

Metode Hybrid Dalam Pengelompokan Kemampuan Calistung Siswa Berbasis Machine Learning

Amanda Salsabila, Andri Anto Tri Susilo, Nelly Khairani Daulay*

Ilmu Teknik, Informatika, Universitas Bina Insan, Lubuklinggau, Indonesia

Email: ¹amanda.saa662233@email.com, ²andri.lubiklinggau@email.com, ^{3,*}nellykahairanilestari@email.com

Email Penulis Korespondensi: nellykahairanilestari@email.com

Abstrak—Kemampuan calistung siswa (membaca, menulis, dan berhitung) merupakan dasar penting dalam perkembangan akademik siswa sekolah dasar. Penelitian ini bertujuan untuk mengelompokkan kemampuan calistung siswa menggunakan metode *hybrid* berbasis machine learning, dengan data nilai dari dua Sekolah Dasar di Kota Lubuklinggau. Metode yang diterapkan menggabungkan algoritma *K-Means Clustering* untuk pengelompokan awal dan *K-Nearest Neighbors (KNN)* untuk klasifikasi. Proses analisis mencakup preprocessing data, penerapan K-Means, validasi kluster menggunakan Silhouette Score, serta klasifikasi dengan KNN untuk memastikan akurasi. Hasilnya, K-Means berhasil mengelompokkan siswa menjadi tiga kluster: Menengah (0), Rendah (1), dan Tinggi (2). Model KNN dengan $k=3$ yang memiliki akurasi tertinggi yaitu 95% memberikan akurasi pada pengujian model klasifikasi *K-Nearest Neighbors (KNN)* yang sangat baik dengan akurasi 97%, dengan nilai *precision*, *recall*, dan *F1-score* yang sangat baik untuk semua kluster. Temuan ini menunjukkan bahwa pendekatan *hybrid* ini efektif dalam mengklasifikasikan kemampuan calistung siswa, yang berimplikasi pada penyusunan strategi pembelajaran yang lebih tepat sasaran berdasarkan karakteristik masing-masing kelompok siswa.

Kata Kunci: Metode Hybrid; K-Means Clustering; K-Nearest Neighbors (KNN); Kemampuan Calistung Siswa

Abstract—Students reading, writing, and arithmetic abilities (reading, writing, and arithmetic) are an important foundation in the academic development of elementary school students. This study aims to group students' reading, writing, and arithmetic abilities using a hybrid method based on machine learning, with grade data from two Elementary Schools in Lubuklinggau City. The method applied combines the K-Means Clustering algorithm for initial grouping and K-Nearest Neighbors (KNN) for classification. The analysis process includes data preprocessing, application of K-Means, cluster validation using Silhouette Score, and classification with KNN to ensure accuracy. As a result, K-Means successfully grouped students into three clusters: Middle (0), Low (1), and High (2). The KNN model with $k = 3$ which has the highest accuracy of 95% provides very good accuracy in testing the K-Nearest Neighbors (KNN) classification model with an accuracy of 97%, with very good precision, recall, and F1-score values for all clusters. These findings indicate that this hybrid approach is effective in classifying students' reading, writing and arithmetic abilities, which has implications for the development of more targeted learning strategies based on the characteristics of each group of students.

Keywords: Hybrid Method, K-Means Clustering, K-Nearest Neighbors (KNN), Calistung Skills

1. PENDAHULUAN

Di era digital abad ke-21, pendidikan mengalami perubahan signifikan dengan penerapan teknologi pintar, analisis data, dan kecerdasan buatan. Transformasi ini menciptakan pengalaman belajar yang lebih personal, kreatif, serta memperluas akses terhadap informasi [1]. Pemerintah dan masyarakat kini perlu memberikan perhatian lebih terhadap pendidikan sebagai upaya untuk meningkatkan kualitas sumber daya manusia di tengah persaingan global yang semakin ketat [2].

Globalisasi turut mendorong peningkatan literasi dan numerasi, termasuk kemampuan berpikir dan menalar. Hal ini menjadikan keterampilan dasar seperti membaca, menulis, dan berhitung (calistung) sebagai fondasi penting dalam pendidikan dasar [3]. Membaca mencakup pengenalan huruf dan kata serta pemahaman makna. Menulis merupakan bentuk komunikasi produktif dan ekspresif, sementara berhitung berkaitan dengan penggunaan pola dan aturan dalam menyelesaikan masalah [4]. Ketiga kemampuan ini membantu individu mengenali huruf dan angka serta memfasilitasi komunikasi melalui bahasa dan simbol [5]. Calistung juga berperan penting dalam pengembangan bahasa dan logika anak, di mana membaca dan menulis meningkatkan pemahaman informasi, sedangkan berhitung memperkuat kemampuan berpikir logis [6].

