

Klasifikasi Penentuan Pengajuan Kartu Kredit Nasabah Pada Bank Mandiri Dengan Metode *Naive Bayes*

Miftah Fadhli As'ad^{1*}, Lut Faizal², A. Fajar Maulana Natsir³, Asrul Paelori Ahmad⁴
 Sistem dan Teknologi Informasi, Universitas Muhammadiyah Sinjai, Sinjai, Indonesia
 *e-mail *Corresponding Author*: Miftah.fadhli19@gmail.com

Abstract

The selection process for credit card applications is a challenge for banks because it still relies heavily on manual evaluation which is prone to subjectivity and inefficiency. This research aims to develop a classification system for credit card applications using the Naive Bayes method to increase accuracy and efficiency in the customer selection process. This method classifies customers based on main parameters such as income, credit history, number of dependents, employment status, and home ownership status. The developed model was tested using a dataset consisting of 166 training data and 20 test data, resulting in 85% accuracy, 86.67% recall and 93% precision. These results indicate that the Naive Bayes method can be an effective solution in helping banks automate the credit card application evaluation process with a high level of accuracy.

Keywords: *Credit Card; Naive Bayes; Classification*

Abstrak

Proses seleksi pengajuan kartu kredit merupakan tantangan bagi perbankan karena masih banyak bergantung pada evaluasi manual yang rentan terhadap subjektivitas dan ketidakefisienan. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi pengajuan kartu kredit dengan metode *Naive Bayes* guna meningkatkan akurasi dan efisiensi dalam proses seleksi nasabah. Metode ini mengklasifikasikan nasabah berdasarkan parameter utama seperti pendapatan, riwayat kredit, jumlah tanggungan, status pekerjaan, dan status kepemilikan rumah. Model yang dikembangkan diuji menggunakan dataset yang terdiri dari 166 data latih dan 20 data uji, menghasilkan akurasi 85%, recall 86,67%, dan *precision* 93%. Hasil ini menunjukkan bahwa metode *Naive Bayes* dapat menjadi solusi yang efektif dalam membantu bank mengotomatisasi proses evaluasi pengajuan kartu kredit dengan tingkat akurasi yang tinggi.

Kata kunci: *Kartu Kredit; Naive bayes; Klasifikasi*

1. Pendahuluan

Dalam dunia perbankan, klasifikasi pengajuan kartu kredit menjadi hal yang sangat penting untuk mengurangi risiko kredit macet dan memastikan stabilitas keuangan lembaga keuangan. Bank sebagai penyedia layanan kartu kredit harus mampu mengelola proses seleksi nasabah secara efisien dan akurat. Dengan meningkatnya jumlah pengajuan kartu kredit, bank membutuhkan sistem yang lebih cerdas dan otomatis dalam menilai kelayakan nasabah guna mempercepat proses pengambilan keputusan serta menghindari risiko kesalahan manusiawi[1].

Saat ini, proses penentuan kelayakan pengajuan kartu kredit di Bank Mandiri masih banyak mengandalkan evaluasi manual dan sistem berbasis aturan konvensional. Pendekatan ini sering kali menghadapi tantangan, seperti ketidakakuratan dalam menilai kemampuan finansial nasabah, subjektivitas dalam pengambilan keputusan, serta waktu pemrosesan yang lama. Idealnya, keputusan pengajuan kartu kredit harus dilakukan secara objektif berdasarkan data historis dan indikator keuangan yang jelas. Namun, kesenjangan antara sistem evaluasi manual dengan kebutuhan akan kecepatan dan akurasi menimbulkan permasalahan yang harus segera diselesaikan. Proses ini bertujuan untuk meminimalkan risiko kredit macet dan memastikan bahwa fasilitas kredit diberikan kepada individu yang memenuhi syarat.

Metode *Naive Bayes* dapat diterapkan untuk mengklasifikasikan kelayakan pengajuan kartu kredit secara lebih sistematis dan berbasis data. *Naive Bayes* merupakan metode klasifikasi probabilistik yang dapat memprediksi kemungkinan persetujuan pengajuan kartu kredit berdasarkan variabel-variabel seperti pendapatan, riwayat kredit, dan faktor lainnya [2]. Metode ini terbukti memiliki kinerja yang baik dalam analisis data berskala besar serta dapat diterapkan dengan efisien dalam sistem perbankan untuk meningkatkan akurasi keputusan kredit.

Penelitian ini bertujuan untuk mengimplementasikan metode *Naive Bayes* dalam klasifikasi pengajuan kartu kredit di Bank Mandiri. Manfaat dari penelitian ini antara lain adalah meningkatkan efisiensi proses persetujuan kredit, mengurangi kesalahan keputusan berbasis subjektivitas, serta memberikan sistem yang lebih akurat dalam menilai kelayakan nasabah. Dengan penerapan metode ini, diharapkan proses seleksi kartu kredit menjadi lebih cepat dan transparan bagi kedua belah pihak, baik bank maupun nasabah.

2. Tinjauan Pustaka

Kartu kredit telah menjadi instrumen keuangan yang penting dalam transaksi modern, memungkinkan konsumen melakukan pembelian dengan fleksibilitas pembayaran. Namun, bagi bank seperti Bank Mandiri, proses penentuan kelayakan pengajuan kartu kredit oleh nasabah merupakan tantangan tersendiri. Analisis yang akurat diperlukan untuk menilai risiko dan memastikan bahwa fasilitas kredit diberikan kepada individu yang memenuhi syarat.

Beberapa penelitian sebelumnya telah dilakukan untuk mengembangkan sistem klasifikasi dalam pengajuan kartu kredit dan bidang keuangan lainnya. Misalnya, penelitian yang dilakukan oleh [2] mengkaji penggunaan metode statistik dalam klasifikasi risiko kredit. Dalam penelitian ini, mereka menggunakan regresi logistik dan *decision tree* untuk menilai kelayakan nasabah berdasarkan riwayat kredit, pendapatan, dan status pekerjaan. Hasil penelitian menunjukkan bahwa pendekatan berbasis model prediktif lebih akurat dibandingkan dengan sistem berbasis aturan manual.

