

Perbandingan Random Forest dan Gradient Boosting pada Prediksi Hasil Belajar Siswa

Sopiyan Apandi*, Muhammad Bahrein

Fakultas Ilmu Komputer, Teknik Informatika, Universitas Pamulang, Tangerang Selatan, Indonesia

Email: ^{1*}dosen02601@unpam.ac.id, ²dosen02676@unpam.ac.id

Email Penulis Korespondensi: dosen02601@unpam.ac.id

Submitted 05-05-2026; Accepted 09-06-2026; Published 30-06-2026

Abstrak

Hasil belajar siswa merupakan indikator penting dalam menilai keberhasilan proses pembelajaran dan dapat dimanfaatkan untuk mendukung pengambilan keputusan akademik berbasis data. Penelitian ini bertujuan untuk membandingkan kinerja algoritma Random Forest dan Gradient Boosting dalam prediksi hasil belajar siswa. Penelitian menggunakan pendekatan kuantitatif dengan desain eksperimen komparatif menggunakan dataset siswa yang terdiri atas 500 data siswa dan 11 atribut. Variabel target yang digunakan adalah *passed*, sedangkan atribut seperti *gender*, *age*, *study_hours_per_week*, *attendance_rate*, *parent_education*, *internet_access*, *extracurricular*, dan *previous_score* digunakan sebagai prediktor. Tahap pra-proses meliputi pembersihan data, penanganan *missing value*, transformasi data kategorikal, seleksi fitur, dan pembagian data latih-uji dengan rasio 80:20. Evaluasi model dilakukan menggunakan *confusion matrix*, *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC*, serta diperkuat dengan *10-fold cross validation*. Hasil penelitian menunjukkan bahwa Random Forest sedikit lebih unggul dibandingkan Gradient Boosting pada sebagian besar metrik evaluasi. Pada data uji, Random Forest memperoleh *accuracy* 87,00%, *precision* 90,63%, *recall* 89,23%, *F1-score* 89,92%, dan *ROC-AUC* 93,27%, sedangkan Gradient Boosting memperoleh *accuracy* 86,00%, *precision* 90,48%, *recall* 87,69%, *F1-score* 89,06%, dan *ROC-AUC* 93,10%. Temuan ini menunjukkan bahwa kedua algoritma memiliki kemampuan yang baik dalam prediksi hasil belajar siswa, dengan Random Forest menunjukkan performa yang lebih stabil pada dataset yang digunakan.

Kata Kunci: Data Mining Pendidikan; Gradient Boosting; Hasil Belajar Siswa; Prediksi; Random Forest

Abstract

Student learning outcomes are important indicators for evaluating the success of the learning process and can be used to support data-driven academic decision-making. This study aims to compare the performance of the Random Forest and Gradient Boosting algorithms in predicting student learning outcomes. The study employed a quantitative approach with a comparative experimental design using the student dataset containing 500 student records and 11 attributes. The target variable was *passed*, while several attributes such as *gender*, *age*, *study_hours_per_week*, *attendance_rate*, *parent_education*, *internet_access*, *extracurricular*, and *previous_score* were used as predictors. The data preprocessing stage included data cleaning, missing value handling, categorical data transformation, feature selection, and train-test splitting with an 80:20 ratio. Model evaluation was conducted using *confusion matrix*, *accuracy*, *precision*, *recall*, *F1-score*, and *ROC-AUC*, supported by *10-fold cross validation*. The results showed that Random Forest slightly outperformed Gradient Boosting on most evaluation metrics. On the test data, Random Forest achieved an *accuracy* of 87.00%, *precision* of 90.63%, *recall* of 89.23%, *F1-score* of 89.92%, and *ROC-AUC* of 93.27%, while Gradient Boosting obtained an *accuracy* of 86.00%, *precision* of 90.48%, *recall* of 87.69%, *F1-score* of 89.06%, and *ROC-AUC* of 93.10%. These findings indicate that both algorithms performed well in predicting student learning outcomes, with Random Forest showing more stable performance on the dataset used.

Keywords: Educational Data Mining; Gradient Boosting; Prediction; Random Forest; Student Learning Outcomes

1. PENDAHULUAN

Perkembangan teknologi informasi telah mendorong lembaga pendidikan memanfaatkan data akademik tidak hanya sebagai arsip administratif, tetapi juga sebagai sumber informasi strategis untuk mendukung pengambilan keputusan berbasis data. Data nilai, kehadiran, aktivitas belajar, latar belakang siswa, dan hasil evaluasi pembelajaran dapat dianalisis untuk mengungkap pola yang berkaitan dengan performa akademik. Dalam konteks informatika, pemanfaatan data tersebut berkaitan erat dengan penerapan *data mining* dan *machine learning* untuk tugas klasifikasi, prediksi, dan identifikasi faktor yang memengaruhi capaian belajar. Penelitian pada konteks pendidikan juga menunjukkan bahwa model klasifikasi dapat dimanfaatkan untuk mendukung deteksi dini terhadap risiko akademik mahasiswa, sekaligus menjadi dasar bagi institusi pendidikan dalam merancang intervensi preventif yang lebih tepat sasaran dan berbasis data [1]. Prediksi data akademik menjadi penting karena membantu lembaga pendidikan mengenali pola performa belajar siswa dan menyusun keputusan akademik yang lebih adaptif [2]. Sejumlah penelitian juga menunjukkan bahwa pendekatan prediktif pada data pendidikan mampu memberikan informasi yang berguna untuk memprediksi capaian akademik, memperkirakan durasi studi, dan mengidentifikasi pola performa peserta didik sebagai dasar penyusunan strategi pembelajaran yang lebih tepat [3]. Dalam kerangka yang lebih luas, *Educational Data Mining* (EDM) telah menjadi pendekatan yang efektif untuk menganalisis data akademik dan mendukung prediksi terhadap berbagai permasalahan pendidikan, termasuk identifikasi siswa yang berisiko mengalami penurunan capaian belajar atau tidak menyelesaikan studi [4].

Penelitian mengenai prediksi capaian akademik berbasis *machine learning* menunjukkan tren yang terus berkembang, terutama pada kajian yang membahas faktor-faktor yang memengaruhi capaian akademik dan evaluasi model prediksi yang digunakan [5]. Hasil belajar siswa merupakan salah satu indikator utama dalam menilai keberhasilan proses pembelajaran. Kemampuan untuk memprediksi hasil belajar sejak dini memberi manfaat penting bagi guru dan institusi pendidikan karena memungkinkan intervensi dilakukan lebih cepat dan tepat sasaran, termasuk dalam bentuk

sistem prediksi dini untuk mendeteksi siswa yang berisiko mengalami kegagalan akademik [6]. Dalam EDM, prediksi performa siswa juga dipandang sebagai salah satu tugas inti karena mendukung pengembangan pendidikan yang lebih personal, membantu pendidik menyesuaikan strategi pengajaran, serta menyediakan dasar yang lebih objektif bagi pengambil kebijakan pendidikan [7]. Penelitian sebelumnya bahkan menunjukkan bahwa data evaluasi akademik dapat dimanfaatkan untuk klasifikasi prestasi siswa secara otomatis melalui pendekatan *machine learning* [8]. Kajian sistematis lebih lanjut juga memperlihatkan bahwa prediksi performa akademik masih didominasi oleh upaya mengidentifikasi faktor-faktor yang memengaruhi hasil belajar, mengevaluasi kinerja algoritma *data mining*, serta memanfaatkan data akademik dan demografis sebagai prediktor utama [9].

