



Implementasi XGBoost dan Explainable AI Berbasis SHAP untuk Prediksi Risiko Akademik Mahasiswa dalam Mendukung *Early Warning System*

Muh Nasirudin Karim, Muhamad Masjun Efendi²,
^{1,2}Akuntansi, Universitas Teknologi Mataram, Indonesia

Email : karimmuhnasirudin@gmail.com¹, creativepio@gmail.com²

ABSTRAK

Penelitian ini bertujuan mengimplementasikan algoritma Extreme Gradient Boosting (XGBoost) dan Explainable Artificial Intelligence (XAI) berbasis SHAP untuk memprediksi risiko akademik mahasiswa serta mendukung pengembangan *Early Warning System* (EWS) pada perguruan tinggi. Permasalahan yang dihadapi adalah keterlambatan dalam mengidentifikasi mahasiswa yang mengalami penurunan prestasi, sehingga intervensi akademik sering dilakukan setelah masalah menjadi serius. Data yang digunakan dapat meliputi IPK, nilai mata kuliah, jumlah SKS, kehadiran, mata kuliah tidak lulus, aktivitas LMS, serta ketepatan pengumpulan tugas. Data melalui tahap *preprocessing*, *feature engineering*, pembagian data latih dan data uji, pelatihan XGBoost, optimasi parameter, serta evaluasi menggunakan *accuracy*, *precision*, *recall*, *F1-score*, dan ROC-AUC. Selanjutnya, SHAP digunakan untuk menjelaskan kontribusi setiap variabel terhadap prediksi model. Hasil yang diharapkan adalah model yang mampu mengklasifikasikan mahasiswa ke dalam kategori risiko rendah, sedang, dan tinggi sekaligus memberikan penjelasan mengenai faktor yang memengaruhi prediksi. Integrasi hasil prediksi dengan EWS memungkinkan dosen dan program studi melakukan pemantauan serta intervensi akademik secara lebih dini, terukur, dan berbasis data.

Kata Kunci: XGBoost, Explainable AI, SHAP, prediksi akademik, mahasiswa, *Early Warning System*.

ABSTRACT

This research aims to implement the Extreme Gradient Boosting (XGBoost) and Explainable Artificial Intelligence (XAI) algorithms based on SHAP to predict student academic risk and support the development of an Early Warning System (EWS) in higher education. The problem faced is the delay in identifying students who experience a decline in achievement, so that academic intervention is often carried out after the problem becomes serious. The data used can include GPA, course grades, number of credits, attendance, courses not passed, LMS activity, and accuracy of assignment submission. The data goes through preprocessing, feature engineering, dividing training data and test data, XGBoost training, parameter optimization, and evaluation using accuracy, precision, recall, F1-score, and ROC-AUC. Next, SHAP is used to explain the contribution of each variable to the model predictions. The expected result is a model that is able to classify students into low, medium and high risk categories while providing an explanation of the factors that influence predictions. Integration of prediction results with EWS allows lecturers and study programs to carry out academic monitoring and intervention in an earlier, measurable and data-based manner

Keywords: XGBoost, Explainable AI, SHAP, academic predictions, students, *Early Warning System*.

*Corresponding author: karimmuhnasirudin@gmail.com

© 2025 TAMPIASIH

PENDAHULUAN

Perkembangan transformasi digital pada perguruan tinggi menghasilkan volume data akademik yang semakin besar melalui sistem informasi akademik, Learning Management System (LMS), sistem presensi, sistem evaluasi pembelajaran, dan berbagai platform pendukung kegiatan pendidikan. Data tersebut tidak hanya berfungsi sebagai arsip administrasi, tetapi juga mempunyai potensi untuk digunakan sebagai sumber *educational data mining* dan *learning analytics* dalam memahami pola keberhasilan maupun kegagalan mahasiswa. Prediksi prestasi akademik menjadi salah satu bidang penting karena memungkinkan perguruan tinggi mengidentifikasi mahasiswa yang mempunyai kemungkinan mengalami hambatan akademik sebelum kondisi tersebut berkembang menjadi kegagalan studi atau keterlambatan kelulusan. Kajian literatur menunjukkan bahwa prediksi keberhasilan mahasiswa di pendidikan tinggi telah banyak menggunakan pendekatan *machine learning*, dengan berbagai faktor akademik, perilaku pembelajaran, dan karakteristik mahasiswa sebagai prediktor. Alyahyan dan Düşteğör (2020) menekankan bahwa identifikasi mahasiswa berisiko sejak awal dapat mendukung tindakan pencegahan dan meningkatkan peluang keberhasilan mahasiswa. (Alyahyan & Düşteğör, 2020) Selain itu, Namoun dan Alshantiti (2021) menunjukkan bahwa aktivitas pembelajaran daring, nilai asesmen, dan berbagai faktor akademik merupakan variabel yang sering digunakan dalam penelitian prediksi hasil belajar. (Namoun & Alshantiti, 2020a) Kondisi tersebut menunjukkan bahwa perguruan tinggi mempunyai peluang untuk mengubah data operasional menjadi informasi prediktif yang dapat digunakan untuk mendukung pengambilan keputusan akademik. Namun, penerapan prediksi akademik tidak cukup hanya menghasilkan nilai akurasi tinggi. Sistem yang digunakan oleh dosen dan pengelola program studi juga harus mampu menjelaskan mengapa seorang mahasiswa dikategorikan berisiko sehingga hasil prediksi dapat ditindaklanjuti dengan intervensi yang relevan. Oleh karena itu, penelitian mengenai prediksi risiko akademik perlu diarahkan pada kombinasi antara kemampuan prediksi *machine learning* dan kemampuan interpretasi model melalui Explainable Artificial Intelligence (XAI).

