

Klasifikasi Naïve Bayes pada Machine Learning untuk Rekomendasi Kredit Customer pada KSP

Siti Aisyah^{*1}, Khoiriya Latifa²

^{1,2} Program Studi Informatika, Universitas PGRI Semarang, Kota Semarang

*Email: aisysyah304@gmail.com^{*1}, khoiriyalatifah@upgris.ac.id²

Abstract

Idola Berkah Sejahtera Savings and Loans Cooperative provides money lending services to its members based on lending limit criteria. In the world of finance, especially small institutions such as KSP, fast and accurate credit assessment is very important to reduce the risk of bad credit and increase operational efficiency. The Naïve Bayes algorithm was chosen because of its simplicity and ability to provide competitive results on categorical and numerical data. This research uses a historical dataset that includes demographic information, credit history, and other relevant factors. The research results show that the Naïve Bayes algorithm is able to provide a high level of accuracy in approved and rejected classifications. With the accuracy obtained in this experiment of 0,72 or 72%, Precision 0,73 or 73%, Recall 0,96 or 96%, F1-Score 0,83 or 83%. The implementation of this machine learning model is expected to increase KSP operational efficiency and reduce the risk of credit default.

Keywords: Naïve Bayes, Classification, Credit Recommendations, Saving and Loans Cooperatives(KSP), Machine Learning

Abstrak

Koperasi Simpan Pinjam Idola Berkah Sejahtera menyediakan jasa layanan peminjaman uang kepada anggotanya berdasarkan kriteria limit peminjaman. Dalam dunia keuangan, khususnya lembaga-lembaga kecil seperti KSP, penilaian kredit yang cepat dan akurat sangat penting untuk mengurangi resiko kredit macet dan meningkatkan efisiensi operasional. Algoritma Naive bayes dipilih karena kesederhanaannya dan kemampuannya dalam memberikan hasil yang kompetitif pada data yang bersifat kategorikal dan numerik. Penelitian ini menggunakan dataset historis yang mencakup informasi demografis, riwayat kredit, dan faktor-faktor lainnya yang relevan. Hasil penelitian menunjukkan bahwa Algoritma Naive bayes mampu memberikan tingkat akurasi yang tinggi dalam klasifikasi yang disetujui dan ditolak. Dengan akurasi yang diperoleh pada percobaan ini sebesar 0,72 atau sebesar 72%, Precision 0,73 atau 73%, Recall 0,96 atau 96%, F1-Score 0,83 atau 83%. Implementasi model machine learning ini diharapkan dapat meningkatkan efisiensi operasional KSP dan mengurangi resiko gagal bayar kredit.

Kata Kunci: Naïve Bayes, Klasifikasi, Rekomendasi Kredit, Koperasi Simpan Pinjam (KSP), Machine Learning

1. Pendahuluan

Koperasi adalah badan usaha yang beranggotakan orang-orang atau badan hukum koperasi dengan melandaskan kegiatannya pada prinsip koperasi sekaligus sebagai gerakan ekonomi rakyat yang berdasarkan asas kekeluargaan [6]. Salah satu tantangan utama yang dihadapi oleh KSP adalah penilaian kredit yang efektif dan efisien untuk meminimalkan resiko kredit macet. Proses ini memerlukan beberapa evaluasi faktor, termasuk riwayat kredit, pendapatan, dan karakteristik demografis calon peminjam. Machine learning telah membuka peluang baru untuk meningkatkan akurasi dan efisiensi dalam penilaian kredit.

Machine learning dapat didefinisikan sebagai aplikasi computer dan algoritma matematika yang diadopsi dengan cara pembelajaran yang berasal dari data dan menghasilkan prediksi dimasa yang akan datang. Adapun proses pembelajaran yang dimaksud adalah suatu usaha dalam memperoleh kecerdasan yang melalui dua tahap antara lain Latihan (training) dan pengujian (testing) [4].

