



Implementasi Algoritma *Machine Learning* Untuk Klasifikasi Kondisi Mesin Mobil Berbasis *Automotive Vehicles Engine Health Dataset*

Implementation of *Machine Learning* Algorithm for Car Engine Condition Classification Based on *Automotive Vehicles Engine Health Dataset*

Sunardi ¹⁾

¹⁾Study Program of Mechanical Engineering, Faculty of Engineering,
Universitas Muhammadiyah Yogyakarta
Email: ¹⁾ sunardi@umy.ac.id

How to Cite :

Sunardi (2024). Implementasi Algoritma *Machine Learning* Untuk Klasifikasi Kondisi Mesin Mobil Berbasis *Automotive Vehicles Engine Health Dataset*. *Gatotkaca Journal*, 5(1) page: 1-12. DOI: <https://doi.org/10.37638/gatotkaca.5.1.1-12>

ARTICLE HISTORY

Received [20 May 2024]

Revised [30 May 2024]

Accepted [10 June 2024]

KEYWORDS

machine learning,
classification, engine
health, predictive
maintenance, automotive
industry

This is an open access
article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/)
license



ABSTRAK

Kemajuan pesat dalam teknik *machine learning* telah berdampak signifikan pada berbagai industri, termasuk sektor otomotif. Studi ini mengeksplorasi implementasi algoritma *machine learning* untuk mengklasifikasikan kondisi mesin mobil berdasarkan *automotive vehicles engine health dataset*. Tujuan utama penelitian ini adalah mengimplementasikan model prediktif yang andal untuk memfasilitasi pemeliharaan proaktif dan mengurangi kegagalan yang tidak terduga. Beberapa algoritma, termasuk Support Vector Machine (SVM), Naive Bayes, dan K-Nearest Neighbor (KNN), dievaluasi. Dataset diproses dan dibagi menjadi 80% data pelatihan dan 20% data uji. Kinerja model dinilai menggunakan metrik akurasi, presisi, recall, dan F1-score. Hasilnya menunjukkan bahwa Naive Bayes mengungguli model lainnya, dengan akurasi 66% dan presisi 82%. Studi ini menunjukkan potensi *machine learning* dalam pemeliharaan prediktif dan pentingnya memilih algoritma serta teknik preprocessing yang tepat. Penelitian masa depan akan fokus pada perluasan dataset, dan eksplorasi metode ensemble untuk meningkatkan kinerja model.

ABSTRACT

The rapid advancements in *machine learning* techniques have significantly impacted various industries, including the automotive sector. This study explores the implementation of *machine learning* algorithms to classify the condition of car engines based on an *automotive vehicles engine health dataset*. The primary objective of this research is to develop a reliable predictive model to facilitate proactive maintenance and reduce unexpected failures. Several algorithms, including Support Vector Machine (SVM), Naive Bayes, and K-Nearest Neighbor (KNN), were evaluated. The dataset was preprocessed and split into 80% training data and 20% test data. Model performance was assessed using metrics such as accuracy, precision, recall, and F1-score. The results indicate that Naive Bayes outperformed the other models, achieving an accuracy of 66% and a precision of 82%. This study demonstrates the potential of *machine learning* in predictive maintenance applications and highlights the importance of selecting appropriate algorithms and preprocessing techniques. Future work will focus on expanding the dataset and exploring ensemble methods to further enhance model accuracy and reliability.

PENDAHULUAN

Pada era industri 4.0, teknologi *machine learning* semakin berkembang pesat dan diterapkan dalam berbagai bidang, termasuk pemeliharaan dan diagnosis kondisi mesin kendaraan (Fonna, 2019; Lei et al., 2020). Dalam beberapa dekade terakhir, perkembangan teknologi di bidang otomotif telah mengalami kemajuan pesat, terutama dengan adanya integrasi sistem sensor dan perangkat lunak cerdas untuk pemeliharaan dan diagnosis kondisi mesin kendaraan. *Machine learning* telah menjadi salah satu teknologi utama yang digunakan untuk memanfaatkan data kondisi mesin kendaraan guna meningkatkan efisiensi dan keandalan operasional (Zhao et al., 2019). Implementasi algoritma *machine learning* untuk klasifikasi kondisi mesin mobil memberikan peluang besar dalam deteksi dini kerusakan, pengurangan biaya perawatan, dan peningkatan keselamatan kendaraan (Xu & Saleh, 2021).

Klasifikasi kondisi mesin mobil berbasis data kesehatan mesin kendaraan (Automotive Vehicles Engine Health Dataset) merupakan salah satu pendekatan yang menjanjikan dalam prediksi kerusakan pada mesin (Vergara et al., 2023). Dataset ini umumnya mencakup berbagai parameter operasi mesin seperti suhu, tekanan, getaran, dan kecepatan putaran yang dikumpulkan melalui sensor-sensor yang terpasang pada mesin (Iliyas Ahmad et al., 2020). Dengan memanfaatkan data tersebut, algoritma *machine learning* dapat dilatih untuk mengenali pola-pola yang mengindikasikan kondisi mesin yang normal maupun abnormal yang memerlukan perawatan atau bahkan indikasi kerusakan serius. Implementasi algoritma *machine learning* dalam klasifikasi kondisi mesin mobil melibatkan beberapa tahap, mulai dari pengumpulan dan praproses data, pemilihan fitur, pemilihan algoritma yang sesuai, pelatihan model, hingga evaluasi kinerja model (Putra et al., 2023). Beberapa algoritma yang sering digunakan dalam klasifikasi ini antara lain adalah Support Vector Machine (SVM), Naive Bayes, dan K-Nearest Neighbor (KNN) (Damayunita et al., 2022; Fanny et al., 2018; Sinaga & Suwilo, 2020).