Meskipun demikian, pemilihan algoritma yang paling tepat untuk prediksi hasil belajar tidak selalu sederhana. Berbagai kajian menunjukkan bahwa Random Forest merupakan salah satu metode yang paling sering digunakan dalam prediksi capaian akademik [5]. Pada data pendidikan, Random Forest dinilai mampu menangkap pola nonlinier dan interaksi yang kompleks antarvariabel, sekaligus memberikan tingkat akurasi dan interpretabilitas yang baik [10]. Secara umum, Random Forest bekerja dengan membangun banyak pohon keputusan dan menggabungkan hasil prediksi melalui mekanisme agregasi, sehingga relatif stabil terhadap *noise* dan risiko *overfitting*. Di sisi lain, Gradient Boosting membangun model secara bertahap dengan memperbaiki kesalahan model sebelumnya, sehingga sering menunjukkan performa tinggi pada data dengan pola yang lebih kompleks. Sejumlah penelitian terdahulu menunjukkan bahwa Random Forest yang dipadukan dengan *cross validation* dan *hyperparameter tuning* mampu menghasilkan performa yang sangat baik, tetapi pada konteks lain pendekatan *boosting* justru memberikan hasil yang lebih unggul. Hal ini menunjukkan bahwa kinerja model ensemble sangat dipengaruhi oleh karakteristik dataset dan jenis prediksi yang dilakukan [11].

Atas dasar itu, kebutuhan akan studi komparatif menjadi semakin penting. Sebagian penelitian pada bidang pendidikan masih berfokus pada penerapan satu algoritma tanpa melakukan perbandingan yang memadai dengan metode lain, padahal performa model sangat dipengaruhi oleh karakteristik data, kualitas fitur, dan tujuan prediksi yang digunakan. Pada beberapa kasus, Random Forest mampu memberikan performa yang baik serta membantu mengidentifikasi faktor-faktor penting melalui analisis *feature importance*, tetapi pada konteks lain model ini belum tentu menghasilkan performa yang optimal sehingga masih memerlukan optimasi fitur maupun eksplorasi algoritma alternatif [12]. Selain itu, studi-studi terdahulu juga menunjukkan bahwa penelitian komparatif antaralgoritma ensemble memiliki landasan metodologis yang kuat, dan Random Forest serta Gradient Boosting sering dijadikan model dasar karena merepresentasikan dua pendekatan ensemble yang berbeda, yaitu *bagging* dan *boosting* [13].

Berdasarkan uraian tersebut, masih terdapat celah penelitian dalam konteks prediksi hasil belajar siswa, khususnya yang berfokus pada perbandingan langsung antara Random Forest dan Gradient Boosting pada dataset pendidikan. Penelitian terdahulu menunjukkan bahwa Random Forest memiliki potensi yang baik dalam klasifikasi prestasi siswa, tetapi belum banyak kajian yang mengevaluasi kinerjanya secara langsung dengan pendekatan *boosting* pada permasalahan prediksi hasil belajar [8]. Oleh karena itu, penelitian ini dilakukan untuk membangun dan membandingkan model Random Forest dan Gradient Boosting menggunakan data hasil belajar siswa, kemudian mengevaluasi performa keduanya melalui metrik yang sesuai. Penelitian ini diharapkan memberikan kontribusi akademik melalui penyajian bukti empiris mengenai perbedaan performa kedua algoritma, sekaligus kontribusi praktis bagi sekolah atau lembaga bimbingan belajar dalam memilih model prediksi yang lebih sesuai untuk mendukung deteksi dini terhadap capaian belajar siswa [14]. Sejalan dengan itu, berbagai penelitian menunjukkan bahwa EDM memiliki potensi besar dalam memprediksi capaian akademik, tetapi performa model tetap dipengaruhi oleh karakteristik data, pemilihan fitur, dan algoritma yang digunakan [15].

Penelitian ini bertujuan untuk membangun model prediksi hasil belajar siswa menggunakan dua algoritma ensemble, yaitu Random Forest dan Gradient Boosting, serta membandingkan performa keduanya secara kuantitatif. Pemilihan kedua algoritma tersebut didasarkan pada perbedaan mekanisme pembelajarannya, sehingga relevan untuk diuji pada data hasil belajar siswa [16]. Dengan demikian, penelitian ini diarahkan untuk menjawab bagaimana kinerja Random Forest dan Gradient Boosting dalam memprediksi hasil belajar siswa, algoritma mana yang memberikan performa terbaik, serta sejauh mana hasil komparasi tersebut dapat dijadikan dasar rekomendasi dalam penerapan analitik pendidikan berbasis data. Hipotesis penelitian ini menyatakan bahwa terdapat perbedaan kinerja antara kedua algoritma tersebut karena performa model ensemble sangat dipengaruhi oleh konteks data dan tujuan prediksi [11]. Kebaruan penelitian ini terletak pada fokusnya yang secara langsung membandingkan performa Random Forest dan Gradient Boosting pada domain prediksi hasil belajar siswa, sehingga diharapkan dapat memberikan bukti empiris mengenai model yang lebih akurat, lebih stabil, dan lebih sesuai diterapkan pada konteks data pendidikan [8], [17].

2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain eksperimen komparatif untuk membandingkan kinerja dua algoritma *ensemble*, yaitu Random Forest dan Gradient Boosting, dalam prediksi hasil belajar siswa. Desain ini dipilih karena memungkinkan evaluasi yang sistematis terhadap performa masing-masing algoritma berdasarkan metrik klasifikasi yang telah ditetapkan. Random Forest dipahami sebagai kumpulan pengklasifikasi berbasis pohon keputusan yang dibangun melalui unsur keacakan dan menghasilkan prediksi akhir melalui mekanisme pemungutan suara, sehingga dikenal stabil terhadap *noise* dan mampu menyediakan informasi mengenai pentingnya variabel [16]. Sementara itu, Gradient Boosting membangun model secara bertahap melalui pendekatan *stagewise additive expansion*, yaitu dengan

menambahkan *base learner* secara berurutan untuk memperbaiki kesalahan model sebelumnya berdasarkan minimisasi fungsi *loss* [18]. Dengan karakteristik pembelajaran yang berbeda tersebut, kedua algoritma dipandang relevan untuk dibandingkan pada konteks prediksi hasil belajar siswa [11].