Algoritma Naïve Bayes dikenal karena kesederhanaannya dan kemampuannya dalam menangani data kategorikal maupun numerik. Naïve Bayes Classifier merupakan sebuah metoda klasifikasi yang berakar pada teorema bayes. Metode pengklasifikasian dengan menggunakan metode probabilitas dan statistic yang dikemukakan oleh ilmuan Inggris Thomas Bayes, yaitu memprediksi peluang dimasa depan berdasarkan pengalaman dimasa sebelumnya sehingga dikenal sebagai Teorema bayes[8]. Meskipun asumsi independensi yang digunakan oleh Naïve Bayes sering dianggap sebagai keterbatasan, algoritma ini telah terbukti memberikan hasil kompetitif dalam berbagai klasifikasi, termasuk dalam penilaian kredit. Dengan mengimplementasikan Naïve Bayes, KSP dapat melakukan analisis data secara lebih efisien dan memberikan rekomendasi kredit yang lebih cepat dan akurat.

Penelitian ini bertujuan untuk mengembangkan model klasifikasi berbasis Naïve Bayes yang dapat digunakan oleh KSP dalam proses rekomendasi kredit customer. Model ini akan dilatih menggunakan dataset historis kredit dan akan dievaluasi berdasarkan kinerja prediktifnya. Hasil penelitian ini diharapkan dapat memberikan kontribusi signifikan terhadap peningkatan efisiensi operasional KSP dan pengurangan resiko kredit macet.

2. Metode

Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model klasifikasi berbasis algoritma Naïve Bayes untuk rekomendasi kredit customer pada Koperasi Simpan Pinjam (KSP). Berikut beberapa metode yang digunakan:

2.1 Machine Learning

Machine learning merupakan kumpulan teknik yang berguna dalam menangani dan memprediksi data berskala besar dengan memanfaatkan algoritma pembelajaran yang diterapkan pada data-data tersebut. Istilah machine learning pertama kali didefinisikan oleh Arthur Samuel pada tahun 1959. Menurut Samuel, machine learning merupakan sebuah bidang dalam ilmu komputer yang memberikan kemampuan belajar kepada komputer untuk memahami sesuatu tanpa harus diprogram secara eksplisit[1]. Ada dua aplikasi utama dalam machine learning yaitu, klasifikasi dan prediksi. Ciri khas dari machine learning adalah adanya proses pelatihan, pembelajaran, atau training.

2.2 Data Mining

Data Mining adalah metode untuk menganalisis pola dan karakteristik di masa depan serta untuk mengumpulkan informasi tak terduga yang belum pernah terlihat sebelumnya dari database yang besar. Data Mining mengeksplorasi pengetahuan dan pola dalam data melalui statistik matematika dan machine learning[7].

2.3 Naive Bayes

Naive Bayes merupakan suatu metode klasifikasi yang membagi suatu permasalahan kedalam sebuah kelas lable menggunakan metode probabilitas dan statistik dengan persamaan dan perbedaannya sehingga hasilnya dapat dijelaskan[5].

Teorema Bayes:

$$P(C|X)=P(X|C) \cdot P(C)/P(X)$$

Di mana:

- $P(C|X)$ adalah probabilitas dari kelas C diberikan data X (probabilitas posterior).
- $P(X|C)$ adalah probabilitas data X diberikan kelas C (probabilitas likelihood).
- $P(C)$ adalah probabilitas apriori dari kelas C (probabilitas prior).
- $P(X)$ adalah probabilitas dari data X (probabilitas evidence).

Untuk klasifikasi dengan Naive Bayes, kita biasanya mengabaikan $P(X)$ karena sama untuk semua kelas. Sehingga rumusnya menjadi:

$$P(C|X) \propto P(X|C) \cdot P(C)$$

Dengan asumsi independensi antar fitur, rumus di atas dapat diperluas menjadi:

$$P(C|X) \propto P(C) \prod_{i=1}^n P(x_i|C)$$

Di mana:

- $X = \{x_1, x_2, \dots, x_n\}$ adalah vektor fitur.
- $P(x_i|C)$ adalah probabilitas fitur x_i diberikan kelas C .

