

Sistem Pendidikan Kinerja Siswa Berbasis Web Menggunakan Algoritma *Decision Tree* dan XGBost

Assyifa Salsabila Hairani¹, Rahmatulloh Cahyono², Athib Abi Balta³

Universitas Bina Sarana Informatika, Indonesia

¹ascsalsabila15@gmail.com, ²adentcahyono523@gmail.com, ³abibalta12345@gmail.com

Abstract

This study aims to develop a student performance prediction model using Decision Tree and XGBoost algorithms and integrate it into a web-based prediction system to support real-time academic monitoring. The research uses the Student Performance dataset from Kaggle, consisting of 1,000 students with eight academic and demographic attributes. The methodology includes data preprocessing, feature selection, model training, and hyperparameter tuning using GridSearchCV and RandomizedSearchCV. The results show that XGBoost achieves the best performance with an accuracy of 0.885, F1-score of 0.885, and AUC of 0.954, while the Decision Tree model only reaches an accuracy of 0.826 and AUC of 0.839. Information gain analysis confirms that the writing score is the most influential variable in the classification process. The best-performing model is then integrated into a Flask-based web system, enabling users to generate predictions quickly without additional installation. This research contributes to the advancement of Educational Data Mining (EDM) by combining machine learning classification techniques with a real-time predictive web platform. The findings are expected to help schools detect students' academic risks earlier and support data-driven decision-making.

Keywords: decision tree, student performance, prediction, web system, XGBoost.

Abstrak

Pemanfaatan data akademik di sekolah masih terbatas sehingga diperlukan sistem prediktif untuk mendukung keputusan berbasis bukti. Penelitian ini bertujuan untuk mengembangkan model prediksi kinerja siswa menggunakan algoritma Decision Tree dan XGBoost serta mengintegrasikannya ke dalam sistem prediksi berbasis web untuk mendukung pemantauan akademik secara real-time. Data penelitian menggunakan dataset Student Performance dari Kaggle yang terdiri dari 1.000 siswa dengan delapan atribut akademik dan demografis. Tahap penelitian meliputi preprocessing data, seleksi fitur, pelatihan model, serta hyperparameter tuning menggunakan GridSearchCV dan RandomizedSearchCV. Hasil penelitian menunjukkan bahwa XGBoost memberikan performa terbaik dengan akurasi 0,885, F1-score 0,885, dan AUC 0,954, sedangkan Decision Tree hanya mencapai akurasi 0,826 dan AUC 0,839. Analisis information gain menegaskan bahwa writing score merupakan variabel paling berpengaruh dalam klasifikasi. Model terbaik kemudian diintegrasikan ke dalam sistem web berbasis Flask, sehingga memungkinkan pengguna melakukan prediksi secara cepat tanpa instalasi tambahan. Kontribusi penelitian ini mencakup penerapan konsep Educational Data Mining (EDM) melalui kombinasi model pembelajaran mesin dan platform web prediktif real-time. Temuan ini diharapkan dapat membantu sekolah dalam mendeteksi risiko akademik siswa lebih awal dan mendukung pengambilan keputusan berbasis data.

Kata kunci: decision tree, kinerja siswa, prediksi, sistem web, XGBoost

1. Pendahuluan

Sektor pendidikan Indonesia mengalami perubahan menuju pengelolaan berbasis data, tetapi pemanfaatannya masih terbatas pada aktivitas administratif sehingga belum mendukung pengambilan keputusan berbasis bukti [1]. Penilaian kinerja siswa umumnya dilakukan pada akhir semester, yang menyebabkan sekolah terlambat mendeteksi kesulitan belajar dan sulit melakukan intervensi dini [2],[3].

Teknologi Machine Learning menawarkan peluang untuk menganalisis pola data siswa secara lebih prediktif [4]. Pemilihan algoritma Decision Tree dan XGBoost dalam penelitian ini didasarkan pada karakteristiknya yang saling melengkapi. Decision Tree dipilih karena sifatnya yang interpretable, transparan, dan mudah dipahami oleh guru maupun administrator sekolah. Struktur pohonnya mampu memperlihatkan hubungan antarvariabel secara eksplisit sehingga membantu pengguna memahami alasan di balik hasil prediksi. Sebaliknya, XGBoost dipilih karena memiliki mekanisme boosting dan regularisasi yang mampu meningkatkan akurasi, mengatasi overfitting, serta memberikan kestabilan performa pada data pendidikan yang variatif [6],[7],[10]. Dengan menggabungkan kedua model ini, penelitian tidak hanya mengejar akurasi prediktif, tetapi juga memastikan interpretabilitas dan kemudahan adopsi di lingkungan sekolah. Penelitian menunjukkan bahwa *Decision Tree* dan *Extreme Gradient Boosting* efektif dalam memprediksi performa akademik dan mendeteksi risiko penurunan prestasi [5]. Kedua algoritma ini juga terbukti memiliki akurasi tinggi dalam konteks pendidikan di Indonesia [6],[7]. Selain itu, penelitian lain menegaskan efektivitas *Decision Tree* dalam mengklasifikasikan nilai dan kehadiran serta pentingnya integrasi model prediktif ke sistem informasi sekolah [8].

