

## ANALISIS KREDIT PEMBAYARAN BIAYA KULIAH DENGAN PENDEKATAN PEMBELAJARAN MESIN

Arliyanti Nurdin\*<sup>1</sup>, Rizqa Amelia Zunaidi<sup>2</sup>, Muhammad Arkan Fauzan Wicaksono<sup>3</sup>, Agi Lobita Japtara Martadinata<sup>4</sup>

<sup>1,2,3,4</sup> Institut Teknologi Telkom Surabaya, Surabaya

Email: <sup>1</sup>arliyanti.n@ittelkom-sby.ac.id, <sup>2</sup>rizqazunaidi@ittelkom-sby.ac.id,

<sup>3</sup>muhammad.arkan.20@student.it.ittelkom-sby.ac.id, <sup>4</sup>agitaraagi@student.ittelkom-sby.ac.id

(Naskah masuk: 09 Mei 2022, diterima untuk diterbitkan: 10 April 2023)

### Abstrak

Salah satu tantangan dalam institusi keuangan adalah manajemen risiko kredit. Hal ini juga terjadi pada institusi pendidikan swasta dimana pengelolaan keuangan dilakukan secara mandiri serta sumber dana mayoritas berasal dari mahasiswa. Setiap institusi harus menjamin kesehatan finansial melalui monitoring *cashflow*. Adanya penundaan atau kredit pembayaran biaya kuliah mahasiswa akan mempengaruhi *cashflow* institusi. Oleh karena itu dibutuhkan analisis kredit sebagai tindakan preventif guna mencegah terjadinya kredit yang bermasalah dan meminimalkan risiko kredit lainnya yang timbul di kemudian hari. Pada penelitian ini, algoritma *machine learning* digunakan untuk analisis kredit pembayaran biaya kuliah pada perguruan tinggi. Dataset yang digunakan adalah data riwayat tagihan, transaksi pembayaran, dan data pengajuan kredit/ angsuran. Tahap perancangan sistem terdiri dari *preprocessing*, pemilihan fitur, pemodelan, pengujian dan evaluasi hasil. Berdasarkan hasil pengujian algoritma dengan kinerja terbaik adalah KNN dengan *recall* untuk prediksi “gagal bayar” sebesar 0,8 dan prediksi “berhasil” sebesar 0,76. Model *machine learning* ini kemudian ditanamkan dalam sebuah sistem informasi analisis kredit biaya kuliah. Selain itu juga sistem akan memberikan skor setiap pengajuan berdasarkan metode *scorecard*. Semakin tinggi skor kredit semakin kecil risiko gagal bayarnya. Skor kredit ini berkisar antara 250 – 600. Jika kredit yang diajukan diprediksi “gagal bayar” dengan skor kredit rendah atau berpotensi menjadi piutang macet, sistem akan merekomendasikan untuk menilik ulang skema pengajuan kredit dari mahasiswa tersebut agar mahasiswa tetap dapat melanjutkan pendidikan dan *cash collection ratio* tetap baik.

**Kata kunci:** analisis kredit, *credit scoring*, *machine learning*, *scorecard*, *cashflow*, keuangan.

## CREDIT ANALYSIS TUITION FEE PAYMENT WITH MACHINE LEARNING APPROACHES

### Abstract

*One of the challenges in financial institutions is credit risk management. This also occurs in private educational institutions where financial management is carried out independently and most of funding sources come from students. Each institution must ensure financial health through cashflow monitoring. Any delay or credit in paying student tuition fees will affect the institution's cashflow. Therefore, credit analysis is needed as a preventive measure to prevent non-performing loans and minimize other credit risks that arise in the future. In this study, machine learning algorithms are used for credit analysis for paying tuition fees activity at universities. The datasets used are billing history data, payment transactions, and credit/installment application data. The system design stage consists of preprocessing, feature selection, modeling, uji and evaluation of results. Based on the results of uji the algorithm with the best performance is KNN with a recall for the prediction of "failure to pay" of 0,8 and prediction of "success" of 0,76. This machine learning model is then embedded in a tuition credit analysis information system. In addition, the system will provide a score for each submission based on the scorecard method. The higher the credit score, the lower the risk of default. This credit score ranges from 250 – 600. If the proposed credit is predicted to be "in default" with a low credit score or has the potential to become bad debts, the system will recommend reviewing the student's credit application scheme so that students can continue their education and cash collection ratio remains good.*

**Keywords:** *credit analysis, credit scoring, machine learning, scorecard, cashflow, finance.*

## 1. PENDAHULUAN

Salah satu tantangan dalam institusi keuangan adalah manajemen risiko kredit. Hal ini juga terjadi pada institusi pendidikan swasta di mana pengelolaan keuangan dilakukan secara mandiri serta sumber dana mayoritas berasal dari mahasiswa. Setiap institusi harus menjamin kesehatan finansial melalui monitoring *cashflow*. Adanya penundaan atau kredit pembayaran biaya kuliah mahasiswa akan mempengaruhi *cashflow* institusi. Oleh karena itu dibutuhkan analisis kredit sebagai tindakan preventif guna mencegah terjadinya kredit yang bermasalah dan meminimalkan risiko kredit lainnya yang timbul di kemudian hari. Analisis kredit merupakan penilaian terhadap permohonan kredit baru, perpanjangan, maupun restrukturisasi layak atau tidak untuk diberikan. Biasanya seorang kredit analis akan melakukan pemeringkatan kelayakan dan risiko kredit yang diajukan dengan metode *Credit Risk Rating* (CRR). Hal ini tentunya sangat bergantung pada kepakaran seseorang dalam melakukan analisis kredit.

