

Implementasi Algoritma Klasifikasi Naïve Bayes Untuk Klasifikasi Credit Scoring Pada Platform Peer-To-Peer Lending

Joel Rayapoh Damanik^{1,*}, Rahmat Fauzi², Faqih Hamami³

Fakultas Rekayasa Industri, Program Studi Sistem Informasi, Universitas Telkom, Bandung, Indonesia

Email: ^{1,*}joeldamanik@student.telkomuniversity.ac.id, ²rahmatfauzi@telkomuniversity.ac.id,

³faqihhamami@telkomuniversity.ac.id

Correspondence Author Email: joeldamanik@student.telkomuniversity.ac.id

Submitted: 10/08/2023; Accepted: 25/08/2023; Published: 25/08/2023

Abstrak—Di Indonesia, seiring dengan pertumbuhan *fintech* mengenai *P2P lending*, juga timbul *P2P lending* ilegal yang beroperasi tanpa izin dari otoritas berwenang. Diperkirakan terdapat sekitar 400 perusahaan *fintech* ilegal yang beroperasi di Indonesia. Masalah umum yang dihadapi oleh platform *P2P lending* adalah ketidakmampuannya mengantisipasi pembayaran yang gagal oleh peminjam. Hal ini disebabkan oleh tingginya suku bunga yang diterapkan dan kurangnya seleksi terhadap peminjam dengan risiko kredit yang tinggi atau rendah. Untuk mengatasi masalah ini, diperlukan pengembangan model sistem *Machine Learning* yang dapat mengklasifikasikan data peminjam dan terintegrasi dengan informasi dari lembaga keuangan lainnya. Tujuannya adalah untuk menyaring calon peminjam dengan risiko kredit yang tinggi atau rendah. Salah satu model yang digunakan adalah algoritma *Naïve Bayes Classifier*. Metode ini berdasarkan teorema Bayes dan merupakan algoritma yang memproses klasifikasi sederhana dengan independensi variabel. Penggunaan algoritma *Naïve Bayes Classifier* diharapkan dapat menciptakan sistem yang membantu platform *P2P lending* dalam seleksi calon peminjam. Model ini akan memprediksi risiko kredit rendah atau tinggi bagi pengguna atau pelanggan *P2P lending*. Untuk mencapai performa klasifikasi optimal, dilakukan tuning hyperparameter pada setiap simulasi. *Hyperparameter tuning* adalah proses mencari nilai terbaik untuk parameter dalam model machine learning guna meningkatkan performa. Pada algoritma GaussianNB, parameter yang dituning adalah *var_smoothing*. Hasil tuning hyperparameter terbaik ditemukan dengan nilai *var_smoothing* sebesar 0.009638958856642498, dengan pembagian *train_size* dan *test_size* sebesar 70:30. Dengan konfigurasi ini, model mencapai tingkat akurasi sebesar 95%.

Kata Kunci: Fintech; Peer-to-Peer Lending; Naïve Bayes Classifier; Credit Score; Hyperparameter Tuning

Abstract—In Indonesia, along with the growth of fintech regarding P2P lending, illegal P2P lending has also emerged that operates without permission from the authorities. It is estimated that around 400 illegal fintech companies are operating in Indonesia. A common problem faced by P2P lending platforms is their inability to anticipate failed payments by borrowers. This is due to the high-interest rates and the need to select borrowers with high or low credit risk. To overcome this problem, it is necessary to develop a Machine Learning system model to classify borrower data and integrate it with information from other financial institutions. The aim is to screen potential borrowers with high or low credit risk. One of the models used is the Naïve Bayes Classifier algorithm. This method is based on Bayes' theorem and is an algorithm that processes a simple classification with variable independence. Using the Naïve Bayes Classifier algorithm is expected to create a system that helps P2P lending platforms select prospective borrowers. This model will predict low or high credit risk for P2P lending users or customers. To achieve optimal classification performance, hyperparameter tuning is performed in each simulation. Hyperparameter tuning finds the best parameter values in a machine-learning model to improve performance. In the GaussianNB algorithm, the parameter to be tuned is *var_smoothing*. The best hyperparameter tuning results were found with a *var_smoothing* value of 0.009638958856642498, with a *train_size* and *test_size* division of 70:30. With this configuration, the model achieves an accuracy rate of 95%.

