

Prediksi Kinerja Siswa SMP Berdasarkan Data Akademik dan Perilaku Menggunakan Machine Learning

Abriel Florent Amor^{a,1}, Muhammad Rizal Ihsanudin^{a,2}, Shandyka Oka Yulistianto^{a,3}, Hidayat^{a,4,*}

^aSistem Komputer, Fakultas Teknik dan Ilmu Komputer, Universitas Komputer Indonesia, Indonesia

¹abriel.10221019@mahasiswa.unikom.ac.id, ²rizal.10221002@mahasiswa.unikom.ac.id,

³shandyka.10221008@mahasiswa.unikom.ac.id

^{4,*}hidayat@email.unikom.ac.id

Diterima	Direvisi	Disetujui	Dipublikasikan
29/5/2025	15/8/2025	29/8/2025	15/9/2025

ABSTRACT

Students' academic performance is a crucial indicator in assessing the effectiveness of the learning process at the junior high school level. This study aims to develop a predictive model of student performance using a machine learning approach based on a combination of academic and behavioral data. The dataset includes mathematics scores, Bahasa Indonesia scores, study time outside of school, participation in extracurricular activities, attendance rate, and number of absences over one semester. Three machine learning algorithms—Logistic Regression, Decision Tree, and Neural Network—were applied to compare their performance in predicting student outcomes. Evaluation using the confusion matrix reveals that each algorithm exhibits varying accuracy levels depending on the proportion of training and testing data. Neural Network achieved the highest accuracy of 59% in the 60:40 data split scenario and 57% in the 70:30 scenario. Decision Tree demonstrated significant performance improvement in the 80:20 scenario, reaching an accuracy of 59%, while Logistic Regression remained relatively stable with a best accuracy of 52% in the 70:30 scenario. These findings suggest that machine learning approaches can significantly contribute to the early identification of students at risk of underachievement. With proper implementation, the model has the potential to support teachers and schools in designing more adaptive and personalized learning strategies. This study serves as a foundation for developing data-driven decision support systems in educational settings.

KEYWORDS

Student Performance
Machine Learning
Academic Data
Student Behavior
Prediction

ABSTRAK

Kinerja akademik siswa merupakan indikator penting dalam menilai efektivitas proses pembelajaran di tingkat Sekolah Menengah Pertama (SMP). Penelitian ini bertujuan untuk membangun model prediksi kinerja siswa menggunakan pendekatan machine learning berdasarkan kombinasi data akademik dan perilaku. Data yang digunakan mencakup nilai Matematika, nilai Bahasa Indonesia, waktu belajar di luar sekolah, keaktifan dalam kegiatan ekstrakurikuler, tingkat kehadiran, dan jumlah absensi dalam satu semester. Tiga algoritma *machine learning* digunakan dalam penelitian ini, yaitu *Logistic Regression*, *Decision Tree*, dan *Neural Network*, untuk membandingkan performa model dalam memprediksi kinerja siswa. Hasil evaluasi menggunakan *confusion matrix* menunjukkan bahwa setiap algoritma memiliki tingkat akurasi yang bervariasi tergantung pada proporsi pembagian data latih dan uji. *Neural Network* mencatat akurasi tertinggi sebesar 59% pada skenario pembagian data 60:40 dan 57% pada skenario 70:30. *Decision Tree* menunjukkan peningkatan performa signifikan pada skenario 80:20 dengan akurasi mencapai 59%, sedangkan *Logistic Regression* cenderung stabil dengan akurasi terbaik 52% pada skenario 70:30. Temuan ini menunjukkan bahwa pendekatan machine learning dapat memberikan kontribusi signifikan dalam proses identifikasi dini siswa yang berisiko mengalami penurunan prestasi. Dengan penerapan yang tepat, model ini berpotensi membantu guru dan sekolah dalam merancang strategi pembelajaran yang lebih adaptif. Penelitian ini menjadi dasar pengembangan sistem pendukung keputusan berbasis data di lingkungan pendidikan.

KATA KUNCI

Kinerja Siswa
Machine Learning
Data Akademik
Perilaku Siswa
Prediksi

This is an open access article under the CC-BY-SA license.