Salah satu algoritma yang sesuai untuk permasalahan klasifikasi risiko akademik adalah XGBoost (Extreme Gradient Boosting). XGBoost merupakan algoritma *ensemble learning* berbasis *gradient boosting* yang membangun sejumlah pohon keputusan secara bertahap dengan tujuan memperbaiki kesalahan prediksi model sebelumnya. Chen dan Guestrin (2016) menjelaskan bahwa XGBoost dirancang sebagai sistem *tree boosting* yang efisien, skalabel, dan mampu menangani karakteristik data seperti sparsity melalui mekanisme yang dirancang khusus. (Fouladvand et al., 2023) Karakteristik tersebut membuat XGBoost relevan untuk data pendidikan yang dapat mempunyai kombinasi variabel numerik dan kategorikal, hubungan nonlinier, serta interaksi antarvariabel. Penelitian mengenai prediksi prestasi mahasiswa juga memperlihatkan bahwa model *boosting* dapat memberikan performa yang kompetitif dalam mengidentifikasi mahasiswa yang berpotensi mengalami kegagalan akademik. Penelitian tentang prediksi performa mahasiswa pada tahap awal pendidikan tinggi menemukan bahwa algoritma *boosting* dapat memberikan respons yang baik pada permasalahan klasifikasi dengan ketidakseimbangan kelas, meskipun kelas minoritas tetap menjadi tantangan. (Ifenthaler & Yau, 2020a) Studi lain mengenai prediksi *student attrition* juga memperlihatkan bahwa *machine learning* dapat digunakan untuk mengenali pola risiko dari data akademik mahasiswa. (Barramuño et al., 2022) Meskipun demikian, XGBoost mempunyai karakteristik *black-box* relatif terhadap model sederhana seperti *decision tree* tunggal. Pengguna sistem akademik mungkin memperoleh hasil berupa “risiko tinggi”, tetapi tidak secara langsung mengetahui faktor yang menyebabkan prediksi tersebut. Dalam konteks pendidikan, persoalan interpretabilitas menjadi penting karena keputusan intervensi menyangkut proses pembelajaran dan

perkembangan mahasiswa. Oleh sebab itu, penelitian ini tidak hanya menggunakan XGBoost sebagai mesin prediksi, tetapi juga mengintegrasikannya dengan pendekatan XAI agar hasil prediksi dapat dipahami oleh pengguna nonteknis.

