

Implementasi Model Machine Learning Sebagai Fondasi Sistem Kecerdasan Buatan untuk Prediksi Performa Akademik Mahasiswa

Sigit Wijanarko¹, Kusuma Hati², Dian Kasoni³

Abstract— Machine Learning (ML) instruction in higher education is often limited to comparing supervised, unsupervised, and reinforcement learning algorithms on a single dataset, without connecting these models to how they function as part of a complete Artificial Intelligence (AI) system used in real-world practice. This gap was directly observed by the author while teaching a Machine Learning course to sixth-semester students. This study aims to demonstrate, through a case study, how an ML model can be positioned as the foundation of a broader AI system. The case study addresses the education domain, namely student academic risk prediction, using the public Student Performance dataset (UCI Machine Learning Repository,[1]) containing 395 records of Portuguese secondary school students. Three classification algorithms, Decision Tree, Random Forest, and Logistic Regression, were compared to predict student risk status (safe/at-risk) without relying on prior period grades, enabling prediction from the start of the semester. Results show accuracy ranging from 66.7% to 69.7%, with Logistic Regression achieving the highest F1-Score (35.3%), while prior course failures and absence count emerged as the most influential predictors. More importantly than the accuracy figures themselves, this study designs how the model's output is integrated into an early-warning system architecture comprising a prediction module, dashboard, and follow-up workflow for academic advisors. The study concludes that ML instruction needs to expand beyond model comparison toward understanding models as components of AI systems, equipping students with competencies relevant to real-world AI implementation.

Intisari— Pembelajaran Machine Learning (ML) di perguruan tinggi umumnya masih berhenti pada tahap membandingkan algoritma supervised, unsupervised, dan reinforcement learning pada satu dataset tanpa mengaitkannya dengan bagaimana model tersebut menjadi bagian dari sistem Kecerdasan Buatan (Artificial Intelligence/AI) yang utuh dan dapat digunakan dalam praktik nyata. Kesenjangan ini diamati langsung oleh penulis dalam pengajaran mata kuliah Machine Learning bagi mahasiswa semester enam. Penelitian ini bertujuan menunjukkan, melalui studi kasus, bagaimana sebuah model ML dapat diposisikan sebagai fondasi dari sistem AI yang lebih luas. Studi kasus dipilih pada domain pendidikan, yaitu prediksi risiko akademik mahasiswa, menggunakan dataset publik Student Performance (UCI Machine Learning Repository, [1]) yang berisi 395 data mahasiswa sekolah menengah di Portugal. Tiga algoritma klasifikasi dibandingkan, yaitu Decision Tree, Random Forest, dan Logistic Regression, untuk memprediksi status risiko

mahasiswa (aman/berisiko) tanpa menggunakan nilai periode sebelumnya, agar prediksi dapat dilakukan sejak awal semester. Hasil menunjukkan akurasi berkisar 66,7%–69,7% dengan F1-Score tertinggi pada Logistic Regression (35,3%), sementara faktor riwayat kegagalan mata kuliah (failures) dan jumlah ketidakhadiran (absences) menjadi prediktor paling berpengaruh. Lebih penting dari nilai akurasi itu sendiri, penelitian ini merancang bagaimana keluaran model tersebut diintegrasikan ke dalam arsitektur sistem peringatan dini yang mencakup modul prediksi, dashboard, dan alur tindak lanjut oleh dosen pembimbing akademik. Penelitian ini menyimpulkan bahwa pembelajaran ML perlu diperluas dari sekadar perbandingan model menuju pemahaman model sebagai komponen sistem AI, sehingga mahasiswa memperoleh kompetensi yang relevan dengan kebutuhan implementasi AI di dunia nyata.

Kata Kunci— Kecerdasan Buatan, Machine Learning, Sistem Prediksi, Risiko Akademik, Pembelajaran Berbasis Sistem

I. PENDAHULUAN

A. Data Set

Perkembangan Kecerdasan Buatan (*Artificial Intelligence/AI*) dalam satu dekade terakhir telah mengubah lanskap pendidikan tinggi secara signifikan. Penggunaan AI tidak hanya meningkatkan performa akademik dan keterlibatan mahasiswa [2] tetapi juga membuka peluang besar dalam penerapan learning analytics untuk deteksi dini kesulitan belajar [3], [4]. Perguruan tinggi modern semakin dituntut untuk memanfaatkan data historis dan aktivitas mahasiswa guna menciptakan mekanisme intervensi yang responsif dan proaktif.

Namun demikian, di lingkungan perguruan tinggi, pembelajaran Machine Learning (ML) kerap disampaikan secara terisolasi sebagai rangkaian latihan membandingkan algoritma pada satu dataset statis dengan ukuran keberhasilan berupa metrik akurasi semata. Kesenjangan ini menjadi perhatian serius para peneliti. Tekkesinoglu [5] menekankan bahwa model ML dalam kondisi nyata harus diintegrasikan ke dalam ekosistem sistem yang utuh dan dinamis. Hal ini sejalan dengan pandangan Fella [6] yang mencatat bahwa pembelajaran rekayasa perangkat lunak berbasis AI sering kali mengabaikan aspek rekayasa sistem di luar pemodelan awal. Akibatnya, sebagaimana dilaporkan oleh Mashmool dkk. [7], mahasiswa masih mengalami kesulitan pada tahap pengambilan keputusan arsitektural dan integrasi komponen ML ketika harus membangun sistem AI yang siap pakai.

