

Algoritma K-Nearest Neighbor Classification Sebagai Sistem Pengelompokan Kemampuan Akademik Siswa Berbasis Web

Utari Indah Wahyuni^{1*}, Rakhmat Kurniawan¹

¹Program Studi Sistem Informasi, Universitas Islam Negeri Sumatera Utara Medan, Indonesia.

Artikel Info

Kata Kunci:

Klasifikasi Kemampuan Akademik;
K-Nearest Neighbor;
Sistem Berbasis Web;
Treatment Pembelajaran.

Keywords:

*Academic Ability Classification;
K-Nearest Neighbor;
Web-based System;
Learning Treatment.*

Riwayat Artikel :

Submitted: 12 Juli 2025
Accepted: 31 Juli 2025
Published: 31 Juli 2025

Abstrak: Penggunaan sistem berbasis web dalam pendidikan dapat meningkatkan akurasi dan efisiensi evaluasi pembelajaran, terutama dalam penerapan Kurikulum Merdeka yang menuntut diferensiasi berdasarkan kemampuan siswa. Penelitian ini bertujuan mengembangkan sistem klasifikasi kemampuan akademik siswa berbasis web menggunakan algoritma K-Nearest Neighbor (K-NN). Sebanyak 254 data nilai akhir siswa kelas XII digunakan sebagai dataset, yang dinormalisasi menggunakan MinMaxScaler dan dilatih menggunakan model K-NN dengan parameter $K = 5$. Proses klasifikasi dan evaluasi dilakukan menggunakan confusion matrix dan classification report, yang menghasilkan akurasi sebesar 90,19%. Sistem ini dikembangkan menggunakan framework Laravel untuk sisi web dan Python (Google Colab) untuk pemrosesan data dan model klasifikasi. Hasil klasifikasi ditampilkan dalam bentuk tabel interaktif dan rekap visual yang memudahkan guru dalam merancang treatment pembelajaran adaptif. Kontribusi utama dari penelitian ini adalah integrasi antara algoritma klasifikasi dan sistem informasi berbasis web yang mendukung evaluasi akademik secara objektif, efisien, dan selaras dengan semangat Kurikulum Merdeka.

Abstract: The use of web-based systems in education has the potential to improve the accuracy and efficiency of academic evaluations, particularly in supporting the Merdeka Curriculum, which emphasizes differentiated instruction. This study aims to develop a web-based student academic ability classification system using the K-Nearest Neighbor (K-NN) algorithm. A dataset of 254 final scores from 12th-grade students was processed through MinMaxScaler normalization and trained using a K-NN model with $K = 5$. The classification and evaluation process utilized a confusion matrix and classification report, resulting in an accuracy of 90.19%. The system was developed using the Laravel framework for the web interface and Python (Google Colab) for data processing and model training. The classification output is displayed in interactive tables and visual summaries, enabling teachers to easily interpret student groups and plan adaptive learning treatments. The main contribution of this study lies in the integration of machine learning classification with a practical school information system that supports objective and efficient academic assessment aligned with the goals of the Merdeka Curriculum.

Corresponding Author:

Utari Indah Wahyuni
Email: indahwahyuniutari@gmail.com

PENDAHULUAN

Kemajuan teknologi informasi dalam beberapa tahun terakhir telah memberikan dampak signifikan terhadap berbagai aspek kehidupan, termasuk sektor pendidikan. Teknologi kini menjadi alat bantu utama dalam meningkatkan efektivitas proses pembelajaran, evaluasi akademik, dan pengambilan keputusan di lingkungan sekolah. Guru tidak hanya dituntut untuk mengajar, tetapi juga mengevaluasi capaian belajar siswa secara objektif, efisien, dan berkelanjutan (Safititri & Wicaksono, 2024). Prestasi belajar siswa merupakan indikator utama keberhasilan pendidikan, di mana peran guru menjadi elemen penting dalam menciptakan proses belajar mengajar yang efektif. Oleh karena itu, kolaborasi antara peningkatan kompetensi guru dan dukungan sistem informasi berbasis teknologi menjadi hal yang tidak dapat dihindari.

SMA Negeri 1 Kutalimbaru, sebagai salah satu sekolah yang telah mengadopsi Kurikulum Merdeka, menghadapi tantangan dalam penerapan sistem penilaian yang menekankan capaian kompetensi dan pengembangan karakter peserta didik secara menyeluruh. Kurikulum Merdeka menuntut evaluasi pembelajaran yang tidak hanya berbasis angka, tetapi juga mempertimbangkan dimensi pengetahuan, keterampilan, dan sikap siswa, serta penerapan pembelajaran yang terdiferensiasi. Prinsip utamanya adalah memberi ruang bagi peserta didik untuk mengembangkan potensi secara optimal sesuai dengan tahap capaian dan kebutuhannya, melalui asesmen formatif yang berkelanjutan dan reflektif. Namun, dalam praktik di lapangan, proses pengelompokan kemampuan akademik serta pemberian treatment pembelajaran masih dilakukan secara manual dan subjektif, mengandalkan observasi guru tanpa dukungan data historis yang sistematis. Hal ini menimbulkan potensi bias dalam penilaian, ketidaktepatan dalam pengambilan keputusan, dan hambatan dalam dokumentasi serta analisis perkembangan siswa secara longitudinal.