Saat ini pemanfaatan analisis data menggunakan *machine learning* sudah banyak diaplikasikan di bidang keuangan, di antaranya deteksi *fraud* kartu kredit (Varmedja et al., 2019), *trading* (Ritter, 2017), *credit scoring* (Dastile, Celik & Potsane, 2020), sistem rekomendasi produk keuangan (Barreau, 2020), *risk management* (Leo, Sharma & Maddulety, 2019), *money-laundering prevention* (Chen et al., 2018), dan sebagainya. Pemodelan *credit scoring* menggunakan algoritma *machine learning* beberapa di antaranya menggunakan algoritma *logistic regression* (Shen, Wang & Shen, 2019; Dumitrescu et al., 2022), *nearest neighbor* (Mukid et al., 2018), Bayesian (Abid et al., 2017), *artificial neural network* (Munkhdalai et al., 2019), *decision tree* (Damrongsakmethee & Neagoe, 2019; Liu, Fan & Xia, 2021), algoritma genetika (Zhang, He & Zhang, 2019), dan SVM (Goh & Lee, 2019).

Penggunaan algoritma *machine learning* sangat membantu dalam analisis data keuangan dengan efektif dan efisien. *Credit scoring* sebagai alat penilaian kredit otomatis yang telah digunakan oleh pemberi pinjaman seperti bank dan lembaga keuangan lainnya. Dengan demikian, permasalahan analisis kredit pembayaran biaya kuliah pada perguruan tinggi pun dapat diselesaikan dengan membangun sistem cerdas yang dapat menganalisis kelayakan kredit yang diajukan. Jika kredit yang diajukan berpotensi menjadi piutang macet, sistem akan merekomendasikan untuk menilik ulang skema pengajuan kredit dari mahasiswa tersebut agar mahasiswa tetap dapat melanjutkan pendidikan dan pembayaran biaya pendidikan lancar. Sistem ini dapat dibangun dengan pemodelan *machine learning* dari data transaksi pembayaran mahasiswa. Beberapa algoritma *machine learning* akan dibandingkan kinerjanya untuk mendapatkan model *machine learning* dengan kinerja terbaik yang akan digunakan pada sistem. Dengan sistem ini unit keuangan akan lebih mudah dalam melakukan *screening* awal terhadap

pengajuan kredit oleh mahasiswa dan dapat meminimalkan risiko penurunan *cash collection ratio*.

Berdasarkan kajian literatur yang telah dilakukan, penelitian ini adalah implementasi pertama kali analisis kredit pembayaran biaya kuliah di Perguruan Tinggi. Pada umumnya analisis kredit dilakukan di Lembaga Keuangan dengan menggunakan berbagai informasi keuangan pribadi yang lebih kompleks seperti FICO *score* atau riwayat kredit pada Sistem Informasi Debitur (SID).

## 2. METODE PENELITIAN

Penelitian yang dilakukan bertujuan untuk pemodelan *machine learning* untuk analisis kredit biaya kuliah mahasiswa. Model *machine learning* yang dibangun akan ditanamkan ke dalam sistem informasi kredit mahasiswa. Pada sistem informasi tersebut mahasiswa dapat mengajukan permohonan angsuran dengan memasukkan data-data yang dibutuhkan, kemudian sistem akan menghitung *score* kredit dari pengajuan untuk memberikan rekomendasi seberapa besar risiko jika kredit disetujui.

### 2.1 Data

Data histori kredit mahasiswa yang telah terkumpulkan sejumlah 393 yang terdiri dari data nomor induk mahasiswa, nama mahasiswa, nominal dan jatuh tempo kredit, serta nominal dan tanggal pembayaran. Dari data ini dapat dihitung keterlambatan pembayaran setiap kredit untuk kemudian dikategorikan ke dalam dua kategori yaitu kategori Bayar: 0 - 90 hari dan Gagal Bayar: >90 hari.

Selain data histori kredit, data profil mahasiswa juga dikumpulkan. Data tersebut terdiri dari data orang tua terkait pekerjaan, penghasilan, pendidikan, dan usia; jumlah anggota dalam keluarga; jumlah anak; dan usia masing-masing anak.

### 2.2 Preprocessing Data

Tahap *preprocessing* dilakukan sebelum tahap analisis atau pembentukan model *machine learning* terhadap data yang telah dikumpulkan. Tahap *preprocessing* di antaranya yaitu memilah data, membersihkan data (*missing value*, *outlier*, dll), memvalidasi data, dan mengkonstruksi data.

Proses memilah data dilakukan dengan menghapuskan data riwayat kredit mahasiswa yang telah berstatus *Drop Out*/ tidak aktif. Data yang diolah hanya data mahasiswa yang berstatus aktif saja, sehingga data berkurang dari 393 menjadi 377 data. Setelah data dipilah kemudian data dibersihkan dari format yang tidak konsisten, *missing value* dan *outlier*. *Missing value* adalah data yang kosong sedangkan *outlier* adalah data yang menyimpang terlalu jauh dari data yang lainnya dalam suatu kumpulan data (pencilan). Terdapat 34 data *outlier* yang dihapuskan dari kumpulan data. Transformasi data kemudian dilakukan untuk data numerik dan kategorik.

Tujuan transformasi data ini adalah untuk mengubah data menjadi skala yang berbeda, meningkatkan kecocokan data dengan asumsi yang mendasari pada proses pemodelan, memodifikasi rentang nilai, dan menormalkan suatu data. Teknik transformasi data yang digunakan yaitu *one hot encoder* untuk data kategorik dan normalisasi untuk data numerik. Selain itu, untuk mengatasi *imbalance* data karena data berlabel '0' lebih banyak dari data berlabel '1' maka diterapkan teknik *oversampling* SMOTE. Setelah dilakukan *oversampling*, data distandarisasi untuk menyamakan skala data.

