

Penggunaan Algoritma *Machine Learning* untuk Memprediksi Kebutuhan Pelatihan Siswa SMK Pustek Tangerang

Siti Maesaroh^{*1}, Anita Ratnasari²

^{1,2} Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Mercu Buana
email: ^{*1}siti.maesaroh@mercubuana.ac.id, ²anita.ratnasari@mercubuana.ac.id

Abstrak

Siswa-siswi SMK Pustek Serpong di Tangerang Selatan memiliki beragam latar belakang, minat, dan potensi yang perlu diidentifikasi dan dikembangkan melalui program pelatihan yang sesuai. Penelitian ini bertujuan untuk meningkatkan akurasi prediksi kebutuhan pelatihan dan pengembangan siswa menggunakan algoritma pembelajaran mesin. Data siswa, termasuk demografi, prestasi akademik, minat, dan kegiatan ekstrakurikuler, akan digunakan untuk melatih model *Random Forest Classifier*, *SVM*, *Gradient Boosting Classifier*, dan *K-NN* sebagai model terpilih yang sesuai dengan atribut target jurusan yang dipilih. Pendekatan pemecahan masalah melibatkan identifikasi masalah, pemilihan metode *machine learning*, pengumpulan dataset, dan implementasi model *machine learning*. Hasil penelitian menunjukkan bahwa *Gradient Boosting Classifier* memiliki performa terbaik dengan akurasi 77%, *precision* 79%, *recall* 96%, dan *f1-score* 87% untuk kelas mayoritas. Sebaliknya, *KNN* memiliki akurasi 67.97% tetapi menunjukkan kinerja rendah dalam mengenali kelas minoritas dengan *precision* dan *recall* sekitar 28% dan 23%.

Kata Kunci : Pembelajaran Mesin, Kebutuhan Pelatihan, Pengembangan Siswa, Model Prediktif.

Abstract

Students at SMK Pustek Serpong in South Tangerang have diverse backgrounds, interests, and potentials that need to be identified and developed through appropriate training programs. This research aims to utilize machine learning algorithms to improve the accuracy of predicting students' training and development needs. Student data, including demographics, academic achievements, interests, and extracurricular activities, will be used to train models such as Random Forest Classifier, SVM, Gradient Boosting Classifier, and K-NN, targeting their chosen academic majors. The problem-solving approach involves problem identification, selection of machine learning methods, dataset collection, and model implementation. The research findings show that Gradient Boosting Classifier performs best with 77% accuracy, 79% precision, 96% recall, and an F1-score of 87% for the majority class. Conversely, K-NN

achieves 67.97% accuracy but exhibits lower performance in identifying minority classes with precision and recall around 28% and 23%, respectively.

Keywords: *Machine Learning, Training Needs, Student Development, Predictive Model*

1. PENDAHULUAN

Pendidikan adalah hal fundamental yang perlu di pertimbangkan dalam setiap lapisan dan komunitas manusia. Indonesia memandang pendidikan sebagai sebuah aspek yang sangat penting untuk menunjang pembangunan dan kemajuan bangsa dan negara, sehingga pemerintah perlu mengambil alih dan berperan aktif dalam jalannya pendidikan di Indonesia

Seperti yang disebutkan Undang Undang dasar 1945 Pasal 31 (3) yang berbunyi "Pemerintah mengusahakan dan menyelenggarakan satu sistem pendidikan nasional, yang meningkatkan keimanan dan ketakwaan serta akhlak mulia dalam rangka mencerdaskan kehidupan bangsa, yang diatur dengan undang-undang.". salah satu bentuk usaha pemerintah Indonesia adalah dengan membentuk Lembaga Pendidikan SMK disamping SMA. Sekolah Menengah Kejuruan (SMK) memiliki keunggulan dibandingkan dengan Sekolah Menengah Atas (SMA) terutama dalam hal persiapan langsung untuk memasuki dunia kerja. SMK menawarkan program keahlian yang spesifik, memungkinkan siswa untuk memperoleh keterampilan praktis dan teknis yang sangat dibutuhkan di industri.

Namun hal ini masih belum memberikan dampak yang maksimal karena sesuai data yang diambil dari Youthmanual Yang merupakan bagian dari Universitas Multimedia Nusantara (UMN) yang mendalami lebih dari 400.000 profil dan data siswa dan mahasiswa di seluruh Indonesia. Dari hasil penelitian tersebut, ditemukan fakta yang cukup menarik yakni 92% siswa SMA/SMK sederhana bingung dan tidak tahu akan menjadi apa kedepannya dan 45% mahasiswa merasa salah mengambil jurusan. hal ini tentu menjadi masalah besar karena data ini menunjukkan bahwa ada masalah dengan jumlah yang besar yang berdampak negatif untuk performa siswa dalam belajar yang mempengaruhi karir pekerjaan mereka, karena menurut (Setyowati, Prabowo, & Yusuf, 2019) "anak perlu mempertimbangkan dengan matang akan pilihan jurusan sesuai dengan kemampuan yang dimiliki. Kesalahan dalam memilih program studi dapat berdampak signifikan terhadap kehidupan masa depan anak. Salah satu dampaknya adalah anak melakukan aktivitas yaitu dipaksa belajar, atau anak gagal belajar.", Hal ini memberikan tanggung jawab yang besar kepada pihak sekolah, untuk membimbing siswa dalam memilih jalur karir yang sesuai dengan potensi dirinya.