2.4 CRISP-DM

Cross-Industry Standard Process for Data Mining (CRISP-DM) yang dikembangkan tahun 1996 oleh analisis dari beberapa industri seperti Daimler Chrysler, SPSS dan NCR. CRISP-DM menyediakan standar proses data mining sebagai strategi pemecahan masalah secara umum dari bisnis atau unit penelitian[3]. [Click or tap here to enter text.](#)

CRISP-DM menyediakan standar proses baku untuk data mining yang dapat diterapkan ke dalam strategi pemecahan masalah umum pada bisnis atau pada unit penelitian. CRISP-DM membandingkan metodologi data mining lain lebih lengkap dan terdokumentasi dengan baik. Setiap fase terstruktur dan terdefinisi dengan jelas sehingga mudah diaplikasikan bahkan bagi pemula sekalipun[2].



Gambar 1 Model proses CRISP-DM

3. Hasil dan Pembahasan

3.1. Data Training

Untuk menganalisa data dengan metode Naive Bayes maka langkah pertama yang dilakukan adalah membaca data latih. Data latih yang digunakan dalam penelitian ini terdapat pada tabel 1.

Tabel 1 Data Training

No	Nama	Gaji	Status	Agunan	Jangka Waktu	Kolektibilitas
1	Kumaidi	Tinggi	Belum Menikah	Sertif Rumah	Jangka Menengah	Lancar
2	Badruddin	Sedang	Sudah Menikah	BPKB SPM	Jangka Panjang	Lancar
3	Widowati	Sedang	Sudah Menikah	BPKB SPM	Jangka Panjang	Lancar
4	Abu Salam	Sedang	Sudah Menikah	BPKB SPM	Jangka Panjang	Tidak Lancar
5	Muhammad Jayadi	Tinggi	Sudah Menikah	BPKB SPM	Jangka Panjang	Lancar

6	Kamidah	Tinggi	Sudah Menikah	Sertif Rumah	Jangka Pendek	Lancar
7	Kasmun	Sedang	Sudah Menikah	BPKB SPM	Jangka Panjang	Lancar
8	Siti Laelah	Sedang	Belum Menikah	BPKB SPM	Jangka Panjang	Lancar
9	Isni Maesaroh	Sedang	Sudah Menikah	BPKB SPM	Jangka Panjang	Lancar
10	Tutik Budiayati	Tinggi	Sudah Menikah	Sertif Rumah	Jangka Menengah	Tidak Lancar
11	Sri Suharti	Tinggi	Sudah Menikah	Sertif Rumah	Jangka Menengah	Tidak Lancar
12	Sofyan Huda	Tinggi	Sudah Menikah	BPKB SPM	Jangka Menengah	Tidak Lancar
13	Sholi'in	Sedang	Sudah Menikah	BPKB SPM	Jangka Panjang	Lancar
14	Slamet Giyanto	Sedang	Sudah Menikah	BPKB SPM	Jangka Panjang	Lancar
15	Abdullah Nur	Tinggi	Sudah Menikah	BPKB SPM	Jangka Panjang	Lancar
16	Sulton	Sedang	Sudah Menikah	BPKB SPM	Jangka Panjang	Tidak Lancar

Perhitungan data training naive bayes berdasarkan tabel diatas

Menentukan Kelas :

1.) Kolektibitas

$$P(\text{Kolektibitas}=\text{Tidak Lancar}) = 5/16 = 0,3125$$

$$P(\text{Kolektibitas}=\text{Lancar}) = 11/16 = 0,6875$$

2.) Gaji

$$P(\text{Gaji}=\text{Tinggi} \mid \text{Kolektibitas}=\text{Tidak Lancar}) = 3/16 = 0,1875$$

$$P(\text{Gaji}=\text{Tinggi} \mid \text{Kolektibitas}=\text{Lancar}) = 4/16 = 0,25$$

$$P(\text{Gaji}=\text{Sedang} \mid \text{Kolektibitas}=\text{Tidak Lancar}) = 2/16 = 0,125$$

$$P(\text{Gaji}=\text{Sedang} \mid \text{Kolektibitas}=\text{Lancar}) = 7/16 = 0,4375$$