2.1 Algoritma Random Forest

Random Forest merupakan algoritma *ensemble learning* yang diperkenalkan oleh Breiman dengan menggabungkan sejumlah *decision tree* untuk menghasilkan prediksi yang lebih akurat dan stabil. Pada proses klasifikasi, hasil prediksi diperoleh melalui mekanisme *majority voting* dari seluruh pohon keputusan yang dibangun. Pendekatan ini memungkinkan Random Forest memiliki kemampuan generalisasi yang lebih baik dibandingkan penggunaan satu pohon keputusan tunggal [16].

Algoritma Random Forest bekerja menggunakan teknik *bootstrap aggregating (bagging)*, yaitu membangun banyak pohon keputusan dari sampel data yang berbeda serta melakukan pemilihan fitur secara acak pada setiap node. Kombinasi kedua mekanisme tersebut membantu mengurangi risiko *overfitting*, meningkatkan ketahanan terhadap *noise*, serta menghasilkan model yang lebih stabil pada berbagai karakteristik data [17].

Dalam bidang pendidikan, Random Forest banyak digunakan untuk prediksi capaian akademik dan identifikasi siswa berisiko karena mampu menangani data yang terdiri atas kombinasi atribut numerik dan kategorikal. Oleh karena itu, algoritma ini digunakan sebagai salah satu model utama dalam penelitian untuk memprediksi hasil belajar siswa berdasarkan berbagai faktor akademik dan non-akademik.

2.2 Algoritma Gradient Boosting

Gradient Boosting merupakan salah satu algoritma *ensemble learning* yang menggunakan pendekatan *boosting* untuk meningkatkan performa prediksi. Berbeda dengan Random Forest yang membangun sejumlah pohon keputusan secara independen, Gradient Boosting membangun model secara bertahap (*stage-wise*) dengan cara menambahkan pohon keputusan baru yang bertujuan memperbaiki kesalahan prediksi dari model sebelumnya. Pendekatan ini memungkinkan model mempelajari pola data secara lebih mendalam dan menghasilkan prediksi yang lebih akurat [18].

Pada setiap iterasi, Gradient Boosting menghitung residual atau kesalahan prediksi yang dihasilkan oleh model sebelumnya, kemudian membangun *decision tree* baru untuk meminimalkan kesalahan tersebut. Hasil prediksi akhir diperoleh dari kombinasi seluruh pohon yang dibentuk secara berurutan. Secara matematis, proses pembaruan model pada Gradient Boosting dapat dinyatakan sebagai berikut:

$$F_m(x) = F_{m-1}(x) + \gamma_m h_m(x) \quad (1)$$

Keterangan:

$F_m(x)$ = model pada iterasi ke-(m)

$F_{m-1}(x)$ = model pada iterasi sebelumnya

$h_m(x)$ = *weak learner* atau pohon keputusan yang dibangun pada iterasi ke-(m)

γ_m = bobot kontribusi dari *weak learner*

(x) = data masukan

Persamaan tersebut menunjukkan bahwa model baru dibentuk dengan menambahkan hasil prediksi *weak learner* ke model sebelumnya. Dengan mekanisme ini, setiap iterasi akan berfokus pada perbaikan kesalahan yang masih muncul sehingga performa model dapat meningkat secara bertahap hingga mencapai kondisi yang optimal [18].

Dalam berbagai penelitian, Gradient Boosting telah banyak digunakan untuk menyelesaikan permasalahan klasifikasi dan prediksi karena kemampuannya dalam memodelkan hubungan yang kompleks serta menangani pola data yang bersifat nonlinier. Pada domain pendidikan, algoritma ini juga digunakan untuk memprediksi performa akademik, mengidentifikasi siswa berisiko, dan mendukung pengambilan keputusan berbasis data. Kajian sebelumnya menunjukkan bahwa model *machine learning* berbasis *ensemble* memiliki kemampuan yang baik dalam menganalisis data pendidikan yang kompleks dan menghasilkan performa prediksi yang kompetitif [22]. Oleh karena itu, penelitian ini menggunakan Gradient Boosting sebagai model pembanding terhadap Random Forest untuk mengevaluasi performa prediksi hasil belajar siswa berdasarkan berbagai karakteristik akademik dan non-akademik.

2.3 Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini berupa Data Siswa, yaitu dataset performa akademik siswa yang terdiri atas 500 data dengan 11 atribut. Atribut yang tersedia meliputi *student_id*, *gender*, *age*, *study_hours_per_week*, *attendance_rate*, *parent_education*, *internet_access*, *extracurricular*, *previous_score*, *final_score*, dan *passed*. Variabel dependen dalam penelitian ini adalah *passed*, yang merepresentasikan ketuntasan hasil belajar siswa dalam dua kategori, yaitu Yes dan No, sehingga permasalahan penelitian diposisikan sebagai klasifikasi biner. Variabel independen yang digunakan meliputi *gender*, *age*, *study_hours_per_week*, *attendance_rate*, *parent_education*, *internet_access*, *extracurricular*, dan *previous_score*. Atribut *student_id* tidak digunakan karena hanya berfungsi sebagai identitas, sedangkan *final_score* dikeluarkan dari proses pemodelan karena berpotensi menimbulkan *data leakage* terhadap label *passed*. Pemilihan variabel tersebut didasarkan pada pertimbangan bahwa karakteristik siswa, intensitas belajar, tingkat kehadiran, dukungan lingkungan belajar, dan performa akademik sebelumnya berpotensi memengaruhi hasil belajar akhir. Selain itu, hasil belajar tidak hanya dipengaruhi oleh faktor akademik, tetapi juga oleh faktor non-akademik dan

konteks lingkungan belajar, sehingga kombinasi beberapa jenis prediktor diperlukan untuk menghasilkan model yang lebih representatif [10].

2.4 Tahap Pengumpulan dan Persiapan Data

Tahap awal penelitian dilakukan dengan menyiapkan dataset agar layak digunakan pada proses pemodelan. Praproses data diawali dengan pembersihan data untuk memastikan tidak terdapat data duplikat maupun inkonsistensi pada nilai atribut. Selanjutnya, dilakukan pemeriksaan *missing value*. Pada dataset ini, nilai yang hilang ditemukan pada atribut *parent_education*, sehingga penanganannya dilakukan melalui imputasi agar informasi tetap dapat dimanfaatkan tanpa mengurangi jumlah data secara signifikan. Setelah itu, atribut kategorikal seperti *gender*, *parent_education*, *internet_access*, dan *extracurricular* ditransformasikan ke dalam bentuk numerik agar dapat diproses oleh algoritma *machine learning*. Tahap berikutnya adalah seleksi atribut dengan mengeluarkan *student_id* dan *final_score* dari data prediktor, sedangkan variabel target ditetapkan sebagai *passed*.