Namun hal ini membuka masalah baru karena untuk menangani siswa yang rata rata dalam 1 angkatan memiliki lebih dari 300 siswa diperlukan tenaga ahli yang banyak dan kompeten dan waktu yang lama, untuk mendapatkan hasil yang jitu dan maksimal. Menurut Hurlock (dalam Friantini & Winata, 2019) mengatakan "bahwa minat mempengaruhi bentuk dan intensitas cita-cita, minat dapat menjadi pendorong yang kuat. prestasi selalu dipengaruhi oleh jenis dan intensitas minat seseorang. siswa cenderung mengulang kegiatan yang berhubungan dengan minatnya tersebut." Prediksi dan pengenalan minat siswa menjadi penting untuk dilakukan untuk memaksimalkan hasil dari kegiatan belajar dan mengajar. Metode pengenalan pola pembelajaran dan prediksi dilakukan menggunakan 4 algoritma *Machine Learning* yaitu *Random Forest Classifier*, *Support Vector Machine*, *Gradient Boosting Classifier* dan *K-NN*

dengan pertimbangan skor precision, recall, f1-score dan support untuk menemukan metode terbaik dalam studi Kasus SMK Pustek Tangerang.

A. Dataset

Dataset yang digunakan adalah kuesioner dari Guru BK yang berisikan jurusan yang dipilih, minat dan kegiatan yang dilakukan yang berupa numerik yang mendefinisikan intensitas kegiatan yang dilakukan dalam satuan minggu. terkumpul data dari 3000 siswa yang berasal dari alumni angkatan 2016 - 2019. data dipecah dengan rasio 80% untuk data testing dan 20% untuk data training. Data Target merupakan atribut 3 jurusan pilihan siswa dan data input nya merupakan inputan intensitas dari kegiatan yang dilakukan setiap minggu.

B. Komponen Pendukung

Terdapat beberapa komponen pendukung keputusan yang menjadi landasan untuk penggunaan algoritma Random Forest dalam memprediksi dan memvisualisasikan data prevalensi gizi pada balita di DKI Jakarta, antara lain:

1. Data : data yang disediakan oleh pihak BP memiliki kriteria yang bagus dan kapabilitas yang baik dengan tingkat keberadaan anomali yang sangat rendah.
2. Informasi : Informasi tentang masalah penyelenggaraan pendidikan di Indonesia terutama pada Lembaga pendidikan SMK yang berasal dari BPS dan identifikasi masalah yang dilakukan oleh pihak sekolah sebelumnya
3. Komponen Komputer : komponen yang mendukung penerapan hasil dari penelitian dan membantu pemecahan masalah dengan lebih baik
4. Tenaga ahli : Tenaga ahli yang dimiliki sekolah yang siap untuk diberikan pelatihan untuk pengimplementasian model dengan menindaklanjuti hasil dari penelitian.
5. Pengetahuan : Website yang berorientasi pada komunitas pemrograman dan informasi terkait dengan pembuatan model melalui pendekatan Computer science

2. METODE PENELITIAN

Penelitian yang dilakukan menggunakan pendekatan kuantitatif yang membahas tentang data numerik dari intensitas kegiatan siswa terpilih yang ditambahkan dengan dengan Metode Eksperimental (Action Research) untuk mencari metode terbaik dengan pengujian dan Implementasi langsung menggunakan dataset dari studi kasus yang nyata. studi ini diarahkan pada pengembangan solusi yang dapat meningkatkan kualitas pendidikan dan pengembangan siswa di SMK Pustek Serpong. Dengan menggabungkan metode terbaik berdasarkan pengujian yang cermat dan penerapan data primer secara riil.

Tahapan Penelitian



Gambar 1. Relation Table tahapan penelitian

Penjelasan:

1. Identifikasi dan penentuan : Langkah ini dilakukan untuk mendapatkan informasi – informasi mendasar tentang kebutuhan selama penelitian mencakup parameter, gambaran hasil dan metode yang akan digunakan, rincian kegiatan yang dilakukan :

Mengidentifikasi kebutuhan hasil → Penentuan hasil yang dibutuhkan → Mengidentifikasi atribut yang diperlukan berdasarkan studi kasus → penentuan metode metode yang diperlukan → menentukan metode pengumpulan data.