Penelitian lain mengeksplorasi penggunaan *machine learning* dalam analisis kredit perbankan. Mereka mengembangkan model klasifikasi menggunakan *Support Vector Machine* (SVM) dan *Random Forest* untuk menentukan kelayakan kredit [3]. Variabel utama yang digunakan dalam penelitian ini mencakup riwayat pembayaran, total hutang, dan rasio pendapatan terhadap hutang. Hasilnya menunjukkan bahwa model berbasis *machine learning* mampu meningkatkan akurasi prediksi dibandingkan metode konvensional.

Sementara itu penelitian yang lain terkait klasifikasi kelayakan kredit dengan membandingkan berbagai algoritma *machine learning*, termasuk *Naive Bayes*, *Neural Networks*, dan *Decision Tree*. Mereka menemukan bahwa *Naive Bayes* memiliki keunggulan dalam efisiensi komputasi serta tetap mempertahankan tingkat akurasi yang tinggi, terutama dalam dataset dengan variabel kategori yang kompleks[4].

Selanjutnya, penelitian membahas penerapan metode data mining dalam evaluasi aplikasi kartu kredit. Mereka menggunakan teknik *clustering* dan klasifikasi untuk mengidentifikasi pola nasabah yang memiliki risiko kredit tinggi. Dengan menggunakan dataset dari institusi perbankan, mereka membuktikan bahwa kombinasi antara metode *supervised* dan *unsupervised learning* dapat meningkatkan kemampuan prediksi dalam sistem evaluasi kredit [5].

Penelitian terbaru mengusulkan pengembangan model *hybrid* yang menggabungkan *Naive Bayes* dengan *deep learning* untuk meningkatkan akurasi dalam klasifikasi kredit. Model ini memanfaatkan teknik *feature extraction* dari *deep learning* untuk memperbaiki representasi data sebelum digunakan dalam klasifikasi *Naive Bayes*. Hasil eksperimen menunjukkan bahwa kombinasi metode ini mampu memberikan performa lebih baik dalam mendeteksi pengajuan kartu kredit yang berisiko tinggi [6].

Secara keseluruhan, penelitian saat ini berfokus pada penggabungan metode klasik seperti *Naive Bayes* dengan pendekatan yang lebih canggih seperti *deep learning* dan *ensemble learning* guna meningkatkan akurasi prediksi dalam klasifikasi pengajuan kartu kredit. Peningkatan ini mencakup optimalisasi dalam seleksi fitur, pemrosesan data yang lebih baik, serta pengembangan model yang lebih adaptif terhadap variasi pola pengajuan kredit. Oleh karena itu, penelitian ini akan berkontribusi dalam memperkaya metode klasifikasi dengan pendekatan *Naive Bayes* yang lebih efisien dan dapat diterapkan dalam sistem perbankan modern.

3. Metodologi

3.1 Algoritma *Naïve Bayes Classifier*

Metode *Naive Bayes* diterapkan untuk membangun model klasifikasi pengajuan kartu kredit berdasarkan data nasabah. Algoritma ini bekerja dengan menghitung probabilitas bersyarat antara atribut nasabah, seperti pendapatan, pekerjaan, dan riwayat kredit, untuk menentukan kelas keputusan (diterima atau ditolak). Kesederhanaan dan efisiensi algoritma membuatnya cocok untuk dataset besar dengan atribut yang saling independen.

Salah satu metode dalam klasifikasi data adalah *Naïve Bayes Classifier (NBC)*. *Naïve Bayes Classifier* merupakan salah satu metode machine learning yang memanfaatkan perhitungan probabilitas dan statistik yang dikemukakan oleh ilmuwan Inggris Thomas Bayes, Formula Matematis Algoritma Naive Bayes Algoritma Naive Bayes didasarkan pada Teorema Bayes.[7]

$$P(C|X) = \frac{P(X|C)P(C)}{P(X)} \dots\dots\dots (1)$$

Keterangan:

X = Data dengan *class* yang belum diketahui

C = Hipotesis data merupakan suatu *class* spesifik

P(C|X) = Probabilitas hipotesis C berdasar kondisi X (*posterior* probabilitas)

P(C) = Probabilitas hipotesis C (*prior* probabilitas)

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

P(X) = Probabilitas X

3.2 Pembagian Data Set

Pembagian data dilakukan secara acak menggunakan fungsi pemisahan dataset yang tersedia dalam perangkat lunak statistik. Langkah ini memastikan distribusi data antara training dan testing tetap representatif. Selain itu, metode stratifikasi digunakan untuk menjaga proporsi kelas target, terutama jika dataset memiliki ketidakseimbangan. [8]

Setelah data dikumpulkan, kemudian data tersebut dianalisis untuk menentukan variabel-variabel yang mana saja yang dapat digunakan dari data nasabah kartu kredit tersebut untuk diterapkan kedalam Aplikasi Rapidminer.

Adapun variabelnya anata lain sebagai berikut :

- 1) **Fitur Input** : Jenis Kelamin, Status Rumah, Status, Jumlah Tanggungan, Status pegawai, Penghasilan Perbulan.
- 2) **Targer Output** : Kartu Kredit (Tidak dapat, Silver, Master, Prioritas)
- 3) **Ukuran Data** : 166 Data Latih dan 20 Data Uji

3.3 Pengolahan Data/Pra Pemrosesan

Tahap pra-pemrosesan data bertujuan untuk memastikan bahwa data yang digunakan dalam penelitian bersih, lengkap, dan relevan. Langkah-langkah yang dilakukan meliputi penghapusan data duplikat, pengisian nilai yang hilang menggunakan metode imputasi, serta normalisasi data untuk menyamakan skala antar atribut, ini dilakukan meningkatkan akurasi algoritma *Naive Bayes*. [9]

Selain itu, atribut-atribut yang tidak relevan atau memiliki korelasi rendah dengan target klasifikasi akan dieliminasi. Data yang telah diproses kemudian dibagi menjadi dua bagian data training dan data testing. Langkah ini memastikan model dapat dilatih dan diuji secara optimal, menghasilkan performa algoritma klasifikasi yang andal. [10]

Menggunakan *RapidMiner* untuk melatih model *Naive Bayes* dengan pendekatan supervised learning. Aplikasi ini menyediakan operator seperti *Retrieve Data*, *Naive Bayes*, dan *Performance Evaluation* yang memungkinkan integrasi algoritma secara efisien. [11]