Berbagai penelitian telah menunjukkan bahwa algoritma klasifikasi, khususnya K-Nearest Neighbor (K-NN), efektif dalam mendukung pengambilan keputusan di dunia pendidikan. (Cholil et al., 2021) menggunakan K-NN dalam seleksi beasiswa dengan akurasi 90,5%. (Purwaningsih & Nurelasari, 2021) mengklasifikasikan tingkat kelulusan siswa, sementara (Widaningsih & Yusuf, 2022) menggunakannya untuk memprediksi siswa berprestasi. (Sanjaya & Wahyana, 2022) serta (Ardiantito S, et al., 2023) menegaskan bahwa K-NN unggul karena kesederhanaannya dan prinsip kedekatan data. (Supriadi et al., 2023) menggunakan K-NN untuk klasifikasi kelulusan siswa berdasarkan nilai rata-rata, dengan hasil sistem berjalan efektif."

Model pengolahan data dalam penelitian ini dikembangkan menggunakan algoritma K-Nearest Neighbor (K-NN), yang dikenal efisien untuk data berskala besar dan mampu menghasilkan prediksi yang lebih akurat (Prasetyawan et al., 2022). Klasifikasi merupakan teknik untuk mengelompokkan data ke dalam kelas tertentu, dan K-NN menjadi salah satu metode yang populer karena kesederhanaannya serta kemampuannya dalam menghasilkan prediksi yang cukup presisi (Bakri & Harahap, 2025). Algoritma ini bekerja dengan mengelompokkan data baru berdasarkan kedekatannya terhadap data yang telah ada. Penelitian ini mengusulkan solusi berupa pengembangan sistem klasifikasi kemampuan akademik siswa berbasis web yang mengimplementasikan algoritma K-NN. Sistem ini dirancang untuk mengelompokkan siswa ke dalam kategori kemampuan tertentu (sangat baik, baik, rata-rata, di bawah rata-rata, dan perlu perbaikan) secara otomatis, objektif, dan cepat.

Penelitian ini mengembangkan sistem klasifikasi kemampuan akademik siswa berbasis web dengan algoritma K-NN untuk mengelompokkan siswa ke dalam lima kategori kemampuan secara otomatis dan objektif. Sistem ini memudahkan guru mengidentifikasi siswa yang membutuhkan perhatian khusus atau tantangan tambahan, serta memberikan rekomendasi treatment pembelajaran yang spesifik. Berbeda dengan pendekatan konvensional yang mengandalkan observasi manual, sistem ini berbasis data, konsisten, dan terotomatisasi. Inovasi penelitian ini terletak pada penerapan K-NN dalam konteks Kurikulum Merdeka untuk mendukung evaluasi akademik yang adil dan adaptif, tidak sekadar sebagai alat prediksi kelulusan seperti dalam penelitian sebelumnya.

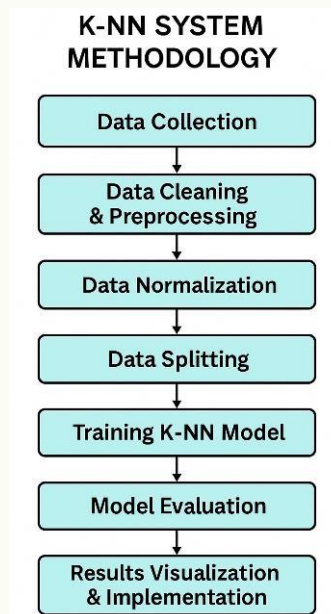
Penelitian ini bertujuan untuk mengembangkan sistem berbasis web yang mampu mengklasifikasikan kemampuan akademik siswa secara otomatis menggunakan algoritma K-Nearest Neighbor (K-NN). Sistem ini diharapkan dapat membantu guru dalam melakukan evaluasi akademik

yang objektif, mempercepat pengambilan keputusan, serta mendukung pembelajaran adaptif yang sesuai dengan semangat Kurikulum Merdeka. Selain itu, sistem ini diharapkan dapat meminimalkan subjektivitas penilaian dan meningkatkan akurasi pemberian treatment berdasarkan hasil klasifikasi kemampuan siswa

METODE

Penelitian ini menerapkan algoritma K-Nearest Neighbor (K-NN) untuk mengelompokkan kemampuan akademik siswa berdasarkan nilai akhir mata pelajaran. Alur kerja dilakukan secara sistematis mulai dari pengumpulan data, praproses, normalisasi, pelatihan model, evaluasi, hingga visualisasi hasil klasifikasi dan treatment yang sesuai (Olivia, 2024). Pemilihan K-NN didasarkan pada kesederhanaan algoritma serta kemampuannya dalam menghasilkan klasifikasi yang akurat, mendukung proses evaluasi dan pengambilan keputusan pembelajaran secara adaptif.

Implementasi sistem klasifikasi dilakukan menggunakan Google Colab untuk seluruh proses analisis data dan machine learning berbasis Python, dengan library utama seperti pandas, scikit-learn, matplotlib, dan seaborn. Sistem berbasis web dikembangkan menggunakan Laravel 10 (PHP Framework), dengan frontend berbasis template admin responsif untuk menampilkan hasil klasifikasi dan rekomendasi treatment.



Gambar 1. Tahapan Penelitian Algoritma KNN

Uraian mendalam terkait masing-masing tahap diatas dijabarkan pada bagian berikut

Pengumpulan Data

Data diperoleh dari rekapitulasi nilai siswa kelas XII yang mencakup 16 mata pelajaran inti. Nilai yang digunakan adalah nilai akhir (NA) dari masing-masing mata pelajaran dalam bentuk numerik. Dataset disimpan dalam format Microsoft Excel (.xlsx) dan diunggah ke Google Colab untuk keperluan pengolahan awal dan pelatihan model.