Keywords: Fintech; Peer-to-Peer Lending; Naïve Bayes Classifier; Credit Score; Hyperparameter Tuning

1. PENDAHULUAN

Menurut laporan[1] berjudul *The Pulse of Fintech 2018* menyebutkan bahwa Asia Tenggara menjadi target pertumbuhan fintech dan ekspansi global. Banyak perusahaan fintech terutama perusahaan fintech yang berasal dari China melihat Asia Tenggara sebagai pasar yang besar. Beberapa perusahaan besar China melakukan investasi secara global di banyak negara[2]. Mayoritas bank di China juga mulai fokus pada digital dan telah menyebabkan pertumbuhan pesat bisnis berorientasi fintech. Mereka berinvestasi di banyak bidang termasuk big data, blockchain, dan kecerdasan buatan [3]. Fenomena ini tidak mengherankan karena China memiliki pertumbuhan layanan keuangan digital yang fenomenal [4] dengan jumlah P2P Lending terbesar di dunia.

Industri P2P Lending di Indonesia menghadapi tantangan yang tak kalah menarik dibandingkan dengan metode tradisional dalam membentuk kredit[5]. P2P Lending di Indonesia masih mengalami kesulitan dalam mendapatkan data kredit atau informasi keuangan konsumen, yang berbeda dengan lembaga keuangan lainnya. Hal ini mengakibatkan keterbatasan data dalam menilai kelayakan kredit[6]. Namun, data dari media sosial tidak secara jelas menggambarkan konten terkait masalah kredit, seperti dalam teks pendek yang seringkali tidak mencakup data statistik yang memadai untuk mendukung berbagai permasalahan[7]. Pandangan tersebut juga didukung oleh pendapat yang menyatakan bahwa data dari media sosial cenderung memberikan informasi yang tidak relevan terkait dengan kredit, sehingga menjadi tantangan besar dalam menentukan kelayakan kredit[8].

Dan pada beberapa penelitian sebelumnya seperti yang dilakukan oleh Sumanto, dkk pada tahun 2021 dimana hasil penelitian yang dilakukan menunjukkan bahwa penerapan Naïve Bayes digunakan untuk

menentukan layak tidaknya sebuah pengajuan kredit rumah dengan menggunakan data training sebanyak 50 dan data testing sebanyak 15 data secara random dan hasil pengujian akurasi cukup tinggi yaitu senilai 80%[9].

Dalam penelitian yang dilakukan oleh Eko Arif Riyanto, dkk pada tahun 2021 yaitu untuk menentukan metode terbaik untuk klasifikasi kelayakan kredit koperasi menggunakan software Rapidminer dengan membandingkan perhitungan algoritma CART, Naïve Bayes berbasis Particle Swarm Optimization dengan menggunakan 113 data anggota koperasi dan mendapatkan hasil nilai *accuracy* 96,43%, nilai *recall* 94,12%, nilai *precision* 100%[10].

Kemudian pada penelitian yang dilakukan oleh Subarkah, dkk pada tahun 2018 yang berjudul “*Improving The Accuracy of Naive Bayes Algorithm for Hoax Classification Using Particle Swarm Optimization*” yang bertujuan untuk mendeteksi berita hoax yang tersebar dengan mengklasifikasi text dari lebih dari 600 dokumen, hasil akurasi yang didapatkan yaitu akurasi bertambah dengan menggunakan PSO dari 91,17% menjadi 92,33%[11].


Dan pada penelitian yang dilakukan oleh Nurajijah, dkk pada tahun 2019 yang dimana penelitian ini bertujuan untuk melakukan klasifikasi data histori pinjaman nasabah koperasi syariah menggunakan algoritma *Naïve Bayes*, *Decision Tree* dan *SVM* untuk memprediksi kredibilitas calon nasabah berikutnya yang dimana hasil akurasi dari penelitian ini menunjukkan algoritma *Naïve Bayes* 77,29%, *Decision Tree* 89,02% dan *Support Vector Machine* 89,86%[12].

Oleh karena itu peneliti melakukan penelitian ini dengan menggunakan metode *Naïve Bayes Classification* yang dimana metode ini sudah sering dipakai dibandingkan dengan metode klasifikasi lainnya, dan juga metode ini memiliki tingkat efektivitas yang tinggi dan dapat bekerja pada tipe variabel input diskrit atau kategoris yang dapat dilakukan pada penelitian ini[13]. Dan tujuan utama dari penelitian ini adalah untuk menentukan nilai kelayakan kredit atau credit score dari calon peminjam untuk pengambilan keputusan lender dalam memberikan pinjaman yang ada pada platform peer-to-peer lending amanah dengan menggunakan dataset dari platform peer-to-peer lending lendingclub.com.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Tahapan penelitian merupakan pangkaidan langkah atau prosedur yang diikuti oleh seorang peneliti untuk merencanakan, melaksanakan, dan menyelesaikan sebuah penelitian. Dengan adanya tahapan penelitian, langkah-langkah yang dijalankan dalam penelitian menjadi sejalan dengan proses yang ditetapkan. Pada Gambar 1 dijelaskan beberapa tahapan penelitian yang dilakukan oleh peneliti dalam melakukan penelitian ini yaitu dari tahap Data Preparation hingga Deployment Model



