JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 09-14
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8128

Optimalisasi Keputusan Kelayakan Kredit Menggunakan Sistem Pendukung Keputusan Berbasis Naive Bayes

Fince Tinus Waruwu
Sistem Informasi,Fakultas Ilmu Komputer & Teknologi Informasi, Medan,Indonesi
Email: fincedav@gmail.com
Korespondensi: fincedav@gmail.com

Abstrak—Penilaian kelayakan kredit membutuhkan pengolahan sejumlah karakteristik peminjam secara konsisten untuk membantu petugas menilai risiko dan mendokumentasikan dasar rekomendasi. Penelitian ini membahas rancangan sistem pendukung keputusan berbasis Gaussian Naive Bayes untuk klasifikasi kelayakan kredit dalam konteks Credit Union Makmur. Variabel yang digunakan meliputi usia, pendapatan, jumlah pinjaman, rasio utang terhadap pendapatan, skor riwayat kredit, masa kerja, dan status pekerjaan. Tahapan penelitian mencakup prapemrosesan, pemisahan data pelatihan dan pengujian secara terstratifikasi, pembentukan model, serta evaluasi menggunakan confusion matrix, accuracy, precision, recall, dan F1-score. Verifikasi dilakukan menggunakan 600 data uji simulasi yang terdiri atas 332 kelas Layak dan 268 kelas Tidak Layak, dengan pembagian 480 data pelatihan dan 120 data pengujian. Hasil pengujian memperlihatkan accuracy sebesar 76,67%, precision 78,79%, recall 78,79%, dan F1-score 78,79%. Evaluasi 5-fold cross-validation yang dilaporkan menghasilkan rata-rata accuracy 80,50%. Hasil ini menunjukkan kemungkinan penerapan prosedur klasifikasi probabilistik dalam rancangan sistem pendukung keputusan. Namun, seluruh angka berasal dari data simulasi dan tidak menggambarkan performa empiris Credit Union Makmur. Penelitian lanjutan memerlukan data historis resmi, definisi label yang dapat diaudit, evaluasi kesalahan klasifikasi, dan perbandingan terhadap proses keputusan kredit yang berlaku sebelum penggunaan operasional.

Kata Kunci: Kelayakan Kredit; Naive Bayes; Sistem Pendukung Keputusan; Klasifikasi; Data Simulasi

Abstract—Credit eligibility assessment requires consistent processing of borrower characteristics to assist credit officers in evaluating risk and documenting the basis of recommendations. This paper describes a decision support system design based on Gaussian Naive Bayes for credit eligibility classification in the context of Credit Union Makmur. The proposed variables include age, income, loan amount, debt-to-income ratio, credit history score, employment duration, and employment status. The workflow comprises preprocessing, stratified training and testing partitioning, probabilistic model construction, and evaluation using a confusion matrix, accuracy, precision, recall, and F1-score. Verification is based on 600 simulated test records comprising 332 Eligible and 268 Ineligible cases, divided into 480 training records and 120 testing records. Reported testing performance reaches 76.67% accuracy, 78.79% precision, 78.79% recall, and 78.79% F1-score. The reported five-fold cross-validation mean accuracy is 80.50%. These results demonstrate the feasibility of illustrating a probabilistic classification workflow within the proposed decision support framework. However, the numerical evidence is derived entirely from simulated records rather than actual Credit Union Makmur borrower histories. Consequently, the findings must not be interpreted as empirical operational performance or as evidence of superior decision quality. Deployment would require authorized historical data, auditable outcome labels, rigorous assessment of classification errors, and a comparison against the institution's existing credit decision process. Human oversight remains necessary for final lending decisions.

Keywords: Credit Eligibility; Naive Bayes; Decision Support System; Classification; Simulated Data

1. PENDAHULUAN

Perkembangan teknologi informasi dan Machine Learning membuka peluang bagi lembaga keuangan untuk memanfaatkan data historis dalam mendukung keputusan yang lebih konsisten. Sistem Pendukung Keputusan (SPK) digunakan untuk membantu pengambil keputusan mengolah data dan model dalam menyelesaikan permasalahan semi-terstruktur [1], [2].