### 2.3. Pelabelan Data

Setelah tahap *preprocessing* selesai, dilakukan tahap pelabelan data. Setiap profil kredit mahasiswa akan diberi label 0 jika kredit yang dimiliki berstatus "berhasil bayar" dan diberi label 1 jika kredit berstatus "gagal bayar". Keterlambatan pembayaran (*Day Past Due/DPD*) yang dihitung berdasarkan selisih antara tanggal pembayaran kredit dengan tanggal jatuh tempo kredit. Fitur ini digunakan sebagai label pada pemodelan. Jika hari jatuh tempo kurang dari 90 hari maka kredit akan berstatus "berhasil bayar", sebaliknya jika hari jatuh tempo adalah 90 hari atau lebih maka kredit berstatus "gagal bayar". Pelabelan ini dilakukan untuk setiap profil mahasiswa bukan setiap termin kredit yang dimiliki. Jika terdapat satu mahasiswa yang memiliki lebih dari satu termin kredit, maka status kredit akan diberikan berdasarkan hari jatuh tempo kredit yang terlama. Misalkan satu mahasiswa memiliki 3 termin kredit. Termin pertama memiliki DPD 0 hari, termin kedua memiliki DPD +50 hari, dan termin ketiga memiliki DPD -123 hari. Maka profil mahasiswa ini akan diberi label 1 atau "gagal bayar", karena memiliki 1 termin angsuran yang dibayarkan melebihi 90 hari. Pelabelan ini dilakukan untuk seluruh data kredit yang berjumlah 377 profil mahasiswa.

### 2.4. Pemilihan Fitur

Setelah pelabelan data, dilakukan pemilihan fitur-fitur yang akan digunakan untuk pemodelan. Fitur-fitur tersebut menggambarkan profil keluarga yang mempengaruhi kondisi ekonomi atau kemampuan untuk membayar kredit. Fitur yang digunakan terdaftar pada Tabel 1 berikut.

Tabel 1 Fitur yang Digunakan pada Pemodelan

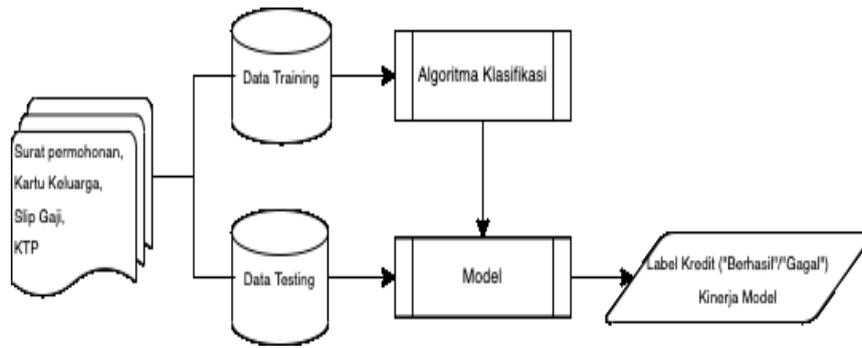
No	Fitur	Jenis	Keterangan
1	Penghasilan Ayah	Numerik	Penghasilan ayah yang diperoleh per bulan
2	Penghasilan Ibu	Numerik	Penghasilan ibu yang diperoleh per bulan
3	Total Penghasilan	Numerik	Total penghasilan ayah dan ibu per bulan
4	Pendidikan Ayah	Kategorik	Jenjang pendidikan ayah berdasarkan data pada Kartu Keluarga [Pegawai Negeri Sipil, Pegawai

No	Fitur	Jenis	Keterangan
			Swasta, Wirausaha, TNI, Pensiunan, Lainnya, Tidak Bekerja]
5	Pendidikan Ibu	Kategorik	Jenjang pendidikan ibu berdasarkan data pada Kartu Keluarga [Pegawai Negeri Sipil, Pegawai Swasta, Wirausaha, TNI, Pensiunan, Lainnya, Tidak Bekerja]
6	Status Pernikahan	Kategorik	Status pernikahan orang tua, bernilai 0 jika berstatus menikah dan 1 jika berstatus cerai.
7	Kematian Ayah	Kategorik	Bernilai 0 jika ayah masih hidup dan bernilai 1 jika ayah sudah meninggal
8	Kematian Ibu	Kategorik	Bernilai 0 jika ibu masih hidup dan bernilai 1 jika ibu sudah meninggal
9	Jumlah Anggota Kartu Keluarga	Numerik	Jumlah seluruh anggota keluarga yang tercatat dalam Kartu Keluarga.
10	Jumlah Anak	Numerik	Jumlah anak dari orang tua yang tercatat dalam Kartu Keluarga.
11	Rata-rata Usia Anak	Numerik	Jumlah usia semua anak dibagi dengan jumlah anak. Usia anak dihitung dengan cara mengurangkan tahun sekarang (2021) dengan tahun lahir anak.
12	Usia Ayah	Numerik	Usia ayah berdasarkan tahun lahir yang tercantum pada Kartu Keluarga/ KTP.
13	Usia Ibu	Numerik	Usia ibu berdasarkan tahun lahir yang tercantum pada Kartu Keluarga/ KTP.

### 2.5. Pemodelan Prediksi Gagal Bayar

Prediksi gagal bayar setiap pengajuan kredit, akan diberi label 0 untuk pengajuan kredit yang diprediksi berpotensi "berhasil bayar" dan label 1 untuk pengajuan yang diprediksi berpotensi "gagal bayar". Alur proses pemodelan prediksi gagal bayar pada Gambar 1 adalah sebagai berikut:

1. Data latih untuk pemodelan prediksi gagal bayar kredit berjumlah 264 data, terdiri dari 13 fitur dan label kredit (0/1). Fitur yang digunakan sebagaimana telah dijabarkan pada Gambar 1 diperoleh dari dokumen pengajuan kredit mahasiswa yaitu surat permohonan kredit (berisi identitas mahasiswa, alasan pengajuan kredit, dan termin kredit), kartu keluarga, slip gaji/ surat keterangan penghasilan, dan KTP orang tua. Sedangkan untuk data uji berjumlah 113 data yang terdiri dari 13 fitur yang tidak diberi label.