2. Proses : menindaklanjuti informasi berupa metode, ketentuan dan parameter. dilakukan pengumpulan data, yang berupa 4 kategori dari sumber yang berbeda antara lain:

- data primer : untuk pengujian metode yang sesuai
- data metode : referensi dan performa metode yang berpotensi untuk diuji
- data training : data alumni yang sudah memiliki hasil
- data test : data siswa aktif yang menjadi objek utama

1. Proses : Melakukan pengujian Metode menggunakan data primer yang sudah siap dipakai. melakukan preprocessing pada data mentah yang diambil untuk diimplementasikan pada metode terbaik berdasarkan pengujian.
2. Implementasi : Penerapan data riil yang sudah melalui proses preprocessing dengan Metode terbaik berdasarkan pengujian.

Parameter Pengukuran

1. *Precision*

Precision mengukur persentase dari prediksi positif yang benar-benar benar. Dalam kata lain, dari semua yang diprediksi positif oleh model, berapa persen yang benar-benar positif. rumusnya :

$$\frac{TP}{TP+FP}$$

Gambar 2. Rumus Precision

TP (*True Positive*) adalah jumlah prediksi yang benar positif, sedangkan FP (*False Positive*) adalah jumlah prediksi yang salah positif.

2. *Recall*

Recall (atau juga dikenal sebagai *Sensitivity* atau *True Positive Rate*) mengukur seberapa banyak dari semua kelas positif yang berhasil terdeteksi oleh model. Ini menunjukkan kemampuan model untuk menemukan semua kasus positif yang relevan dalam sebuah dataset. dengan Rumus :

$$\frac{TP}{TP+FN}$$

Gambar 3. Rumus Recall

TP (*True Positive*) adalah jumlah prediksi yang benar positif, sedangkan FP (*False Positive*) adalah jumlah prediksi yang salah positif. FN (*False Negative*) adalah jumlah prediksi yang salah negatif padahal seharusnya positif.

3. F1-Score

F1-score adalah rata-rata harmonik dari *precision* dan *recall*. Metrik ini memberikan keseimbangan antara *precision* dan *recall*, berguna ketika terjadi *trade-off* antara keduanya. Rumusnya:

$$F1\text{-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Gambar 4. Rumus F1-score

4. Support

Support mengindikasikan jumlah kemunculan setiap kelas dalam dataset yang dievaluasi. Meskipun bukan matrik evaluasi langsung, informasi ini penting untuk memahami distribusi kelas dalam dataset.

Tools dan Penerapan

Identifikasi hubungan sebab-akibat antara variabel yang diteliti secara teliti, memungkinkan pengujian hipotesis yang lebih kuat. Dengan mengatur variabel tertentu dan mengamati dampaknya pada variabel lain, penelitian ini memberikan pemahaman yang mendalam tentang fenomena yang diselidiki dan memberikan dasar yang kuat untuk membuat kesimpulan yang valid dan dapat dipercaya. Peralatan yang digunakan dalam penelitian ini adalah :

1. Hardware

- a. PC intel i3 12100f, ram 16gb, penyimpanan 1TB, VGA Intel ARC A380
- b. Monitor lenovo l23-i30
- c. Mouse + keyboard

2. Software

- Vscode
- Python 3.11 dengan library:
 1. Pandas
 2. Seaborn
 3. Matplotlib
 4. Numpy
 5. Scikit-learn
- Microsoft Excel
- Microsoft word
- Github
- Chat Gpt

3. Langkah Kerja

langkah langkah dalam penelitian antara lain:

1. *Preprocessing* dan penanganan nilai yang hilang

Data yang diambil dari pihak sekolah berada dalam format xlsx, perlu diubah ke dalam csv dan mengubah nilai 'null' menjadi angka 0 agar tidak terjadi interferensi dalam pengolahan.

Kolom '0gradyear' dikonversi menjadi tipe data numerik menggunakan `pd.to_numeric`. Jika terdapat nilai yang tidak dapat dikonversi, akan diisi dengan nilai yang ditentukan oleh parameter `errors='coerce'`.

```
data['0gradyear'] = pd.to_numeric(data['0gradyear'],
errors='coerce')

imputer = SimpleImputer(strategy='median')

data['0gradyear'] =
imputer.fit_transform(data[['0gradyear']])

label_encoder = LabelEncoder()

data['gender'] = label_encoder.fit_transform(data['gender'])
```

Gambar 5. Script Penanganan Data Yang Hilang

2. Bagi Data Menjadi Data Latih dan Data Uji

Menggunakan `train_test_split` dari `sklearn.model_selection` untuk membagi data menjadi data latih (training set) dan data uji (test set), dengan ukuran data uji sebesar 20% dari total data dan menggunakan nilai acak (`random state`) 42 untuk memastikan hasil yang konsisten.

```
X_train, X_test, y_train, y_test = train_test_split(X,
y, test_size=0.2, random_state=42)
```

Gambar 6. Script Data Latih dan Data Uji

3. Inisialisasi dan Pelatihan Model

Untuk Implementasi model yang berbeda hanya perlu mengubah pada bagian (`knn_classifier = KNeighborsClassifier()`) dengan metode lain.

```
knn_classifier = KNeighborsClassifier()

knn_classifier.fit(X_train, y_train)
```