Beberapa penelitian yang pernah dilakukan klasifikasi kondisi mesin kendaraan. Teknik deteksi dan klasifikasi kerusakan mesin menggunakan data getaran pada domain sudut engkol diterapkan pada mesin bensin empat langkah yang digunakan dalam eksperimen. Data getaran ini dianalisis menggunakan metode machine learning untuk mendeteksi kerusakan pada mesin (Ahmed et al., 2014). Dataset kecepatan putaran penggerak utama mesin diesel empat Langkah digunakan untuk mengklasifikasi kondisi mesin (Shahid et al., 2019). Algoritma beberapa pendekatan *machine learning* berbasis data suhu dan tekanan mesin telah diterapkan untuk memodelkan *predictive maintenance* pada mesin (Aydin & Guldamlasioglu, 2017). Namun dari beberapa penelitian yang pernah dilakukan belum ditemukan penerapan *machine learning* menggunakan dataset *variable engine rpm, lub oil pressure, fuel pressure, coolant pressure, lub oil temperature, dan coolant temperature* untuk memprediksi kondisi mesin.

Penelitian ini bertujuan untuk mengeksplorasi efektivitas berbagai algoritma *machine learning* seperti Support Vector Machine (SVM), Naive Bayes, dan K-Nearest Neighbor (KNN) dalam klasifikasi kondisi mesin mobil berdasarkan Automotive Vehicles Engine Health Dataset. Evaluasi dilakukan dengan menggunakan evaluasi metrik seperti akurasi, presisi, recall, dan F1-score untuk menentukan algoritma *machine learning* yang paling optimal dalam mendeteksi kondisi mesin (Sheth et al., 2022). Hasil dari penelitian ini diharapkan dapat memberikan kontribusi signifikan dalam bidang pemeliharaan prediktif dan manajemen kesehatan kendaraan, serta dapat diimplementasikan pada sistem diagnostik mesin kendaraan modern. Dengan demikian, penelitian ini tidak hanya menawarkan wawasan teknis tentang penggunaan *machine learning* dalam pemeliharaan kendaraan, tetapi juga membuka peluang untuk



inovasi lebih lanjut dalam pengembangan sistem diagnostik cerdas yang mampu meningkatkan efisiensi operasional dan keandalan kendaraan di masa mendatang.

LANDASAN TEORI

Machine learning merupakan cabang dari kecerdasan buatan yang berfokus pada pengembangan algoritma yang memungkinkan komputer untuk belajar dari data dan membuat prediksi atau keputusan tanpa diprogram secara eksplisit. Dalam konteks prediksi kondisi mesin, *Machine learning* dapat digunakan untuk mengidentifikasi pola dalam data operasional mesin yang menunjukkan kondisi kesehatan mesin tersebut. Algoritma *machine learning* dapat memproses data sensor, menganalisis riwayat kegagalan, dan memperkirakan waktu kegagalan berikutnya. Hal ini sangat berguna dalam pemeliharaan prediktif, karena memungkinkan deteksi dini masalah sebelum terjadi kegagalan yang lebih serius, sehingga mengurangi waktu henti tak terduga dan biaya pemeliharaan. Dalam implementasinya, terdapat berbagai algoritma *machine learning* yang dapat digunakan untuk prediksi kondisi mesin, termasuk Support Vector Machine (SVM), Naïve Bayes, dan K-Nearest Neighbors (K-NN).

Support Vector Machine (SVM) adalah metode *machine learning* yang digunakan untuk tugas klasifikasi dan regresi. SVM bekerja dengan mencari hyperplane terbaik yang memisahkan data ke dalam kelas yang berbeda, memaksimalkan margin antara kelas-kelas tersebut (Gambar 1). Dalam konteks prediksi kondisi mesin, SVM dapat digunakan untuk membedakan antara mesin yang beroperasi dalam kondisi sehat dan mesin yang memerlukan pemeliharaan berdasarkan data sensor yang tersedia. Salah satu keunggulan utama dari SVM adalah kemampuannya untuk bekerja dengan data berdimensi tinggi dan tetap efektif, bahkan ketika data tidak dapat dipisahkan secara linear, hal ini dicapai dengan menggunakan kernel trick (Cortes & Vapnik, 1995; Schölkopf & Smola, 2002).