Gambar 1 Alur Proses Pemodelan Prediksi Gagal Bayar

2. Data latih dipelajari dengan menggunakan algoritma klasifikasi hingga menghasilkan model yang dapat digunakan untuk memprediksi label dari data uji.
3. Model yang dihasilkan dievaluasi kinerjanya, jika kinerja model masih rendah maka proses pembuatan model diulangi kembali dengan melakukan *fine tuning* parameter algoritma.

Beberapa algoritma *machine learning* yang digunakan untuk kasus klasifikasi pada penelitian ini dan dibandingkan kinerjanya adalah sebagai berikut.

1. *Decision Tree* (DT)

*Decision Tree* (Breiman, 1984) adalah metode pembelajaran terawasi non-parametrik yang dapat digunakan untuk klasifikasi dan regresi. DT mempelajari aturan keputusan sederhana dari fitur data sehingga menghasilkan model yang dapat memprediksi nilai variabel target. DT mengklasifikasikan data dengan mengambil suatu keputusan antara benar atau tidaknya suatu aturan. Cara untuk membangun DT dengan menggunakan perhitungan *Gini Impurity* atau *Information Gain*. Kedua fungsi tersebut akan mengukur kualitas dari percabangan pohon.

Indeks Gini diukur dengan mengurangi jumlah peluang kuadrat dari setiap kelas dari satu, sebaliknya, keuntungan informasi diperoleh dengan mengalikan probabilitas kelas dengan log (basis=2) dari probabilitas kelas tersebut.

*Gini Impurity* dihitung menggunakan rumus (3),

$$Gini = 1 - \sum_{i=1}^c (p_i)^2 \tag{3}$$

Sedangkan *Information Gain* (IG) dihitung menggunakan rumus (4),

$$IG = Entropy \text{ sebelum split} - Entropy \text{ setelah split} \tag{4}$$

Dimana entropy dihitung menggunakan rumus (5)

$$Entropy (P) = - \sum_{i=1}^n p_i \log_2(p_i) \tag{5}$$

Dengan  $(p_i)$  adalah probabilitas titik data dalam himpunan bagian dari  $D_i$  dari kumpulan data  $D$ .

2. Naive Bayes

Naïve Bayes (Murphy, 2006) adalah model probabilistik untuk klasifikasi. Pengklasifikasi Naïve Bayes menerapkan *Bayesian Rule*. Persamaan Naïve Bayes yang digunakan didefinisikan pada persamaan (6) dan (7) berikut.

$$P(y = bad | x) = \frac{p(x|y=bad)P(y=bad)}{p(x)} \tag{6}$$

dan

$$P(y = good | x) = \frac{p(x|y=good)P(y=good)}{p(x)} \tag{7}$$

Naïve Bayes akan memutuskan klasifikasi kelas  $y = bad$  jika

$$P(y = bad | x) \geq P(y = good | x) \tag{8}$$

3. AdaBoost Classifier

AdaBoost atau *Adaptive Boosting* (Freund & Schapire, 1997) adalah metode pembelajaran ansambel dimana beberapa pengklasifikasi digabungkan untuk meningkatkan akurasi. Pengklasifikasi dilatih secara berulang. Adaboost mengatur bobot dan sampel data latih di setiap iterasi sehingga meminimalkan kesalahan pelatihan dan prediksi lebih akurat.

4. *k-Nearest Neighbor* (KNN)

Metode KNN (Altman, 1992) menentukan kelas/label dari suatu data berdasarkan label dari data yang berada di sekitarnya. Tetangga terdekat ditentukan berdasarkan perhitungan *Euclidean distance* atau *Manhalonobis distance* antara input *feature vector*  $x$  dan dataset latih  $\{x_k\}_{k=1}^m$ . Kelas untuk data point baru berdasarkan persamaan (9) berikut.

$$y = \text{majority}_{y \in \{+1, -1\}} [\text{argmin}_k \|\{x_k\}_{k=1}^m - x\|] \tag{9}$$

2.6. Evaluasi Kinerja Model Prediksi

Evaluasi setiap algoritma menggunakan pengukuran *precision*, *recall*, dan *f-measure*.

a. *Precision*

*Precision* adalah rasio dari jumlah data positif yang diprediksi dengan benar terhadap jumlah total

hasil prediksi positif. *Precision* dihitung dengan persamaan (10) berikut.

$$precision = \frac{TP}{TP+FP} \quad (10)$$

#### b. Recall

*Recall* adalah rasio dari data positif yang diprediksi dengan benar terhadap jumlah data aktual yang bernilai positif. *Recall* dihitung dengan persamaan (11) berikut.

$$recall = \frac{TP}{TP+FN} \quad (11)$$

#### c. F-Measure

*F-measure* menghitung hubungan antara *Precision* dan *Recall* dengan persamaan (12) berikut.

$$F - Measure = 2 \frac{precision+recall}{precision+recall} \quad (12)$$

### 2.7. Credit Scoring dengan Metode Scorecard

*Credit Scoring* yaitu pemberian nilai skor pada pengajuan kredit menggunakan *scorecard methodology* dengan logistik regresi. Semakin tinggi skor kredit maka semakin kecil peluang gagal bayarnya. Metode ini banyak digunakan untuk *credit scoring* di Perbankan. Adapun keuntungan menggunakan metode *scorecard* (Naeem Siddiqi, 2012) adalah sebagai berikut:

1. Fleksibel, dapat menangani *missing value* dan *outlier* dengan baik.
2. Mengikuti persyaratan statistik karena *logistic regression* adalah sebuah distribusi logaritma.
3. Mudah digunakan karena tidak perlu membuat *dummy* variabel.
4. Memperlihatkan tren relasi yang jelas antara variabel dan “*bad customers*”.

