



Peningkatkan Kinerja Gaussian Naive Bayes melalui Hyperparameter Tuning pada Dataset Car Evaluation

Novi Trisna¹, Annisak Izzaty Jamhur², Raja Ayu Mahessya³, Firda Yenila⁴

^{1,2,4}Sistem Informasi, Ilmu Komputer, Universitas Putra Indonesia YPTK Padang

³Teknik Informatika, Ilmu Komputer, Universitas Putra Indonesia YPTK Padang

¹novi_trisna@upiptk.ac.id, ²annisakizzaty@gmail.com, ³ayumahessya@upiptk.ac.id, ⁴firdayenila@upiptk.ac.id

Abstract

Car feasibility evaluation is an important classification problem because purchase price, maintenance cost, number of doors, passenger capacity, luggage capacity, and safety level influence decision making. This study applies and optimizes the Gaussian Naive Bayes algorithm for classifying car feasibility using the Car Evaluation dataset from the UCI Machine Learning Repository. The dataset consists of 1,728 records with six input attributes and four target classes, namely unacc, acc, good, and vgood. The research stages include categorical data transformation, train-test splitting with a 90:10 ratio, model training, hyperparameter tuning using GridSearchCV, and performance evaluation using accuracy, precision, recall, and F1-score. The initial Naive Bayes model produced 69% accuracy, 39% macro precision, 51% macro recall, and 37% macro F1-score. After hyperparameter tuning, the model performance increased to 81% accuracy, 63% macro precision, 63% macro recall, and 61% macro F1-score. The results indicate that GridSearchCV-based tuning improves the classification capability of Naive Bayes, especially in recognizing minority classes that were previously difficult to predict.

Keywords: car evaluation, classification, GridSearchCV, hyperparameter tuning, Naive Bayes

Abstrak

Evaluasi kelayakan mobil merupakan permasalahan klasifikasi yang penting karena harga beli, biaya perawatan, jumlah pintu, kapasitas penumpang, ukuran bagasi, dan tingkat keamanan berpengaruh terhadap pengambilan keputusan. Penelitian ini menerapkan dan mengoptimalkan algoritma Gaussian Naive Bayes untuk klasifikasi kelayakan mobil menggunakan dataset Car Evaluation dari UCI Machine Learning Repository. Dataset terdiri dari 1.728 data dengan enam atribut input dan empat kelas target, yaitu unacc, acc, good, dan vgood. Tahapan penelitian meliputi transformasi data kategorikal, pembagian data latih dan data uji dengan rasio 90:10, pelatihan model, hyperparameter tuning menggunakan GridSearchCV, serta evaluasi performa menggunakan accuracy, precision, recall, dan F1-score. Model Naive Bayes awal menghasilkan accuracy 69%, macro precision 39%, macro recall 51%, dan macro F1-score 37%. Setelah dilakukan hyperparameter tuning, performa model meningkat menjadi accuracy 81%, macro precision 63%, macro recall 63%, dan macro F1-score 61%. Hasil penelitian menunjukkan bahwa tuning berbasis GridSearchCV mampu meningkatkan kemampuan klasifikasi Naive Bayes, terutama dalam mengenali kelas minoritas yang sebelumnya sulit diprediksi.

Kata kunci: car evaluation, GridSearchCV, hyperparameter tuning, klasifikasi, Naive Bayes

© 2026 Author
Creative Commons Attribution 4.0 International License



1. Pendahuluan

Perkembangan teknologi machine learning telah memberikan kontribusi penting dalam proses pengambilan keputusan berbasis data. Salah satu penerapan machine learning yang banyak dikembangkan adalah klasifikasi, yaitu proses pengelompokan data ke dalam kelas tertentu berdasarkan pola atribut yang tersedia. Dalam konteks evaluasi kendaraan, klasifikasi dapat digunakan untuk menentukan tingkat kelayakan mobil berdasarkan beberapa faktor, seperti harga beli, biaya perawatan, jumlah pintu, kapasitas penumpang, ukuran bagasi, dan tingkat keamanan.