Gambar 7. Script Inisialisasi dan Pelatihan Model

4. Prediksi pada Data Uji

Model yang sudah dilatih digunakan untuk melakukan prediksi terhadap data uji (`X_test`), menghasilkan prediksi yang disimpan dalam `y_pred`.

```
y_pred = knn_classifier.predict(X_test)
```

Gambar 8. Script Prediksi

5. Menghitung Akurasi (Accuracy):

Akurasi mengukur persentase prediksi yang benar dari total prediksi yang dibuat oleh model. Dengan menggunakan `accuracy_score` dari `sklearn`, kita membandingkan prediksi model (`y_pred`) dengan label sebenarnya (`y_test`).

```
accuracy = accuracy_score(y_test,
y_pred)print("Accuracy:", accuracy)
```

Gambar 9. Script Hitung Akurasi

6. **Classification Report:** Laporan klasifikasi memberikan rincian matrik evaluasi lainnya seperti *precision*, *recall*, dan *F1-score* untuk setiap kelas. *Precision* mengukur persentase prediksi positif yang benar-benar benar. *Recall* mengukur persentase dari total kasus positif yang benar-benar terdeteksi. *F1-score* adalah rata-rata harmonik dari *precision* dan *recall*, memberikan keseimbangan antara keduanya. *Zero_division=1* digunakan untuk menangani kasus dimana ada kelas yang tidak muncul dalam data uji sehingga mencegah pembagian dengan nol.

```
print("\nClassification
Report:")print(classification_report(y_test, y_pred,
zero_division=1))
```

Gambar 10. Script Classification Report

7. Confusion Matrix

Matriks kebingungan (*confusion matrix*) adalah tabel yang menunjukkan jumlah prediksi yang benar dan salah untuk setiap kelas. Baris mewakili label sebenarnya, sedangkan kolom mewakili label yang diprediksi. Ini memberikan wawasan tentang kesalahan spesifik yang dibuat oleh model dan seberapa sering model salah mengklasifikasikan satu kelas sebagai kelas lain.

python
Salin kode

```
cm = confusion_matrix(y_test, y_pred)classes =
np.unique(y_test)
```

Gambar 11. Script Confusion Matrix

8. Plot Confusion Matrix

Matriks kebingungan divisualisasikan menggunakan `seaborn.heatmap` untuk membantu memahami performa model secara visual. Warna dalam heatmap menunjukkan jumlah prediksi yang benar dan salah, membantu mengidentifikasi pola kesalahan. Plot tersebut dibuat dengan menyesuaikan skala font dan rotasi

label untuk keterbacaan yang lebih baik. Gambar matriks kebingungan kemudian disimpan sebagai file 'confusion matrix 4.png'.

```
sns.set(font_scale=1.2) # Set scale font

sns.heatmap(cm, annot=True, fmt='d', cmap='Blues',
            xticklabels=classes, yticklabels=classes)

plt.title('Confusion Matrix')

plt.xlabel('Predicted Label')

plt.ylabel('True Label')

plt.xticks(rotation=45)

plt.yticks(rotation=0)

plt.tight_layout()
```

Gambar 12. Script Ploting Confusion Matrix

9. Menghitung F1-Score:

F1-score memberikan keseimbangan antara *precision* dan *recall*, sangat berguna ketika terdapat ketidakseimbangan kelas dalam dataset. Nilai F1-score yang tinggi menunjukkan bahwa model memiliki baik *precision* maupun *recall* yang baik.

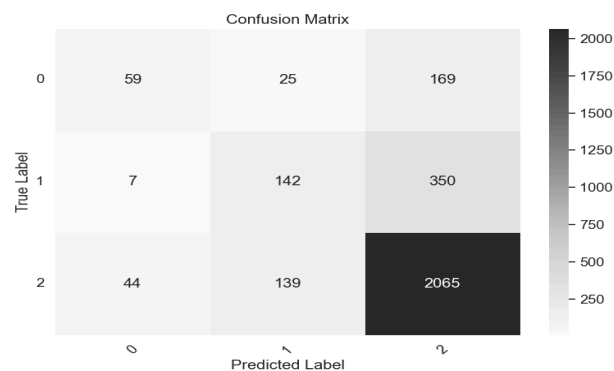
```
f1 = f1_score(y_test, y_pred)

print("\nF1-Score:", f1)
```