Gambar 1. Tahapan Penelitian

Pada Gambar 1 digambarkan tahapan penelitian yang dilakukan peneliti sebagai berikut:

1. Perumusan Masalah, pada tahap ini peneliti menentukan masalah yang akan dijadikan menjadi bahan penelitian dari berbagai sumber seperti dari artikel, buku, ataupun dari sumber lainnya.

2. Pengumpulan Data, pada tahap ini peneliti melakukan pengumpulan data dari platform lendingclub yang merupakan platform peer-to-peer lending yang berasal dari luar negeri.
3. Data Preparation, pada tahap ini peneliti menyeleksi atribut data yang akan digunakan pada tahap preprocessing nantinya
4. Data Preprocessing, pada tahap ini peneliti melakukan pembersihan data yang dimana peneliti menghapus data yang sama atau duplikat kemudian memeriksa data yang inkonsisten yang dimana data yang memiliki *missing value* pada atributnya, kemudian melakukan transformasi data yang sifatnya numerikal dan kategorikal sesuai dengan kebutuhan penelitian ini.
5. Modelling Data, pada tahap ini peneliti mendapatkan model atau pola dari sekumpulan data besar dengan menggunakan berbagai teknik untuk memprediksi hasil.
6. Evaluasi Model, pada tahap ini peneliti melakukan pengecekan nilai akurasi, presisi, dan recall. Akurasi adalah metrik yang mengukur seberapa banyak prediksi yang benar dari seluruh data yang diprediksi. Adapun persamaan dari akurasi adalah sebagai berikut.

$$Accuracy = \frac{TP}{Jumlah\ Data} \quad (1)$$

Kemudian untuk rumus mencari precision, recall, f1-score dari setiap kelas adalah sebagai berikut:

$$Precision = \frac{TP}{(TP+FP)} \quad (2)$$

$$Recall = \frac{TP}{(TP+FN)} \quad (3)$$

$$F1-score = \frac{2 \times precision \times recall}{precision+recall} \quad (4)$$

7. Deployment Model, pada tahap ini peneliti melakukan pengintegrasian model algoritma klasifikasi yang sudah dibuat pada tahapan sebelumnya terhadap platform peer-to-peer lending yang sudah didevelop dengan sistem API.

2.2 Data Mining

Data mining adalah studi tentang mengumpulkan, membersihkan, memproses, menganalisis, dan mendapatkan wawasan yang berguna dari data [14]. Ada variasi yang luas dalam hal domain masalah, aplikasi, formulasi, dan representasi data yang ditemui dalam aplikasi nyata. Oleh karena itu, data mining adalah istilah umum yang digunakan untuk menggambarkan berbagai aspek pemrosesan data [15]. Dari hasil data mining akan mendapatkan informasi-informasi penting yang dimana hasil dari informasi tersebut dapat dijadikan pengembangan ke proses selanjutnya

2.3 Naïve Bayes Classifier

Naïve Bayes Classifier adalah model independen yang menangani klasifikasi sederhana berdasarkan teorema probabilitas Bayes [16]. Probabilitas Bayesian dinamai oleh Thomas Bayes, seorang teolog abad kedelapan belas. Probabilitas Bayesian memungkinkan pengetahuan dan logika sebelumnya diterapkan pada pernyataan yang tidak pasti. Ada interpretasi lain yang disebut probabilitas frekuensi, yang hanya menarik kesimpulan dari data dan tidak memungkinkan logika dan pengetahuan sebelumnya. Naïve bayes adalah algoritma yang dapat mengklasifikasikan variabel tertentu menggunakan metode probabilistik dan statistik. Yang dimana naïve bayes adalah bagian dari bayesian decision theory.

$$P(C|X) = \frac{P(c)P(x|c)}{P(x)} \quad (5)$$

3. HASIL DAN PEMBAHASAN


3.1 Data Preparation

Pada tahap ini dilakukan pencarian data yang berkaitan dengan studi kasus yang diambil, yaitu kumpulan data pengguna pinjaman online. Klasifikasi yang dilakukan adalah kelayakan kredit peminjam berdasarkan beberapa atribut yang penting seperti emp_title, emp_length, homeownership, dll.