1 PENDAHULUAN

Kinerja akademik siswa merupakan aspek krusial dalam menilai keberhasilan proses pendidikan di tingkat sekolah menengah pertama (SMP). Prestasi belajar tidak hanya mencerminkan penguasaan materi ajar, tetapi juga berkaitan erat dengan kesiapan siswa untuk melanjutkan ke jenjang pendidikan berikutnya. Dalam konteks ini, pengukuran dan pemantauan kinerja siswa menjadi tugas penting bagi para pendidik dan lembaga pendidikan. Oleh karena itu, dibutuhkan pendekatan yang lebih adaptif dan berbasis data untuk memahami faktor-faktor yang memengaruhi keberhasilan akademik siswa.

Penelitian terdahulu menunjukkan bahwa faktor akademik seperti nilai mata pelajaran, serta faktor non-akademik seperti kehadiran, aktivitas ekstrakurikuler, dan kebiasaan belajar, berperan signifikan dalam membentuk kinerja siswa secara keseluruhan [1], [2], [3]. Meskipun demikian, pengolahan data pendidikan secara manual masih menjadi kendala dalam menghasilkan prediksi yang akurat dan berkelanjutan. Dengan semakin besarnya volume data pendidikan yang tersedia, pemanfaatan teknologi seperti machine learning menjadi sangat relevan untuk mengeksplorasi informasi yang tersembunyi dalam data. Machine learning memungkinkan proses pengambilan keputusan berbasis data yang lebih objektif dan prediktif dalam bidang pendidikan [4], [5], [6], [7].

Dalam penelitian ini, pendekatan machine learning digunakan untuk membangun model prediksi kinerja siswa SMP berdasarkan data yang terdiri dari enam variabel utama: nilai Matematika, nilai Bahasa Indonesia, waktu belajar di luar sekolah, partisipasi dalam kegiatan ekstrakurikuler, tingkat kehadiran, dan jumlah absensi selama satu semester. Variabel-variabel ini dipilih karena mencerminkan kombinasi antara kemampuan akademik dan perilaku belajar siswa yang dapat diukur secara objektif. Data yang diperoleh kemudian dianalisis menggunakan tiga algoritma machine learning populer, yaitu *Logistic Regression*, *Decision Tree*, dan *Neural Network* [4], [5], [8]. Ketiga model ini dipilih karena mewakili karakteristik pendekatan yang berbeda dalam klasifikasi data. *Logistic Regression* dipilih sebagai *baseline* untuk menguji hubungan linier yang


sederhana, *Decision Tree* digunakan karena kemampuannya menjelaskan aturan keputusan secara visual (*white-box model*), sedangkan *Neural Network* diterapkan untuk menangkap pola non-linier yang kompleks antar variabel yang mungkin tidak terdeteksi oleh metode lain. Pendekatan komparatif ini diharapkan dapat mengidentifikasi model mana yang memiliki performa terbaik dan paling sesuai dengan karakteristik data pendidikan yang digunakan, sehingga dapat dijadikan acuan dalam membangun sistem prediksi yang handal untuk mendukung proses evaluasi akademik siswa.

Hasil dari penelitian ini diharapkan dapat memberikan kontribusi praktis bagi guru dan pihak sekolah dalam melakukan deteksi dini terhadap siswa yang membutuhkan intervensi pembelajaran tambahan. Dengan adanya sistem prediksi yang handal, lembaga pendidikan dapat lebih responsif dalam merancang strategi pembelajaran yang bersifat personalisasi. Selain itu, hasil penelitian ini juga dapat menjadi landasan awal untuk pengembangan sistem pendukung keputusan berbasis kecerdasan buatan di lingkungan pendidikan menengah.