*Weight of Evidence* (WoE) dan *Information Value* (IV) digunakan untuk rekayasa dan seleksi fitur pada pemodelan *credit scoring* metode *scorecard* (Naeem Siddiqi, 2012). WoE adalah ukuran kekuatan prediksi dari variabel independen dalam kaitannya dengan variabel target. WoE mengukur sejauh mana fitur tertentu dapat membedakan antara kelas target. Formula untuk menghitung WoE berdasarkan rumus (13) berikut.

$$WoE = \ln \ln \left( \frac{DistributionBad_i}{DistributionGood_i} \right) \quad (13)$$

Nilai WoE positif menyatakan proporsi *good customers* lebih besar dari *bad customers*. Sedangkan IV dihitung menggunakan persamaan (14) berikut.

$$IV = \sum (DistributionBad_i - DistributionGood_i) * \ln \ln \left( \frac{DistributionBad_i}{DistributionGood_i} \right) \quad (14)$$

Nilai IV pada *credit scoring* direpresentasikan pada Tabel 2 berikut:

Tabel 2 Representasi Nilai IV pada *Credit Scoring* (Naeem Siddiqi, 2012).

Information Value	Variable Predictiveness
< 0,02	Tidak berguna untuk prediksi
0,02 – 0,1	Lemah
0,1 – 0,3	Sedang
0,3 – 0,5	Kuat
>0,5	Sangat kuat

### 2.8. Evaluasi Model Scorecard

Evaluasi model *scorecard* menggunakan *Kolmogorov-Smirnov* (K-S), ROC, dan *Population Stability Index* (PSI).

#### a. Kolmogorov-Smirnov (K-S)

*Kolmogorov-Smirnov* (Massey, 1951) adalah pengujian normalitas yang membandingkan distribusi data (data yang akan diuji normalitasnya) dengan distribusi normal baku. K-S mengukur derajat pemisahan antara distribusi *good/* berhasil bayar dan *bad/* gagal bayar. Nilai K-S 100 jika model dapat dengan baik mengklasifikasikan kelas *good* dan *bad*. Pada model klasifikasi, umumnya K-S akan bernilai antara 0 hingga 100, minimum K-S adalah 20. K-S adalah metrik yang sangat populer digunakan dalam *credit scoring* (Fang & Chen, 2019).

#### b. ROC-AUC

Kurva ROC (Fawcett, 2006) menggambarkan kemampuan model dalam melakukan prediksi atau klasifikasi. Garis kurva yang semakin mendekati sudut kiri atas maka berarti kinerja model semakin baik dalam melakukan klasifikasi data. Area di bawah kurva ROC, yang disebut juga AUC, biasanya digunakan sebagai ukuran kualitas dari model klasifikasi. Pada umumnya, model klasifikasi memiliki nilai AUC antara 0.5 hingga 1. Nilai AUC 0.5 menunjukkan *random classifier*, sedangkan AUC bernilai 1 untuk *perfect classifier*.

*Receiver Operating Characteristic* (ROC) diperoleh dari perhitungan *True Positive Rate* (TPR) / *Sensitivity/ Recall* dan *True Negative Rate* (TNR) atau *Specificity*, dengan persamaan (15), (16), dan (17) berikut.

$$TPR = \frac{TP}{TP+FN} \quad (15)$$

$$Specificity = \frac{TN}{TN+FP} \quad (16)$$

$$FPR = 1 - Specificity = \frac{FP}{TN+FP} \quad (17)$$

#### c. Population Stability Index (PSI)

*Population Stability Index* (PSI) (Yurdakul, 2018) biasanya diimplementasikan untuk mengukur prospektif *customer* yang akan mengajukan aplikasi kredit apakah masih memiliki profil yang sama pada saat model dibuat. PSI melihat perubahan distribusi

data awal/ data latih dan data baru/ data uji. PSI dihitung menggunakan persamaan (18) berikut.

$$PSI = \sum((Actual\% - Expected\%) * \ln(\frac{Actual\%}{Expected\%})) \quad (18)$$

Dengan *Actual%* adalah jumlah nilai di setiap rentang populasi awal dibagi dengan nilai total populasi dan *Expected%* adalah jumlah nilai di setiap rentang populasi baru dibagi dengan nilai total populasi.

### 3. HASIL DAN PEMBAHASAN

#### 3.1. Hasil Evaluasi Model Prediksi

Tabel 3 berikut menunjukkan hasil evaluasi kinerja algoritma untuk setiap kelas. Berdasarkan ukuran *precision*, kinerja terbaik untuk kelas '0' adalah *logistic regression* dan kelas '1' adalah KNN. Nilai *F-Measure* terbaik untuk kelas '0' adalah *Logistik Regression* dan KNN, terbaik untuk kelas '1' adalah KNN. Dan nilai *recall* terbaik untuk kelas '0' adalah *logistic regression*, sedangkan *recall* terbaik kelas '1' adalah KNN.

Hal yang dihindari pada kasus analisis kredit adalah kredit yang berpotensi gagal bayar tetapi diprediksi kebalikannya yaitu berhasil bayar. Oleh karena itu, dari ketiga ukuran kinerja *precision*, *recall*, dan *f-measure*, yang menjadi perhatian adalah *recall* khususnya untuk kelas '1' atau gagal bayar. Dari Tabel 3 dapat dilihat bahwa kinerja KNN terbaik dengan *recall* 0,76 kelas '0' dan 0,8 kelas '1'.