Distribusi kelas pada variabel target kemudian diperiksa untuk memastikan keseimbangan data. Karena distribusi kelas menunjukkan ketidakseimbangan moderat, penyeimbangan data dilakukan menggunakan metode *Synthetic Minority Over-sampling Technique* (SMOTE) pada data latih. Penerapan SMOTE pada data yang tidak seimbang telah dilaporkan mampu meningkatkan performa model prediksi, termasuk pada Random Forest, melalui perbaikan akurasi dan nilai AUC dibandingkan tanpa penyeimbangan data [19]. Dengan demikian, tahap praproses tidak hanya bertujuan membersihkan dan mentransformasikan data, tetapi juga memastikan bahwa data yang digunakan benar-benar representatif untuk tahap pemodelan.

2.5 Pembagian Data, Validasi, dan Tuning

Setelah tahap praproses selesai, dataset dibagi menjadi dua bagian, yaitu data latih dan data uji, dengan proporsi 80:20. Sebanyak 80% data digunakan untuk pelatihan model, sedangkan 20% sisanya digunakan untuk pengujian akhir pada data yang belum pernah dilihat model sebelumnya. Pembagian ini dilakukan untuk memperoleh evaluasi yang lebih objektif terhadap kemampuan generalisasi model. Penggunaan teknik validasi seperti *Stratified K-Fold Cross Validation* dan optimasi hiperparameter telah dilaporkan mampu meningkatkan kestabilan evaluasi model serta memberikan pengukuran performa yang lebih objektif melalui metrik seperti *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC* [20]. Pada data latih diterapkan *10-fold cross validation* untuk meningkatkan kestabilan evaluasi dan mengurangi bias akibat satu kali pemisahan data.

Pada tahap yang sama, dilakukan *hyperparameter tuning* menggunakan Grid Search CV untuk memperoleh kombinasi parameter terbaik bagi masing-masing algoritma. Penggunaan *cross validation* dan *hyperparameter tuning* telah terbukti dapat meningkatkan performa model klasifikasi, dan pada penelitian sebelumnya Random Forest dengan Grid Search CV menghasilkan akurasi terbaik dibandingkan metode lain yang diuji [11]. Parameter yang dioptimasi pada Random Forest meliputi *n_estimators*, *max_depth*, *max_features*, *min_samples_split*, dan *min_samples_leaf*. Sementara itu, pada Gradient Boosting parameter yang dioptimasi meliputi *n_estimators*, *learning_rate*, *max_depth*, *subsample*, dan *min_samples_split*. Melalui tahapan ini, model yang dihasilkan diharapkan tidak hanya memiliki performa yang baik pada data latih, tetapi juga mampu memberikan prediksi yang stabil dan akurat pada data uji

2.6 Pemodelan

Pada penelitian ini, dua model utama yang dibangun dan dibandingkan adalah Random Forest dan Gradient Boosting. Proses pemodelan dilakukan dengan melatih masing-masing algoritma menggunakan data latih yang sama agar perbandingan dapat dilakukan secara objektif. Model terbaik dari masing-masing algoritma ditentukan berdasarkan hasil *cross validation* dan *hyperparameter tuning*, kemudian diuji menggunakan data uji untuk mengevaluasi performanya berdasarkan metrik yang telah ditetapkan. Hasil evaluasi kedua model selanjutnya dibandingkan untuk menentukan algoritma yang memberikan performa paling optimal dalam prediksi hasil belajar siswa.

2.7 Metrik Evaluasi

Karena penelitian ini berfokus pada prediksi kategori hasil belajar siswa, evaluasi model dilakukan menggunakan *confusion matrix* beserta metrik turunannya, yaitu *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC*. *Accuracy* digunakan untuk mengukur proporsi prediksi yang benar terhadap seluruh data, *precision* menunjukkan ketepatan model dalam memprediksi kelas positif, *recall* menggambarkan kemampuan model dalam mendeteksi seluruh data aktual positif, sedangkan *F1-score* digunakan untuk menilai keseimbangan antara *precision* dan *recall*. Secara matematis, metrik yang digunakan adalah sebagai berikut:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2)$$

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

$$F1-score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (5)$$

$$Specificity = \frac{TN}{TN+FP} \quad (6)$$

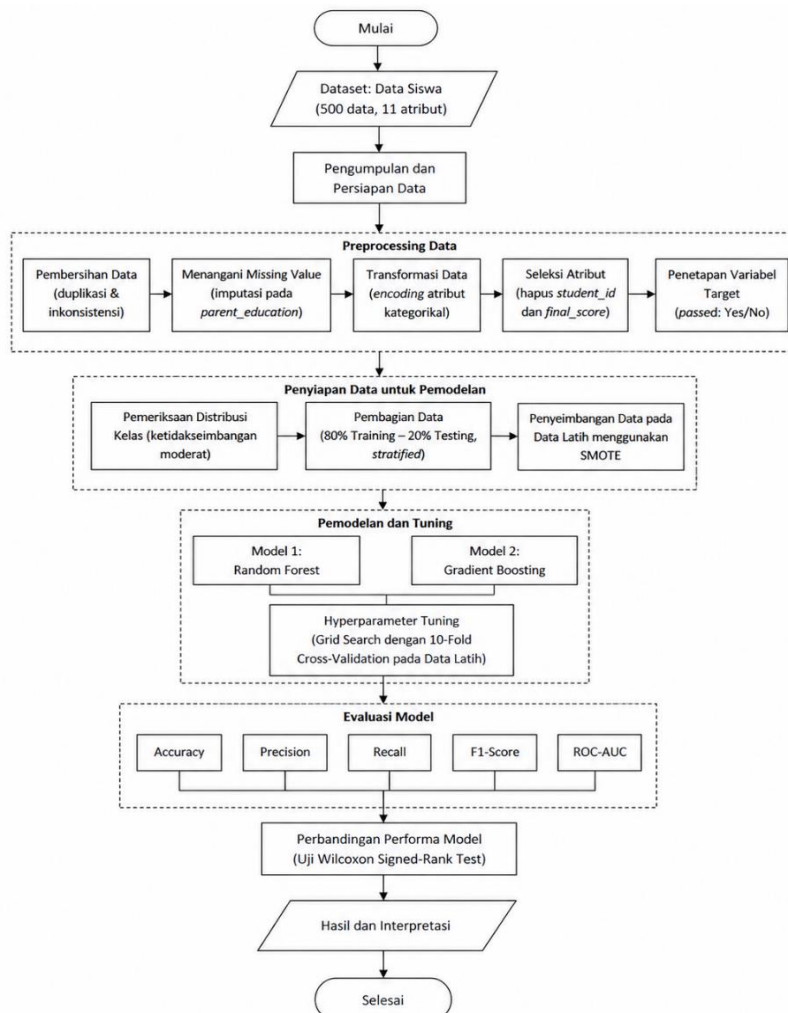
Selain itu, evaluasi juga menggunakan *ROC-AUC* untuk menilai kemampuan model dalam membedakan dua kelas secara keseluruhan pada berbagai nilai ambang klasifikasi. Penggunaan *confusion matrix* dan metrik turunannya telah banyak diterapkan dalam penelitian *educational data mining* karena dinilai efektif untuk mengevaluasi performa model klasifikasi pada data akademik. Seluruh proses pra-proses, pemodelan, validasi, dan evaluasi dilakukan menggunakan bahasa pemrograman Python dengan pustaka *pandas*, *scikit-learn*, dan *imbalanced-learn*.