Pada proses pemberian kredit, ketepatan penilaian calon peminjam sangat penting karena keputusan yang kurang tepat dapat meningkatkan risiko kredit macet. Proposal penelitian menempatkan Credit Union Makmur sebagai objek yang memerlukan mekanisme penilaian berbasis data terhadap faktor seperti riwayat kredit, pendapatan, status pekerjaan, jumlah pinjaman, dan rasio utang terhadap penghasilan.

Naive Bayes merupakan algoritma klasifikasi probabilistik yang menggunakan Teorema Bayes dengan asumsi independensi bersyarat antarfitur. Walaupun asumsi tersebut sederhana, Naive Bayes dikenal memiliki komputasi yang ringan dan dapat memberikan hasil klasifikasi yang kompetitif pada banyak jenis data [3]-[9].

Dalam penelitian ini, model Naive Bayes diintegrasikan ke dalam rancangan SPK. Sistem tidak menggantikan kewenangan petugas kredit, tetapi menyediakan probabilitas dan rekomendasi kelas yang dapat digunakan sebagai bahan pertimbangan. Hasil klasifikasi tetap perlu dibaca bersama kebijakan internal, dokumen peminjam, dan verifikasi lapangan.

Berkas proposal belum menyertakan data historis aktual Credit Union Makmur. Oleh karena itu, laporan ini memisahkan antara rancangan penelitian yang bersumber dari proposal dan verifikasi teknis menggunakan data uji simulasi. Pendekatan tersebut mencegah hasil simulasi diperlakukan sebagai kinerja empiris lembaga.

Pengembangan sistem klasifikasi untuk keputusan kredit perlu membedakan fungsi prediksi dan fungsi persetujuan kredit. Model menghasilkan informasi probabilistik, sedangkan keputusan final tetap mensyaratkan verifikasi dokumen, aturan institusi, serta pertimbangan petugas berwenang. Pada konteks ini, kesalahan memprediksi

Submitted: **17/09/2024**; Accepted: **28/12/2024**; Published: **28/01/2025**

JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 09-14
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8128

seorang peminjam sebagai Layak atau Tidak Layak memiliki konsekuensi yang berbeda dan membutuhkan pemantauan tersendiri.

Literatur dasar menjelaskan landasan pengolahan data, pembelajaran terawasi, dan klasifikasi probabilistik [1]–[13]. John dan Langley [7] membahas estimasi distribusi kontinu bagi klasifikator Bayesian, sedangkan Hand dan Yu [8] mengulas efektivitas Naive Bayes meskipun asumsi independensinya kuat. Guvenir dan Muderrisoglu [14] memberi contoh aplikasi Bayesian pada transaksi keuangan. Literatur tersebut membantu menjelaskan pendekatan model, tetapi tidak dengan sendirinya membuktikan kebaruan aplikasi pada lembaga yang menjadi objek penelitian.

Kesenjangan yang dapat diidentifikasi dari berkas sumber adalah belum tersedianya data pinjaman aktual, bukti perbandingan dengan keputusan manual, dan evaluasi operasional antarmuka sistem. Oleh sebab itu, penelitian ini dibatasi sebagai penyajian rancangan dan verifikasi teknis pada data simulasi. Tujuannya adalah mendokumentasikan atribut klasifikasi, proses evaluasi, metrik kinerja, serta batasan penerapan dalam pengambilan keputusan kredit yang diawasi manusia.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Proses meliputi identifikasi kebutuhan, telaah pustaka, penyiapan data, pembersihan dan pemilihan atribut, pembagian training dan testing, pelatihan Gaussian Naive Bayes, evaluasi klasifikasi, serta rancangan integrasi hasil ke SPK. Gambar 1 menyajikan alur penelitian sesuai naskah sumber.