Persamaan matematis yang mendasari SVM dapat dijelaskan sebagai berikut. Misalkan dataset terdiri dari n sampel, yang dinotasikan $\{(x_i, y_i)\}_{i=1}^n$, di mana x_i adalah vektor fitur untuk sampel ke- i dan y_i adalah label kelasnya. Tujuan SVM adalah menemukan *hyperplane* yang memaksimalkan margin antara kelas-kelas, dengan meminimalkan norma dari vektor bobot w dan dapat direpresentasikan sebagai masalah optimisasi pada persamaan (1):

$$\min_{w,b} \frac{1}{2} \|w\|^2 \dots \dots \dots (1)$$

Dengan syarat:

$$y_i(w \cdot x_i + b) \geq 1 \text{ untuk } i = 1, \dots, n$$

Di mana, w adalah vektor bobot, b adalah bias, dan (x_i, y_i) adalah pasangan data pelatihan. Jika data tidak dapat dipisahkan secara linear, kernel trick digunakan untuk memetakan data ke dalam dimensi yang lebih tinggi di mana pemisahan linear mungkin terjadi. Dengan kemampuannya untuk menangani data yang kompleks dan kemampuannya dalam menyelesaikan masalah klasifikasi, SVM telah menjadi pilihan yang populer dalam berbagai aplikasi, termasuk prediksi kondisi mesin dalam industri.



Gambar 1. Model SVM Linier Mengklasifikasikan Dua Kelas (Merah Dan Biru)
(Patel et al., 2017)

Naive Bayes merupakan metode klasifikasi probabilistik yang didasarkan pada Teorema Bayes dengan asumsi independensi antar fitur. Meskipun asumsi ini seringkali tidak realistis dalam situasi dunia nyata, Naive Bayes tetap memberikan hasil yang baik dalam banyak kasus aplikasi nyata karena kesederhanaan dan efisiensinya. Dalam konteks prediksi kondisi mesin, Naive Bayes dapat digunakan untuk mengklasifikasikan kondisi mesin berdasarkan probabilitas dari fitur-fitur yang diamati dari data operasional mesin.

Persamaan matematis yang mendasari Naive Bayes adalah Teorema Bayes, yang menyatakan bahwa probabilitas suatu hipotesis H diberikan data D dapat dihitung menggunakan persamaan (2):

$$P(H | D) = \frac{P(D|H).P(H)}{(P(D))} \dots\dots\dots (2)$$

di mana:

$P(H | D)$ adalah probabilitas hipotesis H jika data D telah diamati,

$P(D | H)$ adalah probabilitas data D jika hipotesis H benar,

$P(H)$ adalah probabilitas sebelumnya dari hipotesis H ,

$P(D)$ adalah probabilitas keseluruhan dari data.

Dalam Naive Bayes, asumsi naif independensi digunakan, yang menyatakan bahwa setiap fitur independen satu sama lain jika diketahui kelasnya. Oleh karena itu, probabilitas data dapat dihitung menggunakan persamaan (3) sebagai produk probabilitas fitur yang terkait:

$$P(D|H) = P(x_1|H). P(x_2|H), \dots P(x_n|H) \dots\dots\dots (3)$$

Meskipun asumsi independensi ini seringkali tidak realistis, Naive Bayes tetap memberikan hasil yang baik dalam praktiknya karena kemampuannya untuk menangani masalah klasifikasi dengan efisien dan mudah diimplementasikan (Feng et al., 2016).

K-Nearest Neighbors (K-NN) yaitu salah satu metode non-parametrik yang umum digunakan dalam klasifikasi dan regresi. Pendekatan ini didasarkan pada ide bahwa objek yang serupa cenderung berada dalam jarak yang dekat dalam ruang fitur. Dalam K-NN, kelas suatu data ditentukan oleh mayoritas kelas dari k-tetangga terdekatnya dalam ruang fitur. Metode ini dianggap sederhana dan intuitif, namun mampu memberikan hasil yang baik terutama dalam situasi di mana hubungan antara



fitur dan kelas bersifat non-linear. Dalam konteks prediksi kondisi mesin, K-NN dapat digunakan untuk mengklasifikasikan kondisi mesin berdasarkan data sensor saat ini dengan membandingkannya dengan data sensor historis yang telah diberi label kondisi. Dengan cara ini, K-NN dapat mengidentifikasi pola dalam data sensor untuk mengklasifikasikan kondisi mesin, memungkinkan deteksi dini masalah atau kegagalan yang mungkin terjadi.

Persamaan matematis yang mendasari K-NN adalah sederhana dan didasarkan pada penggunaan jarak antara titik data dalam ruang fitur. Untuk suatu titik data x , jaraknya ke titik data lain x_i dihitung menggunakan metrik jarak yang sesuai, seperti jarak Euclidean atau jarak Manhattan. Setelah jarak dihitung, k-tetangga terdekat dari x dipilih, dan kelas mayoritas dari tetangga-tetangga tersebut ditentukan sebagai prediksi kelas untuk x . Dengan kelebihan kesederhanaannya dan kemampuannya dalam menangani masalah non-linear, K-NN tetap menjadi salah satu metode yang populer dalam berbagai aplikasi, termasuk prediksi kondisi mesin dalam industri (Vitola et al., 2017).