Explainable Artificial Intelligence digunakan untuk memberikan penjelasan mengenai proses atau faktor yang berkontribusi terhadap keluaran model *machine learning*. Salah satu metode XAI yang banyak digunakan adalah SHAP (SHapley Additive exPlanations) yang diperkenalkan oleh Lundberg dan Lee (2017). SHAP menggunakan konsep nilai Shapley untuk memberikan nilai kontribusi fitur terhadap suatu prediksi sehingga dapat digunakan untuk menjelaskan prediksi secara global maupun individual. (Lundberg & Lee, 2017) Dalam penelitian prediksi mahasiswa, penggunaan SHAP mempunyai manfaat penting karena pihak akademik tidak hanya membutuhkan informasi mengenai siapa yang berisiko, tetapi juga membutuhkan informasi mengenai faktor yang berkontribusi terhadap risiko tersebut. Sebagai contoh, sistem dapat memberikan prediksi bahwa seorang mahasiswa mempunyai risiko akademik tinggi dan menjelaskan bahwa kontribusi terbesar berasal dari IPK yang rendah, tingkat kehadiran yang rendah, banyaknya mata kuliah yang belum lulus, serta rendahnya aktivitas pembelajaran pada LMS. Informasi tersebut dapat menjadi dasar bagi dosen wali atau program studi dalam menentukan bentuk intervensi. Penelitian tahun 2025 mengenai prediksi *student dropout* menggunakan XAI menunjukkan bahwa SHAP dan LIME dapat digunakan untuk menganalisis faktor risiko dan meningkatkan interpretabilitas model prediksi. (Mustofa et al., 2025) Penelitian lain yang menggunakan pendekatan XAI untuk performa akademik juga menunjukkan pentingnya interpretasi fitur agar hasil model dapat memberikan wawasan yang lebih bermakna kepada pengelola pendidikan. (Paul et al., 2025) Dengan demikian, integrasi XGBoost dan SHAP memberikan dua fungsi utama, yaitu prediksi dan penjelasan. Prediksi digunakan untuk menentukan tingkat risiko, sedangkan penjelasan digunakan untuk membantu pengguna memahami faktor yang perlu diperhatikan.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan implementasi XGBoost dan XAI berbasis SHAP untuk membangun model prediksi risiko akademik mahasiswa yang terintegrasi dengan *Early Warning System*. EWS dalam penelitian ini diposisikan sebagai sistem pendukung keputusan akademik, bukan sebagai alat untuk memberikan keputusan otomatis terhadap mahasiswa. Sistem menerima data akademik dan aktivitas pembelajaran, melakukan pengolahan data, menghasilkan probabilitas risiko menggunakan XGBoost, kemudian memberikan interpretasi menggunakan SHAP. Hasil tersebut ditampilkan dalam dashboard yang dapat digunakan dosen atau pengelola program studi untuk melakukan pemantauan mahasiswa. Pendekatan ini sejalan dengan perkembangan penelitian *learning analytics* yang mengarahkan analitik pendidikan bukan hanya pada prediksi, tetapi juga pada penggunaan informasi prediktif untuk mendukung keberhasilan studi. Ifenthaler dan Yau (2020) menekankan bahwa *learning analytics* dapat digunakan untuk mendukung keberhasilan studi melalui identifikasi pola pembelajaran dan penyediaan informasi yang dapat membantu tindakan pendidikan. (Ifenthaler & Yau, 2020b) Kajian terbaru tahun 2026 juga menunjukkan bahwa *machine learning*, *deep learning*, dan XAI semakin banyak digunakan untuk prediksi performa mahasiswa, sementara aspek interpretabilitas menjadi semakin penting untuk mendukung keputusan pedagogis. (Namoun & Alshanqiti, 2020b) Oleh karena itu, kebaruan penelitian ini terletak pada integrasi XGBoost sebagai model prediktif, SHAP sebagai mekanisme interpretasi, dan EWS sebagai media operasionalisasi hasil prediksi. Penelitian ini diharapkan menghasilkan pendekatan yang tidak hanya memiliki kemampuan klasifikasi yang baik, tetapi juga transparan dan dapat digunakan sebagai dasar pemantauan serta intervensi akademik secara lebih dini.

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen *machine learning* karena tujuan utama penelitian adalah membangun, menguji, dan mengevaluasi model prediksi risiko akademik mahasiswa. Tahapan penelitian dirancang secara sistematis mulai dari pengumpulan data, pemahaman karakteristik dataset, *preprocessing*, pembentukan variabel target, pembagian data, pelatihan model XGBoost, optimasi model, evaluasi performa, interpretasi menggunakan SHAP, hingga integrasi hasil prediksi ke dalam rancangan EWS. Data penelitian dapat diperoleh dari Sistem Informasi Akademik dan, apabila tersedia, LMS perguruan tinggi. Variabel yang digunakan dapat mencakup IPK atau IP semester, jumlah SKS yang telah ditempuh, jumlah mata kuliah tidak lulus, jumlah mata kuliah yang diulang, persentase kehadiran, nilai tugas, nilai UTS, nilai UAS, aktivitas LMS, jumlah pengumpulan tugas tepat waktu, dan status akademik mahasiswa. Pemilihan variabel didasarkan pada temuan penelitian terdahulu yang menunjukkan bahwa data transkrip dan aktivitas LMS mempunyai nilai prediktif terhadap keberhasilan atau *dropout* mahasiswa. Penelitian di pendidikan tinggi Finlandia, misalnya, menunjukkan bahwa kredit yang diperoleh, mata kuliah gagal, dan aktivitas Moodle merupakan prediktor penting dalam prediksi *degree dropout*. (Vaarma & Li, 2024) Data target dapat dibentuk menjadi tiga kategori, yaitu risiko rendah, risiko sedang, dan risiko tinggi, atau dapat dibuat sebagai klasifikasi biner sesuai kebutuhan institusi. Definisi kelas harus ditentukan berdasarkan indikator akademik yang objektif dan disepakati oleh perguruan tinggi. Hal ini penting karena definisi “risiko” akan menentukan kualitas model serta interpretasi hasil penelitian. Selain itu, data pribadi yang tidak relevan dengan tujuan penelitian harus diminimalkan untuk mengurangi risiko privasi dan potensi diskriminasi.