Preprocessing Data

Tahap ini meliputi pembersihan data seperti menghapus nilai kosong, memastikan semua kolom dalam format numerik, dan menyelaraskan struktur dataset (Agung et al., 2023). Dilakukan juga feature selection dengan memilih kolom nilai akhir dari setiap mata pelajaran sebagai fitur (X). Label klasifikasi (Y) ditentukan berdasarkan kriteria berikut:

Table 1. Label Klasifikasi

Kategori	Rentang Nilai
Excellent	≥ 90
Good	80-89
Average	70-79
Below Average	60-69
Needs Improvement	< 60

Normalisasi Data

Untuk menghindari dominasi atribut dengan skala nilai besar, seluruh fitur dilakukan normalisasi menggunakan metode Min-Max Scaler (Whendasmoro & Joseph, 2022). Rumus normalisasi:

$$X_{normal} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

Keterangan:

X_{normal} : Nilai setelah dinormalisasi

X : Nilai asli

X_{min} : Nilai minimum atribut

X_{max} : Nilai maksimum atribut

Split Data

Dataset dibagi menjadi dua bagian, yaitu data pelatihan sebesar 80% dengan jumlah 203 data dan data pengujian sebesar 20% dengan jumlah 51 data, menggunakan fungsi `train_test_split` dari pustaka `sklearn`. Pembagian ini bertujuan untuk melatih model K-NN dan mengujinya terhadap data baru yang belum pernah dilihat model (Azis et al., 2020).

Proses Klasifikasi dengan Algoritma KNN

Algoritma K-NN bekerja dengan menghitung jarak euclidean antara data baru dan seluruh data pada training set (Dinata et al., 2020). Jarak dihitung menggunakan rumus:

$$d(p, q) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2}$$

Di mana $d(p, q)$ adalah jarak antara data uji dan data latih. Nilai k ditentukan (misalnya $k = 5$), dan data uji diklasifikasikan ke dalam kelas mayoritas dari k tetangga terdekat.

Evaluasi Model

Model K-NN yang dibangun dievaluasi menggunakan Confusion Matrix, serta dihitung nilai akurasi, presisi, dan recall-nya.

a. Akurasi $Akurasi = \frac{TP+TN}{TP+TN+FP+FN}$

b. Presisi $Presisi = \frac{TP}{TP+FN}$

c. Recall $Recall = \frac{TP}{TP+FN}$

Prediksi dan Penentuan Treatment

Setelah model terlatih, dilakukan prediksi terhadap data siswa. Hasil klasifikasi menentukan kategori kemampuan siswa dan digunakan untuk menetapkan treatment atau perlakuan pembelajaran yang sesuai. Setiap kategori memiliki rekomendasi treatment berbeda, seperti bimbingan tambahan, proyek mandiri, hingga kelas remedial.

Visualisasi Hasil Klasifikasi dan Treatment

Hasil akhir ditampilkan dalam bentuk tabel interaktif pada halaman web, di mana setiap baris menampilkan data siswa berdasarkan mata pelajaran, nilai yang diperoleh, klasifikasi kemampuan, dan rekomendasi treatment. Tampilan ini dirancang responsif dan mudah diakses oleh guru, sehingga dapat digunakan sebagai referensi pembelajaran adaptif secara langsung melalui sistem berbasis web.

HASIL DAN PEMBAHASAN

Pengumpulan Data

Data dalam penelitian ini diperoleh dari hasil rekapitulasi nilai siswa kelas XII pada salah satu SMA di Kabupaten Deli Serdang. Data mencakup nilai akhir (NA) dari berbagai mata pelajaran inti, yang dikumpulkan dari delapan kelas, yaitu XII-1 hingga XII-8, dengan jumlah siswa masing-masing: 32, 30, 33, 36, 33, 27, 31, dan 32 siswa. Total keseluruhan data berjumlah 254 siswa. Pengumpulan data dilakukan secara langsung dari pihak sekolah dalam bentuk file spreadsheet, kemudian diolah lebih lanjut untuk kebutuhan klasifikasi kemampuan akademik siswa. Seluruh data telah melalui proses validasi untuk memastikan kelengkapan dan kesesuaiannya dengan format pengolahan. Untuk keperluan penyajian di artikel jurnal, ditampilkan sampel data sebanyak 20 siswa sebagai representasi dari keseluruhan populasi.