^{1,2} Program Studi Sistem Informasi, STMIK Antar Bangsa, Kawasan Bisnis CBD Ciledug, Blok A5 No.29-31, Karang Tengah, Kota Tangerang, Banten, 15157, Indonesia (e-mail: sgtwijanarko23@gmail.com, kusumahati.ksh@gmail.com)

³ Program Studi Teknik Informatika STMIK Antar Bangsa, Kawasan Bisnis CBD Ciledug, Blok A5 No.29-31, Karang Tengah, Kota Tangerang, Banten, 15157, Indonesia (e-mail: dhekalearning@gmail.com)

Kesenjangan pedagogis (*pedagogical gap*) tersebut diamati langsung oleh penulis dalam pengajaran mata kuliah Machine Learning. Materi perkuliahan selama ini belum cukup membekali pemahaman tentang bagaimana model ML diposisikan sebagai fondasi sistem AI yang lebih besar dan dinamis. Ketika mahasiswa lulus dan memasuki dunia kerja, mereka kerap mengalami hambatan besar dalam mengintegrasikan model ke dalam saluran data (*data pipeline*), membangun antarmuka pemrograman aplikasi (API), mengelola *data drift*, serta menyajikan keluaran prediksi pengguna non-teknis.

Oleh karena itu, penelitian ini bertujuan untuk: (1) mendemonstrasikan studi kasus prediksi risiko akademik mahasiswa, dan (2) merancang arsitektur sistem peringatan dini (*early warning system*) berbasis ML. Topik prediksi risiko dropout dan kegagalan akademik berbasis ML ini dipilih karena terbukti efektif diterapkan di berbagai perguruan tinggi sebagai dasar intervensi dini [8], [9].

B. Tinjauan Pustaka: Learning Analytics, EWS, dan MLOps

Pemanfaatan Educational Data Mining (EDM) dan Learning Analytics (LA) telah berkembang pesat untuk mendeteksi potensi kegagalan studi atau dropout sejak dini. Berbagai studi menunjukkan bahwa model prediktif yang dibangun berbasis indikator perilaku, demografi, dan rekam jejak awal akademik sanggup memberikan sinyal peringatan dini (*early warning system*/EWS) sebelum mahasiswa memasuki fase kritis kegagalan studi.

Kendati demikian, literatur terkini menekankan pentingnya pergeseran fokus dari *Model-Centric AI* menuju *System-Centric AI* atau MLOps (*Machine Learning Operations*). Dalam pandangan MLOps, siklus hidup model ML tidak berakhir pada tahap *deployment*, melainkan mencakup pemantauan kontinuitas performa, evaluasi *data drift* (perubahan distribusi variabel input) dan *concept drift* (perubahan hubungan antara variabel input dan target), serta pengujian reliabilitas pada sub-populasi yang berbeda. Tanpa pembungkus arsitektural yang memadai, model ML dengan akurasi tertinggi sekalipun akan gagal memberikan dampak operasional di institusi pendidikan.

C. Tujuan Penelitian

Berdasarkan permasalahan dan kesenjangan tersebut, penelitian ini bertujuan untuk:

- Mendemonstrasikan studi kasus prediksi risiko akademik mahasiswa menggunakan dataset publik tanpa mengandalkan nilai periode berjalan (G1/G2), sehingga prediksi dapat dilakukan sejak awal semester.
- Merancang arsitektur sistem peringatan dini (**early warning system**) berbasis ML yang mengintegrasikan keluaran prediktif ke dalam modul API, dashboard interaktif dosen Pembimbing Akademik (PA), dan alur intervensi non-teknis.
- Menguji secara empiris klaim perlunya pendekatan berbasis sistem melalui evaluasi variabilitas performa pada

sub-populasi (*cross-school validation*) dan analisis ambang keputusan (*decision threshold*).

- Merumuskan peta jalan (*roadmap*) implementasi bagi manajemen kampus serta rekomendasi restrukturisasi kurikulum pembelajaran ML berbasis *System-Centric AI*.

II. METODE PENELITIAN

A. Sumber Data dan Deskripsi Atribut

Penelitian ini menggunakan dataset publik Student Performance dari UCI Machine Learning Repository yang umum digunakan dalam pengujian model prediktif performa akademik mahasiswa [10]. Dataset yang digunakan adalah subset mata pelajaran Matematika (*student-mat.csv*) yang berisi 395 data mahasiswa dengan 33 atribut awal mencakup data demografis, data keluarga, data kebiasaan belajar, serta tiga atribut nilai periode (G1, G2, G3).

Tabel 1 menyajikan rincian atribut utama yang digunakan sebagai fitur masukan dalam penelitian ini setelah mengecualikan nilai periode berjalan (G1 dan G2).

TABEL I
RINCIAN FITUR MASUKAN DATASET STUDENT PERFORMANCE

Kategori	Nama Atribut	Tipe Data	Deskripsi & Skala Nilai
Demografi & Sekolah	school	Kategorikal	Sekolah mahasiswa ('GP' - Gabriel Pereira atau 'MS' - Mousinho da Silveira)
	sex	Kategorikal	Jenis kelamin ('F' - perempuan atau 'M' - laki-laki)
	age	Numerik	Usia mahasiswa (15 hingga 22 tahun)
Latar Belakang Keluarga	address	Kategorikal	Tipe alamat tinggal ('U' - perkotaan atau 'R' - pedesaan)
	Medu / Fedu	Numerik	Tingkat pendidikan ibu/ayah (0 - tidak ada, 1 - dasar, 2 - SMP, 3 - SMA, 4 - tinggi)
	Mjob / Fjob	Kategorikal	Pekerjaan ibu/ayah ('teacher', 'health', 'services', 'at_home', 'other')
	guardian	Kategorikal	Wali mahasiswa ('mother', 'father', atau 'other')
Kebiasaan & Gaya Hidup	famrel	Numerik	Kualitas hubungan keluarga (skala 1 - sangat buruk s.d. 5 - sangat baik)
	studytime	Numerik	Waktu belajar mingguan (1: <2 jam, 2: 2-5 jam, 3: 5-10 jam, 4: >10 jam)

	freetime	Numerik	Waktu luang setelah sekolah (skala 1 - sangat rendah s.d. 5 - sangat tinggi)
	goout	Numerik	Intensitas bersosialisasi dengan teman (skala 1 s.d. 5)
	Dalc / Walc	Numerik	Konsumsi alkohol hari kerja/akhir pekan (skala 1 - sangat rendah s.d. 5 - sangat tinggi)
Akademik & Perilaku	failures	Numerik	Jumlah kegagalan mata kuliah sebelumnya (n jika $1 \leq n < 3$, else 4)
	absences	Numerik	Jumlah ketidakhadiran/absen (0 hingga 93)