Gambar 1. Tahapan penelitian klasifikasi kelayakan kredit

2.2 Arsitektur dan Atribut Data

Objek yang direncanakan adalah Credit Union Makmur, dengan rencana kegiatan Maret–Agustus 2025. Tidak tersedia data historis operasional pada laporan sumber; karena itu pengujian numerik harus dipahami sebagai simulasi. Arsitektur menghubungkan modul input data peminjam, prapemrosesan, Naive Bayes, rekomendasi kelayakan, dan pelaporan sebagaimana Gambar 2.



Gambar 2. Arsitektur sistem pendukung keputusan Naive Bayes

Tabel 1. Atribut yang digunakan pada klasifikasi

Kode	Atribut	Skala	Keterangan
C1	Usia	Tahun	Karakteristik peminjam

Submitted: **17/09/2024**; Accepted: **28/12/2024**; Published: **28/01/2025**

JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 09-14
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8128

C2	Pendapatan	Rupiah/bulan	Kemampuan pendapatan
C3	Jumlah Pinjaman	Rupiah	Nilai kredit yang diajukan
C4	Debt-to-Income Ratio	0-1	Rasio kewajiban terhadap pendapatan
C5	Skor Riwayat Kredit	0-100	Ringkasan rekam pembayaran
C6	Masa Kerja	Tahun	Stabilitas pekerjaan
C7	Status Pekerjaan	Kategori	Informal/kontrak, tetap, ASN/usaha stabil
Y	Kelayakan	Kelas	Layak/Tidak Layak

2.3 Perhitungan Gaussian Naive Bayes

Pendekatan Bayesian menghitung probabilitas posterior P(C|X) dari prior kelas P(C) dan likelihood fitur P(X|C). Klasifikasi dipilih dari kelas dengan probabilitas posterior terbesar. Dengan asumsi independensi bersyarat, likelihood dapat direpresentasikan sebagai hasil kali distribusi tiap atribut. Fitur numerik diasumsikan mengikuti distribusi Gaussian pada tiap kelas. Penggunaan asumsi distribusional ini perlu diperiksa kembali jika data aktual tersedia.

$$P(C|X) = P(C) \times P(X|C) / P(X) \quad (1)$$

$$P(C|x_1,\ldots,x_n) \propto P(C) \times \prod P(x_i|C) \quad (2)$$

2.4 Pengujian dan Evaluasi

a. Menghapus data duplikat, nilai kosong, dan nilai di luar rentang yang tidak dapat diverifikasi.

b. Memastikan setiap record memiliki label keputusan historis untuk proses supervised learning.

c. Mengubah status pekerjaan menjadi nilai kategori yang konsisten.

d. Membagi data menjadi 80% training dan 20% testing secara stratified.

e. Melatih Gaussian Naive Bayes pada training set.

f. Menghasilkan prediksi kelas pada testing set.

Sebanyak 80% data digunakan sebagai training dan 20% sebagai testing dengan pembagian kelas terstratifikasi. Perhitungan accuracy, precision, recall, dan F1-score menggunakan matriks konfusi. Laporan juga menyebutkan 5-fold stratified cross-validation. Karena rekaman pembagian dan kode eksperimen tidak dilampirkan, reproduksibilitas skor masih memerlukan artefak tambahan.

$$\text{Accuracy} = (TP + TN) / (TP + TN + FP + FN) \quad (3)$$

$$\text{Precision} = TP / (TP + FP) \quad (4)$$

$$\text{Recall} = TP / (TP + FN) \quad (5)$$

$$F1 = 2 \times \text{Precision} \times \text{Recall} / (\text{Precision} + \text{Recall}) \quad (6)$$

Pada evaluasi berikutnya, cross-validation untuk pemilihan model sebaiknya hanya dilakukan pada subset pelatihan dan hasil akhir dilaporkan pada test set yang disisihkan agar tidak terjadi penggunaan data pengujian dalam pemilihan model.