A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R
no	nama_siswa	agama	pkn	bi	mtk	sejarah	bing	penjas	sbk	kwu	kimia	fisika	biologi	sosiologi	ekonomi	geografi	informatika
1	Aloysa Junita Br Tarigan	92,39	89,83	89,28	86,85	84,82	89,24	90,33	88,71	89,51	87,76	73,00	85,78	88,56	86,33	81,00	80,00
2	Apriel Syah Fikko Barus	84,13	85,31	86,47	77,63	82,23	81,09	79,60	83,22	85,22	70,17	67,50	81,00	85,58	61,56	67,50	74,50
3	Aulia Anugrah	91,86	91,16	90,06	88,49	85,66	88,14	91,06	87,22	90,10	91,66	88,00	86,22	89,78	66,33	87,00	88,50
4	Ayu Lestari Br Tarigan	85,96	91,82	87,50	84,93	84,20	86,69	79,09	85,48	87,04	88,66	75,00	84,89	86,78	85,69	71,50	71,00
5	Bunga Ramadani	85,73	90,72	87,44	85,79	83,73	86,92	89,50	85,76	88,82	88,10	73,50	84,89	88,61	86,17	79,00	75,50
6	Dea Olivia Br Sitepu	86,53	92,32	88,44	85,74	85,27	90,08	89,00	87,34	88,99	87,52	77,50	85,90	89,28	87,44	79,00	77,50
7	Dinda Aulia Salsabilah	89,93	92,49	87,56	84,29	86,11	90,29	88,60	87,34	88,51	88,67	74,50	85,41	87,72	87,03	77,50	76,50
8	Dirhanta Tarigan	74,50	84,29	84,59	78,18	81,77	58,44	84,43	86,23	63,17	85,26	71,00	81,28	84,76	61,06	70,00	74,50
9	Eka Permatasari Kembaren	74,61	79,89	74,33	78,13	72,89	82,03	75,61	78,78	79,11	76,06	74,00	74,56	77,11	78,17	72,50	60,00
10	Elsa Mutia Sari Sembiring	89,73	94,02	88,67	87,49	88,27	89,69	89,56	88,96	90,20	89,04	78,50	86,59	88,28	88,22	74,50	73,50
11	Emiya Ristanty	83,80	85,39	85,91	84,78	82,08	81,11	85,93	83,79	63,44	84,18	70,50	82,56	84,69	63,17	76,50	74,50
12	Erisa Br Tarigan	83,27	85,39	85,61	84,06	74,56	52,61	84,21	80,44	64,39	83,87	71,00	80,78	85,33	63,61	65,00	72,00
13	Grace Calista Surbakti	88,20	89,55	89,00	87,04	87,66	89,13	86,41	87,38	89,29	89,20	75,50	83,73	87,94	87,94	77,50	76,50
14	Iis Krisdayanti	79,22	78,56	80,17	75,06	81,06	75,56	81,28	77,06	80,22	79,78	73,00	77,78	77,67	80,39	67,50	70,00
15	Jail Keni Aguselin Sembiring	86,60	87,99	88,91	86,21	85,37	82,49	88,03	88,31	89,43	86,57	74,00	85,16	88,02	87,06	70,00	74,00
16	Melandri Ginting	87,61	86,28	86,26	77,35	81,29	61,46	85,99	83,74	84,56	85,54	71,50	82,28	85,87	61,72	71,50	71,00
17	Milka Dea Sari Br Sembiring	86,72	90,33	87,28	83,52	85,48	83,70	89,06	87,34	65,96	87,76	74,00	84,07	89,06	67,31	79,00	79,00
18	Mirekel Pranata	83,71	81,27	85,31	78,13	81,40	79,58	85,85	81,90	85,94	70,66	71,00	82,28	84,87	83,28	72,50	75,00
19	Muhammad Aldo	90,87	93,26	89,17	90,91	86,07	91,23	91,17	85,23	88,68	91,36	75,00	88,13	88,33	85,11	77,50	71,00
20	Mustika	87,94	88,43	86,17	79,79	80,77	83,34	88,41	86,64	87,47	87,88	71,50	83,16	85,61	84,61	73,50	73,00

Gambar 2. Dataset Nilai Raport Siswa

Normalisasi Data

Proses normalisasi dilakukan untuk menyamakan skala antar fitur (mata pelajaran) sehingga tidak ada fitur yang mendominasi dalam proses klasifikasi. Dalam penelitian ini, metode Min-Max Scaling digunakan, yang mengubah nilai asli ke dalam rentang 0 hingga 1 (Wenny, 2024). Metode ini dipilih karena mampu mempertahankan distribusi asli data sambil memperkecil skala nilai, sehingga cocok untuk algoritma K-Nearest Neighbor yang sensitif terhadap jarak antar data. Untuk hasilnya ditampilkan pada gambar berikut.

Hasil normalisasi (5 data pertama):

	agama	pkn	bi	mtk	sejarah	bing	penjas
0	0.921899	0.852223	0.925040	0.754352	0.824592	0.889879	0.970012
1	0.694130	0.732509	0.844338	0.401911	0.773885	0.691768	0.583766
2	0.907402	0.887253	0.947368	0.816985	0.840914	0.863158	0.996002
3	0.744768	0.904916	0.874003	0.681104	0.812405	0.827800	0.565374
4	0.738336	0.875773	0.872408	0.714013	0.803264	0.833468	0.940024

	sbk	kwu	kimia	fisika	biologi	sosiologi	ekonomi
0	0.745946	0.867596	0.915463	0.382103	0.835848	0.881143	0.795262
1	0.540541	0.745328	0.636668	0.220444	0.706095	0.789257	0.166385
2	0.690229	0.884384	0.977281	0.822992	0.847918	0.918857	0.287648
3	0.624948	0.797276	0.929729	0.440888	0.811708	0.826286	0.778906
4	0.635343	0.847957	0.920923	0.396799	0.811708	0.882857	0.791032


	geografi	informatika
0	0.849057	0.645161
1	0.594340	0.467742
2	0.962264	0.919355
3	0.669811	0.354839
4	0.811321	0.500000

Gambar 3. Hasil Normalisasi Data

Evaluasi Model

Untuk menentukan nilai parameter K yang optimal dalam algoritma K-Nearest Neighbor, dilakukan pengujian akurasi terhadap rentang nilai K dari 1 hingga 20. Hasil pengujian divisualisasikan dalam bentuk grafik variasi akurasi terhadap nilai K. Dari grafik, terlihat bahwa nilai K = 4 dan K = 16 menghasilkan akurasi tertinggi, yaitu sekitar 94%, sedangkan nilai K = 2 dan K = 11 memiliki akurasi terendah, di bawah 89%.