Evaluasi kelayakan mobil secara manual memiliki keterbatasan karena membutuhkan waktu dan dapat dipengaruhi subjektivitas pengguna. Pendekatan komputasi diperlukan agar proses klasifikasi dapat dilakukan secara lebih objektif, konsisten, dan berbasis data. Dataset Car Evaluation merupakan salah satu dataset yang sering digunakan dalam penelitian klasifikasi karena memiliki atribut yang relevan untuk menilai kelayakan kendaraan. Dataset ini terdiri dari 1.728 data dengan enam atribut, yaitu *buying*, *maint*, *doors*, *persons*, *lug_boot*, dan *safety*, serta memiliki empat kelas target, yaitu *unacc*, *acc*, *good*, dan *vgood* [1].

Penelitian terkait menunjukkan bahwa machine learning terus digunakan untuk evaluasi kendaraan dan optimasi model klasifikasi [2]. Mengembangkan pendekatan multimodal untuk prediksi rating kendaraan menggunakan data gambar, teks, dan data parametrik [3]. Membandingkan beberapa varian Naive Bayes dengan GridSearch validation pada klasifikasi phishing email. Membuktikan bahwa Gaussian Naive Bayes yang dikombinasikan dengan hyperparameter tuning mampu meningkatkan performa prediksi [4]. Penelitian lain juga menunjukkan bahwa GridSearchCV banyak digunakan untuk meningkatkan performa model klasifikasi pada beragam domain, seperti kesehatan, pendidikan, keamanan jaringan, dan prediksi kualitas air [5], [6], [7].

Penelitian terdahulu masih terdapat beberapa keterbatasan karena penelitian klasifikasi pada dataset Car Evaluation umumnya lebih berfokus pada perbandingan berbagai algoritma klasifikasi, seperti Decision Tree, Random Forest, K-Nearest Neighbor, dan Support Vector Machine, sementara evaluasi mendalam terhadap Gaussian Naive Bayes yang dioptimasi menggunakan GridSearchCV masih belum banyak dilakukan. Dan penelitian hanya menggunakan metrik accuracy sebagai indikator utama keberhasilan model, padahal dataset Car Evaluation memiliki distribusi kelas yang tidak seimbang sehingga nilai accuracy saja belum cukup menggambarkan kemampuan model dalam mengenali seluruh kelas. Selain itu, kelas *good* dan *vgood* pada dataset Car Evaluation memiliki jumlah

data yang jauh lebih sedikit dibandingkan kelas *unacc* dan *acc*. Kondisi tersebut menyebabkan model klasifikasi cenderung lebih mudah memprediksi kelas mayoritas, sementara kemampuan mengenali kelas minoritas menjadi menurun [8]. Oleh karena itu, evaluasi menggunakan precision, recall, F1-score, khususnya macro average, menjadi penting karena mampu memberikan gambaran performa model secara lebih seimbang pada seluruh kelas. Namun demikian, analisis mengenai peningkatan nilai macro precision, macro recall, dan macro F1-score setelah dilakukan proses hyperparameter tuning pada Gaussian Naive Bayes masih belum banyak dilaporkan dalam penelitian sebelumnya.

Penelitian ini bertujuan untuk menerapkan dan mengoptimalkan algoritma Naive Bayes dalam klasifikasi kelayakan mobil menggunakan dataset Car Evaluation. Optimasi dilakukan dengan hyperparameter tuning menggunakan GridSearchCV pada model Gaussian Naive Bayes [9], [10], [11]. Evaluasi model dilakukan dengan membandingkan hasil sebelum dan sesudah optimasi berdasarkan nilai accuracy, precision, recall, dan F1-score. Kontribusi penelitian ini adalah memberikan analisis perbandingan performa Naive Bayes sebelum dan sesudah hyperparameter tuning, sehingga dapat diketahui peningkatan kemampuan model dalam melakukan klasifikasi kelayakan mobil secara lebih akurat dan seimbang [12].