Pemanfaatan data akademik dalam pendidikan menjadi dasar penerapan teknik penambangan data pendidikan untuk memprediksi hasil belajar siswa. Secara teoritis, model klasifikasi digunakan untuk mengidentifikasi pola kinerja siswa berdasarkan variabel akademik dan faktor sosial. Algoritma Decision Tree membangun struktur pohon keputusan yang mudah dipahami pengguna, namun metode ini tetap memiliki kerentanan terhadap *overfitting* ketika diterapkan pada data dengan karakteristik yang bervariasi [9]. Sementara itu, XGBoost, sebuah algoritma boosting, memberikan kinerja yang lebih stabil melalui mekanisme regularisasi dan pembobotan bertahap [10].

Beberapa studi nasional telah menunjukkan efektivitas model pembelajaran mesin dalam memprediksi kinerja siswa. Penelitian oleh Sari, 2024 menunjukkan bahwa algoritma klasifikasi mampu mengidentifikasi risiko akademik siswa berdasarkan

kombinasi nilai dan faktor kontekstual [11]. Studi lain oleh Simanulang 2022 [12] membandingkan algoritma C4.5 dan metode berbasis boosting, dan hasilnya menunjukkan bahwa algoritma boosting memberikan akurasi yang lebih tinggi dalam konteks pendidikan Indonesia. Namun, sebagian besar penelitian ini hanya berfokus pada evaluasi kinerja model tanpa mengintegrasikan hasilnya ke dalam sistem berbasis web yang dapat digunakan langsung oleh sekolah

Meskipun demikian, banyak penelitian masih berfokus pada peningkatan akurasi model tanpa menghasilkan sistem yang dapat digunakan langsung oleh sekolah, sementara pemanfaatan digitalisasi untuk mendukung pemantauan akademik real-time masih terbatas [13],[14]. Kondisi ini menimbulkan kebutuhan untuk menghadirkan sistem prediksi yang terintegrasi dan aplikatif. Kebaruan penelitian ini terletak pada integrasi algoritma *Decision Tree* dan XGBoost ke dalam sistem prediktif berbasis web yang mampu menghasilkan keluaran waktu nyata. Sistem ini dirancang untuk membantu guru memantau perkembangan akademik siswa dan mendukung intervensi dini berdasarkan hasil analisis prediktif

Berdasarkan analisis tersebut, penelitian ini mengembangkan sistem prediksi kinerja siswa berbasis web dengan integrasi model Decision Tree dan XGBoost untuk mendukung pemantauan akademik berkelanjutan [15], meningkatkan efisiensi pembelajaran [16], serta memfasilitasi intervensi dini berbasis data [17].

2. Metode Penelitian

Data penelitian diperoleh melalui metode dokumentasi menggunakan dataset Student Performance dari Kaggle yang berisi 1.000 baris dan delapan atribut mengenai karakteristik siswa serta nilai matematika, membaca, dan menulis. Dataset ini digunakan sebagai populasi sekaligus sampel penelitian karena seluruh data dianalisis. Pengolahan data dilakukan melalui tiga tahap, yaitu pembersihan data untuk mengatasi nilai hilang dan duplikasi, transformasi data ke bentuk numerik agar kompatibel dengan algoritma, serta seleksi fitur guna mengidentifikasi variabel yang paling berpengaruh terhadap kinerja akademik. Seleksi fitur diterapkan untuk meningkatkan akurasi dan menurunkan kompleksitas model [16], sementara proses pengolahan keseluruhan dilakukan menggunakan Python dengan bantuan pustaka pandas, numpy, dan scikit-learn yang lazim digunakan dalam penelitian prediktif pendidikan [18].

Tabel 1 Dataset (Input/output)

No	Fitur	Tipe Data	Peran	Keterangan Singkat
1	gender	Kategorika 1	Input	Jenis kelamin siswa
2	race/ethnicity	Kategorika 1	Input	Kelompok etnis siswa
3	parental level of education	Kategorika 1	Input	Pendidikan terakhir orang tua
4	lunch	Kategorika 1	Input	Jenis makan siang (standard/free)
5	test preparation course	Kategorika 1	Input	Mengikuti kursus persiapan tes (yes/no)
6	math score	Numerik	Input	Nilai matematika
7	reading score	Numerik	Input	Nilai membaca
8	writing score	Numerik	Input	Nilai menulis
9	performance class (label)	Kategorika 1	Output	Kategori performa akademik siswa

Untuk meningkatkan performa model dan memastikan algoritma bekerja secara optimal, penelitian ini menerapkan proses hyperparameter tuning. Proses ini dilakukan untuk menemukan kombinasi parameter terbaik yang menghasilkan akurasi dan stabilitas prediksi yang lebih tinggi. [1].

