



# Prediksi Kelayakan Kredit untuk Produk Elektronik dan Furnitur Menggunakan Metode Naive Bayes

Muhammad M.K. Putra <sup>1</sup>, Nurul Anisa Putri <sup>2</sup>, Anton Bayu Nugraha <sup>3</sup>, Dena Hasby <sup>4</sup>

Program Studi Sistem Informasi, Fakultas Teknik & Informatika, Universitas Bina Sarana Informatika

Jl. Cemerlang No.8, Sukakarya, Kec. Warudoyong, Kota Sukabumi 43135

[marifatullah@gmail.com](mailto:marifatullah@gmail.com) <sup>1</sup>, [nurulanisaputri24@gmail.com](mailto:nurulanisaputri24@gmail.com) <sup>2</sup>, [abnugraha66@gmail.com](mailto:abnugraha66@gmail.com) <sup>3</sup>, [hasbydhena07@gmail.com](mailto:hasbydhena07@gmail.com) <sup>4</sup>

**Abstrak**-- Pembelian produk oleh konsumen seringkali mengandalkan kredit sebagai solusi untuk membiayai pembelian, tidak terkecuali untuk produk elektronik dan furnitur. Tidak hanya konsumen yang terlibat dalam penggunaan kredit, tetapi produsen maupun distributor produk elektronik dan furnitur juga mengandalkan fasilitas kredit untuk mendukung penjualan produk. Prediksi kelayakan kredit memiliki dampak langsung pada keputusan pemberi kredit dalam menilai apakah seorang konsumen layak mendapatkan kredit untuk pembelian produk tersebut atau tidak. Dengan melakukan penilaian kelayakan kredit yang tepat, pemberi kredit dapat mengurangi risiko kredit yang terkait dengan penyaluran kredit kepada konsumen yang mungkin memiliki kemampuan pembayaran yang rendah. *Naive bayes* sebagai sebuah analisis menawarkan kemudahan implementasi, efektif dalam mengelola data kategoris, memiliki kemampuan dalam perbandingan probabilitas, akurasi yang baik, memberikan hasil yang mudah diinterpretasikan, serta dapat mengatasi variabel kategori dengan banyak nilai. Penggunaan metode klasifikasi *naive bayes* dalam memprediksi kelayakan pemberian pinjaman terhadap nasabah dalam penelitian ini menghasilkan nilai akurasi data berupa *accuracy* sebesar 90%, *recall* 80%, *precision* 100%. Sedangkan nilai *AUC* yang dihasilkan adalah sebesar 1.000.

**Kata kunci:** elektronik dan furnitur, prediksi kelayakan kredit, naive bayes, risiko kredit

**Abstract** - Consumer product purchases often rely on credit as a solution to finance the acquisition, including for electronic and furniture products. It's not just consumers involved in credit use; manufacturers and distributors of electronic and furniture products also depend on credit facilities to support sales. Predicting credit eligibility directly impacts credit providers' decisions in assessing whether a consumer qualifies for credit to purchase those products or not. Through accurate credit eligibility assessments, credit providers can mitigate credit risks associated with extending credit to consumers who may have lower repayment capabilities. *Naive bayes*, as an analytical method, offers ease of implementation, effectiveness in managing categorical data, the ability to compare probabilities, good accuracy, easily interpretable results, and the capability to handle categorical variables with numerous values. The utilization of naive bayes classification methods in predicting loan eligibility for customers in this study resulted in data accuracy metrics of 90%, recall of 80%, and precision of 100%. Additionally, the *AUC* value produced is 1.000.

**Keywords:** electronics and furniture, credit eligibility prediction, naive bayes, credit risk

## I. PENDAHULUAN

Produk elektronik telah menjadi bagian tidak terpisahkan dalam kehidupan masyarakat, memberikan kemudahan dalam pekerjaan, belajar, dan berkomunikasi, selain itu produk elektronik menyediakan hiburan dan meningkatkan produktivitas [1]. Furnitur memainkan peran penting dalam kehidupan sehari-hari dengan memberikan kenyamanan, mencerminkan selera dan gaya, serta

memengaruhi kualitas hidup masyarakat secara keseluruhan [2].

Pembelian produk oleh konsumen seringkali mengandalkan kredit sebagai solusi untuk membiayai pembelian [3]. Faktor biaya kredit dan tingkat bunga menjadi pertimbangan penting dalam pengambilan kredit [4]. Tidak hanya konsumen yang terlibat dalam penggunaan kredit, tetapi produsen maupun distributor produk elektronik dan furnitur

\* Korepondensi.

Alamat E-mail : [jurnal.larik@bsi.ac.id](mailto:jurnal.larik@bsi.ac.id).

Diterima 30 September 2023; Direvisi 27 Nopember 2023; Diterima 21 Desember 2023

© 2021 Jurnal Larik.

juga mengandalkan fasilitas kredit untuk mendukung penjualan produk [5].