Namun, dalam penelitian ini, digunakan K = 5 sebagai parameter utama karena beberapa pertimbangan. Pertama, meskipun akurasinya sedikit lebih rendah (sekitar 90,2%), selisihnya tidak signifikan dibanding nilai maksimum. Kedua, nilai K = 5 berada di sekitar puncak kurva dan menunjukkan stabilitas hasil yang baik. Hal ini penting untuk implementasi jangka panjang karena model tidak terlalu sensitif terhadap fluktuasi data baru. Ketiga, K = 5 merupakan nilai ganjil terkecil yang meminimalkan kemungkinan hasil prediksi imbang saat voting mayoritas dilakukan dalam klasifikasi. Selain itu, nilai ini juga umum digunakan dalam berbagai studi penerapan K-NN karena memberikan keseimbangan yang baik antara bias dan varians. Pemilihan K juga mempertimbangkan prinsip bias-variance trade-off. Nilai K yang terlalu kecil seperti K = 1 atau 2 berpotensi menyebabkan model overfitting karena terlalu sensitif terhadap noise, sedangkan nilai yang terlalu besar seperti K = 16 atau lebih dapat menyebabkan underfitting, karena terlalu menggeneralisasi data



Gambar 4. Grafik Variasi Nilai K

Evaluasi performa lebih lanjut terhadap model K-NN dengan K = 5 dilakukan menggunakan confusion matrix dan classification report. Dari total 51 data uji, sebanyak 37 siswa yang tergolong "Excellent" berhasil diklasifikasikan dengan benar, dan 2 siswa Excellent salah diklasifikasikan sebagai "Average". Sebaliknya, dari 12 siswa yang seharusnya "Average", 9 terklasifikasi dengan tepat, dan 3


sisanya salah diklasifikasikan sebagai "Excellent". Model ini menghasilkan akurasi sebesar 90,19%, yang berarti lebih dari 90% prediksi sesuai label aktual. Nilai precision tercatat sebesar 82% untuk kelas "Average" dan 93% untuk kelas "Excellent". Sedangkan recall menunjukkan 75% untuk "Average" dan 95% untuk "Excellent". F1-score sebagai metrik gabungan precision dan recall mencatat nilai 78% untuk "Average" dan 94% untuk "Excellent". Berdasarkan hasil tersebut, model K-NN dengan K = 5 dinilai cukup efektif dalam melakukan pengelompokan kemampuan akademik siswa dan layak untuk diterapkan dalam sistem pendukung pembelajaran adaptif berbasis web di lingkungan sekolah.



Gambar 5. Grafik Confusion Matrix

Prediksi dan Penentuan Treatment

Setelah proses pelatihan model K-Nearest Neighbor (K-NN) selesai, sistem melakukan prediksi terhadap data uji maupun data siswa secara keseluruhan. Hasil prediksi ini menghasilkan pengelompokan siswa ke dalam lima kategori klasifikasi kemampuan, yaitu Excellent, Good, Average, Below Average, dan Needs Improvement. Setiap kategori memiliki rekomendasi treatment pembelajaran masing-masing yang dirancang untuk mendukung kebutuhan belajar siswa secara personal dan adaptif.



Gambar 6. Grafik Distribusi Klasifikasi Kemampuan Siswa per Mata Pelajaran

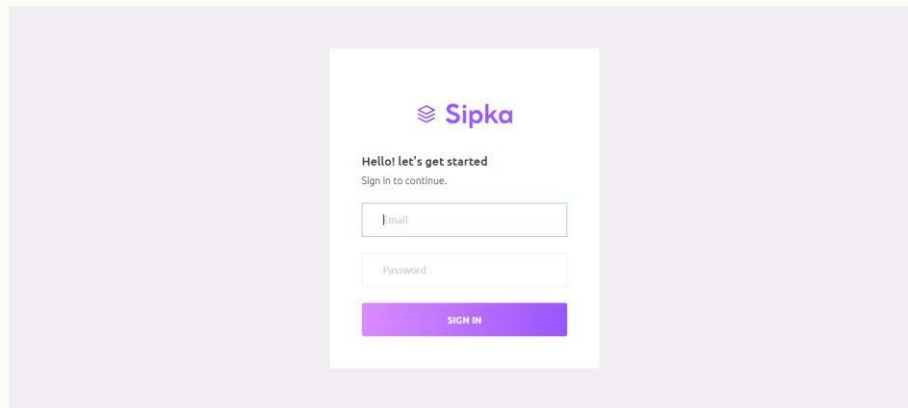
Visualisasi grafik di atas menunjukkan distribusi jumlah siswa berdasarkan klasifikasi kemampuan pada tiap mata pelajaran. Terlihat bahwa kategori "Good" merupakan klasifikasi yang paling dominan hampir di seluruh mata pelajaran. Misalnya, pada mata pelajaran seperti Penjaskes, Bahasa Indonesia, dan Matematika, jumlah siswa yang masuk dalam kategori "Good" sangat tinggi dibandingkan kategori lainnya. Sebaliknya, kategori "Needs Improvement" cenderung paling sedikit, meskipun tetap muncul di beberapa mata pelajaran seperti Ekonomi, Fisika, dan Sosiologi, yang menandakan bahwa terdapat sebagian kecil siswa yang membutuhkan perhatian dan bimbingan lebih lanjut. Adapun kategori "Excellent" juga tampak menonjol pada beberapa mapel seperti Seni Budaya, Bahasa Inggris, dan Pendidikan Kewarganegaraan, yang menunjukkan sebagian siswa mampu memahami materi secara menyeluruh dan mendalam.

