Juta	3-4	...	Tidak
6	35	Numpang	< 21m <sup>2</sup>	900-1.5Juta	1-2	...	Tidak
7	34	Numpang	30-36m <sup>2</sup>	900-1.5Juta	1-2	...	Tidak
...	...	...	...	...	...	...	...
294	30	Kontrak	21-30m <sup>2</sup>	900-1.5Juta	0	...	Kasus Khusus
295	44	Kontrak	21-30m <sup>2</sup>	> 1.5Juta	1-2	...	Tunda
296	38	Kontrak	21-30m <sup>2</sup>	> 1.5Juta	1-2	...	Tunda

Data yang dikumpulkan tersebut kemudian dilakukan transformasi data, yaitu proses mengubah format data agar menjadi format yang sesuai untuk dapat diproses oleh penambahan data dan menyesuaikan dengan kebutuhan dalam penerapan model prediktif. Proses ini terjadi pada tahap transformasi data dari teks nominal ke numerik supaya lebih terstruktur dan menyederhanakan representasi data sehingga lebih mudah dianalisis dan diproses oleh algoritma *naïve bayes*. Pada lembaran formulir layak tidak, beberapa variabel sudah memiliki berbagai nilai skor numerik yang sudah ada untuk dijadikan sebagai nilai acuan untuk dilakukan transformasi data. Berikut pada tabel 3 adalah ringkasan hasil tranformasi data historis yang dilakukan:

**Tabel 3.** Transformasi Data Historis Peminjam Koperasi

No	Usia	Status Rumah	Ukuran Rumah	Penghasilan Anggota	JKD Sedang Sekolah	...	Status Kelayakan
1	27	30	15	0	20	...	Dapat
2	27	30	5	0	0	...	Dapat
3	27	0	5	0	20	...	Dapat
4	27	30	5	100	20	...	Dapat
5	46	30	9	100	30	...	Tidak
6	35	20	15	100	20	...	Tidak
7	34	20	5	100	20	...	Tidak
...	...	...	...	...	...	...	...
294	30	30	9	100	0	...	Kasus Khusus
295	44	30	9	0	20	...	Tunda
296	38	30	9	0	20	...	Tunda

#### 3.2 Pengujian model *Naive Bayes*

Langkah awal untuk pengujian model *naïve bayes* adalah melakukan proses perhitungan terhadap probabilitas masing-masing fitur terhadap 4 kelas target yang diberikan dengan menggunakan persamaan (1) pada data pelatihan. Berikut pada Tabel 4 merupakan probabilitas kemunculan setiap kelas dari 16 variabel yang digunakan terhadap 296 data historis peminjam.

**Tabel 4.** Probabilitas Kelas

Status Kelayakan	Jumlah	Persentase
Dapat	111	37.5%
Tidak	105	35.47%
Tunda	47	15.88%
Kasus Khusus	33	11.15%

Langkah selanjutnya adalah tahap evaluasi kinerja model yang merupakan bagian penting dalam pembelajaran mesin, evaluasi kinerja model dengan menggunakan *confusion matrix* untuk menilai kinerja model klasifikasi membandingkan prediksinya dengan nilai sebenarnya dari data pengujian. Berikut pada tabel 5 adalah ringkasan tabel data pengujian yang memuat 60 baris data atau 20% dari total 296 data historis yang digunakan:

**Tabel 5.** Data Uji

No	Usia	Status Rumah	Ukuran Rumah	Penghasilan Anggota	JKD Sedang Sekolah	...	Status Kelayakan
1	33	30	15	100	20	...	Tidak
2	33	0	2	0	20	...	Dapat
3	37	30	5	0	0	...	Dapat
4	57	0	2	0	20	...	Dapat
5	35	30	2	0	30	...	Kasus Khusus
6	35	0	5	0	20	...	Dapat
7	35	30	5	0	20	...	Tunda
...	...	...	...	...	...	...	...
58	30	30	5	0	20	...	Tidak
59	48	30	5	0	20	...	Dapat
60	26	30	5	0	0	...	Tunda

Hasil dari data pengujian yang terbentuk, kemudian direpresentasikan ke dalam bentuk tabel *confusion matrix* yang menunjukkan jumlah prediksi yang benar dan salah untuk setiap kelas agar dapat dilakukan proses evaluasi kinerja model dengan menggunakan matrik evaluasi *accuracy*, *precision*, *recall*, dan *f1-score*. Evaluasi ini dapat membantu mengidentifikasi bidang-bidang yang memerlukan perbaikan atau penyesuaian lebih lanjut. Berikut pada tabel 6 merupakan hasil klasifikasi *confusion matrix* yang terbentuk dari data pengujian:

**Tabel 6.** Hasil Klasifikasi *Confusion Matrix*

		Prediksi			
		Dapat	Kasus Khusus	Tidak	Tunda
Aktual	Dapat	12	7	0	9
	Kasus Khusus	0	7	0	0
	Tidak	0	2	13	0
	Tunda	0	0	1	9

Berdasarkan hasil klasifikasi *confusion matrix* yang terbentuk, ditemukan jumlah data yang diprediksi benar terklasifikasi pada diagonal utama sebanyak 41 data, serta kesalahan prediksi sebanyak 19 data. Proses selanjutnya yaitu menghitung nilai *accuracy*, *precision*, *recall*, dan *f1-score* dengan menggunakan persamaan yang dijelaskan pada sub bab 2.5 Evaluasi kinerja model.

- a. Menghitung akurasi prediksi yang benar terhadap keseluruhan prediksi.

$$Accuracy = \frac{12+7+13+9}{12+7+9+7+2+13+1+9} = \frac{41}{60} = 0.6833$$

- b. Menghitung *precision*, *recall*, dan *f1-score* untuk setiap kelas. Berikut pada tabel 7 merupakan langkah-langkah perhitungan untuk evaluasi kinerja model dan pada tabel 8 merupakan laporan klasifikasi dari model yang terbentuk:

**Tabel 7.** Hasil Klasifikasi Evaluasi Kinerja Model

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>
Dapat	$\frac{12}{12+0} = \frac{12}{12} = 1$	$\frac{12}{12+16} = \frac{12}{28} = 0.43$	$2x \frac{0.43}{1.43} = 0.6$
Kasus Khusus	$\frac{7}{7+9} = \frac{7}{16} = 0.44$	$\frac{7}{7+0} = \frac{7}{7} = 1$	$2x \frac{0.43}{1.43} = 0.61$
Tidak	$\frac{13}{13+1} = \frac{13}{14} = 0.93$	$\frac{13}{13+2} = \frac{12}{15} = 0.87$	$2x \frac{0.80}{1.8} = 0.9$
Tunda	$\frac{9}{9+9} = \frac{9}{18} = 0.5$	$\frac{9}{9+1} = \frac{9}{10} = 0.9$	$2x \frac{0.45}{1.4} = 0.64$



**Tabel 8.** Laporan Klasifikasi


Kelas	Precision	Recall	F1-Score	Support
Dapat	1	0.43	0.6	28
Kasus Khusus	0.44	1	0.61	7
Tidak	0.93	0.87	0.9	15
Tunda	0.5	0.9	0.64	10
Rata-rata	0.72	0.8	0.69	60

Dari perhitungan evaluasi kinerja model dan hasil laporan klasifikasi yang terbentuk mendapatkan hasil rata-rata dari nilai *precision* sebesar 72% yang menunjukkan semua kasus diprediksi positif memang benar positif, proporsi *recall* dari keseluruhan kelas positif yang berhasil diidentifikasi oleh model sebesar 80% ini menunjukkan kemampuan yang baik dalam mengidentifikasi calon anggota penerima kredit yang berpotensi gagal membayar, sehingga dapat mengurangi risiko kredit macet dan hasil *f1-score* sebesar 69% untuk nilai keseimbangan kelas antara *precision* dan *recall* yang memberikan ukuran keseluruhan kinerja model dalam memprediksi kelas positif dan negatif, ini berarti bahwa proses penilaian kelayakan kredit dapat dilakukan dengan lebih efisien.

### 3.3 Tampilan Layar Aplikasi


Berikut adalah tampilan-tampilan layar aplikasi yang dibuat mulai dari pertama kali aplikasi dijalankan hingga ke tahap akhir visualisasi hasil prediksi. Tampilan layar aplikasi dibuat semudah mungkin untuk dapat dipahami oleh pengguna.

- Tampilan halaman utama, pada gambar 2 merupakan halaman *login* untuk masuk ke dalam aplikasi. Pada halaman ini pengguna diarahkan untuk memasukkan *username* dan *password* terlebih dahulu.