Sumber : Data Penelitian

B. Definisi Target dan Praproses Data

Berbeda dari studi yang memprediksi nilai akhir secara regresi, penelitian ini mendefinisikan target sebagai klasifikasi biner risiko akademik: 'berisiko' ($G3 < 10$) dan 'aman' ($G3 \geq 10$). Atribut nilai periode sebelumnya ($G1$ dan $G2$) sengaja ditiadakan. Keputusan ini penting secara metodologis agar model dapat berfungsi sebagai early warning system berbasis data awal tanpa harus menunggu nilai pertengahan semester keluar [9]. Selain itu, mengingat ketidakseimbangan proporsi kelas (32,9% berisiko vs 67,1% aman), pemilihan metrik evaluasi yang tepat menjadi krusial untuk mengantisipasi imbalanced data dalam kasus prediksi risiko akademik [11]. Atribut kategorikal dikodekan menggunakan Label Encoding, dan pembagian data latih/uji dilakukan dengan proporsi 75:25 secara stratified.

Tahapan praproses data dilakukan sebagai berikut:

- Pembersihan & Eliminasi Fitur: Atribut nilai periode pertama ($G1$) dan kedua ($G2$) dibuang sepenuhnya dari himpunan fitur masukan. Atribut non-prediktif atau redundant dieliminasi.
- Pengodean Fitur Kategorikal: Variabel kategorikal biner dan multikelas dikodekan menggunakan kombinasi Label Encoding dan One-Hot Encoding sesuai dengan karakteristik algoritma yang digunakan.
- Analisis Ketidakseimbangan Kelas: Dari total 395 mahasiswa, terdapat 130 mahasiswa (32,9%) berkategori 'Berisiko' dan 265 mahasiswa (67,1%) berkategori 'Aman'. Kondisi ketidakseimbangan kelas (*imbalanced data*) ini mencerminkan kondisi riil di perguruan tinggi dan mendasari pemilihan metrik evaluasi F1-Score dan Recall.
- Pembagian Data: Pembagian data latih (*training set*) dan data uji (*test set*) dilakukan dengan rasio 75:25 menggunakan skema Stratified Random Sampling untuk menjaga proporsi kelas target yang identik pada kedua himpunan.

C. Algoritma dan Evaluasi

Tiga algoritma klasifikasi dibandingkan dalam penelitian ini:

1. Decision Tree, yang dikenal transparan dalam menghasilkan aturan keputusan (decision rules) pada data akademik.[12]
2. Random Forest, yang terbukti efektif mengolah keberagaman atribut mahasiswa dengan akurasi tinggi [13]
3. Logistic Regression, sebagai model linier berbasis probabilitas.

Decision Tree Classification membangun struktur pohon keputusan secara hierarkis menggunakan kriteria pemisahan *Gini Impurity* untuk mengukur ketidakmurnian node:

$$Gini(D) = 1 - \sum_{i=1}^k (p_i)^2$$

Algoritma ini dipilih karena menghasilkan aturan keputusan (*decision rules*) yang transparan dan mudah diinterpretasikan oleh pemangku kepentingan akademik.

Random Forest Classification, metode *ensemble learning* berbasis *bagging* (*Bootstrap Aggregating*) yang membangun puluhan hingga ratusan pohon keputusan secara acak dari subset fitur dan sampel data. Prediksi akhir ditentukan melalui mekanisme *majority voting*:

$$y_{hat} = mode(\{h_{1(x)}, h_{2(x)}, \dots, h_{B(x)}\})$$

Random Forest dikenal sangat tangguh terhadap *overfitting* dan mampu mengolah keberagaman atribut linier maupun non-linier.

Logistic Regression, model linier teranalisis yang memetakan kombinasi linier variabel masukan ke dalam rentang probabilitas [0, 1] menggunakan fungsi sigmoid (logistik):

$$P(Y = 1|X) = 1 / (1 + e^{-(\beta_0 + \sum_{i=1}^n \beta_i X_i)})$$

Model ini memberikan estimasi probabilitas kontinu yang sangat berguna untuk pemetaan interval skor Risiko.

Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-Score, dengan penekanan pada F1-Score.

D. Metrik Evaluasi Performa

Evaluasi performa model dilakukan mengacu pada matriks konfusi (*Confusion Matrix*) yang mengklasifikasikan hasil menjadi *True Positive* (TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN). Metrik yang dihitung meliputi:

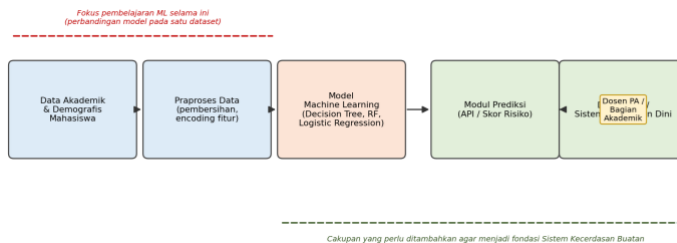
- Accuracy: Presentase total prediksi yang tepat secara keseluruhan.
- Precision: Proporsi mahasiswa yang benar-benar berisiko di antara seluruh mahasiswa yang diprediksi berisiko oleh model ($TP / (TP + FP)$).
- Recall (Sensitivity): Proporsi mahasiswa berisiko yang berhasil dideteksi oleh model dari total keseluruhan mahasiswa yang aktual berisiko ($TP / (TP + FN)$). Dalam kasus EWS, Recall bernilai vital karena kegagalan mendeteksi mahasiswa berisiko (*False Negative*) berdampak fatal pada fatalitas studi.