emp_title	emp_length	state	homeownership	annual_income	verified_income	debt_to_income	annual_income_joint	verification_income_joint	debt_to_income_joint	delinq
global config	3	NJ	MORTGAGE	90000	Verified	18.01	NA			NA
warehouse o	10	HI	RENT	40000	Not Verified	5.04	NA			NA
assembly	3	WI	RENT	40000	Source Verified	21.15	NA			NA
customer sei	1	PA	RENT	30000	Not Verified	10.16	NA			NA
security supe	10	CA	RENT	35000	Verified	57.96		57000	Verified	37.66
NA		KY	OWN	34000	Not Verified	6.46	NA			NA
hr	10	MI	MORTGAGE	35000	Source Verified	23.66		155000	Not Verified	13.12
police	10	AZ	MORTGAGE	110000	Source Verified	16.19	NA			NA

Gambar 2. Sample Data

Pada Gambar merupakan data yang didapatkan dari salah satu platform peer-to-peer lending yaitu lendingclub dengan jumlah data sampai dengan 10000 records dan kolom dengan jumlah 112. Pada tahapan ini dilakukan pemilihan atribut yang akan digunakan untuk pengklasifikasian kredit scoring peminjaman. Namun sebelum melakukan pemilihan atribut, dilakukan kolerasi secara linear dari setiap atribut terhadap atribut grade yang akan menjadi atribut target.



Gambar 3. Heatmap Korelasi Atribut Grade Terhadap Atribut Lainnya

Hasil Heatmap pada Gambar dapat disimpulkan bahwa nilai korelasi linear antara atribut grade dan atribut lainnya yang terbesar adalah interest_rate, term, paid_interest, term, debt_to_income. Berdasarkan hasil korelasi tersebut dapat menentukan untuk memilih atribut debt_to_income, interest_rate, term karena atribut tersebut yang memungkinkan untuk digunakan dengan mempertimbangkan atribut yang akan diterima nantinya dari platform peer-to-peer lending. Berikut hasil dari seleksi atribut ada pada Tabel 1.

Tabel 1. Seleksi Atribut

Atribut	Deskripsi
<i>homeownership</i>	Tipe kepemilikan rumah peminjam
<i>annual_income</i>	Pendapatan tahunan peminjam
<i>debt_to_income</i>	Rasio hutang terhadap pendapatan peminjam
<i>loan_purpose</i>	Tujuan peminjaman
<i>loan_amount</i>	Jumlah peminjaman
<i>balance</i>	Saldo yang belum dilunasi pada pinjaman yang sedang berlangsung atau saldo yang tersisa dalam akun peminjam setelah pembayaran atau penarikan dana dilakukan.
<i>term</i>	Jumlah bulan pinjaman yang diterima pemohon.
<i>interest_rate</i>	Suku bunga peminjaman
<i>grade</i>	Penilaian <i>credit score</i>

3.2 Data Preprocessing

Pada tahap ini dilakukan beberapa proses, yaitu proses data cleaning dan data transformation. Pada proses data cleaning dilakukan tahap data cleaning untuk mengisi ataupun membuang nilai yang hilang pada atribut. Kemudian pada proses data transformation adalah proses mengubah data mentah menjadi bentuk atau representasi yang lebih sesuai dan siap untuk dianalisis lebih lanjut. Tujuan utama dari data transformation adalah untuk meningkatkan kualitas dan relevansi data, mempersiapkannya agar lebih cocok untuk algoritma pemodelan yang akan digunakan, dan menghilangkan masalah atau hambatan yang mungkin muncul selama proses analisis data. Untuk melakukan proses data transformation dibagi dua jenis data yang bersifat kategorikal dan numerikal yang ada pada dataset terlebih dahulu.

homeownership_MORTGAGE	homeownership_OWEN	homeownership_RENT	loan_purpose_car	loan_purpose_credit_card	loan_purpose_debt_consolidation
1.0	0.0	0.0	0.0	0.0	0.0
0.0	0.0	1.0	0.0	0.0	1.0
0.0	0.0	1.0	0.0	0.0	0.0
0.0	0.0	1.0	0.0	0.0	1.0
0.0	0.0	1.0	0.0	1.0	0.0
0.0	1.0	0.0	0.0	0.0	0.0
1.0	0.0	0.0	0.0	1.0	0.0
1.0	0.0	0.0	0.0	0.0	1.0
1.0	0.0	0.0	0.0	0.0	0.0
0.0	0.0	1.0	0.0	1.0	0.0
1.0	0.0	0.0	0.0	0.0	1.0