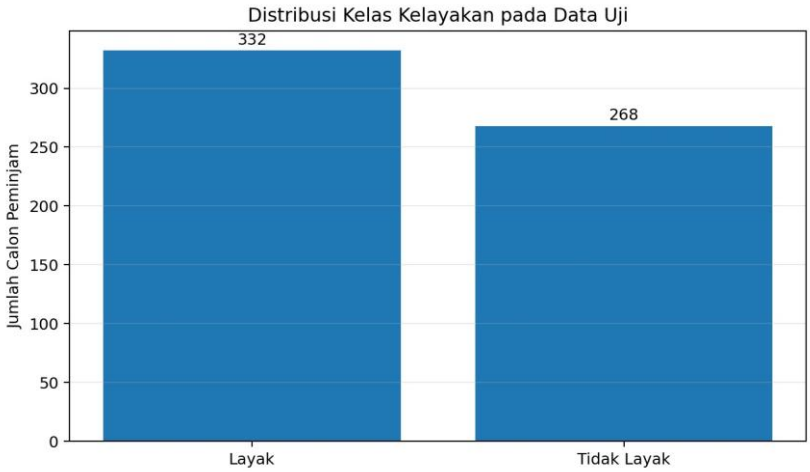
3. HASIL DAN PEMBAHASAN

3.1 Karakteristik Data Simulasi

Sebagaimana laporan sumber, data uji berjumlah 600 catatan, terdiri dari 332 label Layak (55,3%) dan 268 label Tidak Layak (44,7%). Angka ini merupakan gambaran distribusi simulasi dan bukan proporsi calon peminjam aktual. Gambar 3 menampilkan distribusi dua kelas, sedangkan Tabel 2 merangkum statistik fitur yang dilaporkan.

Submitted: **17/09/2024**; Accepted: **28/12/2024**; Published: **28/01/2025**

JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 09-14
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8128



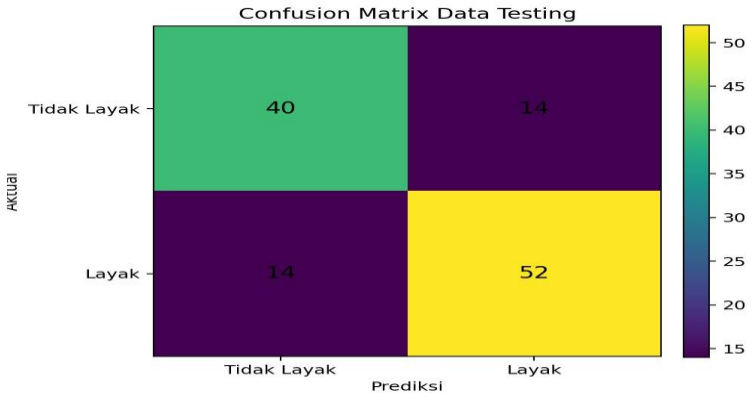
Gambar 3. Distribusi kelas pada data uji simulasi

Tabel 2. Statistik deskriptif fitur pada data simulasi

Variabel	Minimum	Rata-rata	Maksimum
Usia	21.00	37.68	60.00
Pendapatan (Rp.)	2,000,000	5,986,740	12,558,004
Jumlah Pinjaman (Rp.)	3,000,000	20,397,041	64,830,461
Variabel	Minimum	Rata-rata	Maksimum
Debt-to-Income Ratio	0.05	0.37	0.85
Skor Riwayat Kredit	20.00	66.66	100.00
Masa Kerja (tahun)	0.00	5.77	16.60

3.2 Hasil Pemodelan dan Matriks Konfusi

Dataset dibagi menjadi 480 data training dan 120 data testing. Model Gaussian Naive Bayes dilatih menggunakan tujuh fitur. Prediksi testing menghasilkan 40 True Negative, 14 False Positive, 14 False Negative, dan 52 True Positive.