Evaluasi performa model klasifikasi adalah langkah penting untuk memastikan bahwa model yang dibangun memiliki kinerja yang baik dan dapat diandalkan. Beberapa metrik yang umum digunakan dalam evaluasi model klasifikasi meliputi akurasi, presisi, recall, dan F1-score. Akurasi mengukur proporsi prediksi yang benar, presisi mengukur proporsi prediksi positif yang benar, recall mengukur proporsi aktual positif yang diprediksi dengan benar, F1-score adalah rata-rata harmonis dari presisi dan recall (Yacouby & Axman, 2020). Persamaan (4), (5), (6), dan (7) untuk menghitung evaluasi performa dari model klasifikasi.

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots (4)$$

di mana:

TP adalah True Positive, jumlah kasus positif yang diprediksi dengan benar.

TN adalah True Negative, jumlah kasus negatif yang diprediksi dengan benar.

FP adalah False Positive, jumlah kasus negatif yang salah diprediksi sebagai positif.

FN adalah False Negative, jumlah kasus positif yang salah diprediksi sebagai negatif.

$$\text{Presisi} = \frac{TP}{TP+FP} \dots\dots\dots (5)$$

$$\text{Recall} = \frac{TP}{TP+FN} \dots\dots\dots (6)$$

$$\text{F1 - Score} = 2 \times \frac{\text{Presisi} \times \text{Recall}}{\text{Presisi} + \text{Recall}} \dots\dots\dots (7)$$

METODE PENELITIAN

Metode yang digunakan dalam penelitian ini dilakukan melalui beberapa tahapan sebagai berikut:

1. Tahapan Pengambilan Dataset

Tahap pertama adalah pengambilan dataset yang digunakan untuk melatih algoritma *machine learning* (SVM, Naïve Bayes, dan K-NN). Dataset yang digunakan adalah "Automotive Vehicles Engine Health Dataset" dalam format csv dan diunduh dari situs web <https://www.kaggle.com/datasets/parvmodi/automotive-vehicles-engine-health-dataset/>. Dataset ini terdiri dari 19.000 baris data dan 7 kolom data yang terdiri *engine rpm*, *lub oil pressure*, *fuel pressure*, *coolant pressure*, *lub oil temperature*, *coolant temperature*, dan *engine condition*, namun dalam penelitian ini hanya

digunakan 1.000 baris data untuk memfokuskan analisis dan mempermudah proses pengolahan data. Gambar 2 menunjukkan jumlah baris dan kolom dalam dataset, nilai maksimum dan minimum dari setiap atribut, serta tipe data yang digunakan oleh masing-masing atribut.

```
[7] df.describe()
```

	EngineRpm	LubOilPressure	FuelPressure	CoolantPressure	LubOilTemp	CoolantTemp	EngineCondition
count	1000.000000	1000.000000	1000.000000	1000.000000	1000.000000	1000.000000	1000.000000
mean	793.950000	3.253332	6.484923	2.288910	77.913799	78.551493	0.613000
std	200.119017	1.033674	2.967206	0.971315	3.196604	6.419087	0.487307
min	276.000000	0.072615	0.095332	0.155850	72.799747	63.539429	0.000000
25%	606.750000	2.490041	4.899336	1.603583	75.919713	73.818013	0.000000
50%	780.500000	3.121398	6.135565	2.174065	76.997757	78.231833	1.000000
75%	929.250000	3.978044	7.538368	2.799591	78.416689	83.250321	1.000000
max	2143.000000	7.265566	19.510172	7.478505	88.622792	95.234554	1.000000


```
[8] df.info()
```

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 1000 entries, 0 to 999
Data columns (total 7 columns):
#   Column              Non-Null Count  Dtype
---  ---             
0   EngineRpm           1000 non-null   int64
1   LubOilPressure      1000 non-null   float64
2   FuelPressure        1000 non-null   float64
3   CoolantPressure     1000 non-null   float64
4   lubOilTemp          1000 non-null   float64
5   CoolantTemp         1000 non-null   float64
6   EngineCondition     1000 non-null   int64
dtypes: float64(5), int64(2)
memory usage: 54.8 KB
```



```
[9] df.EngineCondition.value_counts()
```

```
1    613
0    387
Name: EngineCondition, dtype: int64
```

Gambar 2. Informasi *Automotive Vehicles Engine Health Dataset*

2. Tahapan Data Preprocessing

Tahapan ini melibatkan dua langkah utama: data cleaning dan data transformation. Data cleaning dilakukan untuk menghilangkan nilai-nilai yang hilang, duplikasi data, dan inkonsistensi dalam data. Selanjutnya, data transformation dilakukan untuk mengubah data mentah menjadi format yang sesuai untuk pemodelan, termasuk normalisasi dan encoding fitur-fitur yang diperlukan.

3. Tahapan Modelling dan Perancangan

Pada tahap ini, algoritma SVM, Naïve Bayes, dan K-NN diimplementasikan pada dataset yang telah dipreproses untuk melakukan prediksi kondisi kesehatan mesin mobil (normal (0) atau abnormal (1)). Untuk keperluan analisis, atribut dalam dataset harus dipisahkan untuk mengidentifikasi variabel dependen dan independen. Variabel independen (X) mencakup atribut-atribut seperti *engine rpm*, *lub oil pressure*, *fuel pressure*, *coolant pressure*, *lub oil temperature*, dan *coolant temperature*. Sedangkan variabel dependen (Y), yang menjadi target dalam analisis ini, adalah *Engine Condition*.



Proses ini melibatkan pemisahan dataset menjadi data latih sebanyak 800 data (80%) dan data uji sebanyak 200 data (20%). Algoritma *machine learning* (SVM, Naïve Bayes, dan K-NN) dilatih menggunakan data latih dan kinerjanya dievaluasi menggunakan data uji. Proses pembagian data latih dan uji dilakukan menggunakan framework Google Colaboratory, seperti yang ditunjukkan pada Gambar 3.