Prediksi kelayakan kredit memiliki dampak langsung pada keputusan pemberi kredit dalam menilai apakah seorang konsumen layak menerima kredit untuk pembelian produk tersebut atau tidak [6]. Dengan melakukan penilaian kelayakan kredit yang tepat, pemberi kredit dapat mengurangi risiko kredit yang terkait dengan penyaluran kredit kepada konsumen yang mungkin memiliki kemampuan pembayaran yang rendah [7].

Algoritma C4.5 merupakan salah satu metode yang digunakan dalam pengambilan keputusan berbasis data dengan menghasilkan pohon keputusan yang mudah dipahami, sangat cocok untuk melakukan klasifikasi, dan secara otomatis memilih variabel yang paling penting dalam pengambilan keputusan [8]. Namun, C4.5 memiliki potensi *overfitting* dan sensitif terhadap kesalahan data, serta terbatas dalam menangani data numerik dan data kategoris dengan banyak nilai [9].

*Naive bayes* sebagai sebuah analisis menawarkan kemudahan implementasi, efektif dalam mengelola data kategoris, memiliki kemampuan dalam perbandingan probabilitas, akurasi yang baik, memberikan hasil yang mudah diinterpretasikan, serta dapat mengatasi variabel kategori dengan banyak nilai [10], meskipun demikian *naive bayes* memiliki kekurangan dalam asumsi sederhana bahwa semua variabel kategori adalah independen yang mungkin tidak selalu sesuai dengan hubungan sebenarnya dalam data [11].

Dengan melihat kelebihan metode algoritma *naive bayes*, maka akan dilakukan prediksi kelayakan kredit pada produk elektronik dan furnitur menggunakan metode tersebut berdasarkan data kredit historis di masa lampau, sehingga dapat digunakan untuk memprediksi kelayakan kredit masa depan. Selain itu dapat membantu pemberi kredit dalam pengambilan keputusan yang lebih informatif dan akurat terkait penyaluran kredit untuk pembelian produk elektronik dan furnitur, sehingga menghindari risiko dan dapat membuat keputusan yang lebih bijak ketika memberikan pinjaman kepada individu yang memiliki kemampuan membayar kredit dengan baik.

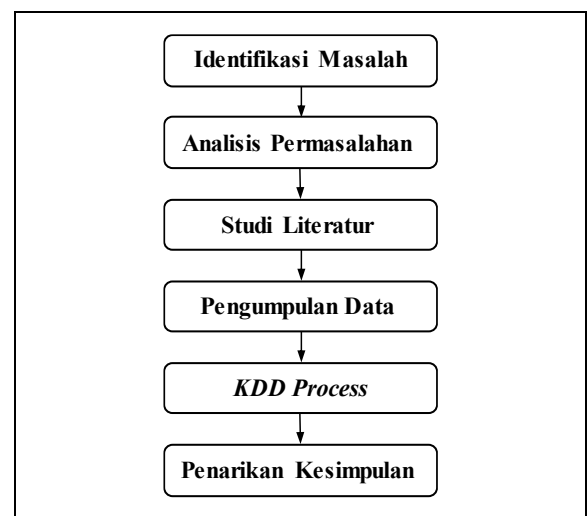
Penelitian oleh Nurjanah [12] dengan kriteria data peminjam: jenis kelamin, umur, pekerjaan, penghasilan, dan *BI Checking* melakukan evaluasi pada sistem klasifikasi kredit dengan menggunakan

metode *black box* mengindikasikan bahwa sistem yang dikembangkan beroperasi sesuai dengan algoritma *naive bayes*, mampu menilai apakah nasabah layak atau tidak layak mendapatkan kredit. Yesputra dalam penelitiannya [13] menggunakan kriteria: pekerjaan, penghasilan, status rumah, jumlah pinjaman, dan jenis pinjaman menghasilkan pengujian akurasi sebesar 90%, *AUC* sebesar 0.880%, *recall* sebesar 83.33%, dan *precision* sebesar 100%. Kriteria data nasabah berupa: jumlah pengajuan kredit, jangka waktu peminjaman, pendapatan, pengeluaran, dan status pinjaman sebelumnya, yang diteliti oleh Habibulloh [14] mendapatkan hasil *good classification* dengan akurasi sebesar 76.76% dengan nilai *AUC* sebesar 0.824 dalam pengujiannya.

Berbeda dengan penelitian-penelitian yang telah ada, penelitian ini dilakukan dengan menggunakan metode *naive bayes* untuk melakukan prediksi kelayakan pemberian kredit tetapi hanya dikhususkan untuk kredit produk elektronik dan furnitur dengan kriteria data peminjam yaitu: karakter, pendidikan, penghasilan, kepemilikan rumah, jumlah, tanggungan, dan jangka waktu peminjaman (*tenor*).