Gambar 4. Hasil Teknik One Hot Encoder

Pada Gambar 4 terdapat data kategorikal yang dimana peneliti mentransformasi data menjadi bentuk biner 0 dan 1 pada setiap class yang ada pada dataset dengan menggunakan Teknik One Hot Encoder yang dimana teknik ini adalah salah satu teknik dalam data preprocessing yang digunakan untuk mengubah data kategori menjadi representasi biner dengan nilai 0 atau 1. Tujuan dari One Hot Encoder adalah untuk memungkinkan model machine learning dapat mengenali pola dan hubungan antara kategori tersebut dalam analisis data[17]. Kemudian pada data numerikal dilakukan transformasi data dengan teknik Standard Scaler.

annual_income	debt_to_income	loan_amount	balance	term	interest_rate
0.1665020260378235	-0.08652246557555629	11.297.523.101.024.300	12.602.231.241.352.600	1.516.683.893.566.250	0.3284390487549622
-0.6059247636537596	-0.9509528983891755	-11.029.448.971.773.700	-0.9842918491453405	-0.6593331703738533	0.03648896170209506
-0.6059247636537596	0.12275367621586708	-1.394.166.272.039.950	-1.267.985.340.728.250	-0.6593331703738533	0.9323358041656871
-0.7604101215920762	-0.6097128200541153	0.5084800437289212	0.4410192021634146	-0.6593331703738533	-11.413.096.771.618.600
-0.6831674426229178	257.608.322.377.711	0.6443833519981268	0.6996375828864749	-0.6593331703738533	0.3284390487549622
-0.6986159784167495	-0.8563120954134361	-11.029.448.971.773.700	-10.239.001.871.559.500	-0.6593331703738533	-11.413.096.771.618.600
-0.6831674426229178	0.2900412927434064	0.7414571436189878	0.8130300744014208	1.516.683.893.566.250	0.23245545849100588
0.4754727419144567	-0.20782264967122221	0.35316197713554337	0.45628706934416324	1.516.683.893.566.250	-0.0874898423888483
-0.21971136880796804	11.444.744.576.370.500	0.35316197713554337	0.37110796652212485	-0.6593331703738533	0.23245545849100588
-0.7604101215920762	-0.026538858055721606	-0.967041588908168	-0.8412016347785222	-0.6593331703738533	-11.433.093.352.923.600

Gambar 5. Hasil Teknik Standard Scaler

Dengan melakukan standard scaler, semua atribut numerik pada dataset akan berada pada skala yang sama, memudahkan algoritma machine learning yang sensitif terhadap skala untuk bekerja dengan lebih baik dan lebih efisien, dan didapatkan hasil standard scaler seperti pada Gambar 5. Sebelum melakukan tahap selanjutnya yaitu data classification, peneliti terlebih dahulu melakukan simulasi untuk data splitting yaitu sebagai berikut :

- Simulasi ke-1 sebelum hyperparameter tuning. Pada simulasi ini, keseluruhan data yang didapatkan, 70% akan digunakan sebagai data training, dan data testing yang digunakan adalah 30% dari data yang diperoleh.
- Simulasi ke-2 sebelum hyperparameter tuning. Pada simulasi ini, dari keseluruhan data yang didapatkan, 80% akan digunakan sebagai data training, dan data testing yang digunakan adalah 20% dari data yang diperoleh.
- Simulasi ke-3 sebelum hyperparameter tuning. Pada simulasi ini, dari keseluruhan data yang didapatkan, 90% akan digunakan sebagai data training, dan data testing yang digunakan adalah 10% dari data yang diperoleh.

Adapun tahap kedua yaitu melakukan data splitting untuk melakukan hyperparameter tuning pada algoritma Naïve Bayes yang terdiri dari :

- Simulasi ke-1 pembagian Data Training 70% dan Data Testing 30% kemudian dilakukan data splitting kembali menjadi variabel Data Validation 50% dari Data Testing.
- Simulasi ke-2 pembagian Data Training 80% dan Data Testing 20% kemudian dilakukan data splitting kembali menjadi variabel Data Validation 50% dari Data Testing.
- Simulasi ke-3 pembagian Data Training 90% dan Data Testing 10% kemudian dilakukan data splitting kembali menjadi variabel Data Validation 50% dari Data Testing.