3.) Status

$$P(\text{Status}=\text{Sudah Menikah} \mid \text{Kolektibitas}=\text{Tidak Lancar}) = 5/16 = 0,3125$$

$$P(\text{Status}=\text{Sudah Menikah} \mid \text{Kolektibitas}=\text{Lancar}) = 2/16 = 0,125$$

$$P(\text{Status}=\text{Belum Menikah} \mid \text{Kolektibitas}=\text{Tidak Lancar}) = 0/16 = 0$$

$$P(\text{Status}=\text{Belum Menikah} \mid \text{Kolektibitas}=\text{Lancar}) = 2/16 = 0,125$$

4.) Agunan

$$P(\text{Agunan}=\text{BPKB} \mid \text{Kolektibitas}=\text{Tidak lancar}) = 3/16 = 0,1875$$

$$P(\text{Agunan}=\text{BPKB} \mid \text{Kolektibitas}=\text{Lancar}) = 9/16 = 0,5625$$

$$P(\text{Agunan}=\text{Sertifikat} \mid \text{Kolektibitas}=\text{Tidak Lancar}) = 2/16 = 0,125$$

$$P(\text{Agunan}=\text{Sertifikat} \mid \text{Kolektibitas}=\text{Lancar}) = 2/16 = 0,125$$

5.) Jangka Waktu

$$P(\text{Jangka Waktu}=\text{Jangka Panjang} \mid \text{Kolektibitas}=\text{Tidak Lancar}) = 2/16 = 0,125$$

$$P(\text{Jangka Waktu}=\text{Jangka Panjang} \mid \text{Kolektibitas}=\text{Lancar}) = 9/16 = 0,5625$$

$$P(\text{Jangka Waktu}=\text{Jangka Menengah} \mid \text{Kolektibitas}=\text{Tidak Lancar}) = 3/16 = 0,1875$$

$$P(\text{Jangka Waktu}=\text{Jangka Menengah} \mid \text{Kolektibitas}=\text{Lancar}) = 1/16 = 0,0625$$

$$P(\text{Jangka Pendek}=\text{Jangka Pendek} \mid \text{Kolektibitas}=\text{Tidak Lancar}) = 0/16 = 0$$

$$P(\text{Jangka Pendek}=\text{Jangka Pendek} \mid \text{Kolektibitas}=\text{Lancar}) = 1/16 = 0,0625$$

3.2. Data Testing

Data testing merupakan data yang akan diprediksi ke dalam sebuah kelas Tidak Lancar atau masuk ke kelas Lancar, data testing ditunjukkan tabel 2.

Gaji	Status	Agunan	Jangka Waktu	Kolektibitas
Tinggi	Sudah Menikah	BPKB SPM	Jangka Panjang	?

Tabel 2 Data Testing

Perhitungan data training pada tabel 2

$$P | (\text{Tidak Lancar}) = 0,1875 * 0,3125 * 0,1875 * 0,125 = 0,00137$$

$$P | (\text{Lancar}) = 0,25 * 0,125 * 0,5625 * 0,5625 = 0,00988$$

Perbandingan nilai $P | (\text{Tidak Lancar})$ dengan $P | (\text{Lancar})$ maka nilai yang tertinggi yang dipilih, jadi hasil label dari data training pada tabel adalah **Lancar**.

Dari hasil perhitungan data tersebut menggunakan Metode Naive Bayes dan dapat disimpulkan bahwa, nasabah tersebut layak mendapatkan pinjaman karena probabilitas kelas Lancar lebih besar dibandingkan kelas Tidak lancar.