2 METODE PENELITIAN

Penelitian ini dibagi ke dalam beberapa tahapan penelitian yaitu, yakni pengumpulan data, pengolahan data, usulan model, eksperimen dan pengujian, dan tahapan evaluasi dan validasi, seperti ditunjukkan dalam Gambar 1. Diagram tersebut mengilustrasikan alur penelitian yang dimulai dari pengumpulan data akademik dan perilaku siswa, dilanjutkan dengan proses pra-pemrosesan data untuk membersihkan nilai yang hilang, hingga tahap eksperimen menggunakan tiga algoritma machine learning dan evaluasi kinerja model. Pada tahap pengumpulan data, data dikumpulkan dari sumber-sumber yang relevan, seperti data nilai akademik, kehadiran, partisipasi ekstrakurikuler dan jam belajar diluar sekolah dari siswa SMP kelas VIII. Tujuan dari tahap ini adalah memperoleh dataset yang dapat merepresentasikan kondisi nyata siswa. Proses ini juga mencakup identifikasi atribut atau fitur yang relevan dengan kinerja akademik, seperti nilai tugas, ujian, dan partisipasi kelas. Selanjutnya, Pada tahap pengolahan data, data yang telah dikumpulkan kemudian dibersihkan dari nilai yang hilang (*missing values*), duplikasi, atau kesalahan pencatatan. Tahap ini juga melibatkan proses transformasi data seperti normalisasi atau kategorisasi. Tujuannya adalah untuk meningkatkan kualitas data sebelum digunakan oleh model. Dataset yang diperoleh sebanyak 158 partisipan siswa SMP kelas VIII dengan delapan atribut utama seperti ditunjukkan pada Tabel 1. Tabel tersebut merinci delapan variabel yang digunakan dalam penelitian, yang terdiri dari atribut akademik (Nilai Matematika dan Bahasa Indonesia) serta atribut perilaku (Absensi, Ekstrakurikuler, dan Jam Belajar) yang dihipotesiskan berpengaruh terhadap label target kinerja siswa. Pada tahap usulan model, penelitian ini mengusulkan tiga metode machine learning untuk memprediksi kinerja akademik siswa, yaitu *Logistic Regression* (LR), *Decision Tree* (DT), dan *Neural Network* (NN). Ketiga model dipilih karena memiliki pendekatan yang berbeda dalam mengenali pola data, sehingga dapat memberikan perspektif yang komprehensif terhadap faktor-faktor yang mempengaruhi prestasi siswa. LR digunakan sebagai model dasar yang mengukur hubungan linier antara variabel input dan output biner. Contoh penelitian yang menerapkan model LR adalah penelitian [9], [10], [11]. Model ini bekerja dengan menghitung probabilitas menggunakan fungsi logit sigmoid, yang mengubah nilai linier menjadi nilai antara 0 dan 1. Kesederhanaan dan interpretabilitas model ini menjadikannya berguna untuk memahami kontribusi masing-masing fitur dalam prediksi. DT memanfaatkan struktur pohon keputusan untuk membagi data berdasarkan aturan if-then. Beberapa contoh penerapan model DT pada penelitian yang berkaitan dengan permasalahan sekolah di antaranya penelitian [7], [12], [13]. Model ini bekerja dengan memilih fitur yang paling informatif untuk membagi data menggunakan kriteria impurity seperti Gini Index dan Entropy. Decision Tree unggul dalam menangani interaksi antar fitur dan dapat menjelaskan proses pengambilan keputusan secara visual. NN, khususnya tipe *Multi-Layer Perceptron* (MLP), digunakan karena kemampuannya dalam menangkap hubungan non-linier yang kompleks. Model ini terdiri dari lapisan neuron yang terhubung melalui bobot dan bias. Proses pembelajaran mencakup forward propagation untuk menghitung output dan backpropagation untuk mengoptimalkan bobot. Fungsi aktivasi ReLU digunakan di hidden layer untuk mempercepat konvergensi, sementara softmax digunakan di output layer untuk menghasilkan probabilitas kelas dalam klasifikasi multikelas. Contoh penerapan Neural Network pada penelitian yang melibatkan murid di antaranya penelitian [8], [14], [15]. Dengan karakteristik yang berbeda, ketiga model ini diharapkan dapat saling melengkapi dan memberikan

wawasan mendalam dalam proses prediksi kinerja akademik berdasarkan data siswa. Pada tahap eksperimen dan pengujian, model yang diusulkan kemudian dilatih (*training*) dan diuji (*testing*) menggunakan skenario pembagian data (misalnya 60:40, 70:30, 80:20). Proses ini bertujuan untuk menguji kemampuan generalisasi model dalam memprediksi data yang belum pernah dilihat sebelumnya. Pada tahapan ini, peneliti menggunakan software Visual Studio Code dengan bahasa pemrograman Python serta berbagai library yang mendukung uji coba dan evaluasi model. Tahap selanjutnya adalah tahap evaluasi. Setelah pengujian, kinerja model dievaluasi menggunakan metrik evaluasi standar seperti: *Accuracy*, yaitu persentase prediksi yang benar, *Precision*, yaitu proporsi prediksi positif yang benar, *Recall*, yaitu kemampuan model dalam menemukan semua kasus positif, *F1-Score*, yaitu harmonisasi antara *precision* dan *recall*. Dari hasil evaluasi, ditarik kesimpulan mengenai model mana yang paling efektif dalam memprediksi kinerja akademik siswa, serta dilakukan analisis untuk menentukan potensi penerapan model dalam konteks pendidikan.