## II. METODE PENELITIAN

Dalam penelitian ini terdapat kerangka kerja yang merupakan gambaran dari langkah-langkah yang harus di jalani agar penelitian dapat berjalan dengan baik. Kerangka kerja penelitian ini dapat dilihat pada gambar 1.



Gambar 1. Kerangka Kerja Penelitian

### A. Identifikasi Masalah

Tahapan awal dalam penelitian ini menentukan permasalahan dan batasan yang akan diteliti, sehingga penelitian memiliki arah yang jelas.

### B. Analisis Permasalahan

Pada tahap ini, analisis dilakukan untuk memahami permasalahan dan batasan yang telah ditentukan. Dengan menganalisis permasalahan yang telah ditentukan, maka memahami masalah tersebut akan menjadi lebih mudah.

### C. Studi Literatur

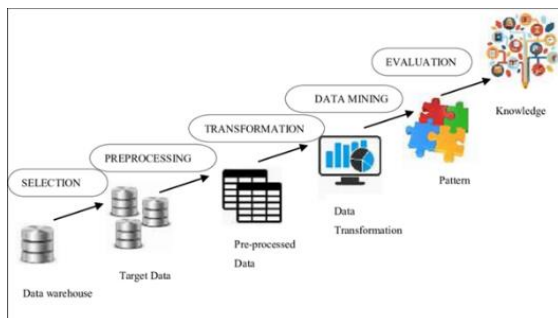
Studi literatur diperlukan sebagai sumber bahan untuk memperkuat dasar penelitian. Referensi diambil dari berbagai sumber, termasuk artikel, jurnal, dan referensi lainnya mendukung kelengkapan penelitian ini.

### D. Pengumpulan Data

Dalam mengumpulkan data dan informasi, peneliti menggunakan data yang terkait dengan data kredit untuk pembelian produk elektronik dan furnitur.

### E. KDD Process

*KDD (Knowledge Discovery in Databases) Process* adalah suatu proses sistematis untuk mengekstraksi pengetahuan yang bermanfaat dan dapat diinterpretasikan dari data yang besar dan kompleks. *KDD process* terdiri atas: *data selection*, *pre-processing/cleaning data*, *transformation*, *data mining*, dan *intepretation/ evaluation* [15] yang diperlihatkan pada gambar 2.



Gambar 2. Knowledge Discovery in Database Process

Tahap awal dalam *KDD Pocess* adalah melakukan seleksi data (*data selection*) dengan memilih informasi yang paling relevan dan penting dari *dataset* untuk analisis lebih lanjut. Hal ini membantu mengoptimalkan kinerja algoritma, meningkatkan akurasi hasil, dan memastikan bahwa

data yang digunakan sesuai dengan tujuan penelitian, sehingga memudahkan dalam menemukan pola atau pengetahuan yang berharga.

Tahap kedua adalah *pre-processing/cleaning data* yaitu membersihkan atau mempersiapkan data untuk analisis dengan cara mengidentifikasi dan menangani masalah-masalah seperti data yang hilang, nilai yang tidak *valid*, atau *outlier*. Proses pembersihan data memastikan bahwa data yang digunakan untuk analisis lebih akurat dan dapat diandalkan.

Tahap ketiga adalah *transformation*, yaitu proses mengubah atau menyesuaikan format, struktur, atau nilai data agar lebih sesuai dengan kebutuhan analisis. Transformasi data membantu dalam mempersiapkan *dataset* agar dapat diolah dengan efektif oleh algoritma data mining, sehingga memudahkan dalam menemukan pola atau pengetahuan yang berguna.

Tahap keempat adalah *data mining*, dimana pada tahap ini melibatkan berbagai teknik untuk mengekstrak pola-pola potensial yang dapat menghasilkan informasi berharga dari data. Hal ini merupakan upaya mencari pola atau informasi menarik dalam data terpilih dengan menggunakan teknik atau metode khusus. Variasi teknik, metode, atau algoritma dalam data mining sangat beragam. Pemilihan metode atau algoritma yang tepat sangat tergantung pada tujuan dan keseluruhan proses data mining.

Tahap kelima adalah *intepretation/evaluation* yang merupakan tahap menganalisis hasil-hasil yang ditemukan dari proses pengeksploasian data. Proses ini membantu dalam menilai seberapa baik model atau pola yang telah ditemukan sesuai dengan tujuan awal, dan memberikan wawasan yang diperlukan untuk membuat keputusan atau rekomendasi yang tepat.

Dalam penelitian ini, untuk tahap pertama (*data selection*) dan tahap kedua (*cleaning data*), dipergunakan bantuan aplikasi *microsoft excel* untuk mempermudah proses pengerjaannya. *Microsoft excel* merupakan perangkat lunak yang berfungsi untuk mengelola data dalam skala besar, menyediakan fitur-fitur seperti perhitungan matematika, visualisasi data melalui grafik atau bagan, serta pembuatan tabel [16].