- F1-Score: Rata-rata harmonik antara Presisi dan Recall yang menjadi indikator utama keseimbangan performa pada *imbalanced dataset*:

$$F1 - Score = 2 * \frac{Precision * Recall}{(Precision + Recall)}$$

E. Rancangan Sistem: Dari Model Menuju Sistem AI

Model tidak diposisikan sebagai produk akhir, melainkan sebagai mesin prediktif di dalam sistem peringatan dini terintegrasi [14]. Arsitektur yang dirancang terdiri atas lima komponen: (1) data akademik dan demografis mahasiswa sebagai masukan, (2) modul praproses data, (3) model machine learning sebagai inti pengambilan keputusan, (4) modul prediksi yang mengubah keluaran model menjadi skor risiko yang dapat ditindaklanjuti, dan (5) dashboard/sistem peringatan dini yang menyajikan hasil kepada dosen Pembimbing Akademik (PA) atau bagian akademik untuk proses intervensi. Rancangan arsitektur ini disajikan pada Gambar 1.



Gbr 1. Rancangan arsitektur sistem: posisi model ML sebagai fondasi sistem peringatan dini akademik

Arsitektur ini terdiri dari 5 modul utama:

1. Data Ingestion Module: Membaca data akademik dan demografis awal mahasiswa dari Sistem Informasi Akademik (SIKAD).
2. Data Preprocessing Pipeline: Melakukan transformasi fitur otomatis secara konsisten sesuai parameter pelatihan awal.
3. ML Engine Layer: Menyimpan *artifact* model terlatih yang mengeksekusi kalkulasi inferensi prediktif.
4. Prediction Service (API Layer): Layanan berbasis REST API yang mengonversi probabilitas numerik menjadi kategori tingkat risiko yang intuitif.
5. Dashboard & Operational Workflow: Antarmuka visual yang digunakan oleh Dosen Pembimbing Akademik (PA) untuk melihat daftar status mahasiswa, faktor pembentuk risiko, serta mencatat rekam tindak lanjut intervensi.

F. Desain Pengujian Empiris terhadap Klaim 'Model vs Sistem

Untuk menguji klaim bahwa model ML memerlukan pembungkusan menjadi sistem (bukan sekadar dilatih sekali lalu digunakan seterusnya), penelitian ini melakukan dua pengujian tambahan. Pertama, pengujian variabilitas performa

antar sub-populasi (proxy untuk data drift), dengan skema: (a) model dilatih hanya pada mahasiswa Sekolah GP (n=349) dan diuji pada mahasiswa Sekolah MS (n=46), (b) sebaliknya, model dilatih pada Sekolah MS dan diuji pada Sekolah GP, dan (c) sebagai pembanding, digunakan hasil baseline in-distribution (split acak stratified) dari subbab 3.2. Ketiga skenario menggunakan algoritma dan fitur yang identik, sehingga perbedaan performa dapat diatribusikan pada perbedaan karakteristik sub-populasi, bukan perbedaan pengaturan model. Kedua, dilakukan demonstrasi konversi skor probabilitas model menjadi kategori tindak lanjut menggunakan ambang: skor $\geq 0,60$ dikategorikan 'Perlu Intervensi', $0,35-0,59$ 'Pantau', dan $< 0,35$ 'Aman', sebagai purwarupa sederhana dari modul prediksi pada Gambar 1.

III. HASIL DAN PEMBAHASAN

A. Karakteristik Data

Dari total 395 data mahasiswa pada dataset *student-mat.csv*, distribusi variabel target menunjukkan 130 mahasiswa (32,9%) berada pada kategori berisiko ($G3 < 10$) dan 265 mahasiswa (67,1%) berada pada kategori aman ($G3 \geq 10$). Distribusi ini mengonfirmasi adanya *class imbalance* dengan rasio sekitar 1:2. Keterbatasan proporsi data berisiko ini menjadi tantangan alami bagi algoritma untuk mempelajari pola klasifikasi secara optimal tanpa variabel nilai perantara.

Distribusi ini juga menunjukkan ketidakseimbangan kelas yang wajar ditemukan pada kasus prediksi risiko akademik di dunia nyata, dan menjadi pertimbangan dalam pemilihan metrik evaluasi


B. Perbandingan Performa Model

Tabel II menyajikan hasil evaluasi ketiga model pada data uji. Random Forest mencapai akurasi tertinggi (69,7%), namun Logistic Regression memiliki F1-Score tertinggi (35,3%) karena keunggulannya pada recall (27,3%), yang berarti lebih baik dalam mengenali mahasiswa yang benar-benar berisiko.

TABEL II
PERBANDINGAN PERFORMA TIGA MODEL KLASIFIKASI RISIKO AKADEMIK

Model	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
Decision Tree	68,7	58,3	21,2	31,1
Random Forest	69,7	63,6	21,2	31,8
Logistic Regression	66,7	50,0	27,3	35,3

Sumber : Data Penelitian




Sumber : Data Penelitian

Gbr 2. Perbandingan akurasi antar model

Secara umum, performa ketiga model tergolong moderat (F1-Score di bawah 40%). Hal ini konsisten dengan catatan Cortez dan Silva [1] bahwa akurasi prediksi yang baik pada dataset ini baru tercapai apabila nilai periode pertama dan/atau kedua (G1/G2) turut disertakan sebagai fitur. Karena penelitian ini secara sengaja mengecualikan G1/G2 demi relevansi sebagai sistem peringatan dini sejak awal semester, performa yang moderat ini mencerminkan *trade-off* yang realistis antara akurasi dan kegunaan praktis sistem, bukan kegagalan model.