3.3 Data Classification

Setelah melakukan data pre-processing pada tahap ini dilakukan pemodelan klasifikasi menggunakan algoritma naïve bayes yaitu menggunakan pipeline agar tahapan atau langkah-langkah pemrosesan data dan pemodelan ke dalam satu kesatuan yang terstruktur. Dilakukan juga dua skema modelling yaitu melakukan hyperparameter tuning dan tanpa hyperparameter tuning dan parameter yang akan digunakan pada penelitian ini yaitu var_smoothing yang berfungsi untuk mengontrol smoothing pada perkiraan varians dari fitur dalam model.

```
# Create pipeline for algorithm
pipeline = Pipeline([
    ('prep', transform),
    ('algo', GaussianNB())
])

# Fit Transform X_train and y_train
pipeline.fit(X_train,y_train)

# Prediction
y_pred = pipeline.predict(X_test)
```

Gambar 6. Model Tanpa Hyperparameter Tuning

Pada Gambar 6 merupakan source code dari model yang tanpa menggunakan hyperparameter tuning.

```
# Create pipeline for algorithm
pipeline = Pipeline([
    ('prep', transform),
    ('algo', GaussianNB(var_smoothing=var_smooth))
])

# Fit Transform X_train and y_train
pipeline.fit(X_train,y_train)

# Prediction
y_pred = pipeline.predict(X_val)
```

Gambar 7. Model Dengan Hasil Hyperparameter Tuning

Pada Gambar 7 merupakan source code dari model yang menggunakan hasil dari hyperparameter tuning.

```
import optuna
from optuna.samplers import TPESampler

def objective(trial):
    var_smooth = trial.suggest_float('var_smoothing', 1e-9, 1e-2)
    train_perc = trial.suggest_categorical('size', [0.7, 0.8, 0.9])

    X_train, X_test, y_train, y_test = train_test_split(X, y, train_size = train_perc)
    X_val, X_test, y_val, y_test = train_test_split(X_test, y_test, train_size=0.5)

    clf = GaussianNB(var_smoothing = var_smooth)
    clf.fit(X_train, y_train)
    y_pred = clf.predict(X_val)

    return (round(accuracy_score(y_val, y_pred), 2))


study = optuna.create_study(direction='maximize',sampler=TPESampler())
study.optimize(objective, n_trials=2000)
```

Gambar 8. Model Hyperparameter Tuning Using Optuna

Pada Gambar 8 merupakan source code dalam melakukan hyperparameter tuning.

3.4 Deployment Diagram

Deployment diagram adalah salah satu jenis diagram yang ada dalam Unified Modeling Language (UML) yang digunakan untuk menggambarkan bagaimana komponen perangkat lunak (software) dan perangkat keras (hardware) berinteraksi dalam lingkungan produksi. Diagram ini menunjukkan bagaimana komponen-komponen sistem didistribusikan atau di-deploy pada node-node fisik seperti server, komputer, perangkat jaringan, atau perangkat keras lainnya.




Gambar 9. Deployment Diagram

Gambar 9 menjelaskan bahwa terdapat tiga komponen utama yaitu client, web server, dan database server. Komponen client terdapat dua komponen yaitu android dan website yang akan terhubung dengan backend pada web server melalui API. Kemudian API dari backend akan terhubung dengan API yang ada pada model untuk mengirimkan respon ataupun menerima respon hasil prediksi yang digenerate dari model. Dan komponen terakhir yaitu database server yang menggunakan mongodb sebagai basis data yang digunakan.

3.5 Perancangan Arsitektur

Pada tahap ini melakukan mendesain rancangan arsitektur yang akan digunakan pada model setelah melakukan deployment seperti pada Gambar 10.




Gambar 10. Perancangan Arsitektur API Model

Pada Gambar 10 merupakan merancang arsitektur untuk integrasi API Model terhadap API Backend dari platform peer-to-peer lending Amanah yang sedang dikembangkan yang dimana didalamnya terdapat sebuah dataset yang akan dijadikan menjadi data training terhadap data input user pada platform Amanah, kemudian dataset tersebut akan diterima oleh machine learning model yang dimana model tersebut akan dipakai oleh REST API menggunakan Flask dan akan langsung melempar hasil response hasil prediksi kepada request dari Backend Amanah.

3.6 Evaluasi Performa Model

Dalam tahap ini peneliti melakukan evaluasi menggunakan *confusion matrix* dan menghitung hasil metrik evaluasi dari simulasi yang telah melakukan tahap *hyperparameter tuning*.

3.6.1 Simulasi ke-1 dengan Ratio 70:30 setelah tahap *Hyperparameter Tuning*




Gambar 11. Confusion Matrix Ratio 70:30 setelah Hyperparameter Tuning

Setelah mendapatkan hasil *confusion matrix* diatas, peneliti selanjutnya menjumlahkan nilai TP (*True Positive*), FP (*False Positive*), FN (*False Negative*), dan TP (*True Positive*) terlebih dahulu yaitu terdapat pada Tabel 2 dibawah.