Gambar 13. Script Hitung F1-Score

3. HASIL DAN PEMBAHASAN

A. Random Forest Classifier (RFC)



Gambar 14. Confusion Matrix Random Forest

Tabel 1. Classification Report:RFC

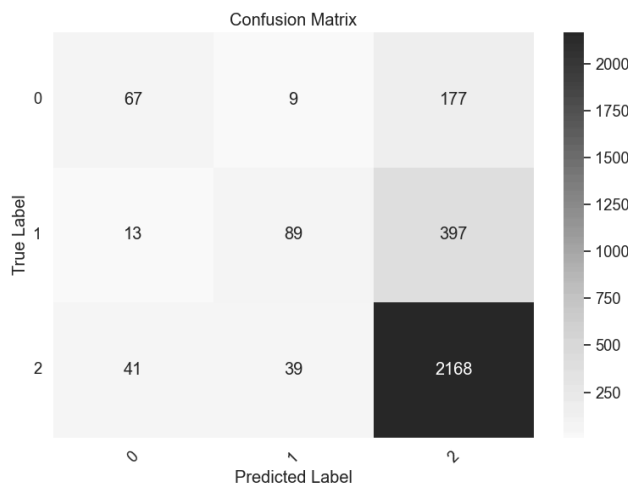
Klas	Precision	Recall	F1-Score	Support
0	0.54	0.23	0.33	253
1	0.46	0.28	0.35	499
2	0.80	0.92	0.85	2248
Accuracy			0.76	3000
Macro avg	0.60	0.48	0.51	3000
Weighted avg	0.72	0.76	0.73	3000

Hasil pengujian model *Random Forest Classifier* menunjukkan akurasi sebesar 75.53%. Dalam melihat rincian performa model, dapat dilihat bahwa model memiliki kecenderungan untuk lebih baik dalam mengidentifikasi kelas mayoritas (kelas 2) dengan precision sebesar 80% dan recall sebesar 92%. Namun demikian, model cenderung memiliki kinerja yang lebih rendah dalam mengidentifikasi kelas minoritas (kelas 0 dan kelas 1), dengan *precision* masing-masing sebesar 54% dan 46%, serta *recall* masing-masing sebesar 23% dan 28%.

Secara keseluruhan, model menunjukkan *f1-score* tertinggi untuk kelas mayoritas (kelas 2) sebesar 85%, sementara *f1-score* untuk kelas minoritas (kelas 0 dan kelas 1) adalah 33% dan 35% berturut-turut. Dengan demikian, meskipun akurasi model tergolong cukup baik, terdapat kecenderungan untuk model menghasilkan prediksi yang lebih baik untuk kelas mayoritas, sedangkan kinerja untuk kelas minoritas masih dapat ditingkatkan.

Hasil pengujian ini memberikan wawasan yang berharga dalam evaluasi kinerja model *Random Forest Classifier* dalam konteks prediksi kebutuhan pelatihan dan pengembangan siswa di SMK Pustek Serpong. Peningkatan lebih lanjut pada model, terutama dalam mengatasi ketidakseimbangan kelas, dapat menjadi fokus untuk menghasilkan prediksi yang lebih akurat dan seimbang bagi semua kelas yang ada.

B. *Gradient Boosting Classifier* (GBC)



Gambar 15.. *Confusion Matrix Gradient Boosting Classifier*

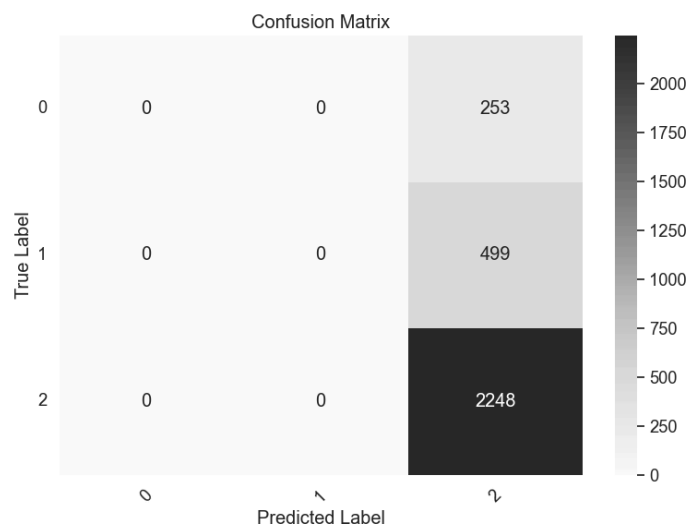
Tabel 2. *Classification Report:GBC*

Klas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
0	0.55	0.26	0.36	253
1	0.65	0.18	0.28	499
2	0.79	0.96	0.87	2248
<i>Accuracy</i>			0.77	3000
<i>Macro avg</i>	0.66	0.47	0.50	3000
<i>Weighted avg</i>	0.75	0.77	0.73	3000

Dalam hasil pengujian menggunakan *Gradient Boosting Classifier*, terlihat bahwa model memiliki akurasi sebesar 77% dalam memprediksi kebutuhan pelatihan dan pengembangan siswa di SMK Pustek Serpong. Dari matriks keakuratan, dapat diamati bahwa model mampu mengklasifikasikan dengan baik kategori kebutuhan pelatihan dan pengembangan siswa yang lebih besar (kelas 2), dengan *precision* sebesar 79% dan *recall* sebesar 96%. Namun, untuk kategori yang lebih kecil (kelas 0 dan 1), model menunjukkan kinerja yang lebih rendah, dengan *precision* dan *recall* yang lebih rendah dibandingkan dengan kelas 2.