KNN adalah algoritma non parametrik yang sederhana dan banyak digunakan pada kasus klasifikasi. KNN cocok digunakan pada dataset yang berukuran kecil seperti dataset yang digunakan pada penelitian ini. Pada tahap *preprocessing* telah dilakukan *feature scaling* sebelum mengimplementasikan algoritma KNN pada dataset sehingga dapat meningkatkan kinerja KNN dalam melakukan klasifikasi data.

Algoritma *logistic regression* dapat bekerja dengan baik pada data yang dapat dipisahkan secara linear sedangkan KNN dapat bekerja pada seluruh jenis data. KNN cenderung bekerja baik pada data dengan banyak *instance* dan berdimensi rendah. Dimensi data ditentukan dari jumlah fitur dataset yang digunakan. Pada penelitian ini fitur data berjumlah 13 fitur. Jumlah fitur ini masih dapat ditoleransi KNN untuk dapat memberikan kinerja yang baik dalam klasifikasi.

Tabel 3 Ukuran Kinerja Algoritma Prediksi setiap Kelas

Algoritma	Kelas	Precision	Recall	F-Measure
Logistik Regression	0	0,65	<b>0,91</b>	<b>0,76</b>
	1	<b>0,88</b>	0,58	0,7
Decision Tree	0	0,73	0,73	0,73
	1	0,77	0,77	0,77
Naïve Bayes	0	0,68	0,7	0,69
	1	0,73	0,71	0,72

Adaboost	0	0,73	0,77	0,75
	1	0,79	0,76	0,77
KNN	0	<b>0,77</b>	0,76	<b>0,76</b>
	1	0,79	<b>0,8</b>	<b>0,8</b>

#### 3.2. Evaluasi Model Scorecard

Evaluasi model *scorecard* menggunakan *Kolmogorov-Smirnov* (K-S), ROC, dan *Population Stability Index* (PSI).

##### a. Kolmogorov-Smirnov (K-S)

Gambar 2 menunjukkan hasil evaluasi model *scorecard* yang diperoleh pada penelitian. Nilai K-S menyatakan perbedaan maksimum antara distribusi kumulatif *good* dan distribusi kumulatif *bad* pada rentang tertentu. Pada grafik nilai K-S dihitung berdasarkan jarak terjauh antara garis *bad* dan *good*. Hasil perhitungan K-S dari setiap distribusi data dapat dilihat pada grafik berwarna biru. Nilai K-S, derajat pemisahan maksimum antara *bad* dan *good*, ditunjukkan pada puncak grafiknya. Nilai K-S pada data latih adalah 0,4164 dan pada data uji 0,5261. Hasil ini sudah cukup baik, melebihi nilai minimum K-S.

##### b. ROC-AUC

Pada kurva ROC sumbu x adalah FPR dan sumbu y adalah sebaran data. Gambar 3 menunjukkan hasil ROC-AUC model *scorecard*. Nilai AUC untuk data latih adalah 0,7492 dan data uji 0,7976. Nilai ini menunjukkan akurasi klasifikasi yang cukup baik, dengan kemampuan di atas 70% dapat membedakan antara kelas positif dan negatif atau kelas *bad* dan *good*.

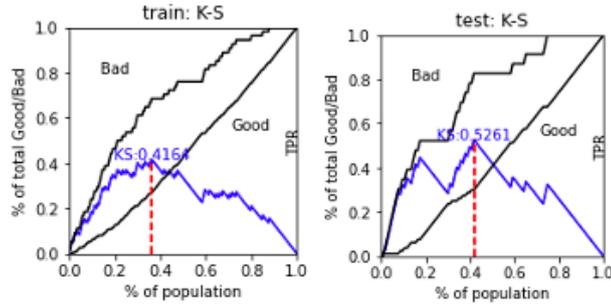
##### c. Population Stability Index (PSI)

Hasil dari PSI diinterpretasikan sebagai berikut.

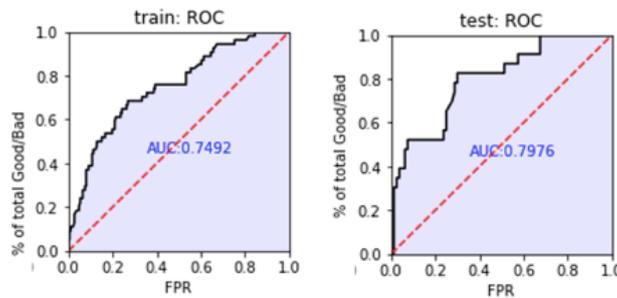
- Jika  $PSI \leq 0,1$ , berarti tidak ada perubahan (tidak perlu mengubah model)
- Jika  $PSI 0,1-0,25$ , berarti terdapat perubahan kecil (tetapi masih tidak perlu mengubah model)
- Jika  $PSI > 0,25$ , berarti terdapat perubahan yang signifikan.

Nilai PSI model *scorecard* pada penelitian ini adalah 0,1669, dapat dilihat Gambar 4. Nilai ini menyatakan perubahan distribusi data latih dan data uji kecil sehingga tidak perlu mengubah model.

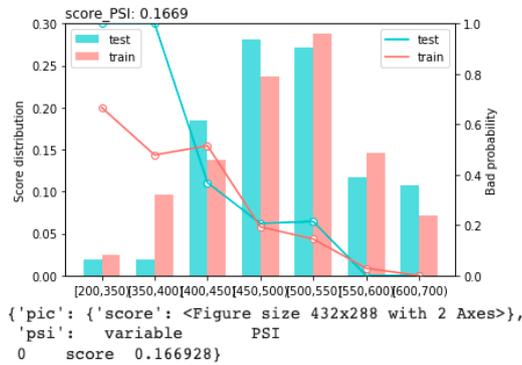
Berdasarkan grafik pada Gambar 4, semakin rendah *score* kredit pada sumbu x maka semakin tinggi kemungkinan untuk gagal bayar pada sumbu y. Di mana rentang *score* kredit dari 250 hingga 600.