Tabel 1. Variabel Penelitian

Variabel	Tipe	Value
X1 : Jenis Kelamin	Binomial	L dan P
X2 : Status Rumah	Polynomial	Milik Sendiri, Milik Keluarga dan Kontrak
X3 : Status	Binomial	Kawin dan Belum Kawin
X4: Jumlah Tanggungan	Polynomial	0,1,2, dan >=3

Variabel	Tipe	Value
X5 : Status Pegawai	Binomial	Tetap dan Tidak Tetap
X6 : Penghasilan Perbulan	Polynomial	0 – 2999999, 3000000 – 5000000, 5000000 – 9999999, dan >=10000000
X7 : Kartu Kredit	Polynomial	Tidak Dapat, Silver, Master, dan Prioritas

3.4 Penerapan Naïve Bayes

Algoritma klasifikasi berbasis probabilistik yang banyak digunakan dalam berbagai bidang, termasuk dalam penentuan kelayakan pengajuan kartu kredit. Dengan kemampuannya dalam menangani data dengan jumlah besar dan memberikan hasil yang cepat serta cukup akurat, *Naïve Bayes* menjadi sangat efektif untuk mendukung sistem pengambilan keputusan dalam perbankan.

Tabel 1 Data *Training* Nasabah Kartu Kredit Bank Mandiri

No	Jk	Status Rumah	Status	Jumlah Tanggungan	Status Pegawai	Penghasilan Perbulan	Kartu Kredit
1	L	kontrak	kawin	>=3	tetap	3000000 - 4999999	tidak dapat
2	P	kontrak	kawin	2	tidak tetap	5000000 - 9999999	tidak dapat
3	P	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
4	P	milik keluarga	belum kawin	2	tetap	0 - 2999999	tidak dapat
5	L	milik keluarga	belum kawin	0	tetap	3000000 - 4999999	silver
6	L	kontrak	kawin	1	tetap	3000000 - 4999999	tidak dapat
7	P	milik sendiri	kawin	1	tetap	3000000 - 4999999	silver
8	L	milik sendiri	belum kawin	0	tidak tetap	0 - 2999999	tidak dapat
9	P	kontrak	kawin	0	tetap	5000000 - 9999999	silver
10	P	milik sendiri	kawin	>=3	tetap	>=10000000	tidak dapat
11	L	milik keluarga	belum kawin	0	tetap	5000000 - 9999999	master
12	P	milik sendiri	kawin	1	tetap	3000000 - 4999999	silver
13	P	milik sendiri	belum kawin	1	tetap	5000000 - 9999999	master
14	P	milik keluarga	kawin	0	tetap	3000000 - 4999999	silver
15	P	milik sendiri	belum kawin	0	tidak tetap	5000000 - 9999999	master
16	L	kontrak	belum kawin	0	tetap	3000000 - 4999999	silver
17	L	kontrak	belum kawin	2	tidak tetap	0 - 2999999	tidak dapat
18	P	milik keluarga	belum kawin	0	tidak tetap	0 - 2999999	tidak dapat
19	P	milik keluarga	kawin	0	tidak tetap	3000000 - 4999999	silver
20	P	milik keluarga	kawin	2	tidak tetap	3000000 - 4999999	silver
21	P	milik sendiri	belum kawin	0	tetap	5000000 - 9999999	master
22	P	kontrak	belum kawin	0	tetap	>=10000000	master
23	P	kontrak	kawin	0	tetap	3000000 - 4999999	silver
24	L	kontrak	kawin	1	tetap	0 - 2999999	tidak dapat
25	P	milik keluarga	kawin	>=3	tetap	5000000 - 9999999	tidak dapat
26	P	milik sendiri	belum kawin	0	tidak tetap	3000000 - 4999999	silver
27	L	milik sendiri	belum kawin	0	tidak tetap	3000000 - 4999999	silver
28	P	milik keluarga	kawin	>=3	tetap	0 - 2999999	tidak dapat
29	L	milik sendiri	kawin	>=3	tetap	3000000 - 4999999	tidak dapat
30	L	milik sendiri	kawin	0	tidak tetap	0 - 2999999	tidak dapat
31	L	kontrak	kawin	>=3	tidak tetap	>=10000000	tidak dapat
32	P	milik sendiri	kawin	1	tetap	>=10000000	prioritas
33	P	kontrak	belum kawin	0	tidak tetap	3000000 - 4999999	tidak dapat
34	P	milik keluarga	belum kawin	0	tetap	5000000 - 9999999	master
35	P	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
36	P	milik keluarga	belum kawin	0	tetap	3000000 - 4999999	silver
37	P	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
38	L	milik keluarga	belum kawin	0	tidak tetap	5000000 - 9999999	master
39	P	kontrak	kawin	>=3	tetap	5000000 - 9999999	tidak dapat
40	P	milik keluarga	kawin	>=3	tetap	>=10000000	tidak dapat
41	P	milik keluarga	belum kawin	0	tetap	3000000 - 4999999	silver
42	P	kontrak	kawin	2	tetap	3000000 - 4999999	tidak dapat
43	P	kontrak	kawin	2	tidak tetap	0 - 2999999	tidak dapat
44	L	kontrak	kawin	>=3	tidak tetap	3000000 - 4999999	tidak dapat
45	L	milik sendiri	belum kawin	0	tidak tetap	0 - 2999999	tidak dapat
46	P	milik keluarga	belum kawin	0	tetap	5000000 - 9999999	master
47	L	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
48	L	milik sendiri	kawin	>=3	tetap	3000000 - 4999999	tidak dapat
49	P	milik sendiri	kawin	>=3	tetap	0 - 2999999	tidak dapat
50	P	kontrak	belum kawin	0	tetap	3000000 - 4999999	silver
51	L	kontrak	kawin	0	tetap	3000000 - 4999999	silver
52	P	milik keluarga	belum kawin	2	tidak tetap	5000000 - 9999999	master
53	P	milik sendiri	kawin	>=3	tetap	5000000 - 9999999	tidak dapat
54	L	milik sendiri	kawin	2	tidak tetap	5000000 - 9999999	master