Pada algoritma Decision Tree, tuning dilakukan menggunakan GridSearchCV karena ruang parameter relatif kecil dan memungkinkan pencarian menyeluruh (exhaustive search). Parameter yang diuji meliputi max_depth, criterion (gini/entropy), min_samples_split, dan min_samples_leaf. Metode ini menilai semua kombinasi parameter secara sistematis dan memilih konfigurasi dengan performa terbaik berdasarkan cross-validation. [19].

Sementara itu, algoritma XGBoost dioptimalkan menggunakan RandomizedSearchCV mengingat ruang parameternya jauh lebih luas dan kompleks. Pendekatan ini lebih efisien dibandingkan GridSearch karena hanya mengevaluasi kombinasi parameter secara acak dalam jumlah tertentu. Parameter yang disesuaikan mencakup n_estimators, max_depth, learning_rate, subsample, colsample_bytree, gamma, serta parameter regularisasi seperti reg_lambda dan reg_alpha. Dengan cara ini, tuning dapat menemukan model dengan generalisasi terbaik tanpa memerlukan waktu komputasi yang berlebihan [21],[22].

Arsitektur sistem web yang dikembangkan pada penelitian ini terdiri atas rangkaian komponen yang saling terhubung dan berfungsi untuk memfasilitasi proses prediksi secara real-time. Pada bagian *front-end*, pengguna seperti guru atau operator sekolah memasukkan data siswa melalui formulir berbasis web yang dibangun menggunakan HTML, CSS, JavaScript, dan Bootstrap sehingga antarmuka

menjadi responsif dan mudah digunakan. Data yang diinput kemudian dikirimkan ke *backend* melalui permintaan HTTP untuk diproses lebih lanjut. Bagian *backend* dibangun menggunakan framework Flask, yang bertugas menangani setiap request, melakukan preprocessing data menggunakan pustaka *pandas* dan *numpy*, serta memanggil model Machine Learning yang telah diekspor. Model Decision Tree dan XGBoost yang sebelumnya dilatih dan dioptimalkan akan menghasilkan prediksi berdasarkan data yang diberikan pengguna. Hasil prediksi ini kemudian dikembalikan ke *front-end* dan ditampilkan dalam bentuk teks maupun visualisasi seperti grafik dan ringkasan nilai prediksi. Secara keseluruhan, alur kerja sistem dimulai dari input data oleh pengguna, dilanjutkan preprocessing, pemanggilan model, hingga penyajian output secara otomatis dan cepat tanpa memerlukan instalasi khusus di sisi pengguna. [19].

Agar model dapat digunakan pada sistem web tanpa proses pelatihan ulang, model terbaik diekspor menggunakan dua pendekatan umum dalam Python, yaitu *pickle* dan *joblib*. Metode *pickle* digunakan untuk menyimpan model dalam bentuk file biner melalui proses serialisasi, sedangkan untuk model berukuran besar atau kompleks seperti XGBoost, digunakan *joblib* karena lebih efisien dalam menangani objek berkapasitas besar. Model yang telah diserialisasi kemudian dapat di-load kembali oleh Flask setiap kali sistem melakukan prediksi. Proses ekspor ini memastikan bahwa model dapat digunakan secara konsisten dan efisien pada aplikasi web, sehingga prediksi kinerja siswa dapat dihasilkan dengan cepat, stabil, dan berkelanjutan[5].

Pemodelan memanfaatkan dua algoritma klasifikasi, yaitu Decision Tree dan XGBoost, yang dipilih karena kemampuannya menangani data tabular dan mengungkap pola non-linear. Data dibagi menjadi set pelatihan dan pengujian, dan performa model dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* sesuai praktik standar analisis klasifikasi [19]. Selain itu, confusion matrix digunakan untuk menilai distribusi prediksi, dan cross-validation diterapkan untuk memastikan stabilitas model terhadap variasi data [19]. Berdasarkan temuan penelitian terdahulu, XGBoost biasanya memberikan akurasi lebih tinggi dibandingkan Decision Tree karena mekanisme boosting yang mampu mengurangi overfitting [20]. Hasil evaluasi digunakan sebagai dasar pemilihan model yang akan diterapkan dalam sistem.

Model terbaik kemudian diintegrasikan ke dalam sistem prediksi berbasis web menggunakan framework Flask. Sistem ini mengolah data dengan *pandas* dan *numpy*, membangun model menggunakan *scikit-learn* dan XGBoost, serta menyajikan visualisasi dengan *Matplotlib* dan *Seaborn*. Antarmuka dikembangkan menggunakan HTML,

CSS, JavaScript, dan Bootstrap untuk memastikan tampilan yang responsif serta memudahkan pengguna dalam memasukkan data siswa melalui formulir daring dan memperoleh hasil prediksi secara real-time [1]. Integrasi model ke dalam sistem web mendukung penerapan pembelajaran berbasis data dan membantu sekolah melakukan pemantauan performa siswa secara berkelanjutan [21],[22]. Dengan pendekatan ini, seluruh proses metodologi tidak hanya menghasilkan model prediksi yang akurat, tetapi juga memastikan kebermanfaatannya dalam konteks implementasi pendidikan.