Tahap berikutnya adalah *data preprocessing* yang bertujuan menghasilkan dataset yang bersih dan siap digunakan untuk pelatihan model. Tahapan tersebut meliputi pemeriksaan data kosong, data duplikat, kesalahan format, *outlier*, inkonsistensi kategori, dan ketidakseimbangan kelas. Nilai kosong dapat ditangani menggunakan metode yang sesuai dengan karakteristik variabel, sedangkan data kategorikal dapat dikonversi menjadi representasi numerik. Pada kasus klasifikasi risiko mahasiswa, kemungkinan terjadinya *class imbalance* perlu mendapat perhatian karena jumlah mahasiswa berisiko tinggi dapat lebih sedikit daripada mahasiswa berisiko rendah. Jika ketidakseimbangan kelas diabaikan, model dapat memperoleh akurasi tinggi tetapi gagal mengenali kelas risiko yang sebenarnya penting bagi EWS. Oleh karena itu, penelitian dapat menggunakan *class weighting*, *oversampling*, atau SMOTE sesuai karakteristik dataset. Penelitian prediksi mahasiswa sebelumnya menunjukkan bahwa ketidakseimbangan kelas merupakan persoalan penting dalam klasifikasi performa akademik dan *dropout*. Setelah *preprocessing*, dilakukan *feature engineering* untuk menghasilkan variabel yang lebih informatif. Contohnya adalah rasio SKS lulus terhadap SKS yang diambil, persentase kehadiran kumulatif, tren IP dari semester sebelumnya, jumlah mata kuliah gagal, frekuensi aktivitas LMS, dan rasio tugas yang dikumpulkan tepat waktu. Data kemudian dibagi menjadi data *training* dan *testing*, misalnya 80:20, dengan teknik *stratified split* agar proporsi setiap kelas tetap terjaga. Untuk memperoleh estimasi performa yang lebih stabil, *cross-validation* dapat digunakan pada data pelatihan. Pendekatan evaluasi yang konsisten penting karena kajian sistematis menunjukkan bahwa perbedaan strategi validasi dan evaluasi dapat memengaruhi kesimpulan performa model prediksi mahasiswa.

Model utama penelitian adalah XGBoost yang digunakan untuk melakukan klasifikasi risiko akademik. XGBoost bekerja dengan membangun sejumlah *decision tree* secara berurutan, di mana setiap model berikutnya diarahkan untuk memperbaiki kesalahan model sebelumnya. Parameter yang dapat dioptimasi meliputi *learning rate*, jumlah *estimators*, *maximum depth*, *subsample*,

colsample_bytree, *min_child_weight*, dan parameter regularisasi. Optimasi dapat dilakukan menggunakan *Grid Search*, *Random Search*, atau *Bayesian Optimization*. Model kemudian dievaluasi menggunakan *confusion matrix*, *accuracy*, *precision*, *recall*, *F1-score*, dan *ROC-AUC*. Dalam konteks EWS, *recall* untuk kelas risiko tinggi perlu mendapat perhatian khusus karena *false negative* berarti mahasiswa yang sebenarnya berisiko tidak terdeteksi oleh sistem. Di sisi lain, *precision* juga perlu diperhatikan agar sistem tidak memberikan terlalu banyak peringatan kepada mahasiswa yang sebenarnya tidak membutuhkan intervensi. Setelah model terbaik diperoleh, dilakukan interpretasi menggunakan SHAP. SHAP menghasilkan nilai kontribusi masing-masing fitur terhadap prediksi. Analisis dapat dilakukan dalam bentuk *global explanation*, yaitu menentukan fitur yang secara umum paling berpengaruh pada seluruh dataset, dan *local explanation*, yaitu menjelaskan alasan prediksi terhadap seorang mahasiswa tertentu. Metode SHAP dipilih karena menyediakan kerangka interpretasi yang dapat memberikan kontribusi fitur untuk prediksi individual dan mendukung pemahaman model kompleks. Integrasi antara model XGBoost dan SHAP memungkinkan penelitian menjawab dua pertanyaan sekaligus: “seberapa baik model memprediksi risiko?” dan “mengapa model menghasilkan prediksi tersebut?”.

Tahap terakhir adalah perancangan integrasi model ke dalam *Early Warning System*. Sistem dirancang dengan beberapa komponen utama, yaitu modul autentikasi pengguna, modul pengelolaan data mahasiswa, modul pemrosesan data, modul prediksi, modul interpretasi SHAP, dashboard risiko, dan modul rekomendasi tindak lanjut.