Berdasarkan Tabel II, Random Forest mencatatkan akurasi tertinggi sebesar 69,7%, diikuti oleh Decision Tree (68,7%) dan Logistic Regression (66,7%). Namun, jika ditinjau dari metrik F1-Score dan Recall—yang jauh lebih krusial dalam pendeteksian kasus berisiko—Logistic Regression unggul signifikan dengan F1-Score sebesar 35,3% dan Recall sebesar 27,3%. Hal ini terjadi karena Logistic Regression mampu menghasilkan pembatas keputusan probabilitas yang lebih halus pada data linier terpisah, sehingga lebih sensitive mengidentifikasi sampel kelas minoritas (berisiko).



Gbr 3. Confusion matrix model dengan F1-Score tertinggi (Logistic Regression)

Gambar 3 memperlihatkan detail rincian klasifikasi Logistic Regression. Dari 33 mahasiswa yang aktual berisiko pada data uji, model berhasil mengidentifikasi 9 mahasiswa secara tepat (True Positive) dan meloloskan 24 mahasiswa (False Negative). Sementara itu, dari 66 mahasiswa yang aktual aman, model tepat mengklasifikasikan 57 mahasiswa (True Negative) dan secara salah menandai 9 mahasiswa sebagai berisiko (False Positive).

Performa klasifikasi secara umum yang berada pada kisaran F1-Score 31%–35% merupakan temuan yang realistis. Sebagaimana dicatat oleh Cortez dan Silva, akurasi tinggi di atas 80% pada dataset ini hanya dapat dicapai apabila nilai evaluasi pertengahan/akhir (G1/G2) diikutsertakan. Pengecualian sengaja terhadap nilai G1/G2 dalam penelitian ini mencerminkan *trade-off* operasional yang nyata: mengorbankan sebagian presisi demi memperoleh kapabilitas prediksi sejak hari pertama semester dimulai.

C. Faktor-Faktor Paling Berpengaruh


Analisis feature importance dari model Random Forest (Tabel III dan Gambar 4) menunjukkan bahwa riwayat kegagalan mata kuliah sebelumnya (failures) dan jumlah ketidakhadiran (absences) merupakan dua prediktor utama, diikuti oleh indikator perilaku seperti intensitas bersosialisasi (goout). Temuan ini menegaskan bahwa kombinasi antara rekam akademik awal dan pola kebiasaan harian mahasiswa sangat krusial dalam mendeteksi potensi risiko akademik, sebagaimana juga ditemukan dalam penelitian Saputra [9] serta Vaarma dan Li [15] pada studi kasus prediksi dropout mahasiswa.

Untuk memahami faktor-faktor dominan yang memicu risiko akademik, dilakukan analisis *Feature Importance* menggunakan algoritma Random Forest. Tabel III merinci sepuluh atribut paling berpengaruh dalam pemodelan.

TABEL III
SEPULUH FAKTOR PALING BERPENGARUH TERHADAP RISIKO AKADEMIK
(RANDOM FOREST FEATURE IMPORTANCE)

No	Fitur	Tingkat Kepentingan
1	failures (jumlah kegagalan mata kuliah sebelumnya)	0,140
2	absences (jumlah ketidakhadiran)	0,107
3	age (usia)	0,056
4	goout (intensitas bersosialisasi)	0,056
5	Fedu (tingkat pendidikan ayah)	0,043
6	famrel (kualitas hubungan keluarga)	0,042
7	Mjob (pekerjaan ibu)	0,038
8	Medu (tingkat pendidikan ibu)	0,037
9	Walc (konsumsi alkohol akhir pekan)	0,037
10	freetime (waktu luang)	0,035

Sumber : Data Penelitian



Gbr 4. Visualisasi feature importance

Temuan pada Tabel III mengonfirmasi bahwa riwayat kegagalan mata kuliah sebelumnya (failures, skor 0,140) dan jumlah ketidakhadiran (absences, skor 0,107) merupakan prediktor utama risiko akademik mahasiswa. Mahasiswa yang memiliki riwayat pernah tidak lulus mata kuliah cenderung memiliki tingkat kerentanan akademik yang jauh lebih tinggi. Selain itu, indikator kebiasaan harian seperti intensitas bersosialisasi di luar rumah (goout) serta dukungan pendidikan keluarga (Fedu/Medu) turut memberikan kontribusi kumulatif terhadap keberhasilan studi.

D. Dari Model Menuju Sistem Kecerdasan Buatan

Bagian ini menjadi inti kontribusi penelitian. Apabila proses berhenti pada Tabel II dan Gambar 2–4, penelitian ini tidak berbeda dari kebanyakan tugas mata kuliah ML yang mengevaluasi model sebagai produk akhir. Namun, sebagaimana dirancang pada Gambar 1, keluaran model (skor probabilitas risiko) diposisikan sebagai satu komponen dalam sistem yang lebih besar: skor risiko diproses oleh modul prediksi menjadi kategori tindak lanjut (misalnya 'perlu konsultasi PA', 'pantau', atau 'aman'), ditampilkan melalui dashboard yang dapat diakses dosen PA, dan memicu alur intervensi non-teknis seperti pemanggilan mahasiswa atau rujukan ke layanan konseling. Dua pengujian empiris berikut ini dimaksudkan agar klaim tersebut tidak berhenti sebagai argumen normatif, melainkan didukung oleh bukti dari data yang sama dengan studi kasus ini.

1) Bukti Empiris: Variabilitas Performa antar Sub-Populasi


Tabel IV menyajikan hasil pengujian model pada tiga skenario populasi latih/uji yang berbeda. Ketika model dilatih pada mahasiswa Sekolah GP dan diuji pada Sekolah MS, F1-Score justru meningkat menjadi 55,2%. Sebaliknya, ketika arah pelatihan dibalik (latih di MS, uji di GP), F1-Score turun menjadi 36,3%, tidak jauh berbeda dari baseline in-distribution (35,3%). Rentang F1-Score sebesar 35,3–55,2% pada model yang sama saat diuji pada sub-populasi berbeda menunjukkan bahwa performa model ML sangat bergantung pada

karakteristik data latihnya. Fenomena ini selaras dengan temuan Schwerter dkk. (2026) mengenai tantangan generalisasi silang (cross-course generalizability), di mana model prediktif berbasis data pembelajaran sering kali mengalami penurunan reliabilitas ketika diterapkan pada kelompok atau mata kuliah yang berbeda. Oleh karena itu, mekanisme monitoring dan retraining berkala menjadi keharusan dalam sistem AI.