Gambar 1. Tahapan Penelitian

Table 1. Definisi Atribut Definisi

No	Atribut	Deskripsi
1	Nilai_Matematika	Skor akademik siswa dalam mata pelajaran Matematika.
2	Nilai_Bahasa_Indonesia	Skor akademik siswa dalam mata pelajaran Bahasa Indonesia.
3	Absen	Jumlah absensi siswa selama satu semester.
4	Persentase_Kehadiran	Persentase kehadiran siswa dalam bentuk persentase.
5	Ekstrakurikuler	Partisipasi siswa dalam kegiatan ekstrakurikuler (0 = tidak, 1 = ya).
6	Jam_Belajar	Jumlah jam belajar siswa di luar jam sekolah.
7	Skor	Skor akademik gabungan berdasarkan faktor akademik dan perilaku.
8	Kinerja	Label klasifikasi kinerja siswa (misalnya: Kurang, Cukup, Baik).

3 HASIL DAN PEMBAHASAN

3.1 Hasil pengujian


3.1.1 Hasil pengujian algoritma Logistic Regression

Pengujian pertama dilakukan menggunakan algoritma *Logistic Regression* dengan tiga skenario pembagian data latih dan data uji, yaitu 60:40, 70:30, dan 80:20. Hasil evaluasi model ini divisualisasikan menggunakan *confusion matrix*. Pada skenario pembagian data 60:40, hasil pengujian ditunjukkan pada Gambar 2a. Berdasarkan matriks tersebut, model menghasilkan akurasi sebesar 48%. Terlihat bahwa model cenderung melakukan kesalahan prediksi yang cukup tinggi, ditandai dengan jumlah *False Negative* yang mencapai 23 dan *False Positive* sebesar 7 (Gambar 3a). Hal ini menunjukkan bahwa dengan data latih 60%, model belum mampu memisahkan kelas target secara optimal. Selanjutnya, pada skenario pembagian data 70:30 seperti terlihat pada Gambar 2b, terjadi peningkatan performa dengan akurasi mencapai 52%. *Confusion matrix* (Gambar 3b) menunjukkan adanya peningkatan jumlah prediksi benar (*True Positive* dan *True Negative*) dibandingkan skenario sebelumnya. Meskipun demikian, akurasi ini masih tergolong moderat, yang

mengindikasikan bahwa hubungan antar variabel dalam dataset ini tidak sepenuhnya linier, sehingga sulit ditangkap secara maksimal oleh *Logistic Regression*. Terakhir, pada skenario 80:20 (Gambar 2c dan Gambar 3c), akurasi justru mengalami penurunan menjadi 50%. Hal ini menunjukkan bahwa penambahan data latih pada model linier ini tidak serta merta meningkatkan akurasi, kemungkinan disebabkan oleh adanya *noise* atau variabilitas data perilaku siswa yang kompleks.

a	Logistic Regression (Train/Test: 60/ 40):				
		precision	recall	f1-score	support
	0	0.47	0.77	0.58	30
	1	0.53	0.24	0.33	34
	accuracy			0.48	64
	macro avg	0.50	0.50	0.45	64
b	Logistic Regression (Train/Test: 70/ 30):				
		precision	recall	f1-score	support
	0	0.55	0.44	0.49	25
	1	0.50	0.61	0.55	23
	accuracy			0.52	48
	macro avg	0.53	0.52	0.52	48
c	Logistic Regression (Train/Test: 80/ 19):				
		precision	recall	f1-score	support
	0	0.55	0.32	0.40	19
	1	0.38	0.62	0.47	13
	accuracy			0.44	32
	macro avg	0.46	0.47	0.44	32
	Logistic Regression (Train/Test: 80/ 19):				
		precision	recall	f1-score	support
	0	0.55	0.32	0.40	19
	1	0.38	0.62	0.47	13
	accuracy			0.44	32
	macro avg	0.46	0.47	0.44	32
	Logistic Regression (Train/Test: 80/ 19):				
		precision	recall	f1-score	support
	0	0.55	0.32	0.40	19
	1	0.38	0.62	0.47	13
	accuracy			0.44	32
	macro avg	0.46	0.47	0.44	32