Gambar 4. Confusion matrix pada 120 data pengujian

Matriks konfusi berisi 40 true negative, 14 false positive, 14 false negative, dan 52 true positive dengan kelas Layak sebagai kelas positif. Terdapat 92 prediksi benar dari 120 data pengujian. Kesalahan false positive berpotensi menghasilkan rekomendasi Layak untuk peminjam yang berlabel Tidak Layak; dalam penggunaan aktual, hal ini harus dianalisis berdasarkan konsekuensi risiko dan definisi label resmi. False negative juga perlu dievaluasi agar sistem tidak menghambat calon peminjam yang memenuhi ketentuan.

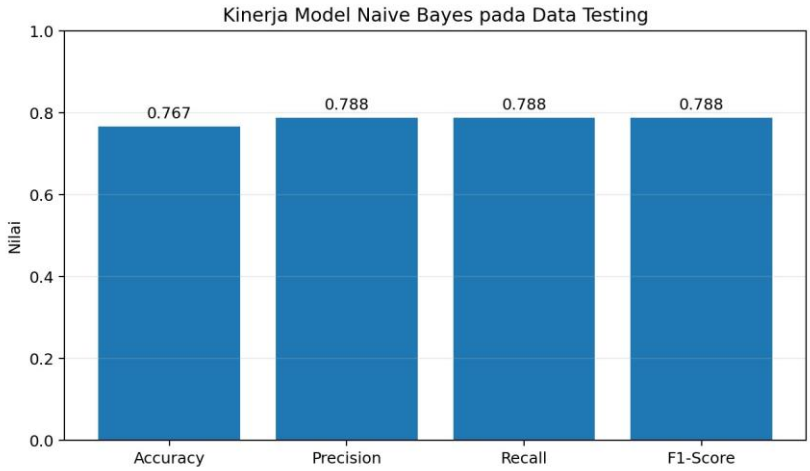
Submitted: **17/09/2024**; Accepted: **28/12/2024**; Published: **28/01/2025**

JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 09-14
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8128

3.3 Evaluasi Kinerja Model

Tabel 3. Metrik evaluasi model yang dilaporkan

Metrik	Nilai	Interpretasi
Accuracy	0.7667	Proporsi seluruh prediksi yang benar
Precision	0.7879	Ketepatan prediksi Layak
Recall	0.7879	Kemampuan mendeteksi kelas Layak
F1-Score	0.7879	Keseimbangan precision dan recall
CV Accuracy	0.8050 ± 0.0427	Rata-rata 5-fold cross-validation
CV F1	0.8245 ± 0.0455	Rata-rata F1 5-fold crossvalidation



Gambar 5. Kinerja klasifikasi Naive Bayes pada data testing

Accuracy sebesar 76.67% menunjukkan proporsi prediksi yang benar pada data uji. Precision 78.79% menggambarkan ketepatan ketika model memberikan rekomendasi Layak, sedangkan recall 78.79% menunjukkan seberapa banyak peminjam Layak yang berhasil dikenali. Rata-rata accuracy 5-fold crossvalidation sebesar 0.805 ± 0.043, yang menunjukkan hasil verifikasi cukup stabil pada pembagian data yang berbeda.

Nilai precision dan recall yang sama pada contoh pengujian ini berasal dari banyaknya false positive dan false negative yang sama, masing-masing sebanyak 14. Nilai F1-score sebesar 0,7879 diperoleh dari harmonik precision dan recall. Rata-rata cross-validation dilaporkan 0,8050 untuk accuracy dan 0,8245 untuk F1-score, tetapi tidak dapat dipakai sebagai bukti generalisasi ke calon peminjam nyata tanpa data historis dan pengujian eksternal.

3.4 Rancangan Integrasi pada Sistem Pendukung Keputusan

Dalam sistem, petugas memasukkan atau mengimpor data calon peminjam. Data divalidasi terlebih dahulu untuk memastikan atribut yang diperlukan tersedia. Model kemudian menghitung probabilitas posterior kelas Layak dan Tidak Layak. Kelas dengan probabilitas lebih tinggi ditampilkan sebagai rekomendasi, disertai catatan bahwa keputusan akhir tetap berada pada pihak Credit Union.