Gambar 2 K-S Data Latih dan Data Uji Model Scorecard



Gambar 3 ROC-AUC Data Latih dan Data Uji Model Scorecard



Gambar 4 PSI Model Scorecard

Username Logout

Dashboard / Daftar Kredit

Data Table Pengajuan

Show 10 entries Search:

No	ID Pengajuan	Nama Mahasiswa	NIM	Semester	Nominal	score	rekomendasi	Status	Aksi
1	010103	Burhan	23517 01	3	6.500.000	500	diterima	Submitted	Detail   Delete   Surat Pengajuan
2	010104	Ardi	23517 03	3	3.500.000	553	diterima	Submitted	Detail   Delete   Surat Pengajuan
3	010105	Doni	23517 02	5	6.400.000	280	ditolak	Submitted	Detail   Delete   Surat Pengajuan

Gambar 5 Halaman Daftar Pengajuan Kredit – Skor Kredit dan Rekomendasi Sistem

### 3.3. Sistem Informasi Analisis Kredit Biaya Kuliah

Tampilan sistem informasi analisis kredit biaya kuliah yang telah dilengkapi dengan algoritma *machine*

*learning* dengan kinerja terbaik yaitu KNN, dapat dilihat pada Gambar 5. Sistem dapat memberikan rekomendasi setiap pengajuan kredit apakah diterima

atau ditolak berdasarkan hasil prediksi dari algoritma KNN terhadap status kredit “berhasil” atau “gagal bayar”. Jika prediksi “berhasil” maka rekomendasi sistem adalah “diterima”, sebaliknya jika prediksi “gagal bayar” maka rekomendasi sistem adalah “ditolak”. Selain itu juga sistem akan memberikan skor setiap pengajuan berdasarkan metode *scorecard* yang telah ditanamkan pada sistem. Semakin tinggi skor kredit semakin kecil risiko gagal bayarnya. Skor kredit ini berkisar antara 250 – 600. Jika rekomendasi kredit “ditolak” maka perlu menilik ulang skema pengajuan kredit dari mahasiswa tersebut.

#### 4. KESIMPULAN

Pada penelitian ini, algoritma *machine learning* digunakan untuk analisis kredit melalui prediksi gagal bayar pada setiap permohonan kredit biaya kuliah. Fitur yang dapat digunakan dari dokumen slip gaji orang tua, Kartu Keluarga dan KTP di antaranya data orang tua (penghasilan, pendidikan, usia, status pernikahan, status kematian), jumlah anggota keluarga, jumlah anak, dan rata-rata usia anak.

Ukuran kinerja model *machine learning* pada kasus ini yang diprioritaskan adalah berdasarkan nilai *recall* pada kelas “1” yang mewakili kelas gagal bayar. Semakin tinggi nilai *recall* maka semakin kecil *false negative* yang terjadi. Dengan demikian kesalahan memprediksi gagal bayar sebagai berhasil bayar semakin sedikit. Berdasarkan hasil pengujian algoritma dengan kinerja terbaik adalah KNN dengan *recall* untuk prediksi “gagal bayar” sebesar 0,8 dan prediksi “berhasil” sebesar 0,76. Model *machine learning* ini kemudian ditanamkan dalam sebuah sistem informasi analisis kredit biaya kuliah. Algoritma *machine learning* untuk memberikan hasil prediksi status kredit “berhasil” atau “gagal bayar”. Selain itu juga sistem akan memberikan skor setiap pengajuan berdasarkan metode *scorecard* yang telah ditanamkan pada sistem. Semakin tinggi skor kredit semakin kecil risiko gagal bayarnya. Skor kredit ini berkisar antara 250 – 600. Jika kredit yang diajukan diprediksi “gagal bayar” dengan skor kredit rendah atau berpotensi menjadi piutang macet, sistem akan merekomendasikan untuk menilik ulang skema pengajuan kredit dari mahasiswa tersebut agar mahasiswa tetap dapat melanjutkan pendidikan dan cash collection ratio tetap baik.

Pada penelitian ini jumlah data histori kredit masih sedikit, sehingga untuk pengembangan penelitian selanjutnya, data histori kredit dan fitur untuk membangun model prediksi dapat ditambahkan seperti data kepemilikan rumah dan kendaraan, tagihan listrik dan PDAM, PBB atau biaya sewa rumah per bulan, serta kredit lainnya yang dimiliki. Fitur tambahan ini berpotensi dapat meningkatkan kinerja algoritma dalam menganalisis kredit apakah berpotensi gagal bayar atau tidak. Pada penelitian ini, fitur-fitur tersebut tidak dapat ditambahkan karena keterbatasan data. Selain penambahan fitur, pada penelitian selanjutnya juga dapat membandingkan algoritma pembelajaran mesin

seperti SVM, dan algoritma pembelajaran lainnya yang belum dilakukan saat ini.