3. Hasil dan Pembahasan

Bagian ini menyajikan hasil eksperimen prediksi kinerja siswa menggunakan dua algoritma pembelajaran mesin, yaitu *Decision Tree* dan *Extreme Gradient Boosting* (XGBoost). Evaluasi dilakukan berdasarkan metrik akurasi (*accuracy*), presisi (*precision*), daya ingat (*recall*), dan F1-score guna memberikan gambaran komprehensif terhadap efektivitas model yang diusulkan

3.1. Evaluasi Model dan Perbandingan Kinerja

Pengujian performa model dilakukan menggunakan skema *5-fold cross-validation* dengan pembagian data secara stratified untuk menjaga proporsi kelas tetap seimbang pada setiap subset data. Dua algoritma yang dibandingkan adalah *Gradient Boosting* dan *Decision Tree*. Hasil evaluasi ditampilkan pada Tabel 1, yang memuat nilai metrik AUC, CA (*Classification Accuracy*), F1-score, *Precision*, *Recall*, *Matthews Correlation Coefficient* (MCC), dan *LogLoss*.

Tabel 2. Hasil Evaluasi Model Decision Tree dan Gradient Boosting

Model	AUC	CA	F1	Precision	Recall	MCC	LogLoss
Gradient Boosting	0.954	0.885	0.885	0.886	0.885	0.770	0.283
Decision Tree	0.839	0.826	0.826	0.826	0.826	0.652	3.617

Sumber: Hasil olahan penulis (2025)

Tabel 2 Algoritma Gradient Boosting menunjukkan kinerja lebih baik dibandingkan Decision Tree pada seluruh metrik evaluasi. Nilai AUC sebesar 0,954 menunjukkan kemampuan diskriminatif yang tinggi, dengan akurasi dan F1-score sebesar 0,885 yang mencerminkan keseimbangan antara presisi dan recall. Sebaliknya, Decision Tree memperoleh AUC 0,839 dan akurasi 0,826, yang menandakan keterbatasan dalam mengenali pola data kompleks. Nilai LogLoss Gradient Boosting yang lebih rendah (0,283) juga menunjukkan prediksi yang lebih pasti. Secara probabilistik, Gradient Boosting memiliki peluang 1,000 untuk menghasilkan AUC lebih tinggi, menunjukkan perbedaan kinerja kedua model bersifat signifikan

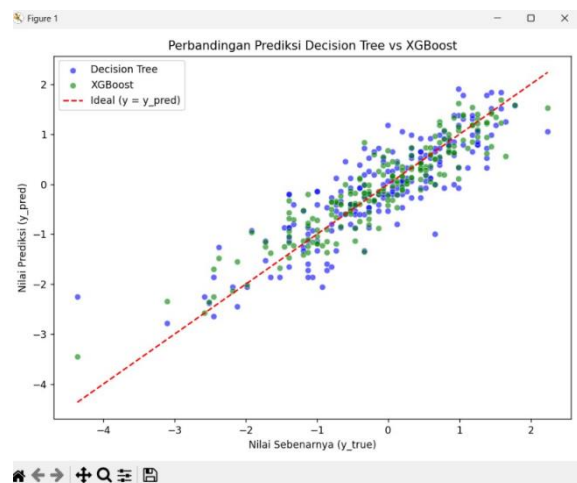
3.2. Hasil Evaluasi Model

	#	Info. gain	Gain ratio
1 lunch	2	0.000	0.000
2 test preparation course	2	0.000	0.000
3 race/ethnicity	5	0.007	0.003
4 parental level of education	6	0.002	0.001
5 math score		0.017	0.009
6 reading score		0.039	0.019
7 writing score		0.073	0.037

Gambar 1. Hasil Analisis *Information Gain* dan *Gain Ratio*
Sumber: Hasil olahan penulis (2025)

Gambar 1 menunjukkan hasil analisis *information gain* dan *gain ratio* untuk menentukan variabel yang paling berpengaruh dalam klasifikasi. Variabel numerik, khususnya *writing score* dengan nilai *information gain* tertinggi (0,073) dan *gain ratio* terbesar (0,037), memberikan kontribusi terbesar terhadap model. Sementara itu, *reading score* dan *math score* memiliki pengaruh sedang, sedangkan variabel kategorikal seperti *lunch* dan *test preparation course* menunjukkan kontribusi yang sangat kecil. Hal ini menegaskan bahwa skor akademik lebih berperan penting dalam membedakan kelas data dibandingkan faktor kategorikal.