```
[17] X = df.drop('EngineCondition',axis=1)
      y = df['EngineCondition']

[18] X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=4)
      X_train.shape, X_test.shape, y_train.shape, y_test.shape

((800, 6), (200, 6), (800,), (200,))
```

Gambar 3. Proses Pembagian Dataset Untuk Data Latih Dan Data Uji

4. Menganalisis Hasil Performa Model

Tahap terakhir Setelah semua model berhasil dilatih dan dievaluasi, tahap berikutnya adalah merancang sistem prediksi kondisi mesin mobil. Model yang telah dilatih diimplementasikan ke dalam program menggunakan bahasa pemrograman Python dan framework Google Colaboratory. Analisis hasil dari matriks evaluasi ketiga model algoritma (SVM, Naïve Bayes, dan K-NN). Matriks evaluasi yang digunakan meliputi akurasi, presisi, recall, dan F1-score. Hasil analisis ini digunakan untuk menentukan model terbaik dalam melakukan prediksi kondisi kesehatan mesin mobil berdasarkan kinerja dari masing-masing algoritma. Analisis ini bertujuan untuk menilai kekuatan dan kelemahan masing-masing model dalam konteks dataset yang digunakan.

HASIL DAN PEMBAHASAN

Hasil evaluasi model algoritma Support Vector Machines (SVM) memiliki performa yang bervariasi pada setiap metrik evaluasi yang digunakan seperti yang ditunjukkan pada Gambar 4. Nilai akurasi sebesar 64% menunjukkan bahwa model mampu mengklasifikasikan kondisi mesin mobil dengan benar pada 64% dari total data uji. Meskipun metrik ini memberikan gambaran umum tentang kemampuan model, akurasi tidak selalu mencerminkan kinerja yang baik dalam konteks klasifikasi dengan distribusi kelas yang tidak seimbang.

F1-Score yang sebesar 43% mengindikasikan bahwa terdapat ketidakseimbangan antara precision dan recall. Nilai F1-Score yang lebih rendah dibandingkan dengan akurasi menunjukkan bahwa model menghadapi kesulitan dalam menangani ketidakseimbangan kelas, atau kesulitan dalam mengklasifikasikan kelas tertentu dengan baik. Nilai precision sebesar 81% menunjukkan bahwa dari semua prediksi model yang menyatakan kondisi mobil abnormal, 81% di antaranya benar-benar abnormal. Precision yang tinggi sangat penting dalam konteks ini untuk mengurangi kemungkinan false positives, yaitu ketika model salah mengidentifikasi mobil normal sebagai abnormal.

Recall sebesar 53% menunjukkan bahwa dari semua kondisi mobil yang benar-benar abnormal, model berhasil mengidentifikasi 53% di antaranya. Nilai recall ini penting untuk memastikan bahwa model tidak terlalu banyak melewatkan kondisi abnormal (false negatives), meskipun masih ada ruang untuk perbaikan. Secara keseluruhan, model SVM menunjukkan performa yang baik dalam hal precision, namun

memerlukan peningkatan pada aspek recall dan F1-Score untuk mencapai klasifikasi yang lebih seimbang dan akurat.

```
from sklearn.svm import SVC
model = SVC(random_state=0)
model.fit(X_train, y_train)
```

SVC
SVC(random_state=0)