Kinerja keseluruhan model dapat dijelaskan sebagai berikut: Model cenderung memiliki kecenderungan untuk mengklasifikasikan dengan benar kebutuhan pelatihan dan pengembangan siswa yang lebih umum (kelas 2), namun masih memiliki kesulitan dalam mengidentifikasi kebutuhan siswa yang mungkin lebih spesifik (kelas 0 dan 1). Oleh karena itu, perlu dilakukan evaluasi lebih lanjut dan penyesuaian model untuk meningkatkan kemampuan dalam mengidentifikasi kebutuhan pelatihan dan pengembangan siswa secara lebih detail.

C. *Support Vector Machine (SVM)*



Gambar 16. *Confusion Matrix SVM*

Tabel 3. Classification Report: SVM

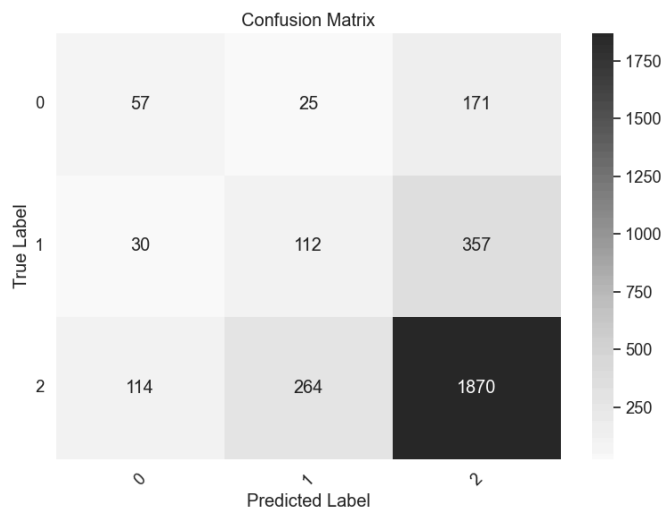
Klas	Precision	Recall	F1-Score	Support
0	1.00	0.00	0.00	253
1	1.00	0.00	0.00	499
2	0.75	1.00	0.86	2248
Accuracy			0.75	3000
Macro avg	0.92	0.33	0.29	3000
Weighted avg	0.81	0.75	0.64	3000

Dalam pengujian model menggunakan metode *Support Vector Machines* (SVM), diperoleh akurasi sebesar 74.93%. Meskipun demikian, ketika melihat lebih dalam ke dalam hasil kualifikasi, terdapat beberapa aspek yang perlu diperhatikan.

Dalam klasifikasi kelas 0, meskipun akurasi mencapai 100%, namun nilai recall yang rendah menunjukkan bahwa model hanya mampu mengenali sebagian kecil dari kelas tersebut. Hal serupa juga terjadi pada klasifikasi kelas 1, di mana meskipun akurasi mencapai 100%, *recall* yang rendah menunjukkan keterbatasan model dalam mengenali kelas tersebut.

Pada klasifikasi kelas 2, akurasi dan *recall* yang tinggi menunjukkan bahwa model mampu dengan baik mengenali dan mengklasifikasikan kelas tersebut. Namun, perlu dicatat bahwa hasil evaluasi secara keseluruhan menunjukkan performa yang lebih rendah pada kelas 0 dan kelas 1 dibandingkan dengan kelas 2. Hal ini menunjukkan bahwa model cenderung lebih baik dalam mengklasifikasikan kelas mayoritas (kelas 2) daripada kelas minoritas (kelas 0 dan kelas 1). Oleh karena itu, dalam pengembangan model selanjutnya, perlu dilakukan penyesuaian dan peningkatan performa untuk dapat lebih baik dalam mengenali semua kelas dengan seimbang.

D. Key Nearest Neighbors (KNN)



Gambar 17. Confusion Matrix KNN

Tabel 4. *Classification Report:KNN*

Klas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
0	0.28	0.23	0.25	253
1	0.28	0.22	0.25	499
2	0.78	0.83	0.80	2248
<i>Accuracy</i>			0.68	3000
<i>Macro avg</i>	0.45	0.43	0.43	3000
<i>Weighted avg</i>	0.65	0.68	0.67	3000

Hasil evaluasi model KNN menunjukkan tingkat akurasi sebesar 67.97%. Dalam melakukan klasifikasi, model KNN memiliki performa yang beragam. Presisi untuk kelas 0 dan kelas 1 masing-masing sebesar 28%, dengan *recall* sebesar 23% untuk kelas 0 dan 22% untuk kelas 1. Sedangkan presisi untuk kelas 2 mencapai 78%, dengan *recall* sebesar 83%. *F1-score* untuk kelas 0 dan kelas 1 adalah 0.25, sementara untuk kelas 2 mencapai 0.80.