2. Metode Penelitian

Metode penelitian ini dilakukan melalui beberapa tahapan, yaitu pengumpulan dataset, transformasi data, pembagian data latih dan data uji, penerapan algoritma Naive Bayes, optimasi menggunakan GridSearchCV, serta evaluasi hasil klasifikasi.

2.1 Machine Learning

Machine learning merupakan salah satu cabang dari kecerdasan buatan yang berfokus pada pengembangan algoritma agar komputer mampu belajar dari data. Melalui machine learning, sistem dapat mengenali pola, melakukan prediksi, dan membuat keputusan berdasarkan data yang telah dipelajari. Machine learning banyak digunakan dalam berbagai bidang, seperti kesehatan, bisnis, transportasi, pendidikan, dan sistem pendukung keputusan [13]. Salah satu tugas utama dalam machine learning adalah klasifikasi. Klasifikasi merupakan proses pengelompokan data ke dalam kelas tertentu berdasarkan pola atau karakteristik yang dimiliki oleh data. Dalam proses klasifikasi, model dilatih menggunakan data latih yang telah memiliki label, kemudian digunakan untuk memprediksi label pada data baru. Hasil klasifikasi dapat dievaluasi menggunakan beberapa metrik, seperti accuracy, precision, recall, dan F1-score [14].

2.2 Klasifikasi Data

Klasifikasi adalah metode supervised learning yang digunakan untuk memprediksi kelas atau kategori suatu data berdasarkan atribut-atribut yang tersedia. Pada klasifikasi, data yang digunakan terdiri dari variabel input dan variabel target. Variabel input digunakan sebagai dasar pembelajaran model, sedangkan variabel target merupakan kelas yang akan diprediksi. Dalam penelitian ini, klasifikasi digunakan untuk menentukan kelayakan mobil berdasarkan beberapa atribut, yaitu harga beli, biaya perawatan, jumlah pintu, kapasitas penumpang, ukuran bagasi, dan tingkat keamanan. Hasil klasifikasi terdiri dari empat kelas, yaitu tidak layak, layak, baik, dan sangat baik. Dengan adanya proses klasifikasi, evaluasi kelayakan mobil dapat dilakukan secara lebih sistematis dan berbasis data[15].

2.3 Dataset Car Evaluation

Dataset Car Evaluation merupakan dataset yang berasal dari UCI Machine Learning Repository. Dataset ini digunakan untuk mengevaluasi tingkat kelayakan mobil berdasarkan beberapa atribut penting. Dataset ini terdiri dari 1.728 data dengan enam atribut input, yaitu buying, maint, doors, persons, lug_boot, dan safety. Atribut buying menunjukkan harga beli mobil, maint menunjukkan biaya perawatan, doors menunjukkan jumlah pintu, persons menunjukkan kapasitas penumpang, lug_boot menunjukkan ukuran bagasi, dan safety menunjukkan tingkat keamanan mobil. Target klasifikasi pada dataset ini terdiri dari empat kelas, yaitu unacc, acc, good, dan vgood. Kelas unacc menunjukkan mobil tidak layak, acc menunjukkan mobil layak, good menunjukkan mobil baik, dan vgood menunjukkan mobil sangat baik. Karena sebagian besar data pada dataset ini berbentuk kategori, maka diperlukan proses transformasi data ke dalam bentuk numerik sebelum diproses menggunakan algoritma machine learning[16].

2.4 Naive Bayes

Naive Bayes merupakan algoritma klasifikasi berbasis probabilitas yang menggunakan Teorema Bayes sebagai dasar perhitungannya. Algoritma ini disebut naive karena mengasumsikan bahwa setiap atribut bersifat independen terhadap atribut lainnya. Meskipun asumsi independensi tersebut tidak selalu sesuai dengan kondisi nyata, Naive Bayes tetap banyak digunakan karena memiliki proses komputasi yang sederhana, cepat, dan efektif pada berbagai kasus klasifikasi. Pada penelitian ini digunakan Gaussian Naive Bayes, yaitu varian Naive Bayes yang cocok digunakan pada data numerik. Model ini menghitung probabilitas setiap kelas berdasarkan distribusi data dan memilih kelas dengan probabilitas tertinggi sebagai hasil prediksi. Naive Bayes memiliki kelebihan dalam kecepatan proses pelatihan dan kemudahan implementasi. Namun, kelemahannya adalah performa model dapat

menurun apabila data memiliki ketidakseimbangan kelas atau hubungan antar atribut yang cukup kuat[17].