3.3. Akurasi Data

Nilai akurasi merupakan cara untuk menentukan kedakatan hasil terhadap nilai sebenarnya.

$$\text{Akurasi} = \frac{\text{Data yang benar}}{\text{Total Data}} * 100\%$$

$$\text{Akurasi} = \frac{15}{16} = 0.9375$$

$$\text{Akurasi} = 93,75\%$$

Uji data dengan 12 data training dan 3 data testing didapat nilai akurasi 93,75%.

3.4. Pengujian dengan Phyton

Sebelum melakukan analisis, terlebih dahulu digunakan fungsi “.info” untuk menampilkan informasi data yang akan dilakukan analisis. Berikut ini *output*-nya.

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 505 entries, 0 to 504
Data columns (total 9 columns):
#   Column          Non-Null Count  Dtype
---  ---
0   No               505 non-null   int64
1   Nama            505 non-null   object
2   Gaji            505 non-null   int64
3   Jenis Kelamin   505 non-null   object
4   Jangka Waktu    505 non-null   object
5   Status          505 non-null   object
6   Pinjaman       505 non-null   int64
7   Agunan         505 non-null   object
8   Kolektibitas   505 non-null   object
dtypes: int64(3), object(6)
memory usage: 35.6+ KB
```

Gambar 2 Informasi Data

Data yang akan dianalisis memiliki 9 variabel (kolom) yaitu kolom *No*, *Nama*, *Gaji*, *Jenis Kelamin*, *Jangka Waktu*, *Status*, *Pinjaman*, *Agunan*, *Kolektibitas* yang memiliki *type* data *integer* dan kolom *time* dengan *type* data *object*.

Tahapan selanjutnya yaitu menentukan variabel independen dan variabel dependen dari data yang akan dianalisis.

	No	Nama	Gaji	Jenis Kelamin	Jangka Waktu	Status	Pinjaman	Agunan
0	1	Kumaidi	6500000	Laki-laki	Jangka Menengah	Belum Menikah	10000000	Sertif Rumah
1	2	Badruddin	2000000	Laki-laki	Jangka Panjang	Sudah Menikah	4000000	BPKB SPM
2	3	Widowati	4000000	Perempuan	Jangka Panjang	Sudah Menikah	3500000	BPKB SPM
3	4	Abu Salam	2000000	Laki-laki	Jangka Panjang	Sudah Menikah	4000000	BPKB SPM
4	5	Muhammad Jayadi	5500000	Laki-laki	Jangka Panjang	Sudah Menikah	5000000	BPKB SPM

Gambar 3 Variabel Independen

Kolom *kolektibitas* di *drop* atau di hapus dari *data frame* karena akan menjadi variabel dependen.

```

0          Lancar
1          Lancar
2          Lancar
3      Tidak Lancar
4          Lancar
Name: Kolektibilitas, dtype: object
    
```

Gambar 4 Output Variabel Dependen

Setelah menentukan variabel independen dan variabel dependen, selanjutnya kan dilakukan analisis menggunakan klasifikasi *Naive Bayes*. Pertama dilakukan *Train Test Split* untuk membagi dataset menjadi training set dan test set.

```

# Import train_test_split function
from sklearn.model_selection import train_test_split
x_train, x_test, y_train, y_test = train_test_split(x, y, test_size = 0.2, random_state = 123)
    
```

Script di atas membagi dataset menjadi 80% *training* set dan 20% *test* set. Yang artinya dari 505 data, *training* set akan berisi 400 data dan *test* set berisi 100 data. Setelah dilakukan pemisahan, selanjutnya akan dilakukan prediksi pada *training* set dan *test* set.

```
array([255., 149.])
```

Selanjutnya, digunakan *script* untuk menentukan hasil prediksi dari *x_test*.