3.3. Perbandingan Hasil Prediksi



Gambar 2. Perbandingan Hasil Prediksi
Sumber: Hasil olahan penulis (2025)

Gambar 2 Perbandingan hasil prediksi Decision Tree dan XGBoost terhadap nilai aktual. Sumbu horizontal menunjukkan nilai sebenarnya, sedangkan sumbu vertikal menampilkan nilai prediksi, dengan garis ideal sebagai acuan kesesuaian sempurna. Titik prediksi Decision Tree terlihat lebih menyebar, sementara titik dari XGBoost lebih terkonsentrasi di sekitar garis ideal. Pola ini menunjukkan bahwa meskipun kedua model memiliki kinerja prediktif yang baik, XGBoost memberikan hasil yang lebih stabil dan lebih dekat dengan nilai aktual.

3.4 Perbandingan *Confusion Matrix*

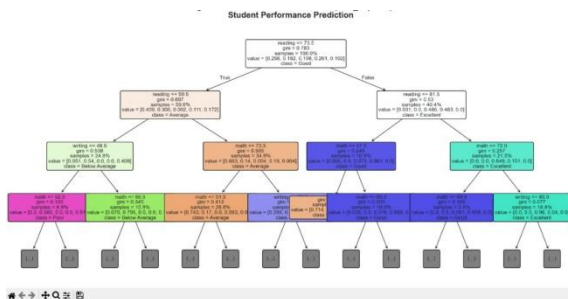


Gambar 3. Perbandingan *Confusion Matrix*
Sumber: Hasil olahan penulis (2025)

Gambar 3 memperlihatkan perbandingan *confusion matrix* antara algoritma Decision Tree dan XGBoost pada proses klasifikasi kinerja siswa. Sumbu vertikal menunjukkan label sebenarnya (*true label*), sedangkan sumbu horizontal menampilkan label hasil prediksi (*predicted label*). Setiap sel menggambarkan jumlah data yang termasuk dalam kombinasi antara label sebenarnya dan label prediksi.

Pada model Decision Tree, masih terdapat beberapa kesalahan klasifikasi, misalnya data dengan label *Average* yang diprediksi sebagai *Below Average* atau *Good*, serta data *Excellent* yang sebagian kecil diklasifikasikan sebagai *Good*. Sebaliknya, pada model XGBoost, sebaran data yang benar terklasifikasi pada diagonal utama terlihat lebih dominan, dengan jumlah kesalahan klasifikasi yang relatif sedikit di luar diagonal.


3.5 Struktur *Decision Tree*



Gambar 4. Struktur Pohon Keputusan
Sumber: Hasil olahan penulis (2025)

Gambar 4 Struktur pohon keputusan yang digunakan untuk memprediksi kinerja siswa. Pemisahan data dimulai dari variabel reading dengan ambang 73.5, yang kemudian mengarahkan data ke cabang-cabang yang lebih homogen. Setiap simpul memuat nilai gini, jumlah sampel, serta distribusi kelas, yang menggambarkan kualitas pemisahan pada tahap tersebut. Variabel reading dan math tampak menjadi penentu utama dalam proses klasifikasi. Secara keseluruhan, pohon keputusan memperlihatkan bagaimana model memecah data secara bertahap hingga mencapai prediksi akhir, sekaligus menunjukkan keterbatasannya dalam menangani keragaman data yang lebih kompleks.

3.6 ROC Curve Comparison



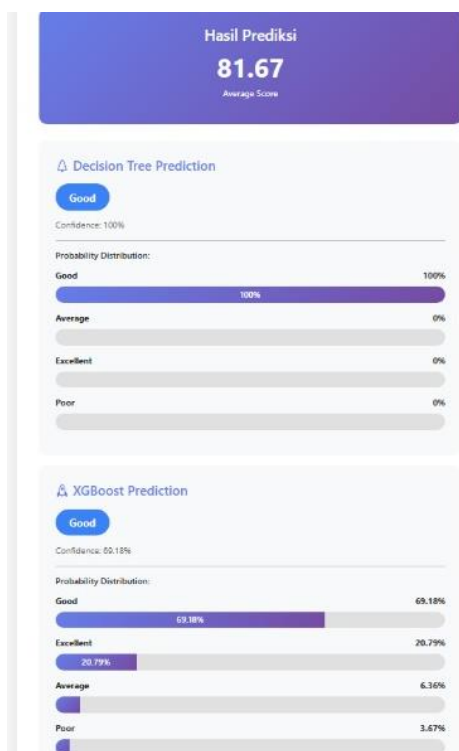
Gambar 5. ROC Curve Comparison
Sumber: Hasil olahan penulis (2025)

Gambar 5 Kurva ROC pada gambar membandingkan kemampuan klasifikasi Decision Tree dan XGBoost dalam memprediksi kinerja siswa. Sumbu horizontal menunjukkan tingkat kesalahan positif, sedangkan sumbu vertikal menggambarkan tingkat deteksi benar. Kurva XGBoost tampak lebih mendekati sudut kiri atas, menghasilkan AUC 0,998, yang menandakan performa hampir sempurna dalam membedakan kelas. Sementara itu, Decision Tree dengan AUC 0,961 tetap menunjukkan kinerja baik, tetapi lebih rendah dibandingkan XGBoost. Perbedaan jarak kurva terhadap garis acuan model acak memperlihatkan bahwa XGBoost memiliki kemampuan diskriminatif yang lebih kuat dan lebih konsisten pada seluruh ambang keputusan.