Penelitian ini berfokus pada dua Sekolah Dasar Negeri di Kota Lubuklinggau, yaitu SD Negeri 48 dan SD Negeri 23. Keduanya berada di wilayah perkotaan dan menghadapi tantangan yang serupa dalam proses pembelajaran calistung. Berdasarkan observasi awal, ditemukan adanya perbedaan signifikan dalam kemampuan membaca, menulis, dan berhitung antar siswa dalam satu kelas. Kondisi ini menyulitkan guru dalam menyampaikan materi secara efektif karena harus menghadapi keberagaman tingkat pemahaman siswa. Guru kesulitan memberikan tugas yang sesuai bagi semua siswa secara merata dan harus memberikan perhatian individual yang lebih besar, yang tentunya menyita waktu dan tenaga.

Proses pengelompokan siswa berdasarkan kemampuan calistung secara manual memerlukan waktu, tenaga, dan rentan terhadap subjektivitas [7]. Dalam konteks Education 4.0, yang menekankan pada integrasi teknologi cerdas dan pemanfaatan data besar, pendekatan berbasis machine learning menjadi sangat relevan [8]. Dengan kemajuan teknologi dan machine learning, metode seperti *K-Means Clustering* dapat mempermudah pengelompokan siswa dengan akurasi lebih tinggi [9]. Metode *K-Means Clustering* ini digunakan karena dapat membagi siswa ke dalam beberapa kelompok berdasarkan kemiripan dalam kemampuan mereka [10].

Lebih lanjut, metode hybrid yang menggabungkan algoritma clustering dan classification mampu memberikan hasil yang lebih efektif, akurat, dan cepat. Penggunaan metode ini memungkinkan pendeteksian pola kemampuan siswa

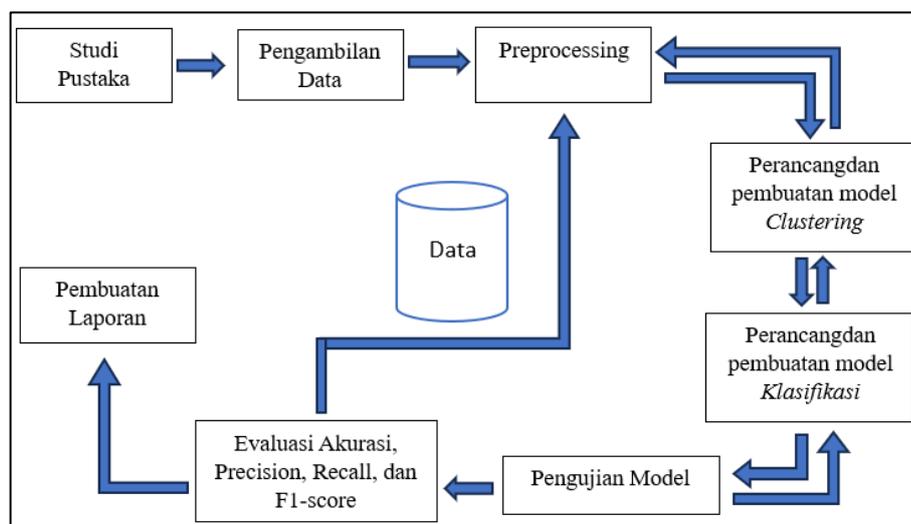
secara lebih mendalam berdasarkan data nilai membaca, menulis, dan berhitung [11]. Selain itu, metode ini dapat mendukung guru dalam menyusun strategi pembelajaran yang lebih tepat sasaran sesuai dengan tingkat kemampuan siswa [12]. Namun, sejauh ini belum banyak penelitian yang secara khusus menerapkan pendekatan hybrid dalam pengelompokan kemampuan calistung siswa di tingkat sekolah dasar, sehingga penelitian ini menawarkan kontribusi yang bersifat inovatif dan relevan dengan kebutuhan pendidikan saat ini.

Oleh karena itu, diperlukan sebuah sistem yang mampu melakukan pengelompokan dan klasifikasi kemampuan calistung siswa secara otomatis berdasarkan data yang dimiliki. Penelitian ini bertujuan untuk membangun sistem berbasis machine learning dengan pendekatan hybrid, yaitu kombinasi antara algoritma *K-Means Clustering* dan *K-Nearest Neighbors (KNN)*. Sistem ini akan mengelompokkan siswa berdasarkan data nilai membaca, menulis, dan berhitung, serta melakukan klasifikasi terhadap siswa baru yang belum dikategorikan.