Mulai dari tahap ketiga sampai tahap akhir (*transformation*, *data mining*, dan *intepretation/evaluation*) digunakan aplikasi *rapidminer* untuk

mempermudah proses pengerjaan dalam tahap-tahap penelitian ini. *Rapidminer* merupakan sebuah perangkat lunak yang efisien dalam penggunaannya untuk pengolahan data maupun *machine learning* dengan dilengkapi berbagai alat yang mendukung persiapan data, proses pemodelan, evaluasi, dan penerapan, sehingga dapat dengan mudah membuat dan menguji berbagai model tanpa memerlukan kemampuan dalam pemrograman [17].

Metode data mining yang digunakan adalah *naive bayes*, yaitu metode klasifikasi yang diperkenalkan oleh ilmuwan Inggris Thomas Bayes dengan mengadopsi prinsip probabilitas dan statistik. Algoritma *naive bayes* memproyeksikan probabilitas kejadian di masa depan dengan menganalisis pada pengalaman di masa sebelumnya, sehingga sering disebut sebagai *Teorema Bayes* [18]. Karakteristik utama dari Naive Bayes adalah adanya asumsi yang sangat kuat (*naif*) mengenai independensi antara kondisi atau kejadian yang berbeda [19].

#### F. Penarikan Kesimpulan

Penarikan kesimpulan merupakan tahap terakhir penelitian ini, di mana peneliti merumuskan kesimpulan-kesimpulan kunci berdasarkan temuan atau hasil penelitian. Proses ini melibatkan analisis mendalam terhadap data, interpretasi temuan, dan penerapan pengetahuan yang diperoleh untuk menjawab pertanyaan penelitian atau mencapai tujuan penelitian.

### III. HASIL DAN PEMBAHASAN

Berdasarkan pengumpulan data yang diperoleh dari sumber terkait, maka diperoleh kriteria-kriteria peminjam dengan 6 atribut prediktor dan 1 atribut *class* untuk prediksi kelayakan pengajuan kredit elektronik dan furnitur. Atribut data yang telah dikelompokkan dapat dilihat pada tabel 1.

Tabel 1. Atribut Data Penelitian

Atribut	Tipe	Value
Karakter konsumen	Polinomial	Baik, cukup, kurang
Pendidikan	Polinomial	SMA, D3, S1
Penghasilan	Numerik	Numerik
Kepemilikan rumah	Binomial	Milik keluarga, kontrak
Jumlah tanggungan	Polinomial	1, 2, 3
Tenor	Polinomial	12 bln, 15 bln, 18 bln
Status	Label	Layak, tidak layak

Pada seleksi data dan pembersihan selesai dilakukan, maka didapatkan 40 data nasabah yang layak untuk diolah menggunakan metode *naive bayes* untuk memprediksi kelayakan kredit produk elektronik dan furnitur dengan data *training* sejumlah 30 data (tabel 2) dan data *testing* sejumlah 10 data (tabel 3).