2.5 Hyperparameter Tuning

Hyperparameter tuning merupakan proses pencarian nilai parameter terbaik yang digunakan untuk mengoptimalkan performa model machine learning. Hyperparameter berbeda dengan parameter model karena nilainya tidak dipelajari secara langsung dari data, melainkan ditentukan sebelum proses pelatihan dilakukan. Pemilihan hyperparameter yang tepat dapat meningkatkan kemampuan model dalam melakukan prediksi. Pada algoritma Gaussian Naive Bayes, salah satu hyperparameter yang dapat dioptimalkan adalah var_smoothing. Parameter ini berfungsi untuk menambahkan nilai kecil pada varians agar model lebih stabil secara numerik. Dalam penelitian ini, proses pencarian parameter terbaik dilakukan menggunakan GridSearchCV. GridSearchCV bekerja dengan mencoba berbagai kombinasi parameter yang telah ditentukan, kemudian memilih kombinasi terbaik berdasarkan hasil validasi silang [18].

2.6 GridSearchCV

GridSearchCV merupakan metode pencarian hyperparameter secara sistematis dengan mencoba seluruh kombinasi parameter yang telah ditentukan. Metode ini menggunakan cross-validation untuk mengevaluasi performa setiap kombinasi parameter. Dengan demikian, GridSearchCV dapat membantu menemukan parameter terbaik yang menghasilkan performa model paling optimal. Penggunaan GridSearchCV dalam penelitian ini bertujuan untuk meningkatkan performa algoritma Naive Bayes pada klasifikasi kelayakan mobil. Setelah dilakukan tuning, performa model mengalami peningkatan pada beberapa metrik evaluasi. Hal ini menunjukkan bahwa optimasi hyperparameter dapat membantu model dalam mengenali pola data dengan lebih baik, terutama pada kelas-kelas yang sebelumnya sulit dikenali[3].

2.7 Evaluasi Model Klasifikasi

Evaluasi model klasifikasi dilakukan untuk mengetahui seberapa baik model dalam memprediksi kelas data. Beberapa metrik yang digunakan dalam penelitian ini adalah accuracy, precision, recall, dan F1-score. Accuracy menunjukkan perbandingan jumlah prediksi benar terhadap seluruh data uji. Precision menunjukkan tingkat ketepatan model dalam memprediksi suatu kelas. Recall menunjukkan kemampuan model dalam menemukan seluruh data yang benar-benar termasuk dalam suatu kelas. Sementara itu, F1-score merupakan rata-rata harmonis antara precision dan recall. Dalam penelitian ini, hasil evaluasi menunjukkan bahwa algoritma Naive Bayes sebelum tuning menghasilkan akurasi sebesar 69%. Setelah dilakukan hyperparameter tuning menggunakan GridSearchCV, akurasi meningkat

menjadi 81%. Selain itu, nilai precision, recall, dan F1-score juga mengalami peningkatan. Hal ini membuktikan bahwa proses tuning mampu meningkatkan performa model dalam klasifikasi data kelayakan mobil[11].

3. Hasil dan Pembahasan

Dataset yang digunakan adalah Car Evaluation yang diperoleh dari UCI Machine Learning Repository. Dataset ini terdiri dari 1.728 data dengan enam atribut input, yaitu buying, maint, doors, persons, lug_boot, dan safety. Kelas target terdiri dari empat kategori, yaitu unacc, acc, good, dan vgood [1].