Penelitian ini diharapkan dapat membantu pihak sekolah, khususnya SD Negeri 48 dan SD Negeri 23 Kota Lubuklinggau, dalam mengevaluasi kemampuan calistung siswa secara objektif dan efisien. Selain itu, hasil dari penelitian ini dapat memberikan kontribusi nyata dalam perencanaan intervensi pembelajaran yang lebih tepat, serta mendukung peningkatan kualitas pendidikan dasar.

2. METODOLOGI PENELITIAN

Penelitian ini terdiri dari beberapa tahapan seperti terlihat pada Gambar 1. Setiap tahapan saling berkaitan dan mendukung proses analisis data secara keseluruhan.



Gambar 1. Tahapan Penelitian

2.1 Pengumpulan Data

Data yang digunakan pada penelitian ini adalah data nilai calistung siswa, nilai membaca, menulis dan berhitung yang di dapatkan dari 2 sekolah yaitu SD Negeri 48 dan SD Negeri 23 Kota Lubuklinggau pada tahun ajaran 2023/2024. Data yang diperoleh berjumlah 508 data siswa, berbentuk data *cross-sectional* atau statis

2.2 Pengolahan Data

Tahapan pengolahan data mencakup preprocessing, penerapan algoritma *K-Means* untuk clustering, dan *K-Nearest Neighbors (KNN)* untuk klasifikasi. Metode ini dipilih sebagai pendekatan *hybrid* yang menggabungkan kekuatan clustering dan klasifikasi [13].

a. Preprocessing Data

Sebelum algoritma diterapkan, data perlu melalui tahapan preprocessing untuk membersihkan dan mempersiapkan data, yang meliputi beberapa langkah penting. Pertama, normalisasi data dilakukan untuk menstandarkan data agar berada dalam rentang yang sama, menggunakan *Min-Max Scaling* [14]. Berikut ini merupakan rumus *Min-Max Normalization*:

$$X_{\text{scaled}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (1)$$

Selanjutnya, penanganan missing data perlu dilakukan jika terdapat data yang hilang, data tersebut dapat diimputasi atau diabaikan tergantung pada jumlah data yang hilang. Terakhir, transformasi fitur diterapkan untuk mengatasi masalah outlier, di mana transformasi seperti log transformation dapat digunakan untuk membuat distribusi data lebih mendekati normal.

b. Clustering dengan K-Means

K-Means Clustering adalah algoritma *unsupervised learning* yang mengelompokkan data ke dalam kluster berdasarkan kesamaan karakteristik dengan memilih *centroid* secara acak dan mengelompokkan data berdasarkan jarak terdekat ke *centroid* [15]. Dalam melakukan klusterisasi, metode *K-means* memiliki beberapa langkah, yaitu [16]:

1. Pilih K sebagai jumlah cluster.
2. menginisialisasi (K) *centroid* secara acak dan menghitung jarak setiap titik data ke *centroid* menggunakan rumus *Euclidean Distance*:

$$d(x, c) = \sqrt{\sum_{i=1}^n (x_i - c_i)^2} \quad (2)$$

3. Mengelompokkan titik data ke *centroid* terdekat
4. Memperbarui posisi *centroid* dengan rumus

$$\mu_j = \frac{1}{|c_j|} \sum_{x_i \in c_j} x_i \quad (3)$$

5. Ulangi langkah 2 hingga 4 sampai *centroid* tidak berubah atau perubahan kecil (konvergensi tercapai).

c. Klasifikasi dengan KNN

Setelah data dikelompokkan oleh *K-Means*, label hasil kluster digunakan sebagai target kelas (label) untuk melatih algoritma *K-Nearest Neighbors (KNN)*. Dengan demikian, *KNN* berfungsi untuk mengklasifikasikan siswa baru yang belum memiliki label ke dalam salah satu kluster berdasarkan kedekatan (jarak) dengan siswa yang sudah diklasifikasikan. [17].

d. Alasan Memilih Metode Hybrid: K-Means + KNN

Kombinasi *K-Means* dan *KNN* dipilih karena *K-Means* unggul dalam menemukan struktur data tanpa label, sedangkan *KNN* efektif dalam memetakan data baru berdasarkan pembelajaran dari data berlabel. Kombinasi keduanya memungkinkan sistem untuk mengelompokkan data tanpa supervisi terlebih dahulu, kemudian memperluas kemampuan sistem dalam klasifikasi baru secara akurat dan efisien.