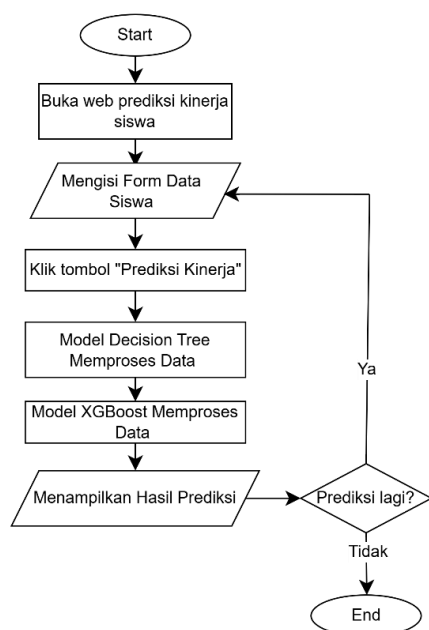
3.7 Implementasi Sistem Berbasis Web

Gambar 6. Tampilan Input Data
Sumber: Tangkapan layar system oleh penulis (2025)

Gambar 8 Alur proses dari web gambar 6 dan 7 dimulai ketika pengguna membuka laman prediksi kinerja siswa dan mengisi formulir data yang diperlukan. Setelah tombol “Prediksi Kinerja” ditekan, sistem memproses masukan menggunakan model Decision Tree dan XGBoost untuk menghasilkan estimasi kinerja siswa. Hasil prediksi kemudian ditampilkan, dan pengguna diberikan opsi untuk melakukan prediksi kembali atau mengakhiri proses.



Gambar 7. Hasil Prediksi Decision Tree dan XGBoost
Sumber: Tangkapan layar system oleh penulis (2025)



Gambar 8. Flowchart Web Prediksi Decision Tree dan XGBoost
Sumber: Hasil penulis (2025)

Hasil analisis information gain menunjukkan bahwa *writing score* memiliki kontribusi paling besar dalam menentukan kelas performa siswa. Hal ini disebabkan oleh beberapa faktor. Pertama, kemampuan menulis merupakan keterampilan produktif yang mencerminkan pemahaman konseptual dan kemampuan berpikir terstruktur, sehingga menjadi indikator kuat dari kemampuan akademik secara

keseluruhan. Kedua, *writing score* memiliki variasi nilai yang lebih stabil dan terdistribusi dengan baik di seluruh kelas dibandingkan nilai matematika dan membaca, sehingga memberikan informasi yang lebih kaya bagi model dalam membedakan kategori performa siswa. Ketiga, variabel ini memiliki korelasi yang lebih konsisten terhadap dua nilai lainnya (*reading* dan *math*), sehingga secara statistik memberikan daya prediksi lebih tinggi. Oleh karena itu, *writing score* menjadi fitur paling dominan dalam menentukan hasil klasifikasi.

3.8 Sistem Web (Backend & Frontend)

Integrasi sistem web pada penelitian ini menggunakan arsitektur *client-server*. Pada sisi frontend, antarmuka pengguna dibangun menggunakan HTML, CSS, JavaScript, dan Bootstrap untuk menghasilkan tampilan yang responsif dan mudah digunakan. Pengguna memasukkan data siswa melalui formulir input, kemudian data tersebut dikirimkan ke server menggunakan metode HTTP POST.

Pada sisi backend, framework Flask digunakan untuk menangani request dari frontend. Backend melakukan preprocessing data menggunakan *pandas* dan *numpy*, memanggil model Machine Learning (Decision Tree dan XGBoost) yang telah diserialisasi menggunakan *pickle* atau *joblib*, kemudian menjalankan proses prediksi. Hasil prediksi dikembalikan ke frontend dalam format JSON. Frontend kemudian menampilkan hasil prediksi dalam bentuk teks maupun visualisasi seperti grafik performa siswa. Arsitektur ini memastikan proses prediksi berjalan secara otomatis, ringan, dan real-time tanpa memerlukan instalasi tambahan di sisi pengguna.

4. Kesimpulan

Hasil penelitian menunjukkan bahwa algoritma XGBoost merupakan model yang paling unggul dalam memprediksi kinerja siswa dibandingkan Decision Tree. Model XGBoost berhasil mencapai akurasi sebesar 0,885, F1-score 0,885, dan AUC 0,954, sehingga menunjukkan kemampuan generalisasi dan stabilitas prediksi yang lebih baik. Sebaliknya, Decision Tree yang hanya memperoleh akurasi 0,826 dan AUC 0,839 masih memiliki keterbatasan dalam menangkap pola data yang kompleks. Temuan ini memperkuat bahwa pendekatan ensemble—khususnya boosting—lebih efektif dalam menangani data pendidikan yang memiliki hubungan non-linear dan variasi kelas yang berbeda.