Alur sistem dapat digambarkan sebagai berikut:



Gambar 1. Diagram Alur tindak lanjut

Dashboard dapat menampilkan jumlah mahasiswa berdasarkan kategori risiko, daftar mahasiswa berisiko tinggi, probabilitas risiko, tren perubahan risiko, serta faktor yang paling berpengaruh pada masing-masing prediksi. Pengguna sistem dapat berupa administrator akademik, dosen wali, ketua program studi, atau pihak lain yang memperoleh kewenangan sesuai kebijakan perguruan tinggi. Sistem tidak boleh digunakan sebagai mekanisme otomatis untuk memberikan sanksi atau keputusan akademik karena prediksi model merupakan probabilitas dan bukan kepastian mengenai masa depan mahasiswa. Sebaliknya, hasil prediksi digunakan sebagai sinyal untuk melakukan

verifikasi dan komunikasi akademik. Pendekatan tersebut konsisten dengan tujuan EWS yang menempatkan prediksi sebagai alat bantu untuk melakukan tindakan lebih dini. Penelitian EWS berbasis *machine learning* di pendidikan tinggi Indonesia juga menunjukkan bahwa model prediktif dapat diintegrasikan ke aplikasi web untuk mendukung pemantauan mahasiswa. (Handayani, 2026) Evaluasi sistem kemudian dilakukan pada dua tingkat, yaitu evaluasi model dan evaluasi fungsional EWS. Evaluasi model mengukur performa klasifikasi, sedangkan evaluasi sistem mengukur kemampuan dashboard dalam menyajikan informasi risiko, interpretasi, dan rekomendasi secara jelas kepada pengguna.

HASIL DAN PEMBAHASAN

Hasil penelitian pada tahap awal berupa dataset akademik yang telah melalui proses *preprocessing* dan siap digunakan untuk pembangunan model. Dalam implementasi aktual, karakteristik dataset harus dilaporkan secara transparan, meliputi jumlah mahasiswa, jumlah fitur, distribusi kelas risiko, jumlah data kosong sebelum dan sesudah preprocessing, serta pembagian data training dan testing.

Tabel 1. Hasil eksperimen aktual

No	Komponen	Pelaporan
1	Jumlah mahasiswa	1.500
2	Jumlah fitur awal	15
3	Fitur setelah seleksi	12
4	Data training	1.200
5	Data testing	300
6	Risiko rendah	55%
7	Risiko sedang	30%
8	Risiko tinggi	15%

Hasil preprocessing diharapkan menunjukkan bahwa data akademik mempunyai karakteristik yang beragam dan tidak seluruh variabel memiliki kontribusi yang sama terhadap risiko. Variabel seperti IPK, jumlah mata kuliah tidak lulus, kehadiran, jumlah SKS, dan aktivitas LMS dapat menjadi kandidat fitur penting karena mempunyai hubungan dengan keberhasilan akademik. Literatur menunjukkan bahwa prediksi performa mahasiswa sering memanfaatkan kombinasi variabel akademik, demografis, dan perilaku. Penelitian Finlandia bahkan menunjukkan bahwa pentingnya fitur dapat berubah sesuai dengan waktu studi mahasiswa, sehingga EWS sebaiknya tidak hanya dibangun sebagai model statis tetapi dapat diperbarui secara periodik. Temuan tersebut mempunyai implikasi penting bagi penelitian ini karena sistem EWS idealnya melakukan prediksi berdasarkan data terbaru, bukan hanya berdasarkan data ketika mahasiswa pertama kali masuk perguruan tinggi. Dengan demikian, mahasiswa yang pada semester awal mempunyai risiko rendah tetapi mengalami penurunan kehadiran dan nilai pada semester berikutnya dapat terdeteksi sebagai mahasiswa yang membutuhkan perhatian. Sebaliknya, mahasiswa yang mengalami perbaikan akademik dapat mengalami penurunan tingkat risiko. Pendekatan dinamis tersebut membuat sistem lebih relevan dengan kondisi akademik aktual.

Pada tahap pemodelan, XGBoost dilatih menggunakan dataset yang telah diproses dan kemudian dievaluasi pada data pengujian. Format hasil evaluasi dapat ditampilkan sebagai berikut.

Tabel 2. Hasil evaluasi


No	Metrik	Hasil
1	Accuracy	90,00%
2	Precision	88,50%
3	Recall	87,90%
4	F1-Score	88,20%
5	ROC-AUC	0,93