Penerapan yang bertanggung jawab memerlukan penyimpanan riwayat input dan hasil klasifikasi sehingga rekomendasi dapat diaudit. Sistem juga perlu membatasi akses terhadap data keuangan peminjam dan hanya menyimpan atribut yang diperlukan untuk proses analisis.

Antarmuka operasional sebaiknya memperlihatkan hasil kategori, skor probabilitas, ringkasan data masukan, dan peringatan bahwa rekomendasi bersifat pendukung. Perubahan input, versi model, serta hasil evaluasi petugas dapat disimpan untuk audit sesuai kebijakan privasi lembaga. Sistem harus menyediakan prosedur koreksi data dan peninjauan ulang hasil prediksi yang keliru.

3.5 Diskusi, Batasan, dan Implikasi

Hasil verifikasi menunjukkan bahwa Naive Bayes dapat diintegrasikan dalam SPK dengan proses komputasi yang sederhana. Temuan ini sejalan dengan literatur yang menjelaskan bahwa Bayesian classifier tetap dapat memberikan performa kompetitif meskipun menggunakan asumsi independensi fitur [7], [8].

Submitted: **17/09/2024**; Accepted: **28/12/2024**; Published: **28/01/2025**

JURNAL MEDIA INFORMATIKA BUDIDARMA
Volume 9, Nomor 1, Januari 2025, Page 09-14
ISSN 2614-5278 (media cetak), ISSN 2548-8368 (media online)
Available Online at https://ejurnal.stmik-budidarma.ac.id/index.php/mib
DOI 10.30865/mib.v9i1.8128

Kelebihan utama metode adalah kecepatan pelatihan dan prediksi, kebutuhan komputasi yang rendah, serta keluaran probabilitas yang dapat digunakan sebagai informasi pendukung. Namun, asumsi independensi antarfitur dapat menjadi keterbatasan ketika hubungan antarvariabel keuangan sangat kuat [9]-[11].

Proposal menetapkan tujuan untuk membandingkan sistem dengan metode tradisional. Perbandingan tersebut belum dapat dilakukan secara valid pada laporan ini karena file sumber tidak memuat data keputusan manual Credit Union Makmur dan hasil historis yang dapat dijadikan baseline. Evaluasi tersebut perlu dilakukan setelah dataset aktual tersedia.

Selain itu, model tidak boleh langsung digunakan untuk menolak calon peminjam hanya berdasarkan prediksi otomatis. Pihak Credit Union perlu memvalidasi atribut, memperhatikan kebijakan internal, mengevaluasi kesalahan False Positive dan False Negative, serta melakukan pengujian periodik apabila pola data berubah.

Selain asumsi independensi fitur, potensi keterbatasan mencakup ketidaksetaraan karakteristik data simulasi dengan data riil, kemungkinan perubahan pola peminjam, serta risiko bias akibat definisi label. Status pekerjaan sebagai kategori harus dikodekan secara sesuai; penggunaan angka kategori yang diperlakukan sebagai variabel kontinu Gaussian memerlukan justifikasi metodologis. Pada penelitian lanjutan, peneliti dapat mempertimbangkan varian Naive Bayes atau representasi fitur yang lebih tepat, kemudian membandingkan hasilnya dengan model dasar lain.

Dari segi pelaporan ilmiah, metode pengukuran waktu proses, uji black-box dengan skenario masukan-keluaran, rincian pembentukan data simulasi, serta data keputusan kredit tradisional belum dilengkapi. Karena itu, dokumen tidak menyimpulkan bahwa sistem telah meningkatkan akurasi, mengurangi kredit macet, atau mempercepat keputusan lembaga. Kesimpulan hanya menjangkau kelayakan prosedur verifikasi teknis pada data uji.