Tahap awal penelitian dilakukan dengan memahami struktur dataset dan distribusi kelas. Dataset Car Evaluation memiliki atribut dalam bentuk kategorikal, sehingga perlu dilakukan transformasi data ke dalam bentuk numerik. Atribut buying dan maint ditransformasikan berdasarkan tingkat harga, mulai dari low, med, high, hingga vhigh. Atribut doors, persons, lug_boot, dan safety juga dikonversi ke dalam nilai numerik sesuai kategori masing-masing. Kelas target juga ditransformasikan ke dalam bentuk angka, yaitu unacc menjadi 1, acc menjadi 2, good menjadi 3, dan vgood menjadi 4.

Penelitian data kelayakan mobil didapatkan pada dataset car evaluation di UC Irvine Machine Learning Repository dari 6 atribut dan 1728 data.

Tabel 1. Data Kelayakan Mobil

index	buying	maint	doors	persons	lug_boot	safety	Class
0	vhigh	vhigh	2	2	small	low	unacc
1	vhigh	vhigh	2	2	small	med	unacc
2	vhigh	vhigh	2	2	small	high	unacc
3	vhigh	vhigh	2	2	med	low	unacc
4	vhigh	vhigh	2	2	med	med	unacc
...	...	...	...	...	...	...	...
1724	low	low	5more	more	med	high	vgood
1725	low	low	5more	more	big	low	unacc
1726	low	low	5more	more	big	med	good
1727	low	low	5more	more	big	high	vgood

Tabel 1. Pada dataset kelayakan mobil target pada class (Kelas) yang dimana Kelas Unacc (tidak layak) terdapat 1210 data, Acc (layak) terdapat 384 data, Good (Baik) terdapat 69 data dan Vgood (Sangat baik) 65 data. Data kelayakan mobil dimana data maasih dalam bentuk objek. Data objek ditansformasikan data kedalam bentuk angka seperti tabel 2.

Tabel 2. Data Objek

Aribut	Nilai Atribut	Transformasi nilai atribut	Keterangan
Buying (Harga Beli Mobil)	vhigh	4	Sangat Mahal
	high	3	Mahal
	med	2	Sedang
	Low	1	Murah
Maint (Biaya Perawatan Mobil)	vhigh	4	Sangat Mahal
	high	3	Mahal
	med	2	Sedang
	Low	1	Murah
Doors (jumlah Pintu)	2	2	2
	3	3	3
	4	4	3
	5more	5	5 pintu atau lebih
Persons (Kapassitas Penumpang)	2	2	2
	4	4	4
	More	6	Lebih dari 4
	Small	1	Kecil
Lug_boot (Ukuran Bagasi)	med	2	Sedang
	Big	3	Besar
	Low	1	Rendah
Safety (Tingkat Keamanan Mobil)	med	2	Sedang
	high	3	Tinggi
	Unacc	1	Tidak Layak
	Acc	2	Layak
Class (Kelas Kelayakan)	Good	3	Baik
	Vgood	4	Sangat Baik

Data yang telah ditransformasikan dilatih model machine learning untuk memperdiksi kelayakan mobil dengan membagi dataset dengan rasio 90:10 yang dimana data latih sebesar 90% sedangkan data uji 10% menggunakan google colab seperti pada gambar 1.

```
from sklearn.model_selection import train_test_split
# Pisahkan fitur dan target
X = df.drop('kelas', axis=1)
y = df['kelas']

# Split data
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.1, random_state=42, stratify=y)
```

Gambar 1. Melatih Model Machine Learning

Kemudian setelah membagi data latih dan data uji dibangun model machine learning menggunakan algoritma naive bayes, seperti tampak pada gambar 2.

```
from sklearn.naive_bayes import GaussianNB
from sklearn.metrics import accuracy_score, recall_score, precision_score, classification_report, confusion_matrix

# Inisialisasi model
nb_model = GaussianNB()

# Melatih model
nb_model.fit(X_train, y_train)

# Prediksi
y_pred_nb = nb_model.predict(X_test)
```

Gambar 2. Membangun Model Algoritma Naive Bayes

Dataset menggunakan klasifikasi model algoritma naive bayes dihitung Akurasi, Presisi, Recal dan F1 score dimana hasilnya dapat dilihat pada gambar 3.