Kelebihan dari pendekatan ini antara lain:

1. *K-Means* membantu mendeteksi pola tersembunyi dalam data tanpa label.
2. Hasil clustering dari *K-Means* digunakan untuk memberi label sementara pada data latih.
3. Model *KNN* kemudian dilatih menggunakan label dari hasil clustering tersebut, sehingga mampu melakukan klasifikasi data baru berdasarkan pola yang telah dikenali.

2.3 Pemodelan

Pengujian model ini dilakukan untuk memastikan keakuratan hasil pengelompokan dan klasifikasi. Pengujian dilakukan melalui beberapa pendekatan untuk mendapatkan performa terbaik dari metode *hybrid* yang digunakan [18].

a. Metode Elbow (*Elbow Method*)

Metode *Elbow* digunakan untuk menentukan jumlah cluster optimal dalam *K-Means Clustering* dengan mengukur nilai *Sum of Squared Errors (SSE)* atau *inertia*, yang menunjukkan seberapa baik titik data cocok dengan *centroid*-nya. Langkah-langkahnya meliputi menjalankan algoritma *K-Means* untuk berbagai jumlah cluster (k), menghitung SSE untuk setiap (k) menggunakan rumus:

$$SSE = \sum_{i=1}^n \sum_{x \in c_i} \|x - \mu_i\|^2 \quad (4)$$

Selanjutnya titik "*elbow*" (titik di mana perubahan *SSE* mulai melambat), yang menandakan jumlah cluster optimal [19].

2.4 Evaluasi

Setelah pengelompokan digunakan algoritma klasifikasi *KNN* maka pengujian model *Confusion Matrix* digunakan untuk menilai akurasi prediksi klasifikasi. *Confusion Matrix* menampilkan jumlah prediksi yang benar dan salah untuk setiap kelas yang diklasifikasikan [20]. *Confusion Matrix* terdiri dari:

- a. True Positive (TP) : Prediksi benar untuk kelas positif.
- b. False Positive (FP) : Prediksi salah untuk kelas positif.
- c. True Negative (TN) : Prediksi benar untuk kelas negatif.
- d. False Negative (FN): Prediksi salah untuk kelas negatif.

Berdasarkan nilai-nilai ini, dihitung metrik evaluasi sebagai berikut:

Akurasi (Accuracy): proporsi prediksi yang benar terhadap seluruh prediksi.

$$\text{Accuracy} = \text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$

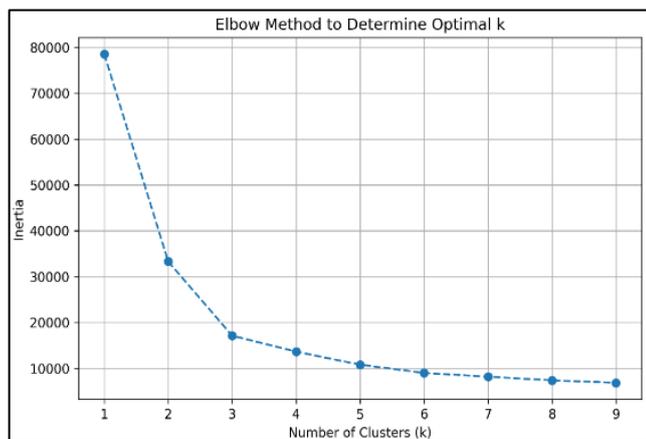
Precision: ketepatan prediksi positif.

Cluster	Nilai 1	Nilai 2	Nilai 3
0	79.007547	77.860377	79.622642
1	88.702247	86.977528	88.657303
2	68.215385	68.615385	68.584615

Gambar 3. Centeroid

3.3 Menentukan Jumlah Cluster Optimal dengan Metode Elbow

Metode *Elbow* digunakan untuk menentukan jumlah cluster optimal dengan memplot jumlah cluster (k) terhadap nilai inertia. Grafik *Elbow* menunjukkan bahwa titik optimal berada pada $k = 3$. Hasil ini menegaskan bahwa pembentukan 3 cluster merupakan pendekatan yang paling efisien. Gambar 4 memperlihatkan grafik *Elbow*.

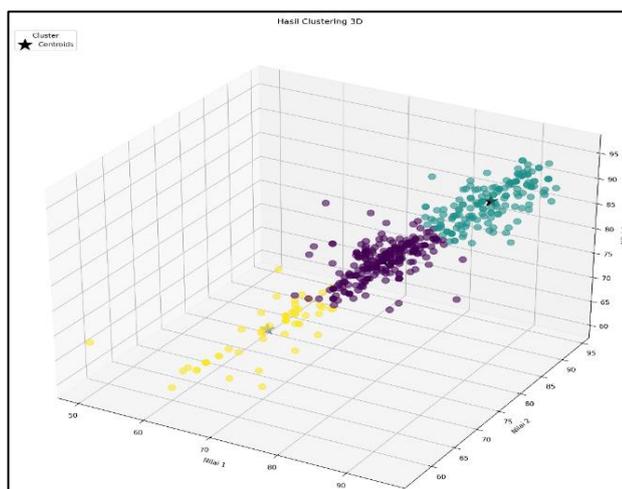


Gambar 4. Grafik Metode Elbow Menentukan Nilai K Optimal.