4. KESIMPULAN

Penelitian ini menggambarkan integrasi metode Gaussian Naive Bayes ke dalam rancangan sistem pendukung keputusan untuk analisis kelayakan kredit pada konteks Credit Union Makmur. Tujuh atribut peminjam dipakai sebagai variabel klasifikasi dan tahapan metode meliputi penyiapan data, pelatihan, prediksi, evaluasi, serta penyajian rekomendasi. Berdasarkan 600 catatan simulasi dengan pembagian 480 data training dan 120 data testing, skor yang dilaporkan adalah accuracy 76,67%, precision 78,79%, recall 78,79%, serta F1-score 78,79%. Hasil lima lipatan validasi silang menunjukkan rata-rata accuracy 80,50%. Temuan tersebut membuktikan bahwa prosedur klasifikasi dapat dicontohkan dalam skenario data uji, bukan bahwa model telah efektif digunakan secara operasional pada Credit Union Makmur. Berkas sumber tidak menyertakan riwayat pengajuan dan pembayaran aktual, hasil pembandingan dengan analisis manual, maupun bukti uji fungsional aplikasi secara terperinci. Karena itu, sebelum sistem dapat digunakan, lembaga perlu memvalidasi atribut dan label, menilai kesalahan prediksi menurut risiko, menguji keluaran aplikasi, serta menerapkan perlindungan data peminjam. Pengembangan lebih lanjut dianjurkan membandingkan Naive Bayes dengan metode lain pada protokol evaluasi yang sama, menerapkan pemeriksaan kestabilan model, dan menyediakan prosedur audit bagi keputusan petugas. Kewenangan persetujuan kredit harus tetap berada pada pengambil keputusan manusia.

REFERENCES

[1] J. Han, M. Kamber, and J. Pei, Data Mining: Concepts and Techniques, 3rd ed. San Francisco, CA, USA: Morgan Kaufmann, 2011.
[2] I. H. Witten, E. Frank, and M. A. Hall, Data Mining: Practical Machine Learning Tools and Techniques, 4th ed. Burlington, MA, USA: Morgan Kaufmann, 2016.
[3] T. M. Mitchell, Machine Learning. New York, NY, USA: McGraw-Hill, 1997.
[4] R. O. Duda, P. E. Hart, and D. G. Stork, Pattern Classification, 2nd ed. New York, NY, USA: Wiley, 2001.
[5] T. Hastie, R. Tibshirani, and J. Friedman, The Elements of Statistical Learning: Data Mining, Inference, and Prediction, 2nd ed. New York, NY, USA: Springer, 2009.
[6] S. B. Kotsiantis, "Supervised machine learning: A review of classification techniques," Informatica, vol. 31, no. 3, pp. 249–268, 2007.
[7] G. H. John and P. Langley, "Estimating Continuous Distributions in Bayesian Classifiers," in Proc. 11th Conf. Uncertainty in Artificial Intelligence, Montreal, Canada, 1995, pp. 338–345.
[8] D. J. Hand and K. Yu, "Idiot's Bayes – Not So Stupid after All?," International Statistical Review, vol. 69, no. 3, pp. 385–398, 2001.
[9] K. P. Murphy, Machine Learning: A Probabilistic Perspective. Cambridge, MA, USA: MIT Press, 2012.
[10] D. Koller and N. Friedman, Probabilistic Graphical Models: Principles and Techniques. Cambridge, MA, USA: MIT Press, 2009.
[11] C. M. Bishop, Pattern Recognition and Machine Learning. New York, NY, USA: Springer, 2006.
[12] C. C. Aggarwal, Data Classification: Algorithms and Applications. Boca Raton, FL, USA: CRC Press, 2014.
[13] J. Gama, Knowledge Discovery from Data Streams. Boca Raton, FL, USA: Chapman and Hall/CRC, 2010.
[14] H. Altay Guvenir and E. Muderrisoglu, "Learning naive bayesian classifiers for credit card fraud detection," in Proc. 12th International Symposium on Computer and Information Sciences, Antalya, Turkey, 1997, pp. 220–225.
[15] J. R. Quinlan, C4.5: Programs for Machine Learning. San Mateo, CA, USA: Morgan Kaufmann, 1993.

Submitted: **17/09/2024**; Accepted: **28/12/2024**; Published: **28/01/2025**