Dari sisi teknologi, penelitian ini memberikan kontribusi penting dengan mengimplementasikan model Machine Learning ke dalam sistem prediksi berbasis web menggunakan Flask. Sistem ini mampu melakukan pemrosesan data, menjalankan model prediksi, dan menampilkan hasil secara real-time hanya melalui antarmuka web, tanpa memerlukan

instalasi perangkat lunak tambahan. Integrasi ini membuktikan bahwa pengembangan sistem prediktif dapat diterapkan secara praktis di lingkungan sekolah untuk mendukung pemantauan kinerja siswa secara cepat dan berkelanjutan.

Secara ilmiah, penelitian ini berkontribusi pada penguatan bidang Educational Data Mining (EDM) dengan menghadirkan pendekatan terpadu antara algoritma klasifikasi dan platform prediksi berbasis web. Berbeda dengan banyak penelitian sebelumnya di Indonesia yang hanya berfokus pada evaluasi akurasi model, penelitian ini menghadirkan sistem prediksi interaktif yang mampu memberikan output waktu nyata, sehingga meningkatkan nilai kebermanfaatan model di konteks implementasi pendidikan.

Meskipun menghasilkan performa yang kuat, generalisasi hasil penelitian tetap perlu dilakukan secara hati-hati mengingat keterbatasan variasi dataset. Penelitian selanjutnya disarankan untuk menggunakan data yang lebih besar dan beragam, memperluas eksplorasi parameter, serta mempertimbangkan analisis interpretabilitas dan uji sensitivitas. Dengan demikian, model prediksi yang dikembangkan tidak hanya unggul secara numerik, tetapi juga transparan, etis, dan dapat diterapkan secara bertanggung jawab pada pengambilan keputusan di sektor pendidikan.