#### DAFTAR PUSTAKA

- ABID, L., ZAGHDENE, S., MASMOUDI, A. & Ghorbel, S.Z., 2017. Bayesian Network Modeling: A Case Study of Credit Scoring Analysis of Consumer Loans Default Payment. *Asian Economic and Financial Review*, 7(9), pp.846–857. <https://doi.org/10.18488/journal.aefr.2017.79.846.857>.
- ALTMAN, N.S., 1992. An introduction to kernel and nearest-neighbor nonparametric regression. *American Statistician*, 46(3), pp.175–185. <https://doi.org/10.1080/00031305.1992.10475879>.
- BARREAU, B., 2020. *Machine Learning for Financial Products Recommendation*. [online] Available at: <<https://tel.archives-ouvertes.fr/tel-02974918>>.
- BREIMAN, L., J.H.F.R.A.O. & C.J.STONE., 1984. *Classification and Regression Trees*. Belmont, CA: Wadsworth International Group.
- CHEN, Z., VAN KHOA, L.D., TEOH, E.N., NAZIR, A., KARUPPIAH, E.K. & LAM, K.S., 2018. Machine learning techniques for anti-money laundering (AML) solutions in suspicious transaction detection: a review. *Knowledge and Information Systems*, 57(2), pp.245–285. <https://doi.org/10.1007/s10115-017-1144-z>.
- DAMRONGSAKMETHEE, T. & NEAGOE, V.-E., 2019. Principal Component Analysis and ReliefF Cascaded with Decision Tree for Credit Scoring. pp.85–95. [https://doi.org/10.1007/978-3-030-19810-7\\_9](https://doi.org/10.1007/978-3-030-19810-7_9).
- DASTILE, X., CELIK, T. & POTANE, M., 2020. Statistical and machine learning models in credit scoring: A systematic literature survey. *Applied Soft Computing*, 91, p.106263. <https://doi.org/10.1016/j.asoc.2020.106263>.
- DUMITRESCU, E., HUÉ, S., HURLIN, C. & TOKPAVI, S., 2022. Machine learning for credit scoring: Improving logistic regression with non-linear decision-tree effects. *European Journal of Operational Research*, 297(3), pp.1178–1192. <https://doi.org/10.1016/j.ejor.2021.06.053>.
- FANG, F. & CHEN, Y., 2019. A new approach for credit scoring by directly maximizing the Kolmogorov–Smirnov statistic. *Computational Statistics and Data Analysis*, 133, pp.180–194. <https://doi.org/10.1016/j.csda.2018.10.004>.
- FAWCETT, T., 2006. An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), pp.861–874. <https://doi.org/10.1016/j.patrec.2005.10.010>.

- FREUND, Y. & SCHAPIRE, R.E., 1997. *A Decision-Theoretic Generalization of on-Line Learning & an Application to Boosting*.
- GOH, R.Y. & LEE, L.S., 2019. Credit Scoring: A Review on Support Vector Machines and Metaheuristic Approaches. *Advances in Operations Research*, 2019, pp.1–30. <https://doi.org/10.1155/2019/1974794>.
- HARRIS, T., 2015. Credit scoring using the clustered support vector machine. *Expert Systems with Applications*, 42(2), pp.741–750. <https://doi.org/10.1016/j.eswa.2014.08.029>.
- LEO, M., SHARMA, S. & MADDULETY, K., 2019. Machine learning in banking risk management: A literature review. *Risks*, 7(1). <https://doi.org/10.3390/risks7010029>.
- LIU, W., FAN, H. & XIA, M., 2021. Step-wise multi-grained augmented gradient boosting decision trees for credit scoring. *Engineering Applications of Artificial Intelligence*, 97, p.104036. <https://doi.org/10.1016/j.engappai.2020.104036>.
- MASSEY, F.J., 1951. The Kolmogorov-Smirnov Test for Goodness of Fit. *Journal of the American Statistical Association*, 46(253), pp.68–78. <https://doi.org/10.1080/01621459.1951.10500769>.
- MUKID, M.A., WIDIHARIH, T., RUSGIYONO, A. & PRAHUTAMA, A., 2018. Credit scoring analysis using weighted k nearest neighbor. In: *Journal of Physics: Conference Series*. Institute of Physics Publishing. <https://doi.org/10.1088/1742-6596/1025/1/012114>.
- MUNKHDALAI, L., WANG, L., PARK, H.W. & RYU, K.H., 2019. Advanced Neural Network Approach, Its Explanation with LIME for Credit Scoring Application. pp.407–419. [https://doi.org/10.1007/978-3-030-14802-7\\_35](https://doi.org/10.1007/978-3-030-14802-7_35).
- MURPHY, K.P., 2006. *Naive Bayes classifiers*.
- NAEEM SIDDIQI, 2012. *Credit risk scorecards: developing and implementing intelligent credit scoring*. John Willey & Sons.
- RITTER, G., 2017. *MACHINE LEARNING FOR TRADING*. [online] Available at: <<https://ssrn.com/abstract=3015609>>.
- SHEN, F., WANG, R. & SHEN, Y., 2019. A COST-SENSITIVE LOGISTIC REGRESSION CREDIT SCORING MODEL BASED ON MULTI-OBJECTIVE OPTIMIZATION APPROACH. *Technological and Economic Development of Economy*, 26(2), pp.405–429. <https://doi.org/10.3846/tede.2019.11337>.
- VARMEDJA, D., KARANOVIC, M., SLADOJEVIC, S., ARSENOVIC, M. & ANDERLA, A., 2019. Credit Card Fraud Detection - Machine Learning methods. In: *2019 18th International Symposium INFOTEH-JAHORINA* (INFOTEH). IEEE. pp.1–5. <https://doi.org/10.1109/INFOTEH.2019.8717766>.
- WRIGHT, R.E., 1995. Logistic regression. In: *In L. G. Grimm & P. R. Yarnold (Eds.), Reading and understanding multivariate statistics*. American Psychological Association. pp.217–244.
- YURDAKUL, B., 2018. *STATISTICAL PROPERTIES OF POPULATION STABILITY INDEX*.
- ZHANG, W., HE, H. & ZHANG, S., 2019. A novel multi-stage hybrid model with enhanced multi-population niche genetic algorithm: An application in credit scoring. *Expert Systems with Applications*, 121, pp.221–232. <https://doi.org/10.1016/j.eswa.2018.12.020>.

*Halaman ini sengaja dikosongka*