Tabel 2. Nilai Metrics TP, FP, dan FN


	TP	FP	FN
A	360	0	11
B	424	22	29
C	369	31	15
D	216	8	9
E	49	7	8
F	8	4	0
G	1	0	1



Gambar 12. Evaluasi Metric Ratio 70:30 setelah Hyperparameter Tuning

Pada Gambar 12 merupakan hasil evaluasi metric diatas didapatkan hasil accuracy score sebesar 95%.

3.6.2 Simulasi ke-2 dengan Ratio 80:20 setelah tahap *Hyperparameter Tuning*




Gambar 13. Confusion Matrix Ratio 80:20 setelah Hyperparameter Tuning

Setelah mendapatkan hasil *confusion matrix* diatas, peneliti selanjutnya menjumlahkan nilai TP (*True Positive*), FP (*False Positive*), FN (*False Negative*), dan TP (*True Positive*) terlebih dahulu yaitu terdapat pada Tabel 3 dibawah.


Tabel 3. Nilai Metrics TP, FP, dan FN

	TP	FP	FN
A	230	1	19
B	293	23	19
C	257	18	4
D	132	4	4
E	31	3	7
F	3	4	0
G	1	0	1

**Gambar 14.** Evaluasi Metric 80:20 setelah Hyperparameter Tuning

Pada Gambar 14 hasil evaluasi metric diatas didapatkan hasil accuracy score sebesar 95%.

3.6.3 Simulasi ke-3 dengan Ratio 90:10 setelah tahap *Hyperparameter Tuning*


**Gambar 15.** Confusion Matrix Ratio 90:10 setelah Hyperparameter Tuning

Setelah mendapatkan hasil *confusion matrix* diatas, peneliti selanjutnya menjumlahkan nilai TP (*True Positive*), FP (*False Positive*), FN (*False Negative*), dan TP (*True Positive*) terlebih dahulu yaitu terdapat pada Tabel 4 dibawah.

Tabel 4. Nilai Metrics TP, FP, dan FN

	TP	FP	FN
A	121	1	12
B	129	24	3

	TP	FP	FN
C	138	4	6
D	75	8	2
E	71	1	5
F	1	1	1
G	Data Tidak Ditemukan		



Gambar 16. Evaluasi Metric 90:10 setelah Hyperparameter Tuning

Pada Gambar 16 hasil evaluasi metric diatas didapatkan hasil accuracy score sebesar 95%.

4. KESIMPULAN

Berdasarkan hasil penelitian dan implementasi model algoritma Naïve Bayes dalam memprediksi dan mengklasifikasi nilai credit score peminjam pada platform peer-to-peer lending Amanah yaitu, hasil akurasi model klasifikasi algoritma Naïve Bayes mencapai 89%, menunjukkan kesesuaian model dalam memprediksi credit score dengan menggunakan dataset yang ada. Ini mengindikasikan bahwa model dapat menjadi alat yang efektif dalam memberikan estimasi credit score kepada peminjam. Dapat melakukan hyperparameter tuning signifikan dalam meningkatkan akurasi model. Simulasi pertama dengan rasio data training 70:30 terhadap data testing dan rasio data validasi 50:30 terhadap data testing, serta var_smoothing sebesar 0.009638958856642498, menghasilkan akurasi mencapai 95%. Hal ini menggarisbawahi pentingnya penyetelan parameter untuk mendapatkan performa terbaik. Selain itu, implementasi deployment API model di Google Cloud Platform (GCP) memungkinkan integrasi model dengan Backend API platform peer-to-peer lending Amanah. Langkah ini berperan dalam menghadirkan model secara nyata dalam operasional platform, memungkinkan penggunaan prediksi credit score secara real-time. Sehingga model algoritma Naïve Bayes memberikan kemampuan yang kuat dalam prediksi dan klasifikasi nilai credit score pada platform P2P lending Amanah. Hasil penelitian menunjukkan potensi model dalam memberikan informasi penting bagi pengambilan keputusan kredit, dengan akurasi yang dapat ditingkatkan melalui tuning parameter. Integrasi model dengan GCP juga membuktikan kesiapan model untuk diimplementasikan dalam lingkungan operasional.