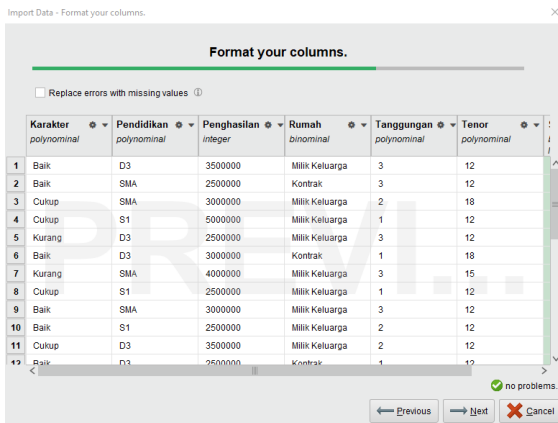
Tabel 2. Data Training

No	Karakter	Pendidikan	Penghasilan	Rumah	Tanggungan	Tenor	Status
1	Baik	D3	3,500,000	Milik Keluarga	3	12	Layak
2	Baik	SMA	2,500,000	Kontrak	3	12	Tidak Layak
3	Cukup	SMA	3,000,000	Milik Keluarga	2	18	Layak
4	Cukup	S1	5,000,000	Milik Keluarga	1	12	Layak
5	Kurang	D3	2,500,000	Milik Keluarga	3	12	Tidak Layak
6	Baik	D3	3,000,000	Kontrak	1	18	Layak
7	Kurang	SMA	4,000,000	Milik Keluarga	3	15	Tidak Layak
8	Cukup	S1	2,500,000	Milik Keluarga	1	12	Layak
9	Baik	SMA	3,000,000	Milik Keluarga	3	12	Tidak Layak
10	Baik	S1	2,500,000	Milik Keluarga	2	12	Layak
11	Cukup	D3	3,500,000	Milik Keluarga	2	12	Layak
12	Baik	D3	2,500,000	Kontrak	1	12	Layak
13	Kurang	S1	4,000,000	Milik Keluarga	3	15	Tidak Layak
14	Baik	SMA	2,500,000	Kontrak	3	12	Tidak Layak
15	Kurang	SMA	2,500,000	Milik Keluarga	1	18	Layak
16	Cukup	SMA	3,500,000	Kontrak	2	18	Layak
17	Cukup	D3	4,000,000	Kontrak	1	15	Layak
18	Baik	SMA	3,500,000	Milik Keluarga	3	12	Tidak Layak
19	Baik	S1	4,000,000	Milik Keluarga	2	12	Layak
20	Cukup	SMA	3,500,000	Milik Keluarga	2	18	Layak
21	Baik	SMA	3,500,000	Kontrak	1	12	Layak
22	Cukup	D3	2,500,000	Milik Keluarga	3	12	Tidak Layak
23	Cukup	SMA	2,500,000	Milik Keluarga	2	15	Tidak Layak
24	Baik	SMA	3,000,000	Milik Keluarga	1	18	Layak
25	Baik	SMA	3,500,000	Milik Keluarga	2	15	Layak
26	Cukup	D3	3,500,000	Milik Keluarga	2	12	Layak
27	Cukup	SMA	3,000,000	Kontrak	3	12	Tidak Layak
28	Cukup	D3	2,500,000	Milik Keluarga	1	12	Layak
29	Baik	SMA	2,500,000	Kontrak	2	15	Tidak Layak
30	Cukup	D3	3,500,000	Milik Keluarga	2	15	Layak

Tabel 3. Data Testing

No	Karakter	Pendidikan	Penghasilan	Rumah	Tanggungan	Tenor	Status
1	Baik	SMA	3,500,000	Milik Keluarga	1	12	Layak
2	Baik	SMA	3,500,000	Kontrak	1	12	Layak
3	Kurang	SMA	3,500,000	Milik Keluarga	2	15	Tidak Layak
4	Cukup	SMA	3,000,000	Milik Keluarga	3	15	Tidak Layak
5	Kurang	S1	5,000,000	Kontrak	2	12	Layak
6	Kurang	SMA	3,000,000	Milik Keluarga	2	12	Tidak Layak
7	Cukup	S1	3,500,000	Kontrak	2	18	Layak
8	Kurang	S1	2,500,000	Milik Keluarga	1	15	Layak
9	Kurang	SMA	3,000,000	Kontrak	2	12	Tidak Layak
10	Baik	SMA	2,500,000	Milik Keluarga	2	12	Tidak Layak

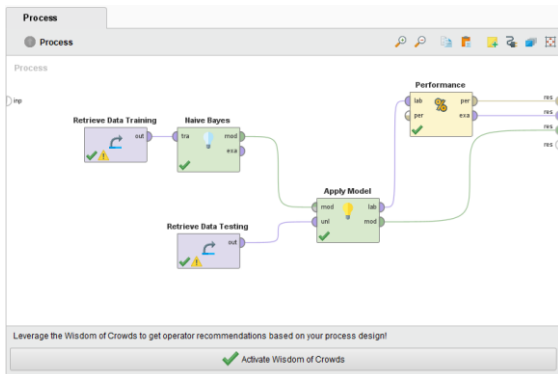
Dari tabel 2 dan tabel 3 yang telah dibuat menggunakan *microsoft excel*, maka perlu dilakukan tranformasi data, yaitu dengan cara memberikan inisialiasi terhadap data yang memiliki nilai akan disesuaikan tipe data yang dibutuhkan pada *naive bayes*. Tipe data yang dibutuhkan adalah *binomial*, *polynomial*, dan *integer*. Transformasi data yang dilakukan dengan menggunakan aplikasi *rapidminer* dapat dilihat pada gambar 3.



Gambar 3. Transformasi Data Menggunakan Rapidminer

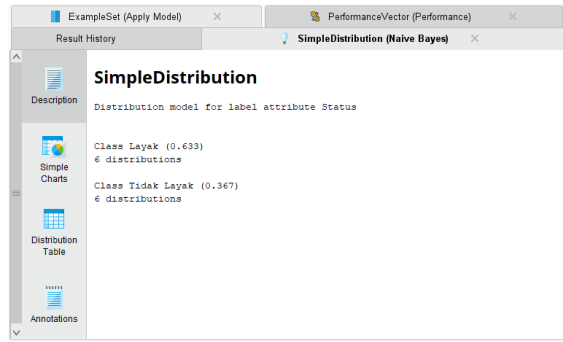
Pada tahap ini transformasi data selesai dilakukan, maka dataset sudah siap diolah menggunakan data mining.