2.8 Teknik Analisis Hasil

Analisis hasil dilakukan dengan membandingkan performa akhir kedua model berdasarkan nilai *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC* yang diperoleh. Model dengan performa terbaik ditentukan berdasarkan kombinasi nilai metrik tersebut agar evaluasi tidak hanya bertumpu pada satu ukuran, tetapi mampu memberikan gambaran yang lebih menyeluruh terhadap kemampuan masing-masing model. Selain membandingkan nilai rata-rata metrik evaluasi, perbedaan performa kedua model juga diuji menggunakan Wilcoxon signed-rank test terhadap skor evaluasi hasil *cross validation* untuk mengetahui apakah perbedaan performa tersebut signifikan secara statistik. Penggunaan Wilcoxon signed-rank test dipilih karena mampu membandingkan dua kelompok hasil evaluasi yang berpasangan tanpa mengharuskan data berdistribusi normal. Uji ini banyak digunakan pada penelitian komparasi machine learning untuk mengevaluasi signifikansi perbedaan performa antar model berdasarkan hasil *cross validation*. Dengan demikian, kesimpulan penelitian tidak hanya didasarkan pada selisih nilai rata-rata, tetapi juga didukung oleh pengujian signifikansi yang memberikan dasar analisis yang lebih kuat.

2.9 Alur Penelitian

Untuk memberikan gambaran mengenai tahapan yang dilakukan dalam penelitian ini, disusun sebuah alur penelitian yang mencakup seluruh proses mulai dari pengumpulan data hingga evaluasi model. Alur penelitian ini dirancang untuk memastikan bahwa setiap tahapan dilakukan secara sistematis dan terstruktur sehingga hasil yang diperoleh dapat dipertanggungjawabkan secara ilmiah. Tahapan penelitian yang digunakan ditunjukkan pada Gambar 1.



Gambar 1. Alur Penelitian

Berdasarkan Gambar 1, penelitian ini dilaksanakan melalui beberapa tahapan yang saling berurutan, dimulai dari pengumpulan data hasil belajar siswa, kemudian dilanjutkan dengan proses pembersihan dan *preprocessing* data. Setelah itu dilakukan pembentukan label hasil belajar sesuai kategori yang telah ditetapkan, diikuti dengan pembagian dataset ke dalam data latih dan data uji. Tahap berikutnya meliputi pelatihan model menggunakan algoritma Random Forest dan Gradient Boosting, yang kemudian dilanjutkan dengan proses *hyperparameter tuning* dan *cross validation* untuk memperoleh konfigurasi model yang optimal. Selanjutnya, performa kedua model dievaluasi menggunakan *confusion matrix* dan berbagai metrik klasifikasi sebelum dilakukan analisis perbandingan untuk menentukan model dengan performa terbaik.

Berdasarkan tahapan tersebut, penelitian ini diharapkan dapat menghasilkan perbandingan yang objektif antara Random Forest dan Gradient Boosting dalam prediksi hasil belajar siswa. Pendekatan yang digunakan tidak hanya menekankan pada tingkat akurasi model, tetapi juga mempertimbangkan kestabilan evaluasi melalui *cross validation* serta kesesuaian metrik klasifikasi dengan karakteristik data pendidikan. Dengan demikian, hasil penelitian ini diharapkan dapat memberikan rekomendasi mengenai model prediksi yang lebih tepat untuk mendukung pengambilan keputusan akademik berbasis data.

3. HASIL DAN PEMBAHASAN

3.1 Deskripsi data dan hasil praproses

Dataset yang digunakan dalam penelitian ini terdiri atas 500 data siswa dengan 11 atribut, yaitu *student_id*, *gender*, *age*, *study_hours_per_week*, *attendance_rate*, *parent_education*, *internet_access*, *extracurricular*, *previous_score*, *final_score*, dan *passed*. Setelah atribut identitas (*student_id*) dan atribut yang berpotensi menimbulkan *data leakage* (*final_score*) dikeluarkan dari proses pemodelan, variabel target yang digunakan adalah *passed* dengan dua kelas, yaitu Yes dan No. Distribusi kelas menunjukkan bahwa terdapat 323 siswa (64,6%) pada kelas Yes dan 177 siswa (35,4%) pada kelas No, sehingga data memiliki ketidakseimbangan kelas pada tingkat sedang. Pada tahap praproses juga ditemukan 117 nilai hilang pada atribut *parent_education*, yang kemudian ditangani melalui imputasi menggunakan nilai modus. Seluruh atribut kategorikal selanjutnya ditransformasikan ke bentuk numerik agar dapat diproses oleh algoritma *machine learning*.

3.2 Hasil pengujian model pada data uji


Setelah tahap praproses selesai, dataset dibagi menjadi data latih dan data uji dengan proporsi 80:20, sehingga diperoleh 400 data latih dan 100 data uji. Pengujian dilakukan terhadap dua model, yaitu Random Forest dan Gradient Boosting. Untuk mengevaluasi kemampuan kedua algoritma dalam memprediksi hasil belajar siswa, dilakukan pengujian menggunakan data uji yang belum pernah digunakan pada proses pelatihan model. Evaluasi dilakukan berdasarkan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC*. Hasil perbandingan performa Random Forest dan Gradient Boosting pada data uji disajikan pada Tabel 1.

Tabel 1. Perbandingan Performa Model pada Data Uji

<i>Model</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>ROC-AUC</i>
<i>Random Forest</i>	0,8700	0,9063	0,8923	0,8992	0,9327
<i>Gradient Boosting</i>	0,8600	0,9048	0,8769	0,8906	0,9310

Berdasarkan Tabel 1, Random Forest menunjukkan performa yang sedikit lebih baik dibandingkan Gradient Boosting pada sebagian besar metrik evaluasi. Random Forest memperoleh *accuracy* 87,00%, *precision* 90,63%, *recall* 89,23%, *F1-score* 89,92%, dan *ROC-AUC* 93,27%. Sementara itu, Gradient Boosting memperoleh *accuracy* 86,00%, *precision* 90,48%, *recall* 87,69%, *F1-score* 89,06%, dan *ROC-AUC* 93,10%. Temuan bahwa Random Forest memberikan performa yang kompetitif juga sejalan dengan penelitian lain yang menunjukkan bahwa algoritma ini mampu menghasilkan akurasi tinggi dan tetap interpretatif melalui identifikasi fitur-fitur yang paling berpengaruh terhadap hasil klasifikasi [21]. Secara keseluruhan, hasil pada Tabel 1 menunjukkan bahwa kedua model memiliki performa yang sangat kompetitif. Meskipun selisih nilai antar metrik relatif kecil, Random Forest tetap menunjukkan keunggulan yang lebih konsisten dibandingkan Gradient Boosting pada dataset yang digunakan.