Gambar 2. Hasil Uji *Logistic Regression*, a) 60:40, b) 70:30, c) 80:20



Gambar 3. Confusion matrix LR, a) 60:40, b) 70:30, c) 80:20

3.1.2 Hasil pengujian algoritma *Decision Tree*

Pengujian kedua menggunakan algoritma *Decision Tree*. Metode ini dikenal mampu menghasilkan aturan keputusan yang dapat diinterpretasikan. Pada skenario 60:40, hasil *confusion matrix* ditampilkan pada Gambar 5b. Model menghasilkan akurasi sebesar 55% (Gambar 4b). *Confusion matrix* memperlihatkan bahwa model mampu mengklasifikasikan 14 siswa dengan benar pada kelas positif, namun masih terdapat kesalahan klasifikasi pada 11 data uji. Peningkatan performa mulai terlihat pada skenario 70:30 (Gambar 4b), di mana akurasi naik sedikit menjadi 56%. Struktur pohon keputusan mulai terbentuk lebih baik dalam memilah fitur-fitur dominan seperti nilai akademik dan absensi. Hasil terbaik untuk algoritma ini dicapai pada skenario pembagian data 80:20 sebagaimana ditunjukkan pada Gambar 4c. Pada skenario ini, akurasi meningkat signifikan menjadi


59%. Berdasarkan *confusion matrix* (Gambar 5c), terlihat dominasi nilai diagonal utama (*True Positive* dan *True Negative*) yang lebih tinggi dibandingkan skenario lainnya. Hal ini membuktikan bahwa *Decision Tree* membutuhkan proporsi data latih yang lebih besar (80%) untuk membangun aturan keputusan yang lebih presisi dan mengurangi risiko *overfitting* atau *underfitting*.

a	Decision Tree (Train/Test: 60/ 40):						
				precision	recall	f1-score	support
			0	0.39	0.50	0.44	30
			1	0.42	0.32	0.37	34
			accuracy			0.41	64
			macro avg	0.41	0.41	0.40	64
			weighted avg	0.41	0.41	0.40	64

b	Decision Tree (Train/Test: 70/ 30):						
				precision	recall	f1-score	support
			0	0.52	0.56	0.54	25
			1	0.48	0.43	0.45	23
			accuracy			0.50	48
			macro avg	0.50	0.50	0.50	48
			weighted avg	0.50	0.50	0.50	48

c	Decision Tree (Train/Test: 80/ 19):						
				precision	recall	f1-score	support
			0	0.67	0.63	0.65	19
			1	0.50	0.54	0.52	13
			accuracy			0.59	32
			macro avg	0.58	0.59	0.58	32
			weighted avg	0.60	0.59	0.60	32

Gambar 4. Hasil Uji *Decision Tree*, a) 60:40, b) 70:30, c) 80:20



Gambar 5. *Confusion matrix* DT, a) 60:40, b) 70:30, c) 80:20


3.1.3 Hasil pengujian algoritma *Neural Network*

Pengujian ketiga menerapkan algoritma *Neural Network* yang dirancang untuk mengenali pola non-linier yang kompleks. Hasil pengujian skenario 60:40 dapat dilihat pada Gambar 6a. *Neural Network* menunjukkan performa tinggi dengan akurasi 59% meskipun menggunakan data latih yang lebih sedikit dibandingkan skenario terbaik *Decision Tree*. *Confusion matrix* (Gambar 7a) menunjukkan keseimbangan yang baik antara nilai *Precision* dan *Recall*, di mana model berhasil memprediksi 24 siswa berisiko dan [masukkan angka] siswa tidak berisiko dengan tepat. Pada skenario 70:30 (Gambar 6b dan Gambar 7b), performa model sedikit menurun namun tetap stabil di angka 57%. Penurunan tipis ini wajar terjadi dalam eksperimen *Neural Network* tergantung pada inisialisasi bobot awal, namun secara umum model tetap mampu mengenali pola data dengan baik. Sementara itu, pada skenario 80:20 (Gambar 6c dan Gambar 7c), akurasi tercatat sebesar 53%.