Model data mining dengan menggunakan algoritma naive bayes dalam melakukan prediksi memanfaatkan aplikasi rapidminer diperlukan proses-proses: *Retrieve Data Kredit Training, Naive Bayes, Retrieve Data Kredit Testing, Apply Model, dan Performance*. Tampilan pemrosesan dengan menggunakan rapidminer dapat dilihat pada gambar 4.



Gambar 4. Metode Naive Bayes Menggunakan Rapidminer

Dalam penelitian ini, ditentukan dua class yaitu class layak dan tidak layak. Dengan pemrosesan rapidminer maka dihasilkan pola pengetahuan dengan menggunakan data training, maka terdapat 19 record data dengan status layak dari 30 data yang digunakan sebagai data training sehingga nilai probabilitasnya adalah 0.633 dan 11 record data dengan status tidak layak dari 30 data sehingga nilai probabilitasnya adalah 0.367 seperti yang ditunjukkan oleh gambar 5.



Gambar 5. Nilai Probabilitas Atribut Class

Terdapat 6 atribut yang digunakan dalam penelitian ini, dan perhitungan dengan rapidminer didapatkan probabilitas masing-masing atribut prediktor dapat dilihat pada gambar 6.

Attribute	Parameter	Layak	Tidak Layak
Karakter	value=Baik	0.420	0.452
Karakter	value=Cukup	0.524	0.272
Karakter	value=Kurang	0.054	0.272
Karakter	value=unknown	0.002	0.003
Pendidikan	value=D3	0.420	0.183
Pendidikan	value=SMA	0.368	0.722
Pendidikan	value=S1	0.211	0.093
Pendidikan	value=unknown	0.002	0.003
Penghasilan	mean	3289473.684	2954545.455
Penghasilan	standard deviation	652256.542	619513.941
Rumah	value=Milik Keluarga	0.735	0.634
Rumah	value=Kontrak	0.264	0.363
Rumah	value=unknown	0.002	0.003
Tanggungan	value=3	0.054	0.811
Tanggungan	value=2	0.472	0.183
Tanggungan	value=1	0.472	0.003

Gambar 6. Nilai Probabilitas Atribut Predictor

Penentuan data testing termasuk kedalam class yang mana dilakukan dengan melihat nilai probabilitas yang tinggi. Untuk memperoleh hasil prediksi secara keseluruhan pada data testing dilakukan dengan mengimplementasikan rapidminer dengan jumlah data testing (tabel 3) sebanyak 10 data, dan hasilnya dapat dilihat pada gambar 7.

Row No.	Status	prediction(S...	confidence(...	confidence(...	Karakter	Pendidikan
1	Layak	Layak	0.994	0.006	Baik	SMA
2	Layak	Layak	0.990	0.010	Baik	SMA
3	Tidak Layak	Tidak Layak	0.233	0.767	Kurang	SMA
4	Tidak Layak	Tidak Layak	0.046	0.954	Cukup	SMA
5	Layak	Layak	0.909	0.091	Kurang	S1
6	Tidak Layak	Tidak Layak	0.270	0.730	Kurang	SMA
7	Layak	Layak	0.999	0.001	Cukup	S1
8	Layak	Layak	0.974	0.026	Kurang	S1
9	Tidak Layak	Tidak Layak	0.188	0.812	Kurang	SMA
10	Tidak Layak	Layak	0.547	0.453	Baik	SMA

Gambar 7. Hasil Prediksi Pada Data Testing

Dengan melihat gambar 6 yang merupakan hasil prediksi terhadap 10 data testing, terdapat satu prediksi yang tidak sesuai dengan pola yang dibuat

menggunakan *naive bayes*, yaitu pada baris ke-3 dengan status (*class*) tidak layak, tetapi prediksinya dimasukkan ke dalam status (*class*) layak.

Pengujian akurasi pada algoritma *naive bayes*, dilakukan menggunakan *performance confusion matrix* untuk mengukur kinerja pada metode tersebut. *Confusion matrix* menghitung nilai *accuracy*, *recall*, dan *precision*. Semakin tinggi nilai *accuracy* maka semakin baik pula kinerjanya.

Terdapat 2 *class* klasifikasi yaitu *class* layak dan *class* tidak layak. *Confusion matrix* hasil dari pengujian metode *naive bayes* untuk memprediksi kelayakan kredit dapat dilihat pada gambar 8.

	true Layak	true Tidak Layak
pred. Layak	5	1
pred. Tidak Layak	0	4

Gambar 8. Confusion Matrix

Dari 10 data testing yang ada, terdapat 5 orang yang dinyatakan layak dengan prediksi layak (*True Positive = TP*), terdapat 4 orang yang dinyatakan tidak layak dengan prediksi tidak layak (*True Negative = TN*), terdapat 1 orang yang dinyatakan tidak layak tetapi diprediksi layak (*False Negative = FN*) dan tidak ada yang dinyatakan layak tetapi diprediksi tidak layak (*False Positive = FP*). Metrik evaluasi yang umum digunakan dalam *confusion matrix* adalah *accuracy*, *precision*, dan *recall*.