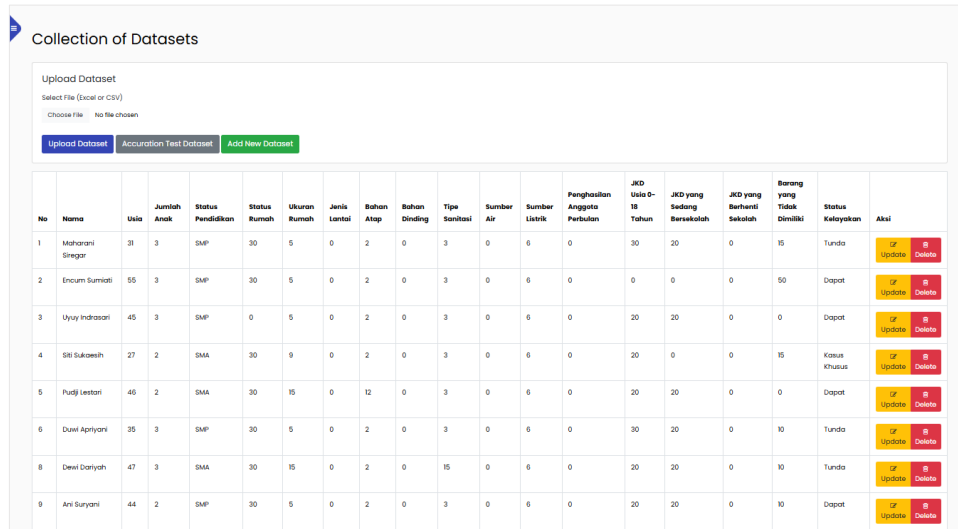
**Gambar 2.** Tampilan Halaman Utama

- Tampilan halaman *dashboard*, pada gambar 3 merupakan tampilan pertama setelah pengguna berhasil *login*. Halaman ini menampilkan beberapa gambar, jumlah *dataset*, dan informasi-informasi lainnya.



**Gambar 3.** Tampilan Halaman *Dashboard*

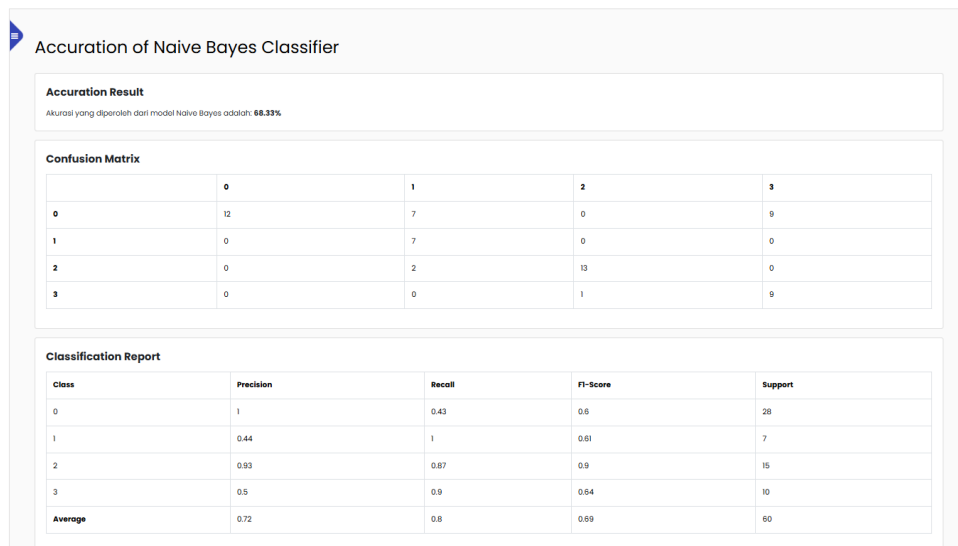
- c. Tampilan menu *dataset*, pada gambar 4 merupakan tampilan *dataset* yang digunakan, tersedia juga tombol untuk mengunggah *dataset*, tombol untuk menguji akurasi, tombol untuk menambah *dataset* baru secara langsung di dalam aplikasi, serta mengubah atau juga menghapus *dataset*.