```

array(['Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar',
'Lancar', 'Tidak Lancar', 'Lancar', 'Lancar', 'Tidak Lancar',
'Lancar', 'Lancar', 'Lancar', 'Tidak Lancar', 'Lancar', 'Lancar',
'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Tidak Lancar', 'Lancar', 'Lancar',
'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar',
'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar',
'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar',
'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar',
'Lancar', 'Lancar', 'Tidak Lancar', 'Lancar', 'Lancar', 'Lancar',
'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar',
'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar',
'Tidak Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar',
'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar',
'Lancar', 'Lancar', 'Tidak Lancar', 'Lancar', 'Lancar', 'Lancar',
'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar', 'Lancar'],
dtype='<U12')
    
```

Gambar 5 Hasil Prediksi dari *x_test*

Untuk menentukan nilai probabilitas dari *x_test* maka digunakan *script* berikut ini:

```

[0.60597325, 0.39402675],
[0.61769716, 0.38230284],
[0.58166023, 0.41833977],
[0.65367517, 0.34632483],
[0.60188254, 0.39811746],
[0.70005288, 0.29994712],
[0.60930832, 0.39069168],
[0.53725586, 0.46274414],
[0.780382 , 0.219618 ],
[0.65168686, 0.34831314],
[0.61361468, 0.38638532],
[0.5474137 , 0.4525863 ],
[0.56877711, 0.43122289],
[0.56303869, 0.43696131],
[0.72222221, 0.27777779],
[0.62436887, 0.37563113],
[0.60062891, 0.39937109],
[0.6870753 , 0.3129247 ],
[0.48585788, 0.51414212],
[0.61141234, 0.38858766],
[0.63579944, 0.36420056],
[0.70244831, 0.29755169],
[0.54094381, 0.45905619],
[0.62690597, 0.37309403],
[0.54901525, 0.45098475],
[0.64549218, 0.35450782],
[0.7551445 , 0.2448555 ],
[0.67943329, 0.32056671],
[0.6245092 , 0.3754908 ],
[0.80930912, 0.19069088],
[0.54960406, 0.45039594],
[0.63025135, 0.36974865],
[0.59639873, 0.40360127],
    
```

Gambar 6 Nilai Probabilitas dari Hasil Prediksi

Setelah diperoleh nilai prediksi (y_{pred}), maka tahapan selanjutnya yaitu melakukan *Confussion Matrix*.

```
array([[69, 3],
       [25, 4]])
```

Gambar 7 Output Confussion Matrix

Gambar 7 merupakan hasil *confussion matrix*, untuk mempermudah dalam membaca, maka digunakan *script* untuk merapihkan hasil *confussion matrix*.