```
[20] y_pred = model.predict(X_test)
y_pred
```

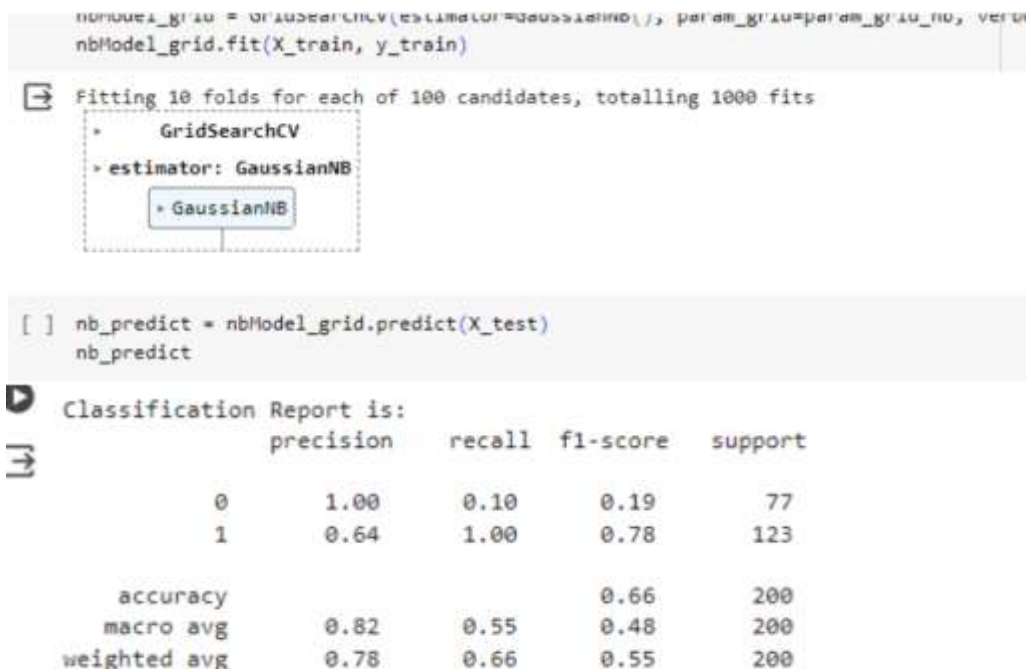
Classification Report is:

	precision	recall	f1-score	support
0	1.00	0.05	0.10	77
1	0.63	1.00	0.77	123
accuracy			0.64	200
macro avg	0.81	0.53	0.43	200
weighted avg	0.77	0.64	0.51	200

Gambar 4. Hasil Metrik Evaluasi Model Algoritma SVM Dalam Mengklasifikasi Kondisi Mesin Mobil

Hasil evaluasi model algoritma Naïve Bayes yang ditunjukkan pada Gambar 5 mencapai nilai akurasi sebesar 66%, yang menunjukkan bahwa 66% dari total prediksi model ini sesuai dengan kondisi sebenarnya. F1-Score yang diperoleh adalah 48%, yang mencerminkan keseimbangan antara presisi dan recall meskipun tidak sekuat yang diharapkan. Presisi model tercatat sangat tinggi, yaitu sebesar 82%, menunjukkan bahwa dari semua prediksi kondisi mesin yang positif, 82% di antaranya benar-benar positif. Hal ini menandakan bahwa model Naïve Bayes sangat efektif dalam mengidentifikasi kondisi mesin yang benar-benar positif.

Recall model sebesar 55% menunjukkan bahwa dari semua kondisi mesin yang sebenarnya positif, model ini mampu mengidentifikasi 55% di antaranya dengan benar. Meskipun presisi tinggi, nilai recall yang lebih rendah menunjukkan bahwa ada sejumlah kondisi positif yang tidak teridentifikasi oleh model. Secara keseluruhan, hasil ini menunjukkan keunggulan model Naïve Bayes dalam hal presisi, menjadikannya sangat berguna dalam situasi di mana false positive lebih dapat diterima dibandingkan false negative. Namun, nilai F1-Score yang relatif rendah menunjukkan bahwa ada trade-off signifikan antara presisi dan recall, yang perlu diperhatikan saat menggunakan model ini untuk klasifikasi kondisi mesin mobil.

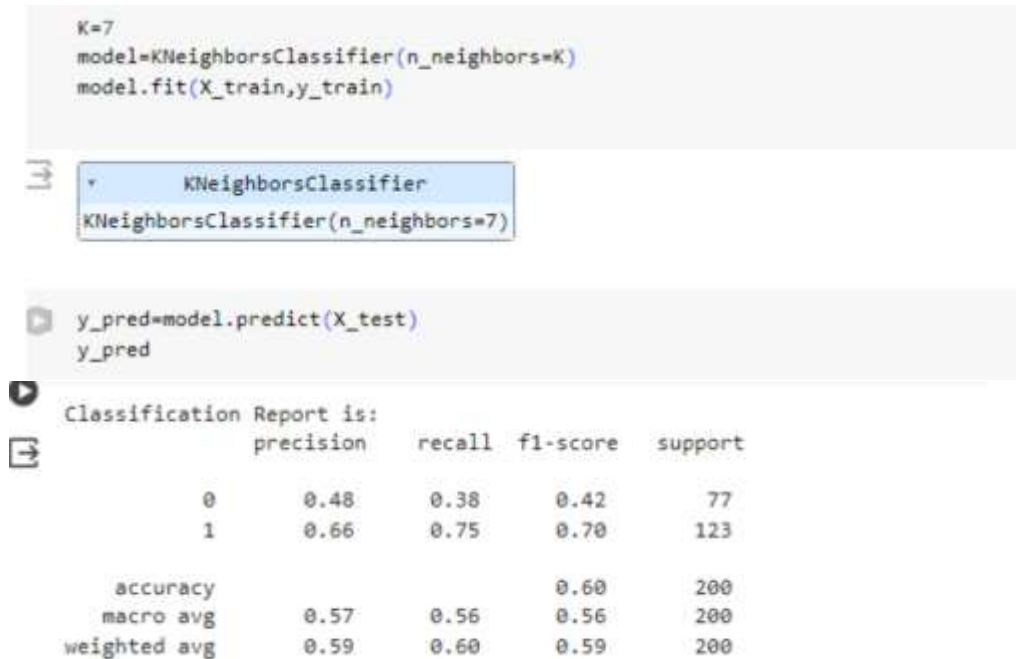


Gambar 5. Hasil Evaluasi Model Algoritma Naïve Bayes Dalam Mengklasifikasi Kondisi Mesin Mobil Normal atau Abnormal

Hasil evaluasi model algoritma K-Nearest Neighbors (K-NN) pada Gambar 6 menunjukkan variasi performa pada beberapa metrik evaluasi. Model K-NN mencapai nilai akurasi sebesar 60%, yang menunjukkan bahwa 60% dari total prediksi model ini sesuai dengan kondisi sebenarnya. *F1-Score* yang diperoleh adalah 56%, mengindikasikan keseimbangan yang cukup baik antara presisi dan recall.

Presisi model tercatat sebesar 57%, yang menunjukkan bahwa dari semua prediksi kondisi mesin yang positif, 57% di antaranya benar-benar positif. Recall model juga sebesar 56%, yang menunjukkan bahwa dari semua kondisi mesin yang sebenarnya positif, model ini mampu mengidentifikasi 56% di antaranya dengan benar. Nilai presisi dan recall yang hampir seimbang mencerminkan bahwa model K-NN memiliki performa yang konsisten dalam mengidentifikasi kondisi mesin mobil yang positif.

Meskipun akurasi model tidak terlalu tinggi, nilai *F1-Score* yang mendekati nilai presisi dan recall menunjukkan bahwa model K-NN cukup andal dalam mengklasifikasikan kondisi mesin mobil pada dataset ini. Hasil ini menekankan pentingnya mempertimbangkan berbagai metrik evaluasi dalam menilai kinerja model pembelajaran mesin, karena fokus hanya pada satu metrik seperti akurasi mungkin tidak memberikan gambaran lengkap mengenai kemampuan model dalam berbagai aspek prediksi.



Gambar 6. Hasil Evaluasi Model Algoritma K-NN Dalam Mengklasifikasi Kondisi Mesin Mobil Normal atau Abnormal