No	Nama	Usia	Jumlah Anak	Status Pendidikan	Status Rumah	Ukuran Rumah	Jenis Lantai	Bahan Atap	Bahan Dinding	Tipe Sanitasi	Sumber Air	Sumber Listrik	Penghasilan Anggota Perbulan	JKD Usia 0-18 Tahun	JKD yang Sedang Bersekolah	JKD yang Berhenti Sekolah	Barang yang Tidak Dimiliki	Status Kelayakan	Aksi
1	Maharani Sreagar	38	3	SMP	30	5	0	2	0	3	0	6	0	30	20	0	15	Tunda	<a href="#">U</a> <a href="#">D</a>
2	Encum Sumiati	55	3	SMP	30	5	0	2	0	3	0	6	0	0	0	0	50	Dapat	<a href="#">U</a> <a href="#">D</a>
3	Uyuy Indrasari	45	3	SMP	0	5	0	2	0	3	0	6	0	20	20	0	0	Dapat	<a href="#">U</a> <a href="#">D</a>
4	Siti Sukawati	27	2	SMA	30	9	0	2	0	3	0	6	0	20	0	0	15	Kerus Khusus	<a href="#">U</a> <a href="#">D</a>
5	Pudji Lestari	46	2	SMA	30	15	0	12	0	3	0	6	0	20	20	0	0	Dapat	<a href="#">U</a> <a href="#">D</a>
6	Duwi Apriyani	35	3	SMP	30	5	0	2	0	3	0	6	0	30	20	0	10	Tunda	<a href="#">U</a> <a href="#">D</a>
8	Devi Daryyah	47	3	SMA	30	15	0	2	0	15	0	6	0	20	20	0	10	Tunda	<a href="#">U</a> <a href="#">D</a>
9	Ani Suryani	44	2	SMP	30	5	0	2	0	3	0	6	0	20	20	0	10	Dapat	<a href="#">U</a> <a href="#">D</a>

Gambar 4. Tampilan Menu *Dataset*

- d. Tampilan menu *accuracy*, pada gambar 5 merupakan tampilan hasil akurasi dari pengujian model, ditampilkan tabel *confusion matrix* dan tabel *classification report* untuk evaluasi model, serta tabel data pengujian yang dihasilkan dari model yang dibuat.



**Accuracy Result**  
Akurasi yang diperoleh dari model Naive Bayes adalah: **68.33%**

**Confusion Matrix**

	0	1	2	3
0	12	7	0	9
1	0	7	0	0
2	0	2	13	0
3	0	0	1	9

**Classification Report**

Class	Precision	Recall	F1-Score	Support
0	1	0.43	0.6	28
1	0.44	1	0.61	7
2	0.93	0.87	0.9	15
3	0.5	0.9	0.64	10
<b>Average</b>	0.72	0.8	0.69	60

Gambar 5. Tampilan Menu *Accuracy*

- e. Tampilan menu *prediction*, pada gambar 6 merupakan halaman untuk memasukkan data calon anggota peminjam baru dan juga tombol untuk menjalankan prediksi, serta menampilkan hasil prediksi.



Submitted Data	
Field	Submitted Value
Nama Anggota	Muslimah
Usia Anggota	36
Jumlah Anak	3
Status Pendidikan	SMA
Status Rumah	Milik
Ukuran Rumah	30-36m <sup>2</sup>
Jenis Lantai	Keramik
Bahan Atap	Genteng / Asbes / Sang dengan Langit*
Bahan Dinding	Bata dengan Taplok
Tipe Sanitasi	Jangkrik
Sumber Air	Sumur Bor / PAM
Sumber Listrik	Motor Sendiri / Genset
Penghasilan Anggota Perbulan	Lebih dari 1.5 Juta
JKD Usia 0-18 Tahun	1-2
JKD yang Sedang Bersekolah	1-2
JKD yang Berhenti Sekolah	1-2
Barang yang Tidak Dimiliki	Motor

Prediction Result	
<b>Prediction: Dapat</b>	Berdasarkan probabilitas terbesar, anggota tersebut DAPAT mendapatkan pinjaman.

Prediction Probabilities	
<b>Tunda:</b>	27.17%
<b>Dapat:</b>	72.45%
<b>Kasus Khusus:</b>	0%
<b>Tidak:</b>	0.38%