No	JK	Status Rumah	Status	Jumlah Tanggungan	Status Pegawai	Penghasilan Perbulan	Kartu Kredit
55	L	milik sendiri	kawin	1	tetap	5000000 - 9999999	master
56	P	milik keluarga	kawin	1	tidak tetap	5000000 - 9999999	master
57	L	milik keluarga	kawin	2	tetap	5000000 - 9999999	master
58	P	milik keluarga	kawin	2	tetap	5000000 - 9999999	master
59	P	milik sendiri	kawin	>=3	tetap	5000000 - 9999999	tidak dapat
60	P	milik keluarga	kawin	0	tetap	0 - 2999999	tidak dapat
61	L	milik keluarga	kawin	2	tidak tetap	5000000 - 9999999	tidak dapat
62	L	milik keluarga	belum kawin	0	tetap	3000000 - 4999999	silver
63	P	milik keluarga	kawin	2	tetap	5000000 - 9999999	master
64	P	milik sendiri	kawin	2	tetap	3000000 - 4999999	silver
65	P	milik keluarga	kawin	0	tetap	3000000 - 4999999	silver
66	L	milik keluarga	kawin	>=3	tetap	3000000 - 4999999	tidak dapat
67	P	milik keluarga	kawin	2	tetap	3000000 - 4999999	silver
68	P	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
69	P	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
70	P	milik sendiri	kawin	>=3	tetap	3000000 - 4999999	tidak dapat
71	P	milik keluarga	kawin	0	tidak tetap	5000000 - 9999999	master
72	L	kontrak	kawin	1	tetap	5000000 - 9999999	tidak dapat
73	L	kontrak	belum kawin	2	tetap	5000000 - 9999999	tidak dapat
74	L	kontrak	kawin	>=3	tetap	0 - 2999999	tidak dapat
75	P	milik keluarga	kawin	2	tetap	3000000 - 4999999	silver
76	P	milik keluarga	kawin	1	tidak tetap	0 - 2999999	tidak dapat
77	P	milik keluarga	kawin	1	tetap	3000000 - 4999999	silver
78	L	milik sendiri	belum kawin	0	tetap	0 - 2999999	tidak dapat
79	P	milik keluarga	kawin	>=3	tidak tetap	3000000 - 4999999	tidak dapat
80	P	milik keluarga	kawin	1	tetap	3000000 - 4999999	silver
81	P	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
82	L	milik keluarga	kawin	>=3	tetap	5000000 - 9999999	tidak dapat
83	P	kontrak	belum kawin	1	tidak tetap	5000000 - 9999999	tidak dapat
84	P	kontrak	kawin	0	tidak tetap	3000000 - 4999999	tidak dapat
85	P	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
86	P	milik keluarga	belum kawin	0	tetap	3000000 - 4999999	silver
87	L	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
88	L	milik keluarga	kawin	>=3	tetap	3000000 - 4999999	tidak dapat
89	L	milik keluarga	kawin	2	tidak tetap	>=10000000	prioritas
90	L	milik sendiri	kawin	>=3	tidak tetap	3000000 - 4999999	tidak dapat
91	P	milik keluarga	kawin	2	tetap	3000000 - 4999999	silver
92	L	kontrak	kawin	>=3	tetap	3000000 - 4999999	tidak dapat
93	P	kontrak	kawin	2	tidak tetap	3000000 - 4999999	tidak dapat
94	P	milik keluarga	belum kawin	0	tetap	3000000 - 4999999	silver
95	P	kontrak	kawin	>=3	tetap	>=10000000	tidak dapat
96	P	milik sendiri	kawin	2	tetap	5000000 - 9999999	master
97	P	milik sendiri	kawin	2	tetap	>=10000000	prioritas
98	L	milik keluarga	belum kawin	0	tetap	>=10000000	prioritas
99	P	milik keluarga	kawin	>=3	tetap	>=10000000	tidak dapat
100	P	milik sendiri	kawin	2	tetap	5000000 - 9999999	master
101	L	milik keluarga	kawin	>=3	tetap	5000000 - 9999999	tidak dapat
102	P	kontrak	belum kawin	0	tetap	5000000 - 9999999	silver
103	P	kontrak	belum kawin	0	tidak tetap	3000000 - 4999999	tidak dapat
104	p	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
105	P	milik keluarga	belum kawin	0	tetap	3000000 - 4999999	silver
106	L	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
107	L	milik sendiri	kawin	>=3	tidak tetap	3000000 - 4999999	tidak dapat
108	L	milik keluarga	belum kawin	0	tidak tetap	>=10000000	prioritas
109	L	milik sendiri	kawin	>=3	tetap	3000000 - 4999999	tidak dapat
110	P	milik keluarga	kawin	2	tetap	3000000 - 4999999	silver
111	L	kontrak	kawin	>=3	tetap	3000000 - 4999999	tidak dapat
112	L	kontrak	kawin	0	tetap	>=10000000	master
113	P	kontrak	kawin	1	tidak tetap	>=10000000	silver
114	P	kontrak	kawin	2	tidak tetap	3000000 - 4999999	tidak dapat
115	P	milik keluarga	belum kawin	0	tetap	3000000 - 4999999	silver
116	L	milik sendiri	kawin	0	tetap	5000000 - 9999999	master
117	L	milik sendiri	kawin	2	tidak tetap	5000000 - 9999999	master
118	P	milik sendiri	kawin	1	tetap	3000000 - 4999999	silver
119	L	milik sendiri	kawin	1	tetap	5000000 - 9999999	master
120	L	milik sendiri	kawin	>=3	tetap	>=10000000	tidak dapat
121	P	kontrak	belum kawin	2	tidak tetap	5000000 - 9999999	tidak dapat
122	L	milik keluarga	kawin	>=3	tidak tetap	5000000 - 9999999	tidak dapat
123	L	kontrak	kawin	2	tetap	>=10000000	tidak dapat
124	L	kontrak	kawin	0	tetap	>=10000000	master