Naive Bayes Performance:
Accuracy: 0.6878612716763006
Precision: 0.38988522238163553
Recall: 0.5129947803392779

Classification Report:				
	precision	recall	f1-score	support
1	0.85	0.87	0.86	121
2	0.50	0.18	0.27	38
3	0.00	0.00	0.00	7
4	0.21	1.00	0.34	7
accuracy			0.69	173
macro avg	0.39	0.51	0.37	173
weighted avg	0.72	0.69	0.67	173

Gambar 3. Hasil Klasifikasi

Dari gambar 3. Hasil Machine Learning didapatkan nilai akurarnya sebesar 69% dan Model gagal total mengenali kelas 3 (Good) yang dimana nilai precision, recall, dan f1 score nilainya 0% sehingga dilakukan Hyperparameter tuning yang dimana mencari dan memilih kombinasi

nilai *hyperparameter* terbaik pada model *machine learning*, sehingga model tersebut dapat menghasilkan prediksi yang paling akurat dan dapat mengenali Kelas target 3 (Good).

Pada algoritma naive bayes dilakukan hyperparameter tuning menggunakan GridSearchCV seperti pada gambar 4, dalam mencari parameter terbaik otomatis, GaussianNB menggunakan model Naive Bayes untuk data numerik dan numpy dipakai membuat range parameter.

```
from sklearn.model_selection import GridSearchCV
from sklearn.naive_bayes import GaussianNB
import numpy as np

param_grid = {
    'var_smoothing': np.logspace(0,-9, num=100)
}

grid_nb = GridSearchCV(
    GaussianNB(),
    param_grid,
    cv=5,
    scoring='accuracy'
)

grid_nb.fit(X_train_scaled, y_train)

print(grid_nb.best_params_)
print(grid_nb.best_score_)

best_nb = grid_nb.best_estimator_

# Prediksi dengan model terbaik
y_pred= best_nb.predict(X_test_scaled)
```

Gambar 4. Hyperparameter Tuning Naive Bayes

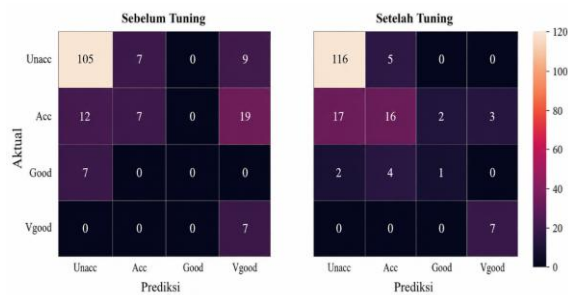
Sehingga setelah dilakukan hyperparameter tuning maka hasil klasifikasi model algoritma naive bayes nilai Akurasi, Presisi, Recal dan F1 score dapat dilihat pada gambar 5.

Best Naive Baiyes Performance:
Accuracy: 0.8092485549132948
Precision: 0.6331481481481481
Recall: 0.6306468650966258

Classification Report:				
	precision	recall	f1-score	support
1	0.86	0.96	0.91	121
2	0.64	0.42	0.51	38
3	0.33	0.14	0.20	7
4	0.70	1.00	0.82	7
accuracy			0.81	173
macro avg	0.63	0.63	0.61	173
weighted avg	0.78	0.81	0.79	173

Gambar 5. Hasil Klasifikasi Setelah Hyperparameter Tuning

Pada Gambar 5. Terdapat perbedaan hasil setelah dilakukan hyperparameter tuning yang dimana nilai akurasinya yang sebelumnya dari 69% menjadi 81% dan juga sebelumnya model gagal total mengenali kelas 3 (good) menjadi sudah dapat dikenali walaupun persentasenya rendah dikarenakan data tidak seimbang terhadap data minoritas tetapi sudah cukup lebih baik.