Selain menggunakan metrik evaluasi numerik, kemampuan model dalam membedakan kelas positif dan negatif juga dianalisis menggunakan kurva Receiver Operating Characteristic (ROC). Kurva ROC memberikan gambaran mengenai keseimbangan antara True Positive Rate dan False Positive Rate pada berbagai nilai ambang klasifikasi. Visualisasi kurva ROC kedua model ditunjukkan pada Gambar 2.



Gambar 2. Kurva ROC model Random Forest dan Gradient Boosting

Selain ditunjukkan melalui metrik evaluasi pada Tabel 1, kemampuan klasifikasi kedua model juga dapat diamati melalui kurva ROC pada Gambar 2. Kurva tersebut memperlihatkan bahwa Random Forest dan Gradient Boosting sama-sama memiliki kemampuan diskriminasi yang baik dalam membedakan dua kelas target. Namun, Random Forest tetap menunjukkan performa yang sedikit lebih baik, dengan nilai *ROC-AUC* 0,9327 dibandingkan 0,9310 pada Gradient Boosting. Perbedaan ini menunjukkan bahwa kemampuan diskriminatif kedua model relatif sangat dekat, meskipun Random Forest masih unggul tipis.

3.3 Hasil confusion matrix

Untuk memperoleh gambaran yang lebih rinci mengenai hasil klasifikasi masing-masing model, dilakukan analisis menggunakan confusion matrix. Confusion matrix menunjukkan jumlah prediksi yang benar maupun salah pada setiap kelas target. Hasil confusion matrix untuk Random Forest dan Gradient Boosting disajikan pada Tabel 2 dan Tabel 3.


Tabel 2. Confusion Matrix Random Forest

Aktual / Prediksi	No	Yes
No	29	6
Yes	7	58

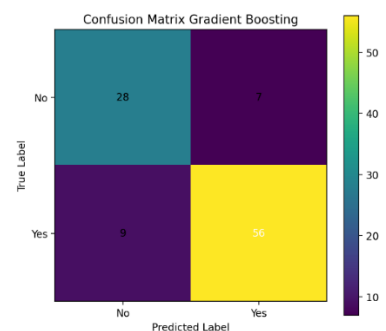
Tabel 3. Confusion Matrix Gradient Boosting

Aktual / Prediksi	No	Yes
No	29	6
Yes	8	57

Hasil *confusion matrix* menunjukkan bahwa kedua model memiliki pola klasifikasi yang hampir serupa. Namun, Random Forest sedikit lebih unggul karena mampu mengklasifikasikan satu data positif lebih banyak secara benar dibandingkan Gradient Boosting. Perbedaan ini berkontribusi pada nilai *recall* dan *F1-score* yang sedikit lebih tinggi pada Random Forest. Selain disajikan dalam bentuk tabel, hasil *confusion matrix* juga divisualisasikan menggunakan heatmap untuk memudahkan interpretasi distribusi prediksi pada masing-masing kelas. Visualisasi confusion matrix untuk model Random Forest dan Gradient Boosting ditampilkan pada Gambar 3 dan Gambar 4.



Gambar 3. Confusion matrix model Random Forest



Gambar 4. Confusion matrix model Gradient Boosting

Distribusi hasil prediksi kedua model juga divisualisasikan dalam bentuk *heatmap confusion matrix* pada Gambar 3 dan Gambar 4. Pada Gambar 3, Random Forest menunjukkan jumlah prediksi benar yang sedikit lebih tinggi pada kelas positif dibandingkan Gradient Boosting. Sementara itu, Gambar 4 memperlihatkan bahwa Gradient Boosting memiliki pola klasifikasi yang hampir sama, tetapi menghasilkan satu kesalahan tambahan pada kelas positif. Visualisasi ini memperkuat hasil pada Tabel 2 dan Tabel 3 bahwa perbedaan performa kedua model relatif kecil, meskipun Random Forest tetap menunjukkan hasil yang sedikit lebih baik.

3.4 Hasil validasi silang

Evaluasi pada data uji memberikan gambaran performa model pada satu kali pembagian data. Untuk memperoleh hasil yang lebih stabil dan mengurangi potensi bias akibat pembagian data tertentu, dilakukan evaluasi tambahan menggunakan metode 10-fold cross validation. Rata-rata hasil validasi silang untuk kedua model disajikan pada Tabel 4.

Tabel 4. Rata-rata Hasil 10-Fold Cross Validation

<i>Model</i>	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>ROC-AUC</i>
<i>Random Forest</i>	0,8320	0,8643	0,8787	0,8699	0,9105
<i>Gradient Boosting</i>	0,8300	0,8681	0,8727	0,8686	0,9071

Berdasarkan hasil validasi silang, Random Forest tetap menunjukkan performa sedikit lebih baik pada accuracy, recall, F1-score, dan ROC-AUC, sedangkan Gradient Boosting sedikit lebih tinggi pada precision. Meskipun demikian, selisih performa antara kedua model relatif kecil. Berdasarkan hasil pada Tabel 4, kedua model menunjukkan performa yang relatif konsisten selama proses validasi silang. Hal ini menunjukkan bahwa model yang dibangun memiliki kemampuan generalisasi yang baik dan tidak hanya bekerja optimal pada data uji tertentu.

3.5 Hasil Analisis Fitur

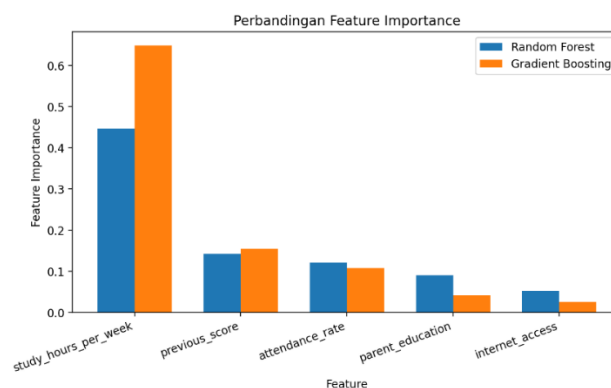
Analisis *feature importance* menunjukkan bahwa atribut yang paling berpengaruh pada kedua model adalah *study_hours_per_week*, *previous_score*, dan *attendance_rate*. Seperti disajikan pada Tabel 5 dan Gambar 5, *study_hours_per_week* menjadi fitur paling dominan baik pada Random Forest maupun Gradient Boosting, diikuti oleh *previous_score* dan *attendance_rate*. Pada Random Forest, nilai *feature importance* ketiga atribut tersebut masing-masing sebesar 0,4470, 0,1434, dan 0,1218, sedangkan pada Gradient Boosting sebesar 0,6491, 0,1544, dan 0,1076. Temuan ini menunjukkan bahwa intensitas belajar, performa akademik sebelumnya, dan tingkat kehadiran merupakan faktor utama yang memengaruhi ketuntasan hasil belajar siswa. Identifikasi fitur penting seperti ini juga bernilai praktis karena dapat digunakan sebagai dasar dalam merancang intervensi yang lebih spesifik dan berbasis data untuk meningkatkan capaian belajar [10] [2].