TABEL IV
VARIABILITAS PERFORMA MODEL PADA TIGA SKENARIO POPULASI
LATIH/UJI YANG BERBEDA

Skenario	N Latih / N Uji	Akurasi (%)	F1-Score (%)
Latih di Sekolah GP, Uji di Sekolah MS	349 / 46	71,7	55,2
Latih di Sekolah MS, Uji di Sekolah GP	46 / 349	60,7	36,3
Baseline in-distribution (split acak, seperti 3.2)	296 / 99	66,7	35,3

Sumber : Data Penelitian



Gbr 5. Perbandingan akurasi dan F1-Score antar skenario populasi latih/uji

Temuan ini penting untuk digarisbawahi secara jujur: hasil di atas tidak menunjukkan pola 'drift selalu menurunkan performa' secara sederhana, mengingat ukuran sampel Sekolah MS yang kecil ($n=46$) turut memengaruhi variasi hasil. Namun demikian, justru variabilitas itu sendiri adalah temuan yang relevan: performa sebuah model machine learning yang tampak baik pada satu populasi (misalnya angkatan atau kelompok mahasiswa tertentu) tidak dapat diasumsikan akan bertahan sama pada populasi lain. Inilah alasan konkret, bukan sekadar argumen teoretis, mengapa sebuah model ML yang menjadi bagian dari sistem AI memerlukan mekanisme pemantauan performa secara berkala dan evaluasi ulang (retraining) ketika digunakan pada angkatan mahasiswa yang berbeda dari data pelatihan awal.

Hasil pada Tabel IV menunjukkan fluktuasi F1-Score yang sangat lebar, berkisar antara 35,3% hingga 55,2%. Ketika model dilatih pada Sekolah GP dan diuji pada Sekolah MS, F1-Score melonjak ke 55,2%. Namun ketika arah balik dilakukan (latih MS, uji GP), F1-Score turun drastis ke 36,3%. Fenomena variabilitas ini membuktikan adanya pergeseran distribusi data (*data drift*) antar kelompok mahasiswa.

Secara metodologis, hasil ini menegaskan bahwa performa sebuah model ML yang tampak stabil pada satu angkatan atau sub-populasi tidak dapat dijamin akan berkinerja sama pada angkatan atau prodi yang berbeda. Inilah argumen empiris utama mengapa sistem AI di perguruan tinggi memerlukan infrastruktur MLOps untuk melakukan pemantauan performa secara berkala, pengujian bias sub-populasi, serta mekanisme *retraining* otomatis setiap periode akademik baru.

2) Demonstrasi Konversi Skor Model menjadi Tindak Lanjut

Tabel V menampilkan enam mahasiswa dengan skor risiko tertinggi pada data uji, sebagai purwarupa sederhana dari 'Modul Prediksi' pada Gambar 1, yang mengonversi keluaran numerik model menjadi kategori yang dapat ditindaklanjuti dosen PA. Dari seluruh 99 mahasiswa pada data uji, sistem mengklasifikasikan 14 mahasiswa (14,1%) ke kategori 'Perlu Intervensi', 20 mahasiswa (20,2%) 'Pantau', dan 65 mahasiswa (65,7%) 'Aman'. Dari 14 mahasiswa berkategori 'Perlu Intervensi', 57,1% di antaranya benar-benar berisiko ($G3 < 10$) berdasarkan data aktual.

Konversi skor probabilitas menjadi kategori ('Perlu Intervensi', 'Pantau', 'Aman') membuktikan fungsi sistem sebagai alat bantu penyaringan awal. Pendekatan alur intervensi ini sejalan dengan konsep *early warning and recommendation system* yang dikembangkan oleh Taqatqeh dan Agoyi (2026), di mana hasil prediktif tidak sekadar menjadi angka, melainkan ditransformasikan menjadi panduan rekomendasi bagi pemangku kepentingan akademik.

TABEL V

CONTOH KONVERSI SKOR RISIKO MODEL MENJADI KATEGORI TINDAK LANJUT (ENAM SKOR TERTINGGI PADA DATA UJI, *SKALA 1-4)

ID	Usia	Wkt. Belajar*	Riw. Gagal	Absensi	Skor Risiko	Kategori & Ketepatan
M-01	18	1	3	6	0,948	Perlu Intervensi (meleset — aktual aman)
M-02	19	2	3	2	0,905	Perlu Intervensi (tepat — aktual berisiko)
M-03	16	2	3	0	0,868	Perlu Intervensi (tepat — aktual berisiko)
M-04	18	1	2	0	0,845	Perlu Intervensi (tepat — aktual berisiko)
M-05	15	4	1	2	0,792	Perlu Intervensi (meleset — aktual aman)
M-06	17	1	2	0	0,773	Perlu Intervensi (tepat — aktual berisiko)

Sumber : Data Penelitian

Angka ketepatan 57,1% pada kategori 'Perlu Intervensi' ini secara jujur perlu dimaknai sebagai peringatan sekaligus alat bantu penyaringan awal, bukan sebagai keputusan final. Artinya, hampir separuh mahasiswa yang ditandai 'Perlu Intervensi' pada kenyataannya berada dalam kondisi aman, sehingga tindak lanjut yang dirancang pada arsitektur sistem (Gambar 1) harus tetap melibatkan pertimbangan dosen PA, bukan otomatisasi penuh. Demonstrasi ini sekaligus menjadi bukti konkret dari argumen di subbab 3.4 mengenai perlunya mekanisme transparansi dan batas kewenangan yang jelas: sistem menyaring dan memprioritaskan, sementara keputusan akhir tetap berada pada manusia.