*Accuracy* adalah kemampuan model untuk mengukur seberapa tepat model dalam mengklasifikasikan data secara keseluruhan. Semakin tinggi nilai *accuracy*, maka semakin baik kemampuan model untuk mengklasifikasikan data dengan benar. *Accuracy* dirumuskan dengan :

$$Accuracy = (TP + TN) / (TP + FP + TN + FN)$$

Perhitungan *accuracy* hasil prediksi dengan menggunakan *rapidminer* dapat dilihat pada gambar 9, yaitu mendapatkan nilai sebesar 90%.

accuracy: 90.00%

	true Layak	true Tidak Layak
pred. Layak	5	1
pred. Tidak Layak	0	4

Gambar 9. Hasil Perhitungan Accuracy Hasil Prediksi

*Precision* adalah kemampuan model untuk mengukur seberapa banyak data yang benar-benar

terklasifikasikan dengan benar. *Precision* dirumuskan dengan :

$$Precision = TP / (TP + FP)$$

Perhitungan *precision* hasil prediksi dengan menggunakan *rapidminer* dapat dilihat pada gambar 10, yaitu mendapatkan nilai sebesar 100%.

precision: 100.00% (positive class: Tidak Layak)

	true Layak	true Tidak Layak
pred. Layak	5	1
pred. Tidak Layak	0	4

Gambar 10. Hasil Perhitungan Precision Hasil Prediksi

*Recall* adalah kemampuan model untuk mengukur seberapa banyak data yang terklasifikasikan dengan benar dari total data yang sebenarnya. *Recall* dirumuskan dengan :

$$Recall = TP / (TP + FN)$$


Perhitungan *recall* hasil prediksi dengan menggunakan *rapidminer* dapat dilihat pada gambar 11, yaitu mendapatkan nilai sebesar 80%.

recall: 80.00% (positive class: Tidak Layak)

	true Layak	true Tidak Layak
pred. Layak	5	1
pred. Tidak Layak	0	4

Gambar 11. Hasil Perhitungan Recall Hasil Prediksi

Untuk memvisualisasikan data confusion matrix maka perlu digunakan Kurva Receiver Operating Characteristic (*ROC*). Garis horizontal mewakili nilai *false positives (FP)* dan garis vertikal mewakili nilai *true positives (TP)*. Dari gambar 12 dapat diketahui bahwa nilai *Area Under Curve (AUC)* model algoritma *naive bayes* yang digunakan adalah 1.000, hal ini menunjukkan bahwa model algoritma *naive bayes* mencapai klasifikasi sempurna.



Gambar 12. Hasil AUC Performance Vector

#### IV. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian yang telah dilakukan penggunaan klasifikasi *naive bayes* untuk memprediksi kelayakan pemberian kredit elektronik dan furnitur, maka dapat disimpulkan bahwa prediksi kelayakan pemberian pinjaman dapat dilakukan dengan mempertimbangkan *dataset* nasabah di masa lalu menggunakan algoritma klasifikasi yaitu *naive bayes*.

Algoritma klasifikasi *naive bayes* dapat diterapkan untuk membantu dalam memprediksi kelayakan pemberian pinjaman terhadap nasabah, dimana dalam penelitian ini menghasilkan nilai akurasi data berupa *accuracy* sebesar 90%, *recall* 80%, *precision* 100%. Sedangkan nilai *AUC* yang dihasilkan adalah sebesar 1.000.

Untuk pengembangan lebih lanjut, disarankan untuk menggunakan algoritma yang berbeda sebagai pembanding, untuk mengetahui metode tersebut dengan tingkat keakuratan optimal sesuai dengan kebutuhan.