No	JK	Status Rumah	Status	Jumlah Tanggungan	Status Pegawai	Penghasilan Perbulan	Kartu Kredit
125	P	kontrak	kawin	1	tidak tetap	>=10000000	silver
126	L	milik sendiri	kawin	>=3	tetap	>=10000000	tidak dapat
127	L	kontrak	kawin	2	tetap	>=10000000	tidak dapat
128	L	milik sendiri	kawin	>=3	tetap	3000000 - 4999999	tidak dapat
129	P	kontrak	belum kawin	0	tidak tetap	3000000 - 4999999	tidak dapat
130	P	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
131	P	milik keluarga	belum kawin	0	tetap	3000000 - 4999999	silver
132	P	milik sendiri	belum kawin	0	tetap	3000000 - 4999999	silver
133	L	milik keluarga	kawin	>=3	tetap	5000000 - 9999999	tidak dapat
134	P	kontrak	belum kawin	0	tetap	5000000 - 9999999	silver
135	L	milik sendiri	kawin	0	tetap	5000000 - 9999999	master
136	L	milik sendiri	kawin	2	tidak tetap	5000000 - 9999999	master
137	P	milik keluarga	kawin	1	tidak tetap	0 - 2999999	tidak dapat
138	P	milik keluarga	kawin	1	tetap	3000000 - 4999999	silver
139	L	milik sendiri	belum kawin	0	tetap	0 - 2999999	tidak dapat
140	P	kontrak	kawin	>=3	tetap	>=10000000	tidak dapat
141	L	milik keluarga	belum kawin	2	tidak tetap	5000000 - 9999999	master
142	L	milik keluarga	belum kawin	0	tetap	>=10000000	prioritas
143	L	milik keluarga	belum kawin	0	tidak tetap	5000000 - 9999999	master
144	L	kontrak	kawin	>=3	tetap	5000000 - 9999999	tidak dapat
145	P	milik keluarga	belum kawin	0	tetap	5000000 - 9999999	master
146	P	milik keluarga	kawin	2	tetap	3000000 - 4999999	silver
147	L	milik sendiri	kawin	>=3	tetap	5000000 - 9999999	tidak dapat
148	L	kontrak	kawin	0	tetap	>=10000000	master
149	P	milik sendiri	kawin	1	tetap	5000000 - 9999999	master
150	P	milik sendiri	kawin	2	tetap	>=10000000	prioritas
151	L	kontrak	kawin	0	tetap	>=10000000	master
152	P	kontrak	kawin	1	tidak tetap	>=10000000	silver
153	P	kontrak	belum kawin	2	tidak tetap	5000000 - 9999999	tidak dapat
154	L	milik keluarga	kawin	>=3	tidak tetap	5000000 - 9999999	tidak dapat
155	L	kontrak	kawin	0	tetap	>=10000000	master
156	P	milik keluarga	belum kawin	0	tetap	5000000 - 9999999	master
157	P	milik keluarga	kawin	2	tetap	3000000 - 4999999	silver
158	L	milik sendiri	kawin	>=3	tetap	5000000 - 9999999	tidak dapat
159	L	kontrak	kawin	0	tetap	>=10000000	master
160	P	kontrak	kawin	1	tidak tetap	>=10000000	silver
161	P	kontrak	kawin	>=3	tetap	>=10000000	tidak dapat
162	L	milik keluarga	belum kawin	2	tidak tetap	5000000 - 9999999	master
163	L	milik keluarga	belum kawin	0	tetap	>=10000000	prioritas
164	L	milik keluarga	belum kawin	0	tidak tetap	5000000 - 9999999	master
165	P	milik keluarga	belum kawin	0	tetap	5000000 - 9999999	master
166	P	kontrak	kawin	1	tidak tetap	>=10000000	silver

Tabel 2 Data *testing* yang digunakan

No	JK	Status Rumah	Status	Jumlah Tanggungan	Status Pegawai	Penghasilan Perbulan	Kartu Kredit
1	L	milik sendiri	kawin	>=3	tidak tetap	3000000 - 4999999	tidak dapat
2	P	milik keluarga	kawin	2	tetap	3000000 - 4999999	silver
3	L	kontrak	kawin	>=3	tetap	0 - 2999999	tidak dapat
4	P	kontrak	kawin	2	tidak tetap	3000000 - 4999999	tidak dapat
5	P	milik keluarga	belum kawin	0	tetap	3000000 - 4999999	silver
6	P	kontrak	kawin	>=3	tetap	>=10000000	tidak dapat
7	P	milik sendiri	kawin	2	tetap	5000000 - 9999999	master
8	P	milik sendiri	kawin	2	tetap	>=10000000	prioritas
9	P	milik keluarga	kawin	>=3	tetap	>=10000000	tidak dapat
10	L	kontrak	kawin	0	tetap	5000000 - 9999999	master
11	P	kontrak	kawin	1	tidak tetap	>=10000000	master
12	P	kontrak	kawin	2	tidak tetap	3000000 - 4999999	tidak dapat
13	P	milik keluarga	belum kawin	0	tetap	3000000 - 4999999	silver
14	L	milik sendiri	kawin	0	tetap	5000000 - 9999999	master
15	P	milik keluarga	kawin	2	tetap	3000000 - 4999999	silver
16	L	kontrak	kawin	>=3	tetap	3000000 - 4999999	tidak dapat
17	L	kontrak	kawin	0	tetap	>=10000000	master
18	P	kontrak	kawin	1	tidak tetap	>=10000000	silver
19	P	kontrak	kawin	2	tidak tetap	3000000 - 4999999	tidak dapat
20	L	milik sendiri	kawin	1	tetap	5000000 - 9999999	master

3.4 Perhitungan Klasifikasi *Naive Bayes*

Berdasarkan teori *Naive Bayes* kita dapat melakukan perhitungan data klasifikasi dari data training yang kita miliki pada tabel 1 dan perhitungan klasifikasi nasabah kartu Bank Mandiri pada tabel 2 dapat dihitung sebagai berikut

Menghitung Jumlah Class

$P(\text{Kartu Kredit "Tidak Terima"})$	$= 0,333$
$P(\text{Kartu Kredit "Silver"})$	$= 0,200$
$P(\text{Kartu Kredit "Master"})$	$= 0,267$
$P(\text{Kartu Kredit "Prioritas"})$	$= 0,200$