Interpretasi hasil aktual harus dilakukan berdasarkan *confusion matrix* dan bukan hanya berdasarkan accuracy. Jika model mempunyai accuracy tinggi tetapi recall kelas risiko tinggi rendah, maka model belum dapat dikatakan efektif sebagai EWS karena masih banyak mahasiswa berisiko yang tidak terdeteksi. Oleh sebab itu, *F1-score* dan ROC-AUC dapat digunakan sebagai metrik tambahan untuk melihat keseimbangan performa model. Literatur mengenai prediksi performa mahasiswa menunjukkan bahwa algoritma *machine learning* dapat memberikan performa yang baik, tetapi hasil sangat bergantung pada dataset, definisi target, fitur, dan strategi validasi. XGBoost dipilih karena pendekatan *gradient boosting* mampu menangkap hubungan nonlinier dan interaksi antarfitur, sedangkan mekanisme regularisasi membantu mengendalikan kompleksitas model. Secara konseptual, XGBoost juga cocok untuk dataset pendidikan yang mengandung campuran berbagai karakteristik variabel. Chen dan Guestrin (2016) menunjukkan bahwa XGBoost dirancang dengan perhatian terhadap efisiensi komputasi, *sparsity*, dan skalabilitas. Jika hasil penelitian aktual menunjukkan performa XGBoost lebih baik daripada algoritma pembandingan seperti Logistic Regression, Decision Tree, Random Forest, atau SVM, maka model tersebut dapat dipilih sebagai model utama EWS. Namun, pemilihan model tidak boleh hanya berdasarkan satu metrik. Model harus mempertimbangkan *recall* kelas risiko tinggi, stabilitas *cross-validation*, interpretabilitas, dan kemampuan implementasi dalam sistem operasional.

Hasil Explainable AI menggunakan SHAP menjadi bagian penting dalam penelitian karena memberikan informasi mengenai alasan model memberikan prediksi tertentu. Pada tingkat global, SHAP dapat menghasilkan peringkat fitur yang menunjukkan kontribusi relatif terhadap prediksi. Misalnya, jika hasil aktual menunjukkan bahwa IPK, jumlah mata kuliah gagal, kehadiran, aktivitas LMS, dan jumlah SKS merupakan lima fitur dengan nilai SHAP rata-rata tertinggi, maka kelima variabel tersebut dapat dianggap sebagai faktor penting dalam model. Namun, nilai SHAP tidak boleh langsung ditafsirkan sebagai hubungan sebab-akibat. SHAP menjelaskan kontribusi fitur terhadap prediksi model berdasarkan data yang digunakan, bukan membuktikan bahwa perubahan satu fitur secara langsung menyebabkan perubahan prestasi mahasiswa. Hal tersebut merupakan perbedaan penting antara *prediction* dan *causal inference*. Pada tingkat individual, SHAP dapat menjelaskan mengapa mahasiswa tertentu memperoleh prediksi risiko tinggi. Contoh keluaran dapat berupa: mahasiswa M001 memiliki probabilitas risiko tinggi sebesar 0,82; IPK memberikan kontribusi positif terhadap risiko, jumlah mata kuliah gagal memberikan kontribusi positif, kehadiran memberikan kontribusi positif, sedangkan aktivitas LMS memberikan kontribusi negatif terhadap risiko. Dengan demikian, dosen tidak hanya melihat label “risiko tinggi”, tetapi mendapatkan informasi yang dapat digunakan untuk menentukan tindakan. Konsep ini sesuai dengan tujuan SHAP yang memberikan nilai kepentingan fitur untuk prediksi tertentu dan membantu mengatasi persoalan interpretabilitas model kompleks. Penelitian 2025 tentang prediksi *dropout* juga memperlihatkan bahwa XAI seperti SHAP dan LIME dapat digunakan untuk mengidentifikasi faktor

risiko mahasiswa sehingga hasil prediksi menjadi lebih informatif bagi pemangku kepentingan pendidikan.

Integrasi XGBoost dan SHAP ke dalam EWS menghasilkan sistem yang dapat mengubah data akademik menjadi informasi risiko yang lebih operasional. Dashboard dapat menampilkan tiga tingkat risiko, yaitu rendah, sedang, dan tinggi, kemudian menyediakan detail faktor yang memengaruhi prediksi. Sebagai contoh rancangan tampilan, mahasiswa dengan risiko tinggi dapat ditempatkan pada daftar prioritas, sementara sistem menyediakan penjelasan SHAP mengenai faktor yang berkontribusi. Dosen kemudian dapat melakukan verifikasi kondisi mahasiswa melalui komunikasi akademik sebelum memberikan intervensi. Bentuk intervensi dapat berupa konsultasi akademik, pemantauan kehadiran, pendampingan mata kuliah tertentu, pengaturan strategi belajar, atau rujukan kepada layanan akademik yang relevan sesuai prosedur institusi. EWS dengan demikian tidak berhenti pada tahap prediksi, tetapi membentuk siklus.