Hasil perbandingan evaluasi kinerja SVM, Naïve Bayes, dan K-NN pada Tabel 1 menunjukkan bahwa model Naïve Bayes memiliki akurasi tertinggi sebesar 66%, diikuti oleh SVM dengan 64% dan K-NN dengan 60%. Dari segi presisi, Naïve Bayes juga unggul dengan nilai 82%, disusul oleh SVM dengan 81%, dan K-NN dengan 57%. Dalam hal recall, K-NN menunjukkan performa terbaik dengan nilai 56%, sedikit lebih tinggi dibandingkan Naïve Bayes (55%) dan SVM (53%).

Nilai F1-score, mengindikasikan bahwa K-NN memiliki nilai tertinggi sebesar 56%, diikuti oleh Naïve Bayes dengan 48%, dan SVM dengan 43%. Walaupun Naïve Bayes unggul dalam akurasi dan presisi, K-NN menunjukkan keseimbangan yang lebih baik antara presisi dan recall, yang tercermin dalam nilai F1-score yang lebih tinggi.

Secara keseluruhan, Naïve Bayes terbukti menjadi model yang paling efektif dalam hal akurasi dan presisi untuk klasifikasi kondisi mesin mobil berdasarkan Automotive Vehicles Engine Health Dataset. Namun, K-NN menunjukkan kinerja yang lebih seimbang antara presisi dan recall, menjadikannya pilihan yang lebih serba guna berdasarkan F1-score. SVM, meskipun memiliki presisi yang tinggi, menunjukkan performa yang lebih rendah dalam recall dan F1-score.

Pemilihan model yang paling sesuai sangat bergantung pada prioritas metrik kinerja yang diinginkan. Jika presisi merupakan prioritas utama, maka Naïve Bayes adalah pilihan yang tepat. Sebaliknya, jika keseimbangan antara presisi dan recall lebih diutamakan, maka K-NN merupakan pilihan yang lebih baik. Untuk aplikasi praktis, diperlukan analisis lebih lanjut dan pengujian di lingkungan nyata untuk mengoptimalkan kinerja model-model ini dalam klasifikasi kondisi mesin mobil.



Tabel 1. Perbandingan Evaluasi kinerja dari masing-masing model *machine learning*

Matrik	SVM	Naïve Bayes	K-NN
Accuracy	64	66	60
Precision	81	82	57
Recall	53	55	56
F1-Score	43	48	56

KESIMPULAN DAN SARAN

Kesimpulan

Berdasarkan hasil penelitian yang dilakukan, penelitian ini mengevaluasi kinerja tiga model pembelajaran mesin, yaitu Support Vector Machine (SVM), Naïve Bayes, dan K-Nearest Neighbors (K-NN), dalam mengklasifikasikan kondisi mesin mobil berdasarkan Automotive Vehicles Engine Health Dataset. Hasil evaluasi menunjukkan bahwa Naïve Bayes memiliki akurasi tertinggi (66%) dan presisi (82%), diikuti oleh SVM (akurasi 64%, presisi 81%) dan K-NN (akurasi 60%, presisi 57%). Dalam hal recall, K-NN unggul dengan nilai 56%, dibandingkan Naïve Bayes (55%) dan SVM (53%). F1-score tertinggi dicapai oleh K-NN (56%), menunjukkan keseimbangan yang lebih baik antara presisi dan recall dibandingkan Naïve Bayes (48%) dan SVM (43%). Oleh karena itu, Naïve Bayes cocok untuk prioritas presisi, sementara K-NN lebih sesuai jika keseimbangan antara presisi dan recall diutamakan. Pemilihan model tergantung pada prioritas metrik yang diinginkan dan aplikasi praktis memerlukan analisis lebih lanjut.

Saran

Penelitian selanjutnya untuk mengintegrasikan lebih banyak fitur terkait kondisi mesin, menerapkan teknik prapemrosesan data yang lebih kompleks, dan mengeksplorasi model *machine learning* lainnya atau teknik ensemble untuk meningkatkan akurasi klasifikasi. Validasi silang yang lebih ekstensif dan analisis kesalahan klasifikasi juga diperlukan untuk memastikan generalisasi model dan meningkatkan kinerjanya.

DAFTAR PUSTAKA

- Ahmed, R., El Sayed, M., Gadsden, S. A., Tjong, J., & Habibi, S. (2014). Automotive internal-combustion-engine fault detection and classification using artificial neural network techniques. *IEEE Transactions on vehicular technology*, 64(1), 21-33.