Penurunan pada rasio data latih terbesar ini dapat mengindikasikan terjadinya *overfitting* pada data latih, sehingga kemampuan generalisasi model terhadap data uji baru menjadi berkurang.

a	Neural Network (Train/Test: 60/ 40):				
		precision	recall	f1-score	support
	0	0.55	0.80	0.65	30
	1	0.70	0.41	0.52	34
	accuracy			0.59	64
b	Neural Network (Train/Test: 70/ 30):				
		precision	recall	f1-score	support
	0	0.57	0.48	0.52	25
	1	0.52	0.61	0.56	23
	accuracy			0.54	48
c	Neural Network (Train/Test: 80/ 19):				
		precision	recall	f1-score	support
	0	0.57	0.42	0.48	19
	1	0.39	0.54	0.45	13
	accuracy			0.47	32

Gambar 6. Hasil Uji *Neural Network*, a) 60:40, b) 70:30, c) 80:20



Gambar 7. *Confusion matrix NN*, a) 60:40, b) 70:30, c) 80:20

3.2 Analisis Kinerja Model

3.2.1 Analisis kinerja model pada pembagian data 80:20

Hasil pengujian berdasarkan pembagian data 80:20 ditunjukkan pada Tabel 2. Model *Decision Tree* menunjukkan kinerja terbaik dalam skenario ini, dengan *precision* sebesar 0,60, *recall* 0,59, *F1-score* 0,60, dan *accuracy* 0,59. Peningkatan signifikan dibanding skenario sebelumnya menunjukkan bahwa model ini diuntungkan oleh jumlah data latih yang lebih besar, yang memungkinkan pembentukan aturan klasifikasi yang lebih akurat dan generalisasi yang lebih baik. Model *Neural Network*, yang sebelumnya unggul pada skenario 60:40 dan 70:30, mengalami penurunan kinerja dengan *precision* 0,50, *recall* 0,47, *F1-score* 0,47, dan *accuracy* 0,47. Penurunan ini menunjukkan bahwa penambahan data latih tidak secara otomatis meningkatkan performa model, kemungkinan karena struktur model yang tidak optimal atau kebutuhan akan tuning lebih lanjut seiring meningkatnya kompleksitas data. Model *Logistic Regression* mencatat performa terendah, dengan *precision* 0,48, *recall* 0,44, *F1-score* 0,43, dan *accuracy* 0,44. Nilai metrik yang rendah

menunjukkan bahwa model ini tidak mampu memanfaatkan tambahan data latih secara efektif, dan masih mengalami kesulitan dalam membedakan antar kelas. Pada skenario pembagian data 80:20, *Decision Tree* menunjukkan performa terbaik dan paling stabil, memanfaatkan data latih yang lebih besar dengan baik. Sebaliknya, *Neural Network* dan *Logistic Regression* mengalami penurunan kinerja, menandakan perlunya penyesuaian parameter atau arsitektur untuk meningkatkan efektivitas pada skenario ini.

Table 2. Hasil pengujian pada pembagian data 80:20

Model	Precision	Recall	F1-Score	Accuracy
<i>Logistic regression</i>	0,48	0,44	0,43	0,44
<i>Decision Tree</i>	0,60	0,59	0,60	0,59
<i>Neural Network</i>	0,50	0,47	0,47	0,47

3.2.2 Analisis kinerja model pada pembagian data 70:30

Hasil pengujian berdasarkan pembagian data 80:20 ditunjukkan pada Tabel 3. Dari tabel hasil evaluasi, model *Neural Network* menunjukkan performa terbaik secara keseluruhan, dengan *precision* sebesar 0,55, *recall* 0,54, *F1-score* 0,54, dan *accuracy* tertinggi sebesar 0,57. Hal ini menunjukkan bahwa *Neural Network* mampu menghasilkan prediksi yang relatif seimbang antara ketepatan dan kelengkapan, serta memiliki kemampuan klasifikasi yang lebih baik dibandingkan dua model lainnya dalam skenario ini. Model *Logistic Regression* berada di posisi kedua, dengan *precision*, *recall*, dan *F1-score* sebesar 0,53, 0,52, dan 0,52, serta *accuracy* 0,55. Performa model ini cukup kompetitif, meskipun sedikit lebih rendah dibandingkan *Neural Network*. Hal ini menunjukkan bahwa *Logistic Regression* masih dapat diandalkan untuk kasus klasifikasi ini, meskipun tidak seoptimal *Neural Network*. Model *Decision Tree* mencatat nilai metrik terendah di antara ketiga model, dengan *precision*, *recall*, dan *F1-score* sebesar 0,50, dan *accuracy* 0,52. Nilai-nilai metrik yang relatif rendah dan seimbang ini menunjukkan bahwa *Decision Tree* memiliki kemampuan klasifikasi yang paling lemah dalam skenario ini, kemungkinan disebabkan oleh overfitting atau struktur pohon yang kurang optimal dalam membedakan antar kelas. Pada skenario pembagian data 70:30, model *Neural Network* memberikan hasil terbaik dalam hal ketepatan, kelengkapan, dan akurasi klasifikasi, diikuti oleh *Logistic Regression*. Sementara itu, *Decision Tree* menunjukkan performa terendah dan kurang direkomendasikan untuk digunakan dalam kasus ini.