Pengujian cluster optimal menggunakan Metode Elbow menunjukkan bahwa jumlah cluster optimal adalah 3.

3.4 Visualisasi 3D Hasil Clustering

Visualisasi 3D memberikan pandangan yang lebih intuitif tentang distribusi siswa dalam ruang tiga dimensi berdasarkan nilai mereka. Gambar 5 menampilkan hasil visualisasi ini.



Gambar 5. Visualisasi 3D Clustering

3.5 Split Data

Persiapan data untuk model pembelajaran mesin, Pembagian data untuk model prediksi yang dibangun dibagi dengan perbandingan 80:20, pembagian data menjadi dataset *training* 80% dan *testing* 20%. Gambar 6 menunjukkan proses pembagian data.

```
# bagi data training dan testing
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
```

```
print(x_train.shape,x_test.shape,y_train.shape,y_test.shape)
(406, 7) (102, 7) (406,) (102,)
```

Gambar 6. Split Data

3.6 Klasifikasi K-Nearest Neighbors (KNN)

Setelah dilakukan *clustering k-means* didapatkan label Data hasil kluster tersebut dapat dijadikan data latih untuk *K-Nearest Neighbors (KNN)*. Setelah terbentuk model Selanjutnya *K-Nearest Neighbors (KNN)* digunakan untuk memprediksi kelas siswa dengan data sampel baru berjumlah 200 data. Untuk data training menggunakan dataset dengan data yang sudah dikelompokkan dan mempunyai label atau kelas. Dengan cara ini, *K-Nearest Neighbors (KNN)* dapat memberikan prediksi klasifikasi kemampuan calistung yang lebih akurat. Dapat dilihat pada Gambar 7.

```
#Membuat model KNN
AB= KNeighborsClassifier(n_neighbors=3)
AB.fit(x_train,y_train)

KNeighborsClassifier
KNeighborsClassifier(n_neighbors=3)
```

Gambar 7. Model K-Nearest Neighbors (KNN)

3.7 Hasil Prediksi Cluster dengan Data Sampel Baru

Untuk menguji performa model yang telah dibangun, dilakukan pengujian dengan data sampel baru. Berikut adalah hasil prediksi dengan data sampel baru dapat dilihat pada Gambar 8 dan Tabel 1.

```
# Prediksi cluster untuk data baru
prediksi_cluster = knn.predict(new_data200)

#Hasil
print("Prediksi Kluster Untuk Data Baru:", prediksi_cluster)

Prediksi Kluster Untuk Data Baru: [0 1 0 0 0 0 0 0 0 0 2 0 0 0 0 0 0 0 2 0 0 0 2 1 0 0 0 2 0 0 0 0 0 0 0 0
 2 0 2 0 0 2 2 0 0 0 0 2 2 0 0 0 1 0 2 0 0 0 2 0 0 2 0 0 2 2 2 0 0 0 0 0 0
 0 0 2 0 2 2 0 0 1 0 0 0 0 0 0 0 0 2 2 0 0 0 0 2 0 0 0 0 0 0 0 2 2 0 0 0 2
 2 0 0 0 2 1 0 0 0 0 0 2 0 0 0 0 2 0 0 0 0 2 2 0 0 0 0 2 0 0 0 1 0 0 1 0
 0 0 0 0 0 0 0 0 0 0 1 0 0 0 0 2 0 0 0 2 0 0 0 2 2 0 2 2 0 0 0 0 0 0 2 0
 0 0 0 0 0 0 0 0 0 0 0 0 0 2 0 2]
```

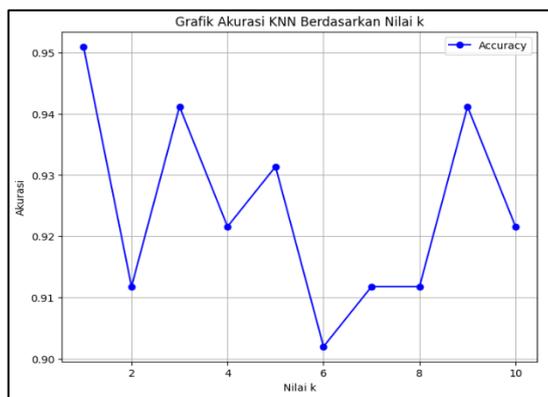
Gambar 8. Hasil Prediksi Clustering dengan data Baru