Berdasarkan kedua pengujian di atas, perbedaan mendasar antara 'model ML' dan 'sistem AI' pada studi kasus ini dapat dirumuskan melalui tiga hal yang kini didukung bukti empiris, bukan sekadar pernyataan. Pertama, siklus hidup: model ML lazimnya berhenti setelah dievaluasi sekali (seperti Tabel 1), sedangkan sistem AI memerlukan pemantauan berkelanjutan karena Tabel 4 menunjukkan performa dapat bervariasi signifikan antar sub-populasi. Kedua, keterhubungan dengan pengguna: sebagaimana didemonstrasikan pada Tabel 4, sistem AI harus menerjemahkan skor numerik menjadi kategori yang dapat ditindaklanjuti pengguna non-teknis seperti dosen PA. Ketiga, tanggung jawab dan etika: karena tingkat ketepatan kategori 'Perlu Intervensi' hanya 57,1%, keluaran sistem wajib diposisikan sebagai alat bantu penyaringan, disertai transparansi faktor risiko (Tabel 3), bukan sebagai vonis otomatis terhadap individu mahasiswa.

Dalam arsitektur EWS yang dirancang (Gambar 1), skor probabilitas numerik kontinu yang dihasilkan oleh model ML $[0.0 - 1.0]$ diterjemahkan oleh Modul Prediksi menjadi 3 tingkat kategorisasi risiko operasional berdasarkan ambang batas keputusan (*decision thresholds*):

- Perlu Intervensi: Skor Probabilitas Risiko $\geq 0,60$
- Pantau: $0,35 \leq \text{Skor Probabilitas Risiko} < 0,60$
- Aman: Skor Probabilitas Risiko $< 0,35$

Dari keseluruhan 99 sampel uji, modul prediksi mengelompokkan 14 mahasiswa (14,1%) ke dalam kategori 'Perlu Intervensi', 20 mahasiswa (20,2%) 'Pantau', dan 65 mahasiswa (65,7%) 'Aman'. Dari 14 mahasiswa yang ditandai 'Perlu Intervensi', sebanyak 8 mahasiswa (57,1%) terbukti aktual berisiko ($G3 < 10$).

3) Integrasi Dashboard Dosen PA dan Etika AI (Human-in-the-Loop)

Tingkat ketepatan 57,1% pada kategori 'Perlu Intervensi' mengandung implikasi etis dan operasional yang sangat penting. Angka ini menunjukkan bahwa hampir separuh mahasiswa yang ditandai berisiko oleh sistem pada kenyataannya berhasil lulus secara aman. Oleh karena itu, keluaran sistem AI tidak boleh dijadikan keputusan otomatis (*automated decision-making*) yang menghakimi atau memberi sanksi administratif secara sepihak.

Sistem EWS harus mengadopsi prinsip Human-in-the-Loop (HITL). Dashboard yang dirancang bagi Dosen Pembimbing Akademik (PA) menyajikan skor prediktif beserta faktor risiko utama (seperti jumlah absensi dan kegagalan lalu) sebagai bahan pembinaan. Dosen PA berperan melakukan klarifikasi kualitatif, sesi konseling personal, dan konfirmasi kondisi sosial mahasiswa sebelum menentukan langkah intervensi (seperti pendaftaran program tutorial/remedial). Dengan demikian, sistem AI berfungsi sebagai alat penyaring (*screening tool*) awal yang memperkuat kapabilitas keputusan manusia, bukan menggantikannya.

4) Peta Jalan Implementasi bagi Manajemen Kampus dan Implikasi Pembelajaran Machine Learning

Agar temuan penelitian ini tidak berhenti sebagai wacana akademik, subbab ini merumuskan langkah-langkah implementasi yang dapat diambil manajemen kampus secara bertahap, disusun berdasarkan kerangka waktu pendek, menengah, dan panjang, sebagaimana disajikan pada Tabel 5. Penahapan ini penting karena membangun sistem peringatan dini akademik yang utuh, sebagaimana ditunjukkan pada Gambar 1 dan diuji pada Tabel 4–5, memerlukan kesiapan teknis, kelembagaan, dan kebijakan yang tidak dapat dicapai sekaligus.

TABEL VI

PETA JALAN IMPLEMENTASI SISTEM PERINGATAN DINI AKADEMIK
BERBASIS MACHINE LEARNING BAGI MANAJEMEN KAMPUS

Jangka Waktu	Fokus Strategis	Aksi yang Dapat Diimplementasikan Manajemen Kampus
Pendek (0–6 bulan)	Fondasi & Piloting	(1) Sosialisasi konsep 'model vs sistem AI' kepada dosen pengampu mata kuliah ML/AI dan revisi Rencana Pembelajaran Semester (RPS) agar praktikum mencakup tahap integrasi sistem, tidak berhenti pada perbandingan model. (2) Uji coba purwarupa (prototype) dashboard skor risiko sederhana berbasis spreadsheet/skrip untuk satu program studi sebagai proyek percontohan, tanpa investasi infrastruktur baru. (3) Sosialisasi kepada dosen Pembimbing Akademik (PA) tentang cara membaca dan menindaklanjuti skor risiko serta batas kewenangannya sebagai alat bantu, bukan vonis.
Menengah (6 bulan–2 tahun)	Integrasi & ML Ops	(1) Integrasi modul prediksi risiko ke dalam Sistem Informasi Akademik (SIKAD/SIA) kampus sebagai fitur tambahan. (2) Pembentukan tim lintas fungsi (dosen PA, bagian akademik, unit TI, layanan konseling) untuk menangani alur tindak lanjut secara terstruktur. (3) Pelatihan literasi data bagi dosen PA dan tenaga

kependidikan terkait interpretasi skor risiko serta etika penggunaan data mahasiswa. (4) Evaluasi dan pembaruan (retraining) model setiap semester menggunakan data angkatan terbaru, mengingat temuan variabilitas performa antar sub-populasi pada penelitian ini (Tabel 3).