Tabel 2. Hasil Klasifikasi dan Penentuan Treatment

Nama Siswa	Rata-rata	Prediksi	Treatment
Irfan Ermansyah	79,78	Good	<ul style="list-style-type: none"> • Latihan soal lanjutan • Diskusi studi kasus • Proyek menantang
Jeans Pirlo	81,07	Good	<ul style="list-style-type: none"> • Latihan soal lanjutan • Diskusi studi kasus • Proyek menantang
Jesika Sabrina	85,75	Average	<ul style="list-style-type: none"> • Bimbingan tambahan • Materi review + diskusi • Penguatan konsep dasar
Lavenia	81,09	Good	<ul style="list-style-type: none"> • Latihan soal lanjutan • Diskusi studi kasus • Proyek menantang
Selin Belinda	84,08	Good	<ul style="list-style-type: none"> • Latihan soal lanjutan • Diskusi studi kasus • <u>Proyek menantang</u>

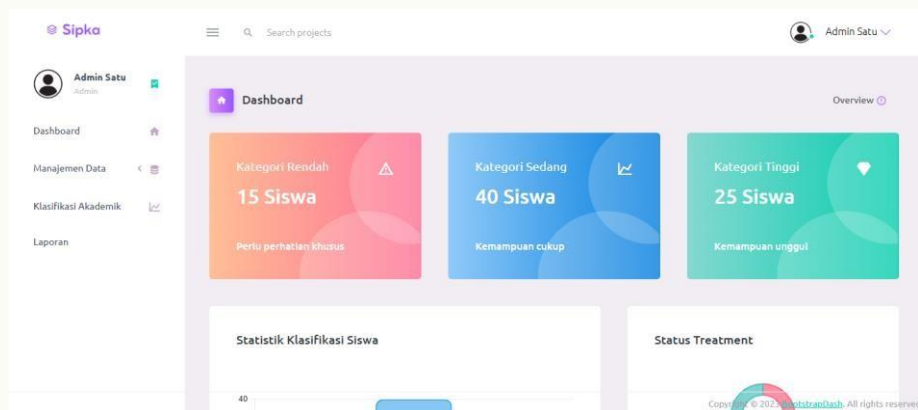
Berdasarkan hasil klasifikasi terhadap lima siswa yang ditampilkan dalam tabel, seluruh siswa berada dalam dua kategori utama yaitu Good dan Average. Tiga siswa, yaitu Irfan Ermansyah, Jeans Pirlo, dan Lavenia, diklasifikasikan ke dalam kategori Good dengan nilai rata-rata berkisar antara 79,78 hingga 81,09. Hal ini menunjukkan bahwa ketiganya telah menguasai sebagian besar materi dengan baik dan memerlukan tantangan tambahan melalui latihan soal lanjutan, diskusi studi kasus, serta proyek yang lebih menantang. Sementara itu, Jesika Sabrina dikategorikan sebagai Average meskipun memiliki nilai rata-rata 85,75, yang menunjukkan adanya ketidaksesuaian antara nilai dan kategori yang kemungkinan disebabkan oleh pengaruh normalisasi atau distribusi data lainnya. Satu siswa lainnya, Selin Belinda, juga berada dalam kategori Good dengan rata-rata 84,08. Data ini menunjukkan bahwa sebagian besar siswa dalam sampel ini memiliki kemampuan akademik yang cukup baik dan hanya memerlukan treatment penguatan untuk mempertajam pemahaman dan kemampuan aplikatifnya.

Visualisasi Sistem



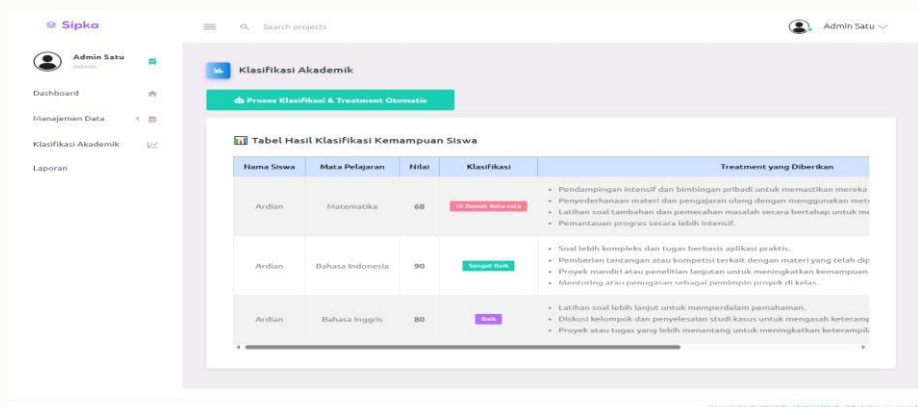
Gambar 7. Halaman Login

Gambar 7. Merupakan tampilan dari halaman login. Pengguna dapat menginputkan email dan password yg sudah terdaftar agar dapat masuk kedalam sistem.