Table 3. Hasil pengujian pada pembagian data 70:30

Model	Precision	Recall	F1-Score	Accuracy
<i>Logistic regression</i>	0,53	0,52	0,52	0,55
<i>Decision Tree</i>	0,50	0,50	0,50	0,52
<i>Neural Network</i>	0,55	0,54	0,54	0,57

Analisis Kinerja Model pada Pembagian Data 60:40

Hasil pengujian berdasarkan pembagian data 80:20 ditunjukkan pada Tabel 4. Model *Neural Network* kembali menunjukkan kinerja terbaik dibandingkan dua model lainnya, dengan *precision* sebesar 0,63, *recall* 0,59, *F1-score* 0,58, dan *accuracy* 0,59. Nilai metrik yang tinggi dan relatif seimbang ini menunjukkan bahwa *Neural Network* memiliki kemampuan yang lebih baik dalam mengklasifikasikan data secara tepat dan lengkap, serta mampu mempertahankan stabilitas performa meskipun data latih lebih sedikit dibandingkan skenario sebelumnya. Model *Logistic Regression* mencatat performa sedang, dengan *precision* 0,50, *recall* 0,48, dan *F1-score* 0,45, serta *accuracy* 0,48. Meskipun tidak sebaik *Neural Network*, model ini masih menunjukkan kinerja yang cukup moderat. Namun, nilai *F1-score* yang lebih rendah menunjukkan ketidakseimbangan antara *precision* dan *recall*, yang dapat berdampak negatif pada klasifikasi yang sensitif terhadap kesalahan deteksi. Model *Decision Tree* menunjukkan performa terlemah pada skenario ini, dengan semua metrik berada pada kisaran 0,40–0,41. Hal ini mengindikasikan bahwa model ini kurang mampu melakukan generalisasi ketika data latih terbatas, dan kemungkinan mengalami *overfitting* atau

kesulitan dalam membentuk aturan klasifikasi yang efektif pada data uji. Pada skenario pembagian data 60:40, model *Neural Network* tetap menjadi pilihan terbaik dengan kinerja klasifikasi yang paling stabil dan akurat. *Logistic Regression* menunjukkan performa menengah, sedangkan *Decision Tree* memiliki kinerja paling rendah dan kurang direkomendasikan untuk digunakan dalam kondisi data latih terbatas.

Table 4. Hasil pengujian pada pembagian data 60:40

Model	Precision	Recall	F1-Score	Accuracy
<i>Logistic regression</i>	0,50	0,48	0,45	0,48
<i>Decision Tree</i>	0,41	0,41	0,40	0,41
<i>Neural Network</i>	0,63	0,59	0,58	0,59

4 KESIMPULAN

Penelitian ini menunjukkan bahwa penerapan algoritma machine learning dapat digunakan untuk memprediksi kinerja akademik siswa SMP. Dari tiga model yang diuji, *Neural Network* memberikan kinerja terbaik pada skenario 60:40 dan 70:30 dengan akurasi masing-masing 59% dan 57%, menunjukkan kemampuannya dalam mengenali pola kompleks. *Decision Tree* unggul pada skenario 80:20 (59%) namun rentan terhadap *overfitting* saat data latih terbatas. *Logistic Regression* menunjukkan performa paling stabil, meskipun tidak seakurat model lainnya. Secara keseluruhan, *Neural Network* merupakan pilihan paling efektif dan dapat digunakan sebagai dasar pengembangan sistem pendukung keputusan di lingkungan pendidikan.

5 KONTRIBUSI PENELITIAN

Penelitian ini diharapkan mampu memberikan manfaat nyata bagi guru dan pihak sekolah dalam mengidentifikasi secara dini siswa yang memerlukan dukungan belajar tambahan. Melalui penerapan sistem prediksi yang akurat, institusi pendidikan dapat merancang pendekatan pembelajaran yang lebih sesuai dengan kebutuhan individu siswa. Di samping itu, temuan dari studi ini juga dapat menjadi pijakan awal dalam merancang sistem pendukung keputusan berbasis kecerdasan buatan untuk diterapkan di lingkungan pendidikan tingkat menengah.