Tabel 1. Hasil Prediksi Clustering dengan data Baru

No.	Nama	(P/L)	Sekolah	Nilai 1	Nilai 2	Nilai 3	Cluster	Label
1	Adi Handayani	P	SD N 48	60	60	81	0	Menengah
2	Fajar Haryono	P	SD N 48	83	80	83	1	Tinggi
3	Eka Haryono	L	SD N 48	72	100	80	0	Menengah
4	Nana Saputra	L	SD N 48	54	55	98	0	Menengah
5	Eka Anggara	P	SD N 48	82	73	75	0	Menengah
6	Oka Wijaya	L	SD N 48	75	57	73	0	Menengah
7	Putu Handayani	L	SD N 48	83	97	64	0	Menengah
8	Indah Santoso	P	SD N 48	91	61	60	0	Menengah
9	Sari Susanti	L	SD N 48	77	97	88	0	Menengah
10	Kiki Santoso	L	SD N 48	63	53	93	0	Menengah
11	Putu Saputra	L	SD N 48	57	53	71	0	Menengah
12	Nana Anggara	L	SD N 48	69	81	77	2	Rendah

3.8 Akurasi K-Nearest Neighbors (KNN) berdasarkan Nilai K

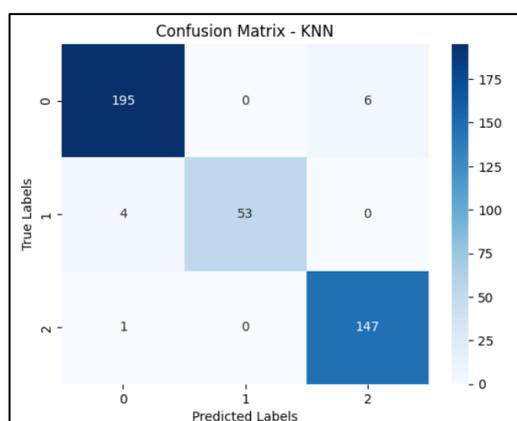
Pada data training dilakukan percobaan nilai k dari 1 hingga 10. Akurasi dihitung untuk setiap nilai k menggunakan data pelatihan dan pengujian. Akurasi *KNN* pada nilai k dapat dilihat pada Gambar 9.



Gambar 9. Akurasi KNN Pada Nilai K

Dari grafik diatas didapatkan bahwa hasil terlihat bahwa Nilai k terbaik yang ditemukan adalah 1, dengan akurasi tertinggi sebesar 95%.

3.9 Hasil Confusion Matrix



Gambar 10. Confusion Matrik

Uji *Confusion Matrix* menunjukkan bahwa model memiliki performa baik dalam mengklasifikasikan data, dengan precision dan recall tinggi untuk setiap kelas. Akurasi keseluruhan model juga tinggi, dengan sebagian besar prediksi benar. Kesalahan prediksi kecil terjadi antara Klaster 0 dan Klaster 2, serta antara Klaster 1 dan Klaster 0. Model *KNN* efektif dalam mengelompokkan siswa, dengan sedikit kesalahan klasifikasi, yang menunjukkan bahwa metode *hybrid* ini cukup efektif dalam mengelompokkan kemampuan calistung siswa.

3.10 Interpretasi Classification Report

```
print(classification_report(y_train, yab))
```

	precision	recall	f1-score	support
0	0.97	0.97	0.97	201
1	1.00	0.93	0.96	57
2	0.96	0.99	0.98	148
accuracy			0.97	406
macro avg	0.98	0.96	0.97	406
weighted avg	0.97	0.97	0.97	406

Gambar 11. Interpretasi Classification Report

Gambar 11 *classification report* menunjukkan bahwa akurasi model mencapai 97%. *Precision* dan *recall* untuk tiap kelas juga tinggi, membuktikan efektivitas metode *hybrid K-Means* dan *KNN*. Ini menunjukkan bahwa model ini dapat digunakan secara andal untuk mengelompokkan kemampuan siswa secara otomatis.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa penerapan metode *hybrid* berbasis *machine learning*, yaitu kombinasi antara algoritma *K-Means Clustering* dan *K-Nearest Neighbors (KNN)*, efektif dalam mengelompokkan kemampuan calistung siswa di dua Sekolah Dasar di Kota Lubuklinggau. *Clustering* dengan *K-Means* berhasil membagi siswa ke dalam tiga kluster