- Aydin, O., & Guldamlasioglu, S. (2017). Using LSTM networks to predict engine condition on large scale data processing framework. 2017 4th International Conference on Electrical and Electronic Engineering (ICEEE),
- Damayunita, A., Fuadi, R. S., & Juliane, C. (2022). Comparative Analysis of Naive Bayes, K-Nearest Neighbors (KNN), and Support Vector Machine (SVM) Algorithms for Classification of Heart Disease Patients. *Jurnal Online Informatika*, 7(2), 219-225.
- Fanny, F., Muliono, Y., & Tanzil, F. (2018). A comparison of text classification methods k-NN, Naïve Bayes, and support vector machine for news classification. *Jurnal Informatika: Jurnal Pengembangan IT*, 3(2), 157-160.

- Feng, W., Sun, J., Zhang, L., Cao, C., & Yang, Q. (2016). A support vector machine based naive Bayes algorithm for spam filtering. 2016 IEEE 35th International Performance Computing and Communications Conference (IPCCC),
- Fonna, N. (2019). *Pengembangan revolusi industri 4.0 dalam berbagai bidang*. Guepedia.
- Iliyas Ahmad, M., Yusof, Y., Daud, M. E., Latiff, K., Abdul Kadir, A. Z., & Saif, Y. (2020). Machine monitoring system: a decade in review. *The International Journal of Advanced Manufacturing Technology*, 108(11), 3645-3659.
- Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N., & Nandi, A. K. (2020). Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mechanical Systems and Signal Processing*, 138, 106587.
- Patel, A. K., Chatterjee, S., & Gorai, A. K. (2017). Development of machine vision-based ore classification model using support vector machine (SVM) algorithm. *Arabian Journal of Geosciences*, 10, 1-16.
- Putra, R. F., Zebua, R. S. Y., Budiman, B., Rahayu, P. W., Bangsa, M. T. A., Zulfadhilah, M., Choirina, P., Wahyudi, F., & Andiyani, A. (2023). *Data Mining: Algoritma dan Penerapannya*. PT. Sonpedia Publishing Indonesia.
- Shahid, S. M., Ko, S., & Kwon, S. (2019). Real-time classification of diesel marine engine loads using machine learning. *Sensors*, 19(14), 3172.
- Sheth, V., Tripathi, U., & Sharma, A. (2022). A comparative analysis of machine learning algorithms for classification purpose. *Procedia Computer Science*, 215, 422-431.
- Sinaga, L. M., & Suwilo, S. (2020). Analysis of classification and Naïve Bayes algorithm k-nearest neighbor in data mining. IOP Conference Series: Materials Science and Engineering,
- Vergara, M., Ramos, L., Rivera-Campoverde, N. D., & Rivas-Echeverría, F. (2023). EngineFaultDB: A Novel Dataset for Automotive Engine Fault Classification and Baseline Results. *IEEE Access*, 11, 126155-126171.
- Vitola, J., Pozo, F., Tibaduiza, D. A., & Anaya, M. (2017). A sensor data fusion system based on k-nearest neighbor pattern classification for structural health monitoring applications. *Sensors*, 17(2), 417.
- Xu, Z., & Saleh, J. H. (2021). Machine learning for reliability engineering and safety applications: Review of current status and future opportunities. *Reliability Engineering & System Safety*, 211, 107530.
- Yacoub, R., & Axman, D. (2020). Probabilistic extension of precision, recall, and f1 score for more thorough evaluation of classification models. Proceedings of the first workshop on evaluation and comparison of NLP systems,
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., & Gao, R. X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213-237.