Menghitung data testing dengan class yang sama

$P(\text{JK "L" Kartu Kredit "Tidak Terima"})$	$= 0,600$
$P(\text{JK "L" Kartu Kredit "Silver"})$	$= 0,667$
$P(\text{JK "L" Kartu Kredit "Master"})$	$= 0,500$
$P(\text{JK "L" Kartu Kredit "Prioritas"})$	$= 0,333$

$P(\text{Status Rumah "Milik Sendiri" Kartu Kredit "Tidak Terima"})$	$= 0,600$
$P(\text{Status Rumah "Milik Sendiri" Kartu Kredit "Silver"})$	$= 0,333$
$P(\text{Status Rumah "Milik Sendiri" Kartu Kredit "Master"})$	$= 0,500$
$P(\text{Status Rumah "Milik Sendiri" Kartu Kredit "Prioritas"})$	$= 0,667$

$P(\text{Status "Kawin" Kartu Kredit "Tidak Terima"})$	$= 0,600$
$P(\text{Status "Kawin" Kartu Kredit "Silver"})$	$= 0,667$
$P(\text{Status "Kawin" Kartu Kredit "Master"})$	$= 0,500$
$P(\text{Status "Kawin" Kartu Kredit "Prioritas"})$	$= 0,667$

$P(\text{Jumlah Tanggungan "1" Kartu Kredit "Tidak Terima"})$	$= 0,200$
$P(\text{Jumlah Tanggungan "1" Kartu Kredit "Silver"})$	$= 0,333$
$P(\text{Jumlah Tanggungan "1" Kartu Kredit "Master"})$	$= 0,250$
$P(\text{Jumlah Tanggungan "1" Kartu Kredit "Prioritas"})$	$= 0,333$

$P(\text{Status Pegawai "Tetap" Kartu Kredit "Tidak Terima"})$	$= 0,400$
$P(\text{Status Pegawai "Tetap" Kartu Kredit "Silver"})$	$= 0,667$
$P(\text{Status Pegawai "Tetap" Kartu Kredit "Master"})$	$= 0,750$
$P(\text{Status Pegawai "Tetap" Kartu Kredit "Prioritas"})$	$= 0,667$

$P(\text{Penghasilan Perbulan "5000000-9999999" Kartu Kredit "Tidak Terima"})$	$= 0,600$
$P(\text{Penghasilan Perbulan "5000000-9999999" Kartu Kredit "Silver"})$	$= 1,000$
$P(\text{Penghasilan Perbulan "5000000-9999999" Kartu Kredit "Master"})$	$= 0,000$
$P(\text{Penghasilan Perbulan "5000000-9999999" Kartu Kredit "Prioritas"})$	$= 0,000$

Perhitungan probabilitas berdasarkan kondisi class

$P(X \text{Kartu Kredit "Tidak Terima"})$	$= 0,010$
$P(X \text{Kartu Kredit "Silver Card"})$	$= 0,033$
$P(X \text{Kartu Kredit "Master Card"})$	$= 0,000$
$P(X \text{Kartu Kredit "Prioritas Card"})$	$= 0,000$

Hasil dari perhitungan Probabilitas

$P(X \text{Kartu Kredit "Tidak Terima"}) * P(\text{Kartu Kredit "Tidak Terima"})$	$= 0,006$
$P(X \text{Kartu Kredit "Silver"}) * P(\text{Kartu Kredit "Silver"})$	$= 0,022$
$P(X \text{Kartu Kredit "Master"}) * P(\text{Kartu Kredit "Master"})$	$= 0,000$
$P(X \text{Kartu Kredit "Prioritas"}) * P(\text{Kartu Kredit "Prioritas"})$	$= 0,000$

3.5 Evaluasi Model

Evaluasi model dilakukan untuk menilai kinerja algoritma *Naive Bayes* dalam mengklasifikasikan pengajuan kartu kredit. Metrik yang digunakan meliputi akurasi, precision, recall. Akurasi mengukur persentase prediksi yang benar, sementara precision dan recall

digunakan untuk mengevaluasi keseimbangan antara prediksi positif yang benar dan cakupan klasifikasi positif

Dari hasil perhitungan, terlihat bahwa nilai probabilitas yang tertinggi adalah Kartu Kredit “Silver” maka dapat disimpulkan bahwa nasabah pengajuan kartu kredit dapat diklasifikasikan yaitu mendapatkan “Kartu Kredit”.

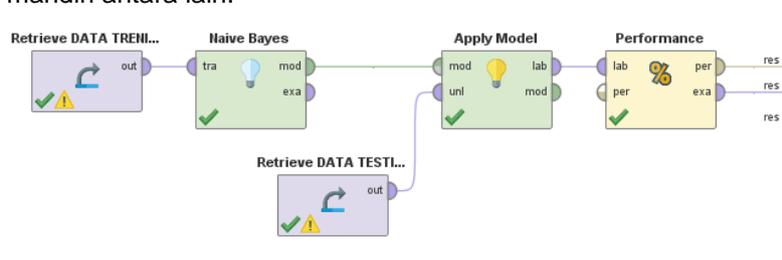
4. Hasil dan Pembahasan

Model yang telah dikembangkan di uji keakuratannya dengan memasukkan data kedalam program. Eksperimen yang dilakukan dalam penelitian ini menggunakan aplikasi Rapidminer. Yang dimana data yang di uji diambil dari history Nasabah Kredit Bank Mandiri.

Penelitian ini menggunakan metode naive bayesian *classification* (NBC), pada metode ini semua atribut akan memberikan kontribusinya dalam pengambilan keputusan, dengan bobot atribut yang sama penting dan setiap atribut saling bebas satu sama lain tidak hanya itu juga menggunakan variabel variabel tertentu ataupun variabel variabel data pada proses pengujian. *Naive bayes* dalam studi kasus yang kami gunakan adalah untuk membuat sebuah prediksi dimasa depan.

4.1 Pengujian Metode

Dalam aplikasi Rapid Miner terdapat beberapa operator yang digunakan dalam pengujian eksperimen metode untuk mengklasifikasi penentuan penerima kartu kredit pada nasabah bank mandiri antara lain.