DAFTAR PUSTAKA

- [1] T. Gori, A. Sunyoto, and H. Al Fatta, "Preprocessing Data dan Klasifikasi untuk Prediksi Kinerja Akademik Siswa," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 1, pp. 215–224, 2024.
- [2] F. J. Hamu, D. Wea, and N. Setiyaningtiyas, "Faktor-faktor yang memengaruhi kinerja akademik mahasiswa: Analisis structural equation model," *J. Paedagogy*, vol. 10, no. 1, pp. 175–186, 2023.
- [3] I. Gligorea, M. U. Yaseen, M. Cioca, H. Gorski, and R. Oancea, "An Interpretable Framework for an Efficient Analysis of Students' Academic Performance," *Sustainability*, vol. 14, no. 14, p. 8885, Jul. 2022, doi: 10.3390/su14148885.
- [4] I. Issah, O. Appiah, P. Appiahene, and F. Inusah, "A systematic review of the literature on machine learning application of determining the attributes influencing academic performance," *Decis. Anal. J.*, vol. 7, p. 100204, Jun. 2023, doi: 10.1016/j.dajour.2023.100204.
- [5] H. Chavez, B. Chavez-Arias, S. Contreras-Rosas, J. M. Alvarez-Rodríguez, and C. Raymundo, "Artificial neural network model to predict student performance using nonpersonal information," *Front. Educ.*, vol. 8, Feb. 2023, doi: 10.3389/educ.2023.1106679.
- [6] L. R. Pelima, Y. Sukmana, and Y. Rosmansyah, "Predicting University Student Graduation Using Academic Performance and Machine Learning: A Systematic Literature Review," *IEEE Access*, vol. 12, pp. 23451–23465, 2024, doi: 10.1109/ACCESS.2024.3361479.
- [7] H. Pallathadka, A. Wenda, E. Ramirez-Asís, M. Asís-López, J. Flores-Albornoz, and K.

- Phasinam, "Classification and prediction of student performance data using various machine learning algorithms," *Mater. Today Proc.*, vol. 80, pp. 3782–3785, 2023, doi: 10.1016/j.matpr.2021.07.382.
- [8] Y. Baashar *et al.*, "Toward Predicting Student's Academic Performance Using Artificial Neural Networks (ANNs)," *Appl. Sci.*, vol. 12, no. 3, p. 1289, Jan. 2022, doi: 10.3390/app12031289.
- [9] H. P. Singh and H. N. Alhulail, "Predicting Student-Teachers Dropout Risk and Early Identification: A Four-Step Logistic Regression Approach," *IEEE Access*, vol. 10, pp. 6470–6482, 2022, doi: 10.1109/ACCESS.2022.3141992.
- [10] A. M. Rabelo and L. E. Zárate, "A model for predicting dropout of higher education students," *Data Sci. Manag.*, vol. 8, no. 1, pp. 72–85, Mar. 2025, doi: 10.1016/j.dsm.2024.07.001.
- [11] M. Yağcı, "Educational data mining: prediction of students' academic performance using machine learning algorithms," *Smart Learn. Environ.*, vol. 9, no. 1, 2022, doi: 10.1186/s40561-022-00192-z.
- [12] E. Alhazmi and A. Sheneamer, "Early Predicting of Students Performance in Higher Education," *IEEE Access*, vol. 11, pp. 27579–27589, 2023, doi: 10.1109/ACCESS.2023.3250702.
- [13] A. Hussain, M. Khan, and K. Ullah, "Student's performance prediction model and affecting factors using classification techniques," *Educ. Inf. Technol.*, vol. 27, no. 6, pp. 8841–8858, Jul. 2022, doi: 10.1007/s10639-022-10988-8.
- [14] O. A. Olabanjo, A. S. Wusu, and M. Manuel, "A machine learning prediction of academic performance of secondary school students using radial basis function neural network," *Trends Neurosci. Educ.*, vol. 29, p. 100190, Dec. 2022, doi: 10.1016/j.tine.2022.100190.
- [15] H. Waheed, S.-U. Hassan, R. Nawaz, N. R. Aljohani, G. Chen, and D. Gasevic, "Early prediction of learners at risk in self-paced education: A neural network approach," *Expert Syst. Appl.*, vol. 213, p. 118868, Mar. 2023, doi: 10.1016/j.eswa.2022.118868.