Gambar 8. Halaman Dashboard

Gambar 8. Merupakan tampilan halaman dashboard. Pada tampilan ini akan menyajikan data terkait hasil klasifikasi siswa.



Gambar 9. Halaman Klasifikasi Akademik

Gambar 9. Merupakan tampilan klasifikasi akademik. Pada halaman ini pengguna dapat melakukan pengelompokan siswa berdasarkan kategori yang telah dibuat dan menentukan treatment yg akan dilakukan.

Perbandingan dengan Studi Sebelumnya dan Uji Coba Sistem

Penelitian ini membuktikan bahwa algoritma K-Nearest Neighbor (K-NN) dapat digunakan secara efektif untuk mengklasifikasikan kemampuan akademik siswa dengan akurasi mencapai 90,19%. Temuan ini selaras dengan studi sebelumnya yang juga menggunakan K-NN dalam bidang pendidikan. Cholil et al. (2021) mengaplikasikan K-NN untuk seleksi penerima beasiswa dan memperoleh akurasi 90,5%, sedangkan Purwaningsih & Nurelasari (2021) menggunakannya untuk klasifikasi kelulusan siswa. Supriadi et al. (2023) juga menunjukkan keberhasilan sistem klasifikasi kelulusan siswa SMA menggunakan K-NN, dan Widaningsih & Yusuf (2022) menerapkan K-NN untuk memprediksi prestasi siswa berdasarkan nilai akademik dan faktor non-akademik.

Berbeda dari studi-studi tersebut yang umumnya berfokus pada hasil akhir seperti kelulusan atau seleksi bantuan pendidikan, penelitian ini mengimplementasikan K-NN untuk mengelompokkan siswa berdasarkan nilai mata pelajaran dan memberikan treatment pembelajaran yang adaptif. Sistem ini tidak hanya menyajikan hasil klasifikasi, tetapi juga secara otomatis merekomendasikan strategi pembelajaran sesuai dengan kelompok kemampuan siswa. Selain itu, pengembangan berbasis framework Laravel memungkinkan sistem diakses dengan mudah oleh guru melalui antarmuka web yang interaktif dan responsif, yang belum banyak dikaji dalam studi sebelumnya.

Untuk menguji keterterapan sistem dalam lingkungan sekolah, dilakukan uji coba oleh tiga guru mata pelajaran di SMA Negeri 1 Kutalimbaru. Guru mengakses sistem sebagai wali kelas dan mengevaluasi fitur-fitur utama seperti klasifikasi per siswa, rekomendasi treatment, dan cetak laporan. Berdasarkan form evaluasi, hasil penilaian menunjukkan bahwa sistem memiliki kemudahan penggunaan dan mendukung perencanaan pembelajaran secara praktis.

Table 3. Ringkasan Umpan Balik Guru

Aspek yang Dinilai	Skor Rata-rata	Tahapan Ringkas
Kemudahan Akses Sistem	4.7 / 5	Antarmuka mudah digunakan dan cepat diakses
Kejelasan Tampilan Klasifikasi	4.5 / 5	Tabel interaktif mudah dipahami dan navigasi jelas
Kesesuaian Treatment dengan Siswa	4.3 / 5	Saran treatment cukup sesuai dengan kondisi siswa
Kegunaan untuk Perencanaan Belajar	4.6 / 5	Membantu guru menyusun strategi pembelajaran
Kelengkapan dan Integrasi Data	4.4 / 5	Data tersaji lengkap dan saling terhubung

Dengan demikian, sistem klasifikasi berbasis K-NN yang dikembangkan tidak hanya terbukti akurat secara algoritmik, tetapi juga relevan secara praktis untuk mendukung pembelajaran diferensiatif. Perbandingan dengan studi sebelumnya dan validasi langsung oleh pengguna akhir menunjukkan bahwa pendekatan ini memberikan nilai tambah dalam membangun sistem pembelajaran adaptif berbasis data di lingkungan sekolah.

KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi kemampuan akademik siswa berbasis web dengan menerapkan algoritma K-Nearest Neighbor (K-NN). Sistem mampu mengelompokkan siswa ke dalam lima kategori berdasarkan nilai rata-rata dan secara otomatis memberikan rekomendasi treatment pembelajaran yang sesuai. Model klasifikasi menunjukkan performa yang tinggi dengan tingkat akurasi sebesar 90,19%, yang menjadikannya alat bantu evaluasi akademik yang objektif, sistematis, dan mendukung pelaksanaan Kurikulum Merdeka secara lebih adaptif. Meskipun demikian, penelitian ini memiliki beberapa keterbatasan. Pertama, data yang digunakan hanya berasal dari satu sekolah dan satu jenjang kelas, sehingga generalisasi hasil masih terbatas. Kedua, sistem belum mengakomodasi dimensi penilaian non-akademik seperti sikap atau keaktifan siswa, yang juga penting dalam evaluasi menyeluruh. Selain itu, proses klasifikasi masih berbasis nilai akhir tanpa mempertimbangkan perkembangan nilai dari waktu ke waktu (longitudinal analysis). Ke depan, sistem ini dapat dikembangkan lebih lanjut dengan mengintegrasikan fitur pelacakan perkembangan siswa dari semester ke semester, serta menggabungkan data kehadiran dan aspek afektif untuk menghasilkan klasifikasi yang lebih holistik. Pengembangan juga dapat diarahkan pada peningkatan antarmuka pengguna agar lebih intuitif, serta integrasi dengan sistem informasi sekolah secara menyeluruh untuk mendukung pengambilan keputusan berbasis data yang lebih luas di tingkat manajemen sekolah. Dengan arah pengembangan ini, sistem diharapkan tidak hanya menjadi alat klasifikasi, tetapi juga instrumen pendukung pembelajaran yang lebih cerdas dan berkelanjutan.