berdasarkan nilai membaca, menulis, dan berhitung, dengan interpretasi sebagai berikut: Cluster 0 (Menengah), Cluster 1 (Tinggi), dan Cluster 2 (Rendah). Analisis terhadap centroid masing-masing cluster menunjukkan bahwa kategori ini mencerminkan tingkat kemampuan siswa secara intuitif dan konsisten dengan distribusi nilai mereka. Pengujian klasifikasi menggunakan *KNN* dilakukan untuk memprediksi klaster siswa pada data baru berdasarkan hasil clustering sebelumnya. Hasil evaluasi model menunjukkan bahwa nilai *k* optimal adalah 1, dengan akurasi tertinggi sebesar 95%. Namun, berdasarkan *classification report* model secara keseluruhan mencapai akurasi sebesar 97%, yang mencerminkan kinerja terbaik model setelah pelatihan dan pengujian menyeluruh. Evaluasi klasifikasi berdasarkan metrik Confusion Matrix menunjukkan nilai yang sangat baik: *precision* untuk *cluster 0* (97%), *cluster 1* (100%), *cluster 2* (96%); *recall* untuk *cluster 0* (97%), *cluster 1* (93%), *cluster 2* (99%); serta *F1-Score* untuk *cluster 0* (97%), *cluster 1* (96%), dan *cluster 2* (98%). Perbedaan nilai akurasi antara uji coba nilai *k* dan *classification report* kemungkinan berasal dari penggunaan data yang berbeda (uji *k* menggunakan validasi silang internal, sementara *classification report* berdasarkan hasil akhir pengujian dengan data sampel baru). Dengan demikian, *metode hybrid K-Means* dan *KNN* terbukti efektif secara kuantitatif dalam mengelompokkan dan mengklasifikasikan siswa berdasarkan kemampuan calistung. Efektivitas ini didukung oleh nilai evaluasi yang tinggi dan konsistensi hasil klasifikasi, serta menunjukkan potensi penggunaan metode ini sebagai alat bantu dalam proses pengambilan keputusan pendidikan berbasis data.