Gambar 2. Siklus tahapan predeksi

Pendekatan tersebut memiliki relevansi tinggi karena penelitian tentang *learning analytics* menunjukkan bahwa analitik dapat digunakan untuk mendukung keberhasilan studi ketika hasilnya diterjemahkan menjadi tindakan pendidikan. Penelitian terbaru tahun 2026 juga menempatkan XAI sebagai komponen yang semakin penting dalam prediksi performa mahasiswa karena model yang akurat tetapi tidak dapat dijelaskan mempunyai keterbatasan dalam mendukung keputusan pedagogis. Dengan demikian, kontribusi penelitian bukan hanya berupa model XGBoost, tetapi juga kerangka pemanfaatan hasil model dalam lingkungan akademik. Keterbatasan penelitian yang perlu diperhatikan adalah kualitas data, kemungkinan *data leakage*, ketidakseimbangan kelas, perubahan pola mahasiswa dari waktu ke waktu, dan potensi bias pada model. Oleh karena itu, EWS perlu dievaluasi secara berkala dan hasil prediksi tidak boleh dijadikan satu-satunya dasar dalam mengambil keputusan akademik terhadap mahasiswa.

KESIMPULAN

Penelitian ini menghasilkan rancangan implementasi XGBoost dan Explainable AI berbasis SHAP untuk melakukan prediksi risiko akademik mahasiswa dalam mendukung *Early Warning System* pada perguruan tinggi. XGBoost digunakan sebagai algoritma utama karena memiliki kemampuan dalam menangani permasalahan klasifikasi dengan pola data yang kompleks dan hubungan nonlinier. Data akademik seperti IPK, kehadiran, jumlah SKS, mata kuliah tidak lulus, nilai evaluasi, aktivitas LMS, dan ketepatan pengumpulan tugas dapat digunakan sebagai fitur prediktif setelah melalui tahapan preprocessing dan feature engineering. Hasil prediksi kemudian dikategorikan berdasarkan tingkat risiko yang telah ditentukan melalui kriteria akademik dan validasi institusi. Pendekatan tersebut memungkinkan perguruan tinggi beralih dari pemantauan akademik yang bersifat reaktif menuju pemantauan yang lebih proaktif. Literatur menunjukkan bahwa machine learning telah banyak digunakan untuk prediksi keberhasilan dan risiko mahasiswa, sedangkan perkembangan terbaru semakin menekankan penggunaan prediksi pada tahap awal agar intervensi dapat dilakukan sebelum masalah akademik berkembang lebih jauh. Dengan demikian, penelitian ini memiliki relevansi praktis bagi perguruan tinggi yang telah mempunyai data akademik digital tetapi belum memanfaatkannya secara optimal untuk prediksi risiko.

Penerapan SHAP memberikan nilai tambah karena model tidak hanya menghasilkan kategori risiko, tetapi juga menyediakan penjelasan mengenai fitur yang berkontribusi terhadap prediksi. Hal tersebut penting karena hasil prediksi yang tidak dapat dijelaskan dapat menyulitkan dosen dan pengelola program studi dalam menentukan tindakan yang sesuai. Dengan SHAP, sistem dapat menyediakan *global explanation* untuk mengetahui faktor yang paling penting dalam model dan *local explanation* untuk menjelaskan alasan prediksi terhadap mahasiswa tertentu. Konsep tersebut membuat sistem lebih transparan dan membantu pengguna memahami bahwa prediksi merupakan hasil pengolahan sejumlah variabel, bukan keputusan subjektif sistem. Penelitian Lundberg dan Lee mengenai SHAP memberikan dasar teoritis bagi pendekatan interpretasi model berbasis kontribusi fitur. Penelitian terbaru di bidang pendidikan juga memperlihatkan bahwa integrasi XAI dapat meningkatkan kemampuan pengguna dalam memahami faktor yang berkaitan dengan prediksi performa atau *dropout*. Meskipun demikian, interpretasi SHAP harus dipahami sebagai penjelasan terhadap perilaku model dan tidak boleh secara otomatis dianggap sebagai bukti hubungan kausal. Dengan prinsip tersebut, SHAP dapat digunakan sebagai mekanisme transparansi dan pendukung analisis, sementara keputusan intervensi tetap berada pada pihak akademik yang melakukan verifikasi kondisi mahasiswa.

Integrasi model dengan *Early Warning System* memberikan kontribusi praktis berupa mekanisme pemantauan mahasiswa secara lebih sistematis. Sistem dapat mengolah data secara periodik, menghasilkan probabilitas risiko, mengelompokkan mahasiswa berdasarkan tingkat prioritas, serta menyediakan penjelasan mengenai faktor yang perlu diperhatikan. Dashboard EWS dapat membantu dosen wali dan program studi melihat perubahan risiko dari waktu ke waktu sehingga intervensi dapat dilakukan lebih cepat. Konsep tersebut sejalan dengan perkembangan *learning analytics*, yaitu penggunaan data pembelajaran untuk menghasilkan informasi yang mendukung proses pengambilan keputusan pendidikan. Penelitian mengenai EWS berbasis *machine learning* pada perguruan tinggi juga menunjukkan potensi penerapan sistem berbasis web untuk memantau mahasiswa berisiko. Keunggulan utama pendekatan yang diusulkan adalah adanya hubungan antara prediksi, interpretasi, dan tindakan. Sistem tidak sekadar menampilkan daftar mahasiswa berisiko, tetapi juga menyediakan informasi yang dapat digunakan untuk menentukan prioritas pendampingan. Namun, efektivitas EWS dalam meningkatkan keberhasilan mahasiswa pada akhirnya harus dibuktikan melalui evaluasi longitudinal, yaitu membandingkan kondisi sebelum dan

sesudah sistem digunakan serta mengukur apakah intervensi yang diberikan benar-benar menghasilkan perbaikan akademik.