DAFTAR PUSTAKA

- Agung, A., Daniswara, A., Kadek, I., & Nuryana, D. (2023). Data Preprocessing Pola Pada Penilaian Mahasiswa Program Profesi Guru. *Journal of Informatics and Computer Science*, 05(1), 97-100.
- Ardiantito S, W., Ramadhan, R. A., & Immanuel S, R. S. (2023). Komparasi Algoritma Machine Learning dalam Memprediksi Penyakit Gagal Ginjal. *Mutiara : Jurnal Penelitian Dan Karya Ilmiah*, 1(6), 363–374. <https://doi.org/10.59059/mutiara.v1i6.781>
- Azis, H., Purnawansyah, P., Fattah, F., & Putri, I. P. (2020). Performa Klasifikasi K-NN dan Cross Validation Pada Data Pasien Pengidap Penyakit Jantung. *ILKOM Jurnal Ilmiah*, 12(2), 81–86. <https://doi.org/10.33096/ilkom.v12i2.507.81-86>
- Bakri, S. N., & Harahap, L. S. (2025). Analisis klasifikasi Algoritma K-Nearest Neighbor (K-NN) pada struktur Daerah di Kota Medan. *Jurnal Ilmiah Komputer dan Sistem Informasi*, 4(2), 182-193. <https://doi.org/10.70340/jirsi.v4i2.165>
- Cholil, S. R., Handayani, T., Prathivi, R., & Ardianita, T. (2021). Implementasi Algoritma Klasifikasi K-Nearest Neighbor (KNN) Untuk Klasifikasi Seleksi Penerima Beasiswa. *IJCIT (Indonesian Journal on Computer and Information Technology)* 6(2). <https://doi.org/10.31294/ijcit.v6i2.10438>
- Dinata, R. K., Akbar, H., & Hasdyna, N. (2020). Algoritma K-Nearest Neighbor dengan Euclidean Distance dan Manhattan Distance untuk Klasifikasi Transportasi Bus. *ILKOM Jurnal Ilmiah*, 12(2), 104–111. <https://doi.org/10.33096/ilkom.v12i2.539.104-111>
- Olivia, D. (2024). Penerapan Algoritma K-Nearest Neighbor (Knn) Untuk Ketepatan Waktu Lulus Mahasiswa. https://digilibadmin.unismuh.ac.id/upload/39413-Full_Text.pdf
- Prasetyawan, D., Gatra, R. (2022). Algoritma K-Nearest Neighbor untuk Memprediksi Prestasi Mahasiswa Berdasarkan Latar Belakang Pendidikan dan Ekonomi. In *Jurnal Informatika Sunan Kalijaga*, 7(1), 259-266. <https://doi.org/10.14421/jiska.2022.7.1.56-67>

- Purwaningsih, E., & Nurelasari, E. (2021). Penerapan K-Nearest Neighbor Untuk Klasifikasi Tingkat Kelulusan Pada Siswa. *Syntax: Jurnal Informatika*, 10(01), 46-56.
<https://doi.org/10.35706/syji.v10i01.5173>
- Safititri, D., & Wicaksono, N. F. (2024). Guru Sebagai Pilar Utama: Meningkatkan Kualitas Pendidikan Di Sekolah. *Jurnal Pendidikan Vokasi dan Seni*, 3(1), 1–12. <https://doi.org/10.52060/jpvs.v2i1>
- Sanjaya, A., & Wahyana, T. (2022). Penerapan Metode K-Nearest Neighbour Untuk Sistem Prediksi Kelulusan Siswa Mts Nurul Muslimin Berbasis Website. *Journal Transformation of Mandalika*, 3(2) 31-47.
- Supriadi, D., Yupianti, Y., Suryana, E. (2023). Penerapan K-Nearest Neighbor Untuk Klasifikasi Tingkat Kelulusan Pada Siswa Sma Negeri 11 Kota Bengkulu. *Jurnal Media Infotama*, 19 (2), 427-478.
<https://doi.org/10.37676/jmi.v19i2.4360>
- Wenny, W. (2024). Bulletin of Information System Research (BIOS) Normalisasi Data Kependudukan Dengan Model Min Max Dan Algoritma K-Means Untuk Pengelompokkan Tingkat Ekonomi Masyarakat. *Bulletin of Information System Research*, 2(2), 53-63.
<https://doi.org/10.62866/bios.v2i2.141>
- Whendasmoro, R. G., & Joseph, J. (2022). Analisis Penerapan Normalisasi Data Dengan Menggunakan Z-Score Pada Kinerja Algoritma K-NN. *JURIKOM (Jurnal Riset Komputer)*, 9(4), 872-883.
<https://doi.org/10.30865/jurikom.v9i4.4526>
- Widaningsih, S. (2022). Penerapan Data Mining Untuk Memprediksi Siswa Berprestasi Dengan Menggunakan Algoritma K Nearest Neighbor. *Jurnal Teknik Informatika Dan Sistem Informasi*, 9(3), 2598-2611. <https://doi.org/10.35957/jatisi.v9i3.859>