#### V. REFERENSI

- [1] R. B. Trianto, A. Triyono, and D. M. P. Arum, "Klasifikasi Rating Otomatis pada Dokumen Teks Ulasan Produk Elektronik Menggunakan Metode N-gram dan Naive Bayes," *Jurnal Informatika Universitas Pamulang*, vol. 5, no. 3, p. 295, 2020.
- [2] A. Izza and D. Retnowati, "Analisis Kualitas Produk Furniture Dengan Pendekatan Metode Six Sigma," *Jurnal Heuristic*, pp. 59–72, 2021.
- [3] R. P. Juliansyah and R. Rachman, "Tinjauan Prosedur Pemberian Pinjaman Dana Pada PT. FIF Group Cabang Bogor 3 Kabupaten Bogor," *Jurnal Aplikasi Bisnis Kesatuan*, vol. 2, no. 1, pp. 19–30, 2022.
- [4] N. N. Padang, "Faktor-faktor yang Mempengaruhi Tingkat Pemberian Suku Bunga Kepada Nasabah dan Debitur pada PT. Bank X di Medan," *Jurnal Riset Akuntansi & Keuangan*, pp. 110–118, 2022.
- [5] N. Putri, "Analisis Audit Sistem Pembelian Kredit pada Toko Elektronik," *Jurnal Ekonomi dan Bisnis*, vol. 15, no. 2, pp. 32–39, 2023.
- [6] T. T. Muryono and I. Irwansyah, "Implementasi Data Mining Untuk Menentukan Kelayakan Pemberian Kredit Dengan Menggunakan Algoritma K-Nearest Neighbors (K-Nn)," *Infotech: Journal of Technology Information*, vol. 6, no. 1, pp. 43–48, 2020.
- [7] S. Nurdin, "Penerapan Prinsip 5C Upaya Memperkecil Resiko Kredit Macet terhadap Penyaluran Kredit pada PT Bankaltimara Unit Samarinda," *Jurnal EKSIS*, vol. 19, no. 01, pp. 44–56, 2023.
- [8] D. David, "Analisis Kelayakan Menerima Pinjaman Kredit Dengan Algoritma C4.5 Pada PT BPR Buana Arta Mulia," *UPB Repository*, Jan. 2022, Accessed: Nov. 10, 2023. [Online]. Available: <http://repository.upbatam.ac.id/1480/>
- [9] A. Setianingrum, A. Hindayanti, D. M. Cahya, and D. S. Purnia, "Perbandingan Metode Algoritma K-NN & Metode Algoritma C45 Pada Analisa Kredit Macet (Studi Kasus PT Tunggung Textil Bintan)," *EVOLUSI: Jurnal Sains Dan Manajemen*, vol. 9, no. 2, 2021.
- [10] D. Librado and A. H. Nasyuha, "Penerapan Data Mining Untuk Klasifikasi Penerima Kredit Dengan Perbandingan Algoritma Naive Bayes dan Algoritma C4. 5," *JURNAL MEDIA INFORMATIKA BUDIDARMA*, vol. 7, no. 4, pp. 1952–1961, 2023.
- [11] M. K. Tamami and I. Kharisudin, "Komparasi Metode Support Vector Machine dan Naive Bayes Classifier untuk Pemodelan Kualitas Pengajuan Kredit," *Indonesian Journal of Mathematics and Natural Sciences*, vol. 46, no. 1, pp. 38–44, 2023.
- [12] I. Nurjanah, J. Karaman, I. Widaningrum, D. Mustikasari, and S. Sucipto, "Penggunaan Algoritma Naive Bayes Untuk Menentukan Pemberian Kredit Pada Koperasi Desa," *Explorer (Hayward)*, vol. 3, no. 2, pp. 77–87, 2023.
- [13] R. Yesputra and A. Sapta, "Prediksi Kelancaran Pembayaran Angsuran Pada Koperasi Dengan Metode Naive Bayes Classifier," *Indonesian Journal of Computer Science*, vol. 11, no. 2, 2022.
- [14] W. Habibulloh and S. Topiq, "Klasifikasi Kelayakan Kredit Menggunakan Algoritma Naive Bayes Pada Ksp Mekar Jaya Maleber," *Jurnal Responsif: Riset Sains dan Informatika*, vol. 3, no. 1, pp. 92–99, 2021.
- [15] A. Tahta, I. Karim, and S. Sudioanto, "Dominant Requirements for Student Graduation in the Faculty of Informatics using the C4.5 Algorithm," *Journal of Dinda Data Science, Information Technology, and Data Analytics*, vol. 3, no. 2, pp. 50–58, 2023, [Online]. Available: <http://journal.itelkom-pwt.ac.id/index.php/dinda>
- [16] F. F. Addini and D. Haryanto, "Pelatihan Microsoft Excel Untuk Remaja Di Desa Segara Makmur," *Jurnal Pengabdian Masyarakat Multidisiplin*, vol. 6, no. 3, pp. 307–314, Jul. 2023, doi: 10.36341/jpm.v6i3.3310.
- [17] M. R. Nahjan, N. Heryana, and A. Voutama, "Implementasi Rapidminer Dengan Metode Clustering K-Means Untuk Analisa Penjualan Pada Toko Oj Cell," *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 7, no. 1, pp. 101–104, 2023.
- [18] H. H. Sucinta and T. Setiadi, "Penerapan Algoritma Holt-Winters Exponential Smoothing Untuk Estimasi Dan Naive Bayes Untuk Klasifikasi Produksi Kelapa Sawit," *Kesatria: Jurnal Penerapan Sistem Informatika (Komputer dan Manajemen)*, vol. 4, no. 4, pp. 1158–1170, 2023.
- [19] E. E. Pramana and A. Saifudin, "Implementasi Data Mining Untuk Diagnosa Prediksi Penyakit Tuberculosis Dengan Menggunakan Algoritma Naive Bayes," *BINER: Jurnal Ilmu Komputer, Teknik dan Multimedia*, vol. 1, no. 3, pp. 745–759, 2023.