Gambar 1 Proses Rapid Miner

- 1) *Retrieve Data* : operator ini berfungsi untuk memanggil atau memasukkan data yang akan diolah pada aplikasi Rapid Miner.
- 2) *Naive Bayes* : operator atau algoritma yang digunakan untuk mengklasifikasi data yang telah dimasukkan.
- 3) *Apply Model* : digunakan untuk menerapkan model yang telah dilatih sebelumnya menggunakan data training, tujuannya adalah untuk mendapatkan prediksi pada unlabeled data (data testing) yang belum memiliki label.
- 4) *Performance* : operator performance digunakan untuk mengevaluasi kinerja model yang memberikan daftar nilai kriteria kinerja secara otomatis sesuai dengan tugas yang diberikan. Misalkan untuk klasifikasi, kriteria yang diberikan adalah accuracy, precision dan recall.

4.2 Hasil Performance Rapid Miner

RapidMiner adalah platform analitik data berbasis perangkat lunak yang digunakan untuk data mining, *machine learning*, dan *predictive analytics*. Dengan antarmuka drag-and-drop, RapidMiner mempermudah analisis data kompleks.[12]

Dari hasil percobaan pertama dengan jumlah Data *Training* sebanyak 50 data dan jumlah data *testing* sebanyak 20 data, maka didapatkan hasil *accuracy* 60% , hasil class precision untuk prediksi Tidak Dapat 50%, prediksi Silver 100%, Prediksi Master 0% dan prediksi Prioritas 0%, sedangkan untuk hasil class recall nya yaitu untuk Tidak Dapat 100%, *Silver* 80%, Master 0% dan Prioritas 0%. Berikut gambar hasil performance nya.

accuracy: 60.00%

	true TIDAK DAPAT	true SILVER	true MASTER	true PRIORITAS	class precision
pred. TIDAK DAPAT	8	1	6	1	50.00%
pred. SILVER	0	4	0	0	100.00%
pred. MASTER	0	0	0	0	0.00%
pred. PRIORITAS	0	0	0	0	0.00%
class recall	100.00%	80.00%	0.00%	0.00%	

Gambar 2 Hasil performance percobaan pertama

Hasil percobaan kedua dengan jumlah Data Training sebanyak 100 data dan jumlah data *testing* sebanyak 20 data, maka didapatkan hasil *accuracy* 80% , hasil *class precision* untuk prediksi Tidak Dapat 66,67%, prediksi *Silver* 100%, Prediksi Master 100% dan prediksi Prioritas 100%, sedangkan untuk hasil *class recall* nya yaitu untuk Tidak Dapat 100%, *Silver* 80%, Master 50% dan Prioritas 100%. Berikut gambar hasil *performance* percobaan kedua.

accuracy: 80.00%

	true TIDAK DAPAT	true SILVER	true MASTER	true PRIORITAS	class precision
pred. TIDAK DAPAT	8	1	3	0	66.67%
pred. SILVER	0	4	0	0	100.00%
pred. MASTER	0	0	3	0	100.00%
pred. PRIORITAS	0	0	0	1	100.00%
class recall	100.00%	80.00%	50.00%	100.00%	

Gambar 3 Hasil performance percobaan kedua

Hasil percobaan ketiga dengan jumlah Data *Training* sebanyak 166 data dan jumlah data *testing* sebanyak 20 data, maka didapatkan hasil *accuracy* 85% , hasil *class precision* untuk prediksi Tidak Dapat 72,73%, prediksi *Silver* 100%, Prediksi Master 100% dan prediksi Prioritas 100%, sedangkan untuk hasil *class recall* nya yaitu untuk Tidak Dapat 100%, *Silver* 100%, Master 57,14% dan Prioritas 100%. Berikut gambar hasil *performance* percobaan ketiga.

accuracy: 85.00%

	true TIDAK DAPAT	true SILVER	true MASTER	true PRIORITAS	class precision
pred. TIDAK DAPAT	8	1	2	0	72.73%
pred. SILVER	0	4	0	0	100.00%
pred. MASTER	0	0	4	0	100.00%
pred. PRIORITAS	0	0	0	1	100.00%
class recall	100.00%	80.00%	66.67%	100.00%	

Gambar 4 Hasil performance percobaan kedua

Hasil prediksi dari aplikasi ripid miner dapat dilihat pada gambar 5 yang dimana ada terdapat tiga prediksi yang tidak sama.

NO	KARTU KRE...	prediction(K...	confidence(...	confidence(...	confidence(...	confidence(...
1	TIDAK DAPAT	TIDAK DAPAT	1	0	0	0
2	SILVER	SILVER	0.210	0.790	0	0
3	TIDAK DAPAT	TIDAK DAPAT	1	0	0	0
4	TIDAK DAPAT	TIDAK DAPAT	0.711	0.289	0	0
5	SILVER	SILVER	0.012	0.988	0	0
6	TIDAK DAPAT	TIDAK DAPAT	1	0	0	0
7	MASTER	MASTER	0.283	0.064	0.653	0
8	PRIORITAS	PRIORITAS	0.268	0.175	0.250	0.307
9	TIDAK DAPAT	TIDAK DAPAT	1	0	0	0
10	MASTER	MASTER	0.343	0.024	0.633	0
11	MASTER	TIDAK DAPAT	0.656	0.177	0.167	0
12	TIDAK DAPAT	TIDAK DAPAT	0.711	0.289	0	0
13	SILVER	SILVER	0.012	0.988	0	0
14	MASTER	MASTER	0.158	0.027	0.815	0
15	SILVER	SILVER	0.210	0.790	0	0
16	TIDAK DAPAT	TIDAK DAPAT	1	0	0	0
17	MASTER	TIDAK DAPAT	0.513	0.105	0.382	0
18	SILVER	TIDAK DAPAT	0.656	0.177	0.167	0
19	TIDAK DAPAT	TIDAK DAPAT	0.711	0.289	0	0
20	MASTER	MASTER	0.299	0.030	0.671	0

Gambar 5 Hasil performance percobaan kedua

4.3 Hasil Analisa

Setelah melakukan percobaan sebanyak 3 kali, maka peneliti mendapatkan hasil seperti yang ditampilkan pada tabel 4

Tabel 4 Variabel Penelitian

Data Traning	Data Testing	Class Recall	Class Precision	Accuracy
50	20	48%	38%	60%
100	20	82,50%	92%	80%
166	20	86,67%	93%	85%

4.4 Pembahasan

Temuan dalam penelitian ini sejalan dengan beberapa penelitian terdahulu yang membahas efektivitas metode *Naive Bayes* dalam klasifikasi data keuangan. Misalnya, penelitian oleh [13] membandingkan metode *Naive Bayes* dengan algoritma *machine learning* lainnya dan menemukan bahwa metode ini unggul dalam efisiensi komputasi serta memiliki tingkat akurasi yang cukup baik dalam dataset kategori yang kompleks. Selain itu, penelitian oleh [14] menunjukkan bahwa kombinasi metode klasifikasi dan *clustering* dalam analisis kartu kredit dapat meningkatkan prediksi risiko kredit.