```

0 1
0 69 3
1 25 4
```

Gambar 8 Hasil Analisis Menggunakan Naive Bayes

Gambar 8 menunjukkan bahwa, prediksi *kolektibilitas* dinyatakan gagal dan ternyata *kolektibilitas* gagal sebanyak 69, prediksi *kolektibilitas* gagal dan ternyata *kolektibilitas* berhasil 25, prediksi *kolektibilitas* berhasil dan ternyata *kolektibilitas* gagal sebanyak 3 dan prediksi *kolektibilitas* berhasil dan ternyata *kolektibilitas* berhasil sebanyak 4.

Karena sebagian besar prediksi dan hasil nya sesuai maka dapat di katakan bahwa *prediksi rekomendasi customer* baik digunakan untuk Rekomendasi Kredit Customer pada KSP.

Selanjutnya, akan dilakukan perhitungan nilai akurasi.

	precision	recall	f1-score	support
Lancar	0.73	0.96	0.83	72
Tidak Lancar	0.57	0.14	0.22	29
accuracy			0.72	101
macro avg	0.65	0.55	0.53	101
weighted avg	0.69	0.72	0.66	101

Gambar 9 Nilai Akurasi dari Klasifikasi Naive Bayes

Dari pengujian diperoleh hasil bahwa, dari 100 data testing di atas diperoleh hasil dimana terdapat 29 data yang Failed saat pengujian. Akurasi yang diperoleh pada percobaan ini sebesar 0,72 atau sebesar 72%.

4. Kesimpulan

Penelitian ini berhasil mengembangkan model machine learning menggunakan algoritma Naive Bayes untuk rekomendasi kredit customer pada Koperasi Simpan Pinjam (KSP). Model Naive Bayes menunjukkan performa yang baik dalam klasifikasi kredit customer, dengan menggunakan perhitungan manual uji data dengan 12 data training dan 3 data testing didapat nilai akurasi 93,75%. Sedangkan pengujian dengan bahasa pemrograman Python, dengan melakukan tahap pengujian terhadap 505 data training. dari 100 data testing diperoleh hasil dimana terdapat 29 data yang Failed saat pengujian. Akurasi yang diperoleh pada percobaan ini sebesar 0,72 atau sebesar 72%, Precision 0,73 atau 73%, Recall 0,96 atau 96% dan F1-Score 0,83 atau 83%.

Keseluruhan hasil penelitian ini memberikan bukti bahwa algoritma Naive Bayes dapat diandalkan sebagai alat bantu dalam pengambilan keputusan kredit di KSP. Implementasi model ini diharapkan dapat membantu KSP dalam meningkatkan efisiensi operasional dan mengurangi resiko gagal bayar kredit, serta memberikan dasar bagi pengembangan lebih lanjut dalam penggunaan teknologi machine learning di sektor keuangan.

5. Referensi

- [1]. Akmaluddin, M., & Dewayanto, T. (n.d.). SYSTEMATIC LITERATURE REVIEW: IMPLEMENTASI ARTIFICIAL INTELLIGENCE DAN MACHINE LEARNING PADA BIDANG AKUNTANSI MANAJEMEN. *DIPONEGORO JOURNAL OF ACCOUNTING*, 12(4), 1–11. <http://ejournal-s1.undip.ac.id/index.php/accounting>
- [2]. Fadillah, A. P. (2015). Penerapan Metode CRISP-DM untuk Prediksi Kelulusan Studi Mahasiswa Menempuh Mata Kuliah (Studi Kasus Universitas XYZ). In *Jurnal Teknik Informatika dan Sistem Informasi* (Vol. 1).
- [3]. Farid Rifai, M., Jatnika, H., Valentino, B., & Tinggi Teknik PLN, S. (2019). Penerapan Algoritma Naïve Bayes Pada Sistem Prediksi Tingkat Kelulusan Peserta Sertifikasi Microsoft Office Specialist (MOS). 12(2).
- [4]. Homepage, J., Roihan, A., Abas Sunarya, P., & Rafika, A. S. (2019). IJCIT (Indonesian Journal on Computer and Information Technology) Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper. In *IJCIT (Indonesian Journal on Computer and Information Technology)* (Vol. 5, Issue 1).
- [5]. Nurjanah, I., Karaman, J., Widaningrum, I., & Mustikasari, D. (2023). Penggunaan Algoritma Naive Bayes Untuk Menentukan Pemberian Kredit Pada Koperasi Desa. In *Journal of Computer Science and Information Technology E-ISSN* (Vol. 3, Issue 2).
- [6]. Samsudin, M., Abdurahman, M., Abdullah, M. H., Studi, P., Akuntansi, K., Sains, P., Teknologi, D., Maluku, W., Program, U., Manajemen Informatika, S., Komputer, T., Ilmu, A., & Ternate, K. (n.d.). *Sistem Informasi Pengkreditan Nasabah Pada Koperasi Simpan Pinjam Sejahtera Baru Kota Ternate Berbasis Web*. 2621–4970.
- [7]. Sekar Setyaningtyas, Indarmawan Nugroho, B., & Arif, Z. (2022). TINJAUAN PUSTAKA SISTEMATIS: PENERAPAN DATA MINING TEKNIK CLUSTERING ALGORITMA K-MEANS. *Jurnal Teknoif Teknik Informatika Institut Teknologi Padang*, 10(2), 52–61. <https://doi.org/10.21063/jtif.2022.v10.2.52-61>
- [8]. Syukri Mustafa, M., & Simpen, W. (n.d.). *Implementasi Data Mining untuk Evaluasi Kinerja Akademik Mahasiswa Menggunakan Algoritma Naive Bayes Classifier*.