Gambar 6. Confusion Matrix

Gambar 6 confusion matrix menunjukkan perbandingan hasil klasifikasi algoritma Naive Bayes sebelum dan sesudah dilakukan hyperparameter tuning. Pada matrix tersebut, baris menunjukkan kelas aktual, sedangkan kolom menunjukkan kelas hasil prediksi model. Nilai pada diagonal utama menunjukkan jumlah data yang berhasil diklasifikasikan dengan benar, sedangkan nilai di luar diagonal menunjukkan kesalahan klasifikasi. Sebelum dilakukan tuning, model masih mengalami kesulitan dalam mengenali kelas minoritas, terutama kelas Good yang belum berhasil diprediksi dengan benar. Setelah dilakukan tuning menggunakan GridSearchCV, performa model mengalami peningkatan, terlihat dari bertambahnya jumlah prediksi benar pada kelas Unacc, Acc, dan mulai dikenalnya kelas Good. Hal ini menunjukkan bahwa hyperparameter tuning mampu memperbaiki kemampuan model Naive Bayes dalam melakukan klasifikasi kelayakan mobil, meskipun kelas minoritas masih memerlukan peningkatan lebih lanjut.

Tabel 3. Perbandingan Hasil

Metrics	Model Naive Bayes	Model Naive bayes setelah Hyperparameter Tuning	Perubahan
Accuracy	69%	81%	Meningkat
Precision	39%	63%	Meningkat
Recall	51%	63%	Meningkat
F1-score	37%	61%	Meningkat

Pada Tabel 3. Perbandingan hasil matrik dari yang sebelum hyperparameter dengan sudah hyperparameter tuning dimana nilai accuracy meningkat sebesar 12%, nilai rata-rata macro Precision meningkat sebesar 24%, nilai rata-rata macro Recall meningkat sebesar 12% dan nilai rata-rata macro F1 Score meningkat sebesar 24%’ dari hasil sebelumnya. Sehingga algoritma Naive Bayes setelah di hyperparameter tuning memiliki performa yang jauh lebih baik dibanding model Naive Bayes sebelumnya.

4. Kesimpulan

Berdasarkan evaluasi perbandingan hasil algoritma Naive Bayes setelah di hyperparameter tuning memiliki mengalami peningkatan dibanding model

Naive Bayes sebelumnya. Yang terlihat pada nilai Accuracy naik dari 69% menjadi 81%, nilai rata-rata macro Precision naik dari 39% menjadi 63%, nilai rata-rata macro Recall naik dari 51% menjadi 63%, dan nilai rata-rata macro F1-score juga meningkat dari 37% menjadi 61%. Algoritma Naive Bayes setelah di hyperparameter tuning tidak hanya lebih akurat, tetapi juga lebih mampu mengenali kelas minoritas yang sebelumnya sulit diprediksi, terutama pada kelas 2 (Acc), 3 (Good), dan 4 (Vgood). Penelitian hanya menggunakan satu algoritma klasifikasi, yaitu Gaussian Naive Bayes, sehingga belum diketahui bagaimana performanya dibandingkan algoritma lain yang lebih kompleks. Untuk Penelitian selanjutnya disarankan melakukan perbandingan dengan algoritma klasifikasi lain, seperti Random Forest, XGBoost, dan CatBoost, yang dikenal memiliki kemampuan tinggi dalam menangani hubungan data yang kompleks dan distribusi kelas yang tidak seimbang.