Dibandingkan dengan penelitian lain yang menggunakan model *machine learning* seperti *Support Vector Machine* (SVM) dan *Random Forest*[15], metode *Naive Bayes* dalam penelitian ini terbukti memberikan hasil yang kompetitif dengan keunggulan utama pada kecepatan pemrosesan dan kemudahan implementasi. Sementara penelitian lain mengusulkan penggabungan *Naive Bayes* dengan *decision tree* untuk meningkatkan akurasi, hasil penelitian ini menunjukkan bahwa metode *Naive Bayes* sendiri sudah cukup efektif untuk diterapkan dalam skenario perbankan [16].

5) Simpulan

Hasil penelitian menunjukkan bahwa metode *Naive Bayes* memiliki kinerja yang baik dalam klasifikasi kelayakan pengajuan kartu kredit, dengan akurasi mencapai 85%. Temuan ini mendukung penelitian sebelumnya yang menyatakan bahwa metode ini memiliki efisiensi komputasi yang tinggi serta mampu menangani dataset kategori dengan baik. Implementasi metode ini dapat membantu bank dalam meningkatkan efisiensi proses evaluasi pengajuan kartu kredit serta mengurangi kesalahan subjektif dalam pengambilan keputusan.

Daftar Referensi

- [1] F. Margaretha and S. May Sari, "Faktor Penentu Tingkat Literasi Keuangan Para Pengguna Kartu Kredit di Indonesia," *J. Akunt. dan Investasi*, vol. 16, no. 2, pp. 132–144, 2015, doi: 10.18196/jai.2015.0038.132-144.
- [2] K. P. Murphy, *Machine Learning: A Probabilistic Perspective*. London, England: The MIT Press, 2012.
- [3] A. E. Khandani, A. J. Kim, and A. W. Lo, "Consumer Credit Risk Models Via Machine-Learning Algorithms," *SSRN Electron. J.*, vol. 34, no. 11, pp. 2767–2787, 2012.
- [4] H. Qian, S. Zhang, B. Wang, L. Peng, S. Gao, and Y. Song, "A comparative study on machine learning models combining with outlier detection and balanced sampling methods for credit scoring," *arxiv.org/abs/2112.13196*, 2021.
- [5] I. C. Yeh and C. hui Lien, "The comparisons of data mining techniques for the predictive accuracy of probability of default of credit card clients," *Expert Syst. Appl.*, vol. 36, no. 2 PART 1, pp. 2473–2480, 2009, doi: 10.1016/j.eswa.2007.12.020.
- [6] N. Hafid and L. Khikmah, "Perbandingan Metode Algoritma C4 . 5 , Naïve Bayes , dan Logistic Regression untuk Penentuan Kelayakan Penerima Kredit Comparison of C4 . 5 , Naïve Bayes , and Logistic Regression Algorithm Methods for Determining Credit Recipient Eligibility," vol. 14, no. 2, pp. 85–93, 2024.
- [7] A. Indriani, "Klasifikasi Data Forum dengan menggunakan Metode Naïve Bayes Classifier," in *Seminar Nasional Aplikasi Teknologi Informasi (SNATI) Yogyakarta*, 2014, pp. 21–2014.
- [8] Q. H. Nguyen *et al.*, "Influence of data splitting on performance of machine learning models in prediction of shear strength of soil," *Math. Probl. Eng.*, vol. 2021, no. 6, 2021, doi: 10.1155/2021/4832864.
- [9] S. García, J. Luengo, and F. Herrera, *Data Processing in Data Mining*, vol. 72. Spain: Springer, 2015. doi: 10.1007/978-3-319-10247-4_8.
- [10] R. R. Pratama, "Analisis Model Machine Learning Terhadap Pengenalan Aktifitas Manusia," *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 19, no. 2, pp. 302–311, 2020, doi: 10.30812/matrik.v19i2.688.
- [11] S. B. Kim, H. C. Rim, D. S. Yook, and H. S. Lim, "Effective methods for improving naive Bayes text classifiers," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 2417, pp. 414–423, 2002, doi: 10.1007/3-540-45683-x_45.
- [12] G. Ertek, D. Tapucu, and I. Arin, "Text Mining with RapidMiner," in *RapidMiner: Data Mining Use Cases and Business Analytics Applications*, Chapman and Hall/CRC.: Chapman & Hall/CRC Data Mining and Knowledge Discovery Series, 2013, pp. 1–47.
- [13] L. Y. Bai *et al.*, "Prediction of Effective Drug Combinations by an Improved Naïve Bayesian Algorithm," *Int. J. Mol. Sci.*, vol. 19, no. 2, pp. 1–14, 2018.
- [14] J. C. Nugraha and F. Sulianta, "Meningkatkan Pengambilan Keputusan Industri Keuangan melalui Analisis Data Pinjaman Bank Menggunakan K-Means Clustering," *Res. Gate*, 2024.
- [15] M. P. Pangaribuan and V. A. Purba, "Pemodelan Probability Of Default Portofolio Pembiayaan Bersama Fintech Lending dan Multi Finance :Studi Kasus Bank ABC," *Oikos J. Kaji. Pendidik. Ekon. dan Ilmu Ekon.*, vol. VII, no. 2, pp. 562–576, 2023.
- [16] F. P. Budiana and H. Shelviani, "Kombinasi Algoritma Decision Tree Dan Naive Bayes Untuk Meningkatkan Akurasi Dan Kecepatan," in *Seminar Nasional Riset dan Inovasi Teknologi (SEMNAS RISTEK)*, 2025, pp. 419–425.