Selain mengevaluasi performa prediksi, penelitian ini juga menganalisis tingkat kontribusi masing-masing atribut terhadap hasil klasifikasi menggunakan *feature importance*. Analisis ini bertujuan untuk mengidentifikasi faktor-faktor yang paling berpengaruh terhadap ketuntasan hasil belajar siswa. Nilai *feature importance* tiga atribut utama dari masing-masing model disajikan pada Tabel 5.

Tabel 5. Nilai Feature Importance Tiga Fitur Paling Berpengaruh

Peringkat	Fitur	Random Forest	Gradient Boosting
1	<i>study_hours_per_week</i>	0,4470	0,6491
2	<i>previous_score</i>	0,1434	0,1544
3	<i>attendance_rate</i>	0,1218	0,1076

Untuk memberikan gambaran visual mengenai tingkat kontribusi masing-masing atribut, nilai *feature importance* dari Random Forest dan Gradient Boosting divisualisasikan dalam bentuk diagram batang. Perbandingan *feature importance* kedua model ditunjukkan pada Gambar 5.



Gambar 5. Perbandingan *feature importance* pada model Random Forest dan Gradient Boosting

3.6 Pembahasan

Hasil penelitian menunjukkan bahwa Random Forest dan Gradient Boosting sama-sama mampu memberikan performa yang baik dalam prediksi hasil belajar siswa. Nilai *accuracy* kedua model berada di atas 85% pada data uji, yang menunjukkan bahwa pendekatan *ensemble* memadai untuk menangani permasalahan klasifikasi pada data pendidikan. Temuan ini sejalan dengan penelitian terdahulu yang menunjukkan bahwa model *ensemble* efektif digunakan pada data akademik karena mampu menangkap hubungan yang kompleks antarfaktor yang memengaruhi hasil belajar. Namun demikian, penelitian lain juga menunjukkan bahwa penggunaan Random Forest pada data akademik tidak selalu menghasilkan performa yang optimal, sehingga optimasi fitur maupun eksplorasi algoritma alternatif tetap diperlukan [3].

Secara umum, Random Forest menunjukkan performa yang sedikit lebih unggul dibandingkan Gradient Boosting. Keunggulan ini terlihat secara konsisten pada *accuracy*, *recall*, *F1-score*, dan *ROC-AUC*, baik pada data uji maupun hasil validasi silang. Temuan ini memperkuat hasil penelitian sebelumnya yang menunjukkan bahwa algoritma *ensemble*, khususnya Random Forest, dapat memberikan performa prediksi yang kuat pada data pendidikan [4]. Dari sisi metodologis, hasil tersebut dapat dipahami karena Random Forest bekerja melalui mekanisme *bagging* yang cenderung lebih stabil terhadap variasi data dan lebih tahan terhadap *overfitting*, terutama pada dataset dengan jumlah atribut yang tidak terlalu besar namun memuat kombinasi fitur numerik dan kategorikal.

Di sisi lain, Gradient Boosting juga menunjukkan performa yang kompetitif. Nilai *precision* yang diperoleh bahkan sangat dekat dengan Random Forest, baik pada data uji maupun validasi silang. Hal ini menunjukkan bahwa Gradient Boosting tetap efektif dalam mempelajari pola data hasil belajar siswa, terutama karena pendekatan *boosting* secara iteratif berfokus pada perbaikan kesalahan model sebelumnya. Dengan demikian, meskipun Random Forest unggul tipis, Gradient Boosting tetap dapat dipandang sebagai alternatif yang layak.

Perbedaan performa kedua model secara statistik juga tidak menunjukkan perbedaan yang signifikan. Uji Wilcoxon *signed-rank test* terhadap skor *F1* hasil validasi silang menghasilkan *p-value* = 0,8203, sehingga perbedaan antara Random Forest dan Gradient Boosting tidak signifikan pada taraf 5%. Temuan ini menunjukkan bahwa keunggulan Random Forest lebih tepat dipahami sebagai keunggulan praktis, bukan sebagai perbedaan yang sangat kuat secara statistik. Dengan kata lain, kedua algoritma pada dasarnya sama-sama layak digunakan untuk prediksi hasil belajar siswa, dan pemilihan model akhir dapat mempertimbangkan kebutuhan praktis seperti stabilitas performa, kemudahan interpretasi, dan efisiensi komputasi.

Temuan lain yang penting adalah dominasi fitur *study hours per week*, *previous score*, dan *attendance rate* pada kedua model. Secara substantif, hasil ini menunjukkan bahwa ketuntasan hasil belajar sangat dipengaruhi oleh intensitas belajar, capaian akademik sebelumnya, dan keterlibatan siswa dalam proses pembelajaran yang tercermin melalui kehadiran. Dari sudut pandang pendidikan, hasil ini dapat menjadi dasar bagi sekolah untuk memfokuskan intervensi pada siswa dengan jam belajar rendah, nilai akademik sebelumnya yang menurun, dan tingkat kehadiran yang kurang baik. Dengan demikian, model prediksi tidak hanya berfungsi sebagai alat klasifikasi, tetapi juga sebagai dasar untuk mengidentifikasi faktor-faktor penting dalam pengambilan keputusan akademik.

Penelitian ini memiliki beberapa keterbatasan. Dataset yang digunakan masih memiliki jumlah atribut yang terbatas dan belum sepenuhnya merepresentasikan kondisi pembelajaran yang lebih beragam. Selain itu, perbandingan hanya dilakukan pada dua algoritma *ensemble* tanpa melibatkan model lain seperti XGBoost, LightGBM, atau SVM. Oleh karena itu, hasil penelitian ini perlu dipahami dalam konteks dataset yang digunakan. Di sisi lain, kajian sistematis terbaru menunjukkan bahwa model *machine learning* pada umumnya lebih unggul dibandingkan pendekatan statistik tradisional dalam menangani data pendidikan yang kompleks dan nonlinier, meskipun tetap terdapat tantangan terkait interpretabilitas, bias data, dan generalisasi model [22].