REFERENCES

- [1] KPMG, "Pulse of Fintech," *KPMG-Fintech-report*, no. February, 2020.
- [2] A. Y. A. Nanggala, "Use of Fintech for Payment: Approach to Technology Acceptance Model Modified," *Journal of Contemporary Information Technology, Management, and Accounting*, vol. 1, no. 1, 2020.
- [3] Y. T. Muryanto, "The urgency of sharia compliance regulations for Islamic Fintechs: a comparative study of Indonesia, Malaysia and the United Kingdom," *J Financ Crime*, 2022, doi: 10.1108/JFC-05-2022-0099.
- [4] W. Zhou, D. W. Arner, dan R. P. Buckley, "Regulating FinTech in China: From Permissive to Balanced," dalam *Handbook of Blockchain, Digital Finance, and Inclusion*, 2018. doi: 10.1016/B978-0-12-812282-2.00003-6.
- [5] T. Hidajat, "Unethical practices peer-to-peer lending in Indonesia," *J Financ Crime*, vol. 27, no. 1, 2020, doi: 10.1108/JFC-02-2019-0028.

- [6] A. Basori Alwi, U. Airlangga Jl Airlangga No, dan K. Gubeng, "Pembiayaan Berbasis Teknologi Informasi (Fintech) yang Berdasarkan Syariah," 2018. [Daring]. Tersedia pada: <https://katadata.co.id/berita/2017/08/28/bi-prediksi-transaksi-fintech-naik->
- [7] B. Niu, J. Ren, dan X. Li, "Credit scoring using machine learning by combing social network information: Evidence from peer-to-peer lending," *Information (Switzerland)*, vol. 10, no. 12, 2019, doi: 10.3390/INFO10120397.
- [8] R. R. Suryono, B. Purwandari, dan I. Budi, "Peer to peer (P2P) lending problems and potential solutions: A systematic literature review," dalam *Procedia Computer Science*, 2019. doi: 10.1016/j.procs.2019.11.116.
- [9] S. Sumanto, L. S. Marita, L. Mazia, dan T. W. Ratnasari, "Analisis Kelayakan Kredit Rumah Menggunakan Metode Naïve Bayes untuk Mengurangi Kredit Macet," *Applied Information System and Management (AISM)*, vol. 4, no. 1, 2021, doi: 10.15408/aism.v4i1.20274.
- [10] E. A. Riyanto, T. Juninisvianty, D. F. Nasution, dan R. Risnandar, "Analisis Kinerja Algoritma CART dan Naive Bayes Berbasis Particle Swarm Optimization (PSO) untuk Klasifikasi Kelayakan Kredit Koperasi," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 8, no. 1, 2021, doi: 10.25126/jtiik.0812988.
- [11] P. Subarkah, A. N. Ikhsan, dan A. Setyanto, "The effect of the number of attributes on the selection of study program using classification and regression trees algorithms," dalam *Proceedings - 2018 3rd International Conference on Information Technology, Information Systems and Electrical Engineering, ICITISEE 2018*, 2018. doi: 10.1109/ICITISEE.2018.8721030.
- [12] N. Nurajijah dan D. Riana, "Algoritma Naïve Bayes, Decision Tree, dan SVM untuk Klasifikasi Persetujuan Pembiayaan Nasabah Koperasi Syariah," *Jurnal Teknologi dan Sistem Komputer*, vol. 7, no. 2, 2019, doi: 10.14710/jtsiskom.7.2.2019.77-82.
- [13] A. Pandhu Wijaya dan H. Agus Santoso, "Improving the Accuracy of Naïve Bayes Algorithm for Hoax Classification Using Particle Swarm Optimization," dalam *Proceedings - 2018 International Seminar on Application for Technology of Information and Communication: Creative Technology for Human Life, iSemantic 2018*, 2018. doi: 10.1109/ISEMANTIC.2018.8549700.
- [14] R. J. Brook dan G. C. Arnold, "07. Data Science for Business: What You Need to Know about Data Mining and Data-Analytic Thinking," *Applied Regression Analysis and Experimental Design*, 2019.
- [15] K. Leong, "FinTech (Financial Technology): What is It and How to Use Technologies to Create Business Value in Fintech Way?," *International Journal of Innovation, Management and Technology*, 2018, doi: 10.18178/ijimt.2018.9.2.791.
- [16] A. AlAbbad, M. K. Hassan, dan I. Saba, "Can Shariah board characteristics influence risk-taking behavior of Islamic banks?," *International Journal of Islamic and Middle Eastern Finance and Management*, vol. 12, no. 4, 2019, doi: 10.1108/IMEFM-11-2018-0403.
- [17] P. Cerda dan G. Varoquaux, "Encoding High-Cardinality String Categorical Variables," *IEEE Trans Knowl Data Eng*, vol. 34, no. 3, 2022, doi: 10.1109/TKDE.2020.2992529.