REFERENCES

- [1] A. Candra Dewi *et al.*, "Peran Kemajuan Teknologi dalam Dunia Pendidikan," *J. Educ.*, vol. 06, no. 01, pp. 9725–9734, 2023.
- [2] P. Weraman, I. P. Agus, and D. Hita, "Kemampuan Calistung Dan Motivasi Belajar," vol. 4, no. 2, pp. 1234–1239, 2023.
- [3] L. Latifah and F. P. Rahmawati, "Penerapan Program CALISTUNG untuk Meningkatkan Literasi Numerasi Siswa Kelas Rendah di Sekolah Dasar," *J. Basicedu*, vol. 6, no. 3, pp. 5021–5029, 2022, doi: 10.31004/basicedu.v6i3.3003.
- [4] J. Jumrodah, M. Oktaviany, D. Amelia Safitri, U. Amalia, Y. Yunita, and L. Safitri, "Penerapan Model Pembelajaran Calistung di Rumah Pintar Sebagai Upaya Pendidikan Anak-Anak di Desa Walur," *J. Pengabd. Kpd. Masy. Nusan.*, vol. 5, no. 2, pp. 2442–2450, 2024, doi: 10.55338/jpkmn.v5i2.3201.
- [5] A. Safitri, H. Y. Ayyasy, H. Purba, M. B. Winanda, and ..., "Upaya Peningkatan Kemampuan Calistung Siswa Kelas I Sd Negeri 106224 Desa Kerapuh," *Pedamas ...*, vol. 2, pp. 293–299, 2024.
- [6] S. Wahyuni, S. Syamsuyurnita, D. Kesuma, and ..., "Peningkatan Kemampuan Literasi Numerasi Melalui Program Calistung Di Sanggar Bimbingan Kampung Bharu Kuala Lumpur, Malaysia," *Innov. J. ...*, vol. 3, pp. 1652–1662, 2023.
- [7] L. Juliasih, G. Sya'ban Maulana, S. Rahmawati, and L. Siti Muslimah, "Pendampingan Siswa Melalui Metode Calistung di Desa Mekarsari Kecamatan Mekarmukti Kabupaten Garut," *Bantenese J. Pengabd. Masy.*, vol. 6, no. 1, pp. 1–8, 2024, doi: 10.30656/ps2pm.v6i1.7782.
- [8] R. A. Ananda, "Clustering Menggunakan Algoritma K-Means untuk Mengelompokkan Data Perjudian Berdasarkan Wilayah di Kota Binjai (Studi Kasus : Pengadilan Negeri Binjai)," *Jurnal Sains dan Teknologi Informasi*, vol. 2, no. 4, 2024.
- [9] H. Hairani and H. A. Id, "Pelatihan Implementasi Machine Learning Pada Bidang Pendidikan," *J. Pengabd. dan Pemberdaya. Masy. Tahun*, vol. 2, no. 2, pp. 305–310, 2022, doi: 10.30821/adma.v2i2.xxxx.
- [10] A. Asmana, Y. Arie Wijaya, and M. Martanto, "Clustering Data Calon Siswa Baru Menggunakan Metode K-Means Di Sekolah Menengah Kejuruan Wahidin Kota Cirebon," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 6, no. 2, pp. 552–559, 2022, doi: 10.36040/jati.v6i2.5236.
- [11] Dewi Eka Putri and Eka Praja Wiyata Mandala, "Hybrid Data Mining berdasarkan Klasterisasi Produk untuk Klasifikasi Penjualan," *J. KomtekInfo*, vol. 9, pp. 68–73, 2022, doi: 10.35134/komtekinfo.v9i2.279.
- [12] A. E. Wibowo and T. Habanabakize, "K-Means Clustering untuk Klasifikasi Standar Kualifikasi Pendidikan dan Pengalaman Kerja Guru SMK di Indonesia," *J. Din. Vokasional Tek. Mesin*, vol. 7, no. 2, pp. 152–163, 2022, doi: 10.21831/dinamika.v7i2.53848.
- [13] A. Premana, O. Saeful Bachri, and A. Pandhu Wijaya, "Klasifikasi Jenis Mangga Apel Menggunakan Metode K-Means Klustering," *J. Tek. Indones.*, vol. 1, no. 1, pp. 16–25, 2022, doi: 10.58860/jti.v1i1.1.
- [14] A. Of *et al.*, "Penerapan K-Means Clustering Untuk Mengelompokkan Performa Siswa Dalam Pelajaran Bahasa Indonesia," *SATI Sustain. Agric. Technol. Innov.*, pp. 510–522, 2024.
- [15] R. Fauziah and A. I. Purnamasari, "Implementasi Algoritma K-Means pada Kasus Kekerasan Anak dan Perempuan Berdasarkan Usia," *Hello World J. Ilmu Komput.*, vol. 2, no. 1, pp. 34–41, 2023, doi: 10.56211/helloworld.v2i1.232.
- [16] F. Andini, D. Zilfitri, Y. Filki, and M. Ridho, "Algoritma K-Means Clustering dalam Optimalisasi Komposisi Pakan Ternak Ayam Petelur," *J. Sistim Inf. dan Teknol.*, vol. 5, pp. 44–48, 2022, doi: 10.37034/jsisfotek.v5i2.168.
- [17] A. Rudiyan, A. E. Dzulkifli, and K. Munazar, "Klasifikasi Kebakaran Hutan Menggunakan Metode K-Nearest Neighbor : Studi Kasus Hutan Provinsi Kalimantan Barat," *JTIM J. Teknol. Inf. dan Multimed.*, vol. 3, no. 4, pp. 195–202, 2022, doi: 10.35746/jtim.v3i4.177.
- [18] U. Muslim and N. Al Washliyah, "HYBRID LEARNING SEBAGAI METODE PEMBELAJARAN LITERASI DI MASA PANDEMI Fita Fatria 1), Tiflatul Husna 2)," *Prosiding Seminar Nasional Hasil Pengabdian*, no. 1, pp. 83–88, 2022, [Online]. Available: <https://sevima.com/apa-perbedaan-blended-learning-dan->
- [19] Fadil Danu Rahman, M. I. Z. Mulki, and A. Taryana, "Clustering Dan Klasifikasi Data Cuaca Cilacap Dengan Menggunakan Metode K-Means Dan Random Forest," *J. SINTA Sist. Inf. dan Teknol. Komputasi*, vol. 1, no. 2, pp. 90–97, 2024, doi: 10.61124/sinta.v1i2.15.
- [20] R. Zulfiqri, B. N. Sari, T. N. Padilah, U. S. Karawang, and T. Timur, "ANALISIS SENTIMEN ULASAN PENGGUNA APLIKASI MEDIA SOSIAL INSTAGRAM PADA SITUS GOOGLE PLAY STORE MENGGUNAKAN NAÏVE BAYES CLASSIFIER," vol. 12, no. 3, p. 9, 2024, [Online]. Available: <http://dx.doi.org/10.23960/jitet.v12i3.4995%0AANALISIS>