4. KESIMPULAN

Penelitian ini menunjukkan bahwa Random Forest dan Gradient Boosting sama-sama memiliki kemampuan yang baik dalam prediksi hasil belajar siswa. Berdasarkan hasil evaluasi, Random Forest memberikan performa yang sedikit lebih unggul pada sebagian besar metrik, terutama *accuracy*, *recall*, *F1-score*, dan *ROC-AUC*. Namun, uji statistik menunjukkan bahwa perbedaan performa kedua model tidak signifikan secara statistik, sehingga keduanya tetap layak digunakan pada konteks data yang serupa. Penelitian ini juga mengidentifikasi bahwa *study hours per week*, *previous score*, dan *attendance rate* merupakan fitur yang paling berpengaruh terhadap prediksi ketuntasan belajar. Dengan demikian, Random Forest dapat dipertimbangkan sebagai model yang lebih sesuai pada dataset yang digunakan, sementara Gradient Boosting tetap menjadi alternatif yang kompetitif. Penelitian selanjutnya disarankan menggunakan dataset yang lebih besar, fitur yang lebih beragam, serta melibatkan algoritma pembandingan lain agar diperoleh hasil yang lebih kuat dan lebih general.

REFERENCES

- [1] C. Algorithm and N. F. Rahmadani, "Prediction of Burnout Syndrome Risk in University Students Using the," vol. 13, no. 2, pp. 526–536, 2026, doi: 10.30865/jurikom.v13i2.9550.
- [2] J. S. Tarigan, "Integration of ARIMA Models and Machine Learning for Academic Data Forecasting : A Case Study

- in Applied Mathematics Corresponding Author :,” vol. 9, no. 1, pp. 297–304, 2025, doi: 10.30829/zero.v9i1.24148.
- [3] M. A. M. Setiawan, K. Kusriani, and A. D. Hartono, “Menggunakan Metode Machine Learning Untuk Memprediksi Nilai Mahasiswa Dengan Model Prediksi Multiclass,” *J. Inform. J. Pengemb. IT*, vol. 10, no. 1, pp. 190–204, 2025, doi: 10.30591/jpit.v10i1.8334.
- [4] H. Sutanto and A. Puji, “Implementation of the Ensemble Machine Learning Algorithm for Student Dropout Prediction Analysis,” vol. 02, pp. 159–166, 2025, doi: 10.14710/vol15iss2pp159-166.
- [5] F. Nugraha, W. Widowati, and A. Sugiharto, “Machine Learning Methods for Academic Achievement Prediction : A Bibliometric Review,” vol. 02, pp. 221–226, 2025.
- [6] G. Akçap, M. N. Hasnine, R. Majumdar, B. Flanagan, and H. Ogata, “Developing an early-warning system for spotting at-risk students by using eBook interaction logs,” vol. 4, 2019.
- [7] Y. Zhang, Y. Yun, R. An, J. Cui, H. Dai, and X. Shang, “Educational Data Mining Techniques for Student Performance Prediction : Method Review and Comparison Analysis,” vol. 12, no. December, pp. 1–19, 2021, doi: 10.3389/fpsyg.2021.698490.
- [8] S. Apandi, “Pemodelan Klasifikasi Siswa Berprestasi dengan Random Forest: Studi Kasus pada Bimbingan Belajar,” vol. 18, no. 1, pp. 1979–276, 2025.
- [9] M. H. bin Roslan and C. J. Chen, “Educational Data Mining for Student Performance Prediction: A Systematic Literature Review (2015-2021),” *Int. J. Emerg. Technol. Learn.*, vol. 17, no. 5, pp. 147–179, 2022, doi: 10.3991/ijet.v17i05.27685.
- [10] A. I. Pramesti, U. S. Dharma, C. E. Murwaningtyas, and U. S. Dharma, “Classification of Numeracy Achievement of Junior High School Educational Units Based on National Assessment Data using Random Forest,” vol. 9, no. 2, pp. 490–500, 2025, doi: 10.30829/zero.v9i2.26156.
- [11] R. A. Putri and N. S. Fatonah, “Perbandingan Metode Klasifikasi serta Analisis Faktor Akademis Pola Kelulusan Mahasiswa di Perguruan Tinggi,” *J. Inform. J. Pengemb. IT*, vol. 7, no. 2, pp. 109–117, 2022, doi: 10.30591/jpit.v7i2.3082.
- [12] M. Rahma, M. Fikry, and Y. Afrillia, “Prediksi Kesehatan Mental Remaja Berdasarkan Faktor Lingkungan Sekolah Menggunakan Machine Learning,” *J. Inform. J. Pengemb. IT*, vol. 10, no. 2, pp. 382–390, 2025, doi: 10.30591/jpit.v10i2.8556.
- [13] M. N. Hibatulloh, G. D. Prakoso, A. D. Putri Yunus, and T. D. Putra, “Prediksi Harga Rumah di Bandung 2024 Menggunakan Ensemble Learning: Analisis Komparatif dan Interpretabilitas,” *J. Inform. J. Pengemb. IT*, vol. 10, no. 2, pp. 484–493, 2025, doi: 10.30591/jpit.v10i2.8200.
- [14] G. Erutjahjo and A. Supriyanto, “Prediksi Tinggi Gelombang Laut di Perairan Semarang – Demak dengan Menggunakan Random Forest dan XGBoost,” *J. Inform. J. Pengemb. IT*, vol. 10, no. 4, pp. 869–881, 2025, doi: 10.30591/jpit.v10i4.9315.
- [15] 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.
- [16] M. Reza, S. Miri, and R. Javidan, “Random Forests,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 7, no. 6, pp. 1–33, 2021.
- [17] L. Chen, “Using Decision Trees and Random Forest Algorithms to Predict and Determine Factors Contributing to First-Year University Students’ Learning Performance,” 2021.
- [18] B. J. H. Friedman, “1999 REITZ LECTURE,” vol. 29, no. 5, pp. 1189–1232, 2001.
- [19] K. Jawad, M. A. Shah, and M. Tahir, “Students’ Academic Performance and Engagement Prediction in a Virtual Learning Environment Using Random Forest with Data Balancing,” 2022.
- [20] A. P. B. Pratama and Wahyu Aji Eko Prabowo, “No Title,” *J. Ris. Komput.*, vol. 13, no. 2, 2026, [Online]. Available: <https://ejurnal.stmik-budidarma.ac.id/index.php/jurikom/article/view/9670>
- [21] I. K. Nisa *et al.*, “Analisis Prediksi Resiko Perceraian Menggunakan Algoritma Random Forest dengan Optimasi Hyperparameter Random Search,” vol. 13, no. 2, pp. 474–483, 2026, doi: 10.30865/jurikom.v13i2.9529.
- [22] A. Almalawi, B. Soh, A. Li, and H. Samra, “Predictive Models for Educational Purposes : A Systematic Review,” pp. 1–42, 2024.