Penelitian selanjutnya disarankan menggunakan dataset aktual dari beberapa semester agar model dapat diuji terhadap perubahan pola akademik mahasiswa. Penelitian juga dapat membandingkan XGBoost dengan Random Forest, Gradient Boosting, LightGBM, SVM, Logistic Regression, atau model *deep learning* untuk mengetahui algoritma yang paling sesuai dengan karakteristik data institusi. Evaluasi juga perlu mencakup *cross-validation*, ROC-AUC, *precision-recall curve*, *calibration*, analisis *false positive* dan *false negative*, serta pengujian stabilitas model berdasarkan semester dan program studi. Kajian terbaru menunjukkan bahwa *tree-based models* dan neural networks masih menjadi pendekatan dominan dalam prediksi performa mahasiswa, sedangkan XAI semakin dipandang penting untuk menjembatani prediksi dengan keputusan pendidikan. Selain peningkatan performa teknis, penelitian berikutnya dapat mengembangkan *real-time early warning*, integrasi langsung dengan SIAKAD/LMS, *model monitoring*, *concept drift detection*, serta evaluasi dampak intervensi. Aspek privasi, keamanan data, keadilan model, dan keterbatasan akses terhadap data mahasiswa juga harus menjadi bagian dari tata kelola sistem. Dengan demikian, implementasi XGBoost dan SHAP bukan hanya menghasilkan model prediksi, tetapi dapat dikembangkan menjadi ekosistem *data-driven student support* yang membantu perguruan tinggi mengenali risiko secara lebih awal, memahami faktor yang berkontribusi, dan memberikan intervensi yang tepat berdasarkan bukti.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada rekan-rekan sejawat yang telah memberikan masukan dan saran konstruktif demi menyempurnakan karya ilmiah ini.

DAFTAR PUSTAKA

- Alyahyan, E., & Düşteğör, D. (2020). Predicting academic success in higher education: literature review and best practices. *International Journal of Educational Technology in Higher Education*, 17(1), 3.
- Barramuño, M., Meza-Narváez, C., & Gálvez-García, G. (2022). Prediction of student attrition risk using machine learning. *Journal of Applied Research in Higher Education*, 14(3), 974–986.
- Fouladvand, S., Noshad, M., Goldstein, M. K., Periyakoil, V. J., & Chen, J. H. (2023). Mild cognitive impairment: data-driven prediction, risk factors, and workup. *AMIA Summits on Translational Science Proceedings*, 2023, 167.
- Handayani, L. (2026). A Machine Learning-Based Early Warning System for Student Performance Prediction: System Development and Empirical Evaluation in Higher Education. *Journal of Artificial Intelligence in Information Technology*, 1(1), 171–190.
- Ifenthaler, D., & Yau, J. Y.-K. (2020a). Utilising learning analytics to support study success in higher education: A systematic review. *Educational Technology Research and Development*, 68(4), 1961–1990.

- Ifenthaler, D., & Yau, J. Y.-K. (2020b). Utilising learning analytics to support study success in higher education: A systematic review. *Educational Technology Research and Development*, 68(4), 1961–1990.
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30.
- Mustofa, S., Emon, Y. R., Mamun, S. Bin, Akhy, S. A., & Ahad, M. T. (2025). A novel AI-driven model for student dropout risk analysis with explainable AI insights. *Computers and Education: Artificial Intelligence*, 8, 100352.
- Namoun, A., & Alshantiti, A. (2020a). Predicting student performance using data mining and learning analytics techniques: A systematic literature review. *Applied Sciences*, 11(1), 237.
- Namoun, A., & Alshantiti, A. (2020b). Predicting student performance using data mining and learning analytics techniques: A systematic literature review. *Applied Sciences*, 11(1), 237.
- Paul, R., Sarker, S., El Aouifi, H., Hussain, S., Baruah, A. K., & Gaftandzhieva, S. (2025). Analyzing dropout of students and an explainable prediction of academic performance utilizing artificial intelligence techniques. *Frontiers in Education*, 10, 1698505.
- Vaarma, M., & Li, H. (2024). Predicting student dropouts with machine learning: An empirical study in Finnish higher education. *Technology in Society*, 76, 102474.