Gambar 6. Tampilan Menu *Prediction*

#### 4. KESIMPULAN

Berdasarkan hasil pengujian yang dilakukan pada penelitian ini, beberapa kesimpulan penting dapat diambil yaitu: model *naïve bayes* yang diterapkan mampu memberikan prediksi yang memadai terhadap data calon anggota penerima kredit yang diberikan. Hasil evaluasi kinerja model mendapatkan tingkat akurasi sebesar 68.33% dari prediksi model adalah benar, ini menunjukkan bahwa model algoritma ini dapat membantu Koperasi Kasih Indonesia dalam menilai kelayakan calon penerima kredit dengan cukup baik, sehingga kredit yang diberikan lebih tepat sasaran. Dengan hasil rata-rata *recall* sebesar 80%, model ini menunjukkan kemampuan yang baik dalam mengidentifikasi calon anggota penerima kredit yang berpotensi gagal membayar, sehingga dapat mengurangi risiko kredit macet. Model *naïve bayes* cepat dalam melakukan prediksi dan menghasilkan matrik evaluasi yang baik, dengan hasil rata-rata *precision* sebesar 72% dan *f1-score* sebesar 69%. Ini berarti bahwa proses penilaian kelayakan kredit dapat dilakukan dengan lebih efisien, menghemat waktu dan sumber daya. Untuk meningkatkan keberlanjutan dan efektivitas implementasi model *naïve bayes* dalam penilaian kelayakan penerima kredit di sektor koperasi, beberapa saran yang dapat dipertimbangkan untuk penelitian di masa depan antara lain: melakukan eksperimen lanjutan dengan mengintegrasikan lebih banyak data dan variabel yang relevan dalam penilaian kelayakan kredit, serta menerapkan teknik penanganan ketidakseimbangan data antar kelas guna meningkatkan efektivitas dan akurasi model.

#### DAFTAR PUSTAKA

- [1] B. Asyari, S. P. A. Alkadri, and P. Y. Utami, "Uji Akurasi Algoritme K-Nearest Neighbor dan Naive Bayes dalam Klasifikasi Kelayakan Pemberian Kredit Perbankan," *Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 12, no. 3, pp. 999-1012, 2023.
- [2] I. Nurjanah, J. Karaman, I. Widaningrum, D. Mustikasari, and Sucipto, "Penggunaan Algoritma Naive Bayes untuk Menentukan Pemberian Kredit pada Koperasi Desa," *Journal of Computer Science and Information Technology*, vol. 3, no. 2, pp. 77-87, 2023.
- [3] M. Rianto, R. Rusdiah, and H. Ichwan, "Penerapan Data Mining dengan Metode Naive Bayes dan Learning Vector Quantization Credit Rating dalam Memprediksi Kelayakan Pemberian Kredit oleh PT. BPR Lebak Sejahtera," *Jurnal Teknologi Informasi*, vol. 17, no. 1, pp. 69-76, 2023.
- [4] B. Prasajo, and E. Haryatmi, "Analisa Prediksi Kelayakan Pemberian Kredit Pinjaman dengan Metode Random Forest," *Jurnal Nasional Teknologi dan Sistem Informasi*, vol. 7, no. 2, pp. 79-89, 2021.

- [5] O. Pahlevi, Amrin, and Y. Handrianto, “Implementasi Algoritma Klasifikasi Random Forest untuk Penilaian Kelayakan Kredit,” *Jurnal Infortech*, vol. 5, no. 1, pp. 71-76, 2023.
- [6] Rosihan, M. Fhadli, and A. A. Hi. Usman, “Klasifikasi Kelayakan Pemberian Kredit Menggunakan Metode Decision Tree dengan Seleksi Fitur (Studi Kasus: PT. Adira Finance Cabang Kota Ternate,” *Jurnal Pendidikan Tambusai*, vol. 7, no. 3, pp. 21517-21524, 2023.
- [7] Betrisandi, R. Sulaehani, and I. C. R. Drajana, “Klasifikasi Nasabah dalam Pengelolaan Resiko Kredit Menggunakan Metode Naive Bayes,” *Jurnal Nasional Komputasi dan Teknologi Informasi*, vol. 6, no. 6, pp. 804-808, 2023.
- [8] S. Sumanto, L. S. Marita, L. Mazia, and T. W. Ratnasari, “Analisa Kelayakan Kredit Rumah Menggunakan Metode Naive Bayes untuk Mengurangi Kredit Macet,” *Jurnal Applied Information Systems and Management*, vol. 4, no. 1, pp. 17-22, 2021.
- [9] A. Triayudi, and Sumiati, “Implementasi Klasifikasi Data Mining untuk Penentuan Kelayakan Pemberian Kredit dengan Menggunakan Algoritma Naive Bayes,” *Jurnal Sistem Komputer dan Informatika*, vol. 4, no. 1, pp. 240-244, 2022.
- [10] E. A. Riyanto, T. Juninisvianty, D. F. Nasution, and Risnandar, “Analisis Kinerja Algoritma CART dan Naive Bayes Berbasis Particle Swarm Optimization (PSO) untuk Klasifikasi Kelayakan Kredit Koperasi,” *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 1, pp. 55-60, 2021.