Daftar Rujukan

- [1] 1988. [Online]. Available: <https://doi.org/10.24432/C5JP48>. M. Bohanec. “Car Evaluation,” UCI Machine Learning Repository, “satu.pdf.”
- [2] E. Utami, “Enhanced Heart Disease Diagnosis Using Machine Learning Algorithms.,” vol. 5, no. 158, pp. 385–392, 2026.
- [3] R. Tsaniya, E. Putri, J. Zeniarja, S. Winarno, and A. N. Cahyani, “GridSearch and Data Splitting for Effectiveness Heart Disease Classification,” vol. 8, no. 1, pp. 317–331, 2024.
- [4] V. No, O. N. Cahyani, and F. Budiman, “Edumatic : Jurnal Pendidikan Informatika Performa Logistic Regression dan Naive Bayes dalam Klasifikasi Berita Hoax di Indonesia,” vol. 9, no. 1, pp. 60–68, 2025, doi: 10.29408/edumatic.v9i1.28987.
- [5] D. Asif, M. Bibi, and M. S. Arif, “Enhancing Heart Disease Prediction through Ensemble Learning Techniques with Hyperparameter Optimization,” pp. 1–17, 2023.
- [6] A. B. Pohan and A. Kurniasih, “Optimization of Classification Algorithm with GridSearchCV and Hyperparameter Tuning for Sentiment Analysis of the Nusantara Capital City,” vol. 3, no. 3, 2024.
- [7] L. Lai *et al.*, “The Use of Machine Learning Models with Optuna in Disease Prediction,” pp. 1–20, 2024.
- [8] R. Arifudin and Y. N. Ifriza, “STUDENT ADAPTABILITY LEVEL OPTIMIZATION USING GRIDSEARCHCV WITH GAUSSIAN NAIVE BAYES AND K-NEAREST NEIGHBOR METHODS AS AN EFFORT TO IMPROVE ONLINE EDUCATION PREDICTIONS,” vol. 14, no. 2, pp. 287–295, 2025.
- [9] I. Artikel and A. Info, “PERBANDINGAN ALGORITMA KNN , NAIVE BAYES DAN SVM UNTUK KLASIFIKASI STATUS STUNTING ANAK BALITA DI PUSKESMAS,” vol. 4, no. 4, pp. 360–369, 2025.
- [10] A. Kurniasih and C. N. Previana, “Implementation of GridSearchCV to Find the Best Hyperparameter Combination for Classification Model Algorithm in Predicting Water Potability,” vol. 4, no. 2, 2025.
- [11] S. Kania, N. Alya, I. Jumiatin, and I. Sulistia, “Implementation of Hyperparameter Tuning for

- Classification Models in Heart Disease Risk Prediction Penerapan Hyperparameter Tuning pada Model Klasifikasi untuk Prediksi Risiko Penyakit Jantung,” vol. 5, no. October, pp. 1181–1189, 2025.
- [12] S. Chen and S. Chen, “Enhancing Machine Learning-Based DDoS Detection Through Hyperparameter Optimization,” pp. 1–19, 2025.
- [13] P. Iacobescu, V. Marina, and C. Anghel, “Evaluating Binary Classifiers for Cardiovascular Disease Prediction : Enhancing Early Diagnostic Capabilities,” pp. 1–17, 2024.
- [14] E. Ramadanti, D. A. Dinathi, C. Sri, K. Aditya, and D. R. Chandranegara, “Diabetes Disease Detection Classification Using Light Gradient Boosting (LightGBM) With Hyperparameter Tuning,” vol. 8, no. 2, pp. 956–963, 2024.
- [15] I. A. Cahyani, P. I. Ashuri, C. Sri, and K. Aditya, “Stunting Disease Classification Using Multi- Layer Perceptron Algorithm with GridSearchCV,” vol. 8, no. 1, pp. 392–401, 2024.
- [16] V. No, M. Fadhli, and A. S. Wardana, “Edumatic : Jurnal Pendidikan Informatika Optimasi Gaussian Naïve Bayes dengan Hyperparameter Tuning dan Univariate Feature Selection dalam Prediksi Cuaca,” vol. 7, no. 2, pp. 237–246, 2023, doi: 10.29408/edumatic.v7i2.21179.
- [17] R. Rahman and F. F. Abdulloh, “Performance of Various Naïve Bayes Using GridSearch Approach In Phishing Email Dataset,” vol. 7, no. 4, pp. 2336–2344, 2023.
- [18] “Multi-modal Machine Learning for Vehicle Rating Predictions Using Image, Text, and Parametric Data Hanqi Su 1 * , Binyang Song 1 , Faez Ahmed 1 1 Massachusetts Institute of Technology, Department of Mechanical Engineering, Cambridge, MA,” pp. 1–15.