Daftar Rujukan

- [1] Q. Aini, A. Kurniawan, and T. B. Sulistiyowati, "Digital Transformation: Best Practices of Educational Platform in Indonesia," *J. Transform.*, vol. 10, no. 1, pp. 42–59, 2024, doi: DOI: 10.21776/ub.transformative.2024.010.01.3.
- [2] F. M. Siddiq, "Prediksi Prestasi Akademik Siswa Jurusan PPLG dengan Metode Algoritma Decision Tree (Studi Kasus: SMK Negeri 1 Depok)," *Syntax Lit. J. Ilm. Indones.*, vol. 10, no. 1, pp. 1–11, 2025, doi: <https://doi.org/10.36418/syntax-literature.v10i1.17220>.
- [3] P. A. Thamrin, R. Nasuah, N. Talaohu, Maharani, and M. Almasi, "Digital Transformation In Education Management Optimizing Technology For Effective Learning," *JiEMAN J. Islam. Educ. Manag.*, vol. 6, no. 2, pp. 73–88, 2024, doi: <https://doi.org/10.35719/jieman.v6i2.259>.
- [4] A. Fathurohman, "Machine Learning Untuk Pendidikan: Mengapa dan Bagaimana," *J. Inform. dan Teknol. Komput.*, vol. 1, no. 3, pp. 57–62, 2021.
- [5] S. A. A. Kharis and A. H. A. Zili, "Learning Analytics dan Educational Data Mining pada Data Pendidikan," *J. Ris. Pembelajaran Mat. Sekol.*, vol. 6, no. 1, pp. 12–20, 2022, doi: <https://doi.org/10.21009/jrpms.061.02>.
- [6] Nurbaeti, N. Sulistyaningsih, and R. Rismayati, "Comparison of Random Forest, Decision Tree, and XGBoost Models in Predicting Student Academic Success," *J. Artif. Intell. Softw. Eng.*, vol. 5, no. 3, pp. 920–929, 2025, doi: <http://dx.doi.org/10.30811/jaise.v5i3.7138>.
- [7] S. Dipa, J. Santoso, and F. H. Chandra, "Prediction of Student Performance in the Results of the Online Learning Process Assessment in Informatics Subjects in High School," *J-Intech J. Inf. Technol.*, vol. 12, no. 1, pp. 73–81, 2024, doi: <https://doi.org/10.32664/j-intech.v12i1.1259>.
- [8] M. F. H. Febrian, W. A. Triyanto, and D. L. Fithri, "Perbandingan Kinerja KKN dan Decision Tree dalam Klasifikasi Akademik Siswa SMP Wilayah Mejobo," *Rabit J. Teknol. Dan Sist. Inf. Univrab*, vol. 10, no. 2, pp. 887–897, 2025, doi: <https://doi.org/10.36341/rabit.v10i2.6412>.
- [9] T. H. Hasibuan and D. Mahdiana, "Prediksi Kelulusan Mahasiswa Tepat Waktu Menggunakan Algoritma C4.5 Pada UIN Syarif Hidayatullah Jakarta," *J. Skanika*, vol. 6, no. 1, pp. 61–74, 2023, doi: <https://doi.org/10.36080/skanika.v6i1.2976>.
- [10] M. T. Nururrohman and E. Setyati, "Sistem Rekomendasi Penerima Beasiswa pada Calon Mahasiswa Menggunakan Algoritma XGBoost di Universitas Islam Darul 'Ulum Lamongan," *J. Inform.*, vol. 14, no. 1, 2025, doi: <https://doi.org/10.35706/syji.v14i01.13070>.
- [11] L. F. Sari, "Analisis Pengaruh Faktor-faktor Eksternal Terhadap Kinerja Komputer Menggunakan Machine Learning," *J. Dunia Data*, vol. 1, no. 4, pp. 1–16, 2024.
- [12] R. Simanullang, D. Hartama, Poningsih, I. Parlina, and M. R. Lubis, "Model Aturan dalam Menentukan Prestasi Nilai Siswa di SMK GKPS 1 Raya Menggunakan Algoritma C4.5," *J. Ilmu Komput. dan Inform.*, vol. 2, no. 1, pp. 1–24, 2022, doi: <https://doi.org/10.54082/jiki.16>.
- [13] C. E. Murwaningtyas, "Identification of Demographic Factors Affecting Student Performance using Tree-Based Machine Learning Models," *JTAM (Jurnal Teor. dan Apl. Mat.*, vol. 9, no. 2, pp. 467–481, 2025, doi: <https://doi.org/10.31764/jtam.v9i2.28815>.
- [14] I. Akbar, I. S. Samad, Rahmat, and S. Rosmiana, "Data Mining Analysis of K-means Algorithm and Decision Tree for Early Detection of Students at Risk of Dropping Out," *J. Informatics, Inf. Syst. Softw. Eng. Appl.*, vol. 7, no. 2, pp. 148–162, 2025, doi: <https://doi.org/10.20895/inista.v7i2.1630>.
- [15] A. I. Gufroni, Purwanto, and Farikhin, "Academic Performance Prediction Using Supervised Learning Algorithms in University Admission," *JOIV Int. J. Inform. Vis.*, vol. 9, no. 1, pp. 184–194, 2025, doi: <http://dx.doi.org/10.62527/joiv.9.1.2974>.
- [16] T. W. Putra, A. Triayudi, and Andrianingsih, "Analisis Sentimen Pembelajaran Daring menggunakan Metode Naïve Bayes, KNN, dan Decision Tree," *J. JTIK (Jurnal Teknol. Inf. Dan Komunikasi)*, vol. 6, no. 1, p. 21, 2022, doi: <https://doi.org/10.35870/jtik.v6i1.368>.
- [17] H. Amalia, A. Puspita, A. F. Lestari, and Frieyadie, "Application of Decision Tree and Naive Bayes on Student Performance Dataset," *J. Pilar Nusa Mandiri*, vol. 18, no. 1, pp. 53–58, 2022, doi: <https://doi.org/10.33480/pilar.v18i1.2714>.
- [18] I. D. Ayulani, A. M. Yunawan, T. Prihutaminingsih, D. Sarwinda, G. Ardaneswari, and B. D. Handari, "Tree-Based Ensemble Methods and Their Applications for Predicting Students' Academic Performance," *nt. J. Adv. Sci. Eng. Inf. Technol.*, vol. 13, no. 3, pp. 919–927, 2023, doi: <https://doi.org/10.18517/ijaseit.13.3.16880>.
- [19] S. Hasan and N. Muhammad, "Sistem Informasi Pembayaran Biaya Studi Berbasis Web pada Politeknik Sains dan Teknologi Wiratama Maluku Utara," *IJIS-Indonesian J. Inf. Syst.*, vol. 5, no. 1, pp. 44–55, 2020, doi: <https://doi.org/10.36549/ijis.v5i1.66>.
- [20] L. G. R. Putra, D. D. Prasetya, and Mayadi, "Student Dropout Prediction Using Random Forest and XGBoost Method," *INTENSIF J. Ilm. Penelit. Dan Penerapan Teknol. Sist. Inf.*, vol. 9, no. 1, pp. 147–157, 2025, doi: <https://doi.org/10.29407/intensif.v9i1.21191>.

- [21] M. Al Hafidz, A. C. Puspitaningrum, M. S. Prasetya, and L. D. Fitriani, "Implementasi Aplikasi Prestasi Siswa Berbasis Web pada Sekolah Menengah Atas di Indonesia," *Sist. J. Sist. Inf.*, vol. 13, no. 4, pp. 2540–9719, 2024, [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [22] D. N. Muhammady, H. A. E. Nugraha, V. R. S. Nastiti, and C. A. K. Sri, "Students Final Academic Score Prediction Using Boosting Regression Algorithms," *J. Ilm. Tek. Elektro Komput. dan Inform.*, vol. 10, no. 1, pp. 154–165, 2024, doi: 10.26555/jiteki.v10i1.28352.