Meskipun tingkat akurasi secara umum terlihat cukup tinggi, hasil evaluasi juga menunjukkan bahwa model memiliki kinerja yang lebih baik dalam mengklasifikasikan siswa ke dalam kelas kebutuhan pelatihan dan pengembangan yang lebih besar (kelas 2) dibandingkan dengan kelas yang lebih kecil (kelas 0 dan kelas 1). Ini menunjukkan adanya potensi untuk meningkatkan performa model dalam mengidentifikasi kebutuhan pelatihan dan pengembangan siswa dengan lebih tepat, terutama untuk kelas minoritas.

4. KESIMPULAN

Dari hasil penelitian ini, dapat disimpulkan bahwa penggunaan algoritma *machine learning* dapat menjadi pendekatan yang efektif dalam memprediksi kebutuhan pelatihan dan pengembangan siswa di SMK Pustek Serpong, Tangerang Selatan. Empat metode *machine learning* yang dievaluasi, yaitu *Random Forest Classifier*, *Gradient Boosting Classifier*, *Support Vector Machines* (SVM), dan *K-Nearest Neighbors* (KNN), menunjukkan tingkat akurasi yang beragam dalam mengklasifikasikan kebutuhan siswa.

1. Akurasi Model:

Model *Gradient Boosting Classifier* mencapai akurasi tertinggi sebesar 77%, diikuti oleh *Random Forest Classifier* dengan akurasi 75.53%, SVM dengan 74.93%, dan KNN dengan 67.97%. Meskipun *Gradient Boosting* memiliki akurasi tertinggi secara keseluruhan, perbedaan akurasi antara model tidak terlalu signifikan.

2. Kinerja Kelas Mayoritas dan Minoritas:

- Secara umum, semua model cenderung memiliki kinerja yang lebih baik dalam mengklasifikasikan kelas mayoritas (kelas 2). Hal ini terlihat dari nilai *precision*, *recall*, dan *f1-score* yang lebih tinggi untuk kelas 2 dibandingkan dengan kelas 0 dan kelas 1 pada hampir semua model.
- Model *Random Forest* dan *Gradient Boosting Classifier* menunjukkan kinerja yang lebih seimbang dibandingkan SVM dan KNN, dengan nilai *f1-score* untuk kelas minoritas (kelas 0 dan kelas 1) yang lebih tinggi.

3. Kesimpulan Performa Model:

- **Random Forest Classifier** memiliki keseimbangan yang cukup baik antara akurasi keseluruhan dan kinerja kelas minoritas. Meskipun akurasi sedikit lebih rendah dari Gradient Boosting, model ini menunjukkan potensi untuk mengklasifikasikan kelas minoritas dengan lebih baik setelah disesuaikan.
- **Gradient Boosting Classifier** memiliki akurasi tinggi dan kinerja baik untuk kelas mayoritas, tetapi perlu peningkatan untuk mengenali kelas minoritas dengan lebih baik.
- **SVM** memiliki kinerja yang sangat baik untuk kelas mayoritas (kelas 2), tetapi memiliki kinerja yang buruk untuk kelas minoritas (kelas 0 dan kelas 1), terutama dalam hal recall.
- **KNN** menunjukkan kinerja yang paling rendah dalam mengklasifikasikan kelas minoritas, meskipun memiliki akurasi keseluruhan yang cukup tinggi.

Berdasarkan kesimpulan dari evaluasi yang telah dilakukan terhadap empat model, dapat ditarik beberapa penilaian terhadap performa masing-masing model: Model terbaik adalah *Gradient Boosting Classifier* dengan akurasi tertinggi 77%, *precision* 79%, *recall* 96%, dan *f1-score* untuk kelas 2 sebesar 87%, menunjukkan kinerja yang baik dalam mengidentifikasi kelas mayoritas. Sebaliknya, model terburuk adalah KNN yang meskipun memiliki akurasi 67.97%, menunjukkan kinerja rendah dalam mengenali kelas minoritas dengan *precision* dan *recall* sekitar 28% dan 23%.

5. SARAN

Berdasarkan hasil penelitian ini, beberapa saran dapat diajukan untuk pengembangan lebih lanjut dalam memprediksi kebutuhan pelatihan dan pengembangan siswa di SMK Pustek Serpong:

1. Fokus utama selanjutnya adalah meningkatkan kinerja untuk mengenali kelas minoritas (kelas 0 dan kelas 1). Ini dapat dicapai dengan teknik-teknik seperti penyesuaian threshold, oversampling, atau penggunaan metode klasifikasi yang lebih adaptif terhadap ketidakseimbangan kelas.
2. Evaluasi lebih lanjut terhadap fitur-fitur yang digunakan dalam model juga penting untuk memastikan bahwa model dapat menangkap variabilitas yang relevan dalam data.
3. Perlu mempertimbangkan trade-off antara akurasi keseluruhan dan kinerja kelas minoritas, tergantung pada kebutuhan spesifik dari aplikasi prediksi yang dilakukan.
4. Penelitian lanjutan dapat dilakukan untuk memperbaiki dan meningkatkan kinerja model *machine learning* yang ada, terutama dalam mengatasi ketidakseimbangan kelas dan meningkatkan kemampuan dalam mengidentifikasi kebutuhan siswa secara lebih rinci.
5. Penggunaan teknik-teknik preprocessing data, seperti *oversampling* dan *undersampling*, dapat dipertimbangkan untuk mengatasi ketidakseimbangan kelas dan meningkatkan kinerja model dalam mengidentifikasi kelas minoritas.
6. Evaluasi lebih lanjut terhadap atribut-atribut yang digunakan dalam model prediksi dapat dilakukan untuk menentukan atribut mana yang paling berpengaruh dalam memprediksi kebutuhan pelatihan dan pengembangan siswa.
7. Kolaborasi dengan pihak terkait, termasuk guru dan staf sekolah, dapat dilakukan untuk memperoleh masukan lebih lanjut dan memvalidasi hasil prediksi model.

Dengan mengambil langkah-langkah ini, diharapkan dapat dikembangkan model prediksi yang lebih akurat dan dapat memberikan rekomendasi yang lebih tepat untuk meningkatkan kualitas pendidikan dan pengembangan siswa di SMK Pustek Serpong.

DAFTAR PUSTAKA

- [1] Tri Hardianingsih L, Istighosah M, Alin AY, Ghonim Asgar MR. Systematic Literature Review of Trend and Characteristic Agile Model. *J Tek Inform.* 2023;16(1):45–57.
- [2] David Patón-Romero J, Baldassarre MT, Rodríguez M, Piattini M. Maturity model based on CMMI for governance and management of Green IT. *IET Softw.* 2019;13(6):555–63.
- [3] Szczepaniuk EK, Szczepaniuk H, Rokicki T, Klepacki B. Information security assessment in public administration. *Comput Secur.* 2020;90.
- [4] Wu W, Huang T, Gong K. Ethical Principles and Governance Technology Development of AI in China. *Engineering* [Internet]. 2020;6(3):302–9. Available from: <https://doi.org/10.1016/j.eng.2019.12.015>
- [5] Hamzane I. Implementation of a Decision System for a Suitable IT Governance Framework. *Int J Comput Sci Inf Secur* [Internet]. 2019;(May). Available from: https://www.academia.edu/39534967/Implementation_of_a_decision_system_for_a_suitable_IT_governance_framework
- [6] Uysal M, Çetinkaya E. Information Technology Governance Practices, Challenges and Effects on Enterprise Performance. *Acta Infologica.* 2021;5(1):65–78.
- [7] Levstek A, Pucihar A, Hovelja T. Towards an Adaptive Strategic IT Governance Model for SMEs. *J Theor Appl Electron Commer Res.* 2022;17(1):230–52.
- [8] Jansen S. A focus area maturity model for software ecosystem governance. *Inf Softw Technol* [Internet]. 2020;118(June 2019):106219. Available from: <https://doi.org/10.1016/j.infsof.2019.106219>
- [9] Waghire AA, Joshi R, Rathore APS, Jain R. Development of maturity model for assessing the implementation of Industry 4.0: learning from theory and practice. *Prod Plan Control* [Internet]. 2021;32(8):603–22. Available from: <https://doi.org/10.1080/09537287.2020.1744763>
- [10] Permatahati I, Winarno WW, Kurniawan MP. Penerapan Capability Maturity Model Integration Untuk Mengukur Tingkat Kematangan Organisasi Dalam Proses Pengembangan Perangkat Lunak (Studi Kasus: Direktorat Innovation Center Universitas Amikom Yogyakarta). *Respati.* 2020;15(1):43.
- [11] Saiful A, Andryana S, Gunaryati A. Prediksi Harga Murah Menggunakan Web Scraping dan Machine Learning Dengan Algoritma Linear Regression. *Jurnal Teknik Informatika dan Sistem Informasi.* 2021;8(1):41-50.
- [12] Retnoningsih E & Pramudita R. Mengenal Machine Learning Dengan Teknik Supervised dan Unsupervised Learning Menggunakan Python. *Bina Insani Ict Journal.* 2020;7(2)

- [13] Setyowati, R., Prabowo, W., & Yusuf, M. (2019). Pengambilan Keputusan Menentukan Jurusan Kuliah Ditinjau Dari Student Self Efficacy Dan Persepsi terhadap Harapan Orang Tua. *Jurnal Psikologi Pendidikan Dan Konseling: Jurnal Kajian Psikologi Pendidikan Dan Bimbingan Konseling*, 5(1), 42–48.
- [14] Undang-Undang Dasar Negara Republik Indonesia Tahun 1945.
- [15] Friantini, R. N., & Winata, R. (2019). Analisis Minat Belajar pada Pembelajaran Matematika. *JPMI (Jurnal Pendidikan Matematika Indonesia)*, 4(1), 6–11.