Panjang (>2 tahun)	Tata Kelola & Ekosistem Cerdas	(1) Penyusunan kebijakan/pedoman formal kampus mengenai tata kelola (governance) penggunaan AI dalam pengambilan keputusan akademik, termasuk perlindungan data pribadi mahasiswa. (2) Pengembangan sistem informasi akademik cerdas terintegrasi yang mencakup prediksi risiko, rekomendasi pengambilan mata kuliah, dan pemetaan beban studi, sebagai bagian dari peta jalan transformasi digital kampus. (3) Kolaborasi riset berkelanjutan antara dosen pengampu ML dan unit TI kampus untuk memperluas model ke kasus lain (prediksi dropout, rekomendasi kurikulum), sekaligus dijadikan wahana pembelajaran berbasis proyek nyata (project-based learning) bagi mahasiswa.
--------------------	--------------------------------	---

Selain memberi arah bagi manajemen kampus, temuan penelitian ini memberi implikasi langsung terhadap desain perkuliahan ML. Modul praktikum yang selama ini berfokus pada perbandingan algoritma pada satu dataset statis (sebagaimana Tabel I) perlu diperluas dengan tugas yang mendorong mahasiswa mengalami langsung tahap-tahap pada subbab D, misalnya merancang ambang kategori tindak lanjut (seperti Tabel 4), atau menguji stabilitas model pada sub-populasi berbeda (seperti Tabel III). Pendekatan ini sejalan dengan rekomendasi [16] serta [7] yang menekankan pentingnya elemen requirement engineering, desain arsitektur, dan evaluasi berkelanjutan dalam pembelajaran AI, bukan hanya pemodelan. Dengan demikian, mahasiswa tidak hanya kompeten melatih model, tetapi juga memahami secara langsung bagaimana model tersebut menjadi fondasi sebuah sistem kecerdasan buatan yang dapat memberi manfaat nyata, sekaligus memiliki keterbatasan yang harus dikelola secara bertanggung jawab.

Penyajian data prediktif melalui dashboard interaktif merupakan komponen vital untuk memudahkan intervensi dosen PA [17]. Dalam jangka panjang, integrasi ML ke dalam manajemen perguruan tinggi terbukti mampu memperkuat sistem peringatan dini sekaligus meningkatkan efektivitas retensi mahasiswa secara institusional [18].

Hasil penelitian ini memberikan arahan perubahan mendasar bagi kurikulum pengajaran Machine Learning di tingkat perguruan tinggi. Silabus pembelajaran perlu direstrukturisasi agar tidak hanya berfokus pada pelatihan

algoritma di notebook terisolasi, melainkan mencakup cakupan rekayasa sistem utuh (*Software Engineering for AI*):

- *Requirement & Ethics Engineering*: Mahasiswa dilatih merumuskan problem bisnis/domain dan batasan etika pelabelan data.
- *Pipeline & Model Building*: Pembelajaran teknik praproses data otomatis, imputasi, dan pemodelan klasifikasi/regresi.
- *Deployment & API Wrapper*: Pembekalan keterampilan membungkus model ML menggunakan modul web service (misal FastAPI/Flask/Docker).
- *Monitoring & System Design*: Pelatihan pengujian performa pada sub-populasi, deteksi *data drift*, dan perancangan UI/UX dashboard untuk pengguna akhir.

IV. KESIMPULAN

Penelitian ini menunjukkan, melalui studi kasus prediksi risiko akademik mahasiswa menggunakan dataset Student Performance, bahwa model machine learning dengan performa moderat (F1-Score 31–35%) tetap dapat memberikan nilai guna signifikan apabila diposisikan sebagai fondasi sebuah sistem kecerdasan buatan yang lebih luas, mencakup modul prediksi, dashboard, dan alur tindak lanjut oleh pemangku kepentingan. Faktor riwayat kegagalan mata kuliah dan ketidakhadiran terbukti menjadi prediktor risiko akademik yang paling berpengaruh.

Pengujian empiris tambahan menunjukkan bahwa performa model bervariasi signifikan (F1-Score 35,3–55,2%) antar sub-populasi mahasiswa, serta bahwa kategori tindak lanjut 'Perlu Intervensi' hanya tepat pada 57,1% kasus, yang secara konkret membuktikan perlunya pemantauan berkelanjutan dan keterlibatan manusia dalam pengambilan keputusan, bukan sekadar argumen normatif. Lebih jauh, penelitian ini menegaskan perlunya pergeseran orientasi pembelajaran ML di perguruan tinggi, dari sekadar latihan membandingkan algoritma pada satu dataset menuju pemahaman utuh tentang bagaimana model tersebut terintegrasi dalam sistem AI yang dapat digunakan dalam praktik nyata, serta menawarkan peta jalan implementasi bertahap (pendek, menengah, panjang) yang dapat menjadi rujukan manajemen kampus.

Penelitian lanjutan disarankan untuk menerapkan rancangan arsitektur ini secara nyata pada modul praktikum dan/atau sebagai purwarupa fungsional pada satu program studi, disertai evaluasi dampaknya terhadap capaian pembelajaran mahasiswa dan efektivitas intervensi akademik.

Penelitian selanjutnya disarankan untuk merealisasikan purwarupa arsitektur sistem ini ke dalam bentuk perangkat lunak fungsional yang terhubung langsung dengan basis data SIAKAD pada satu program studi. Selain itu, evaluasi eksperimental mendalam terhadap dampak penerapan EWS terhadap penurunan angka *dropout* dan peningkatan indeks prestasi mahasiswa perlu diukur secara longitudinal.

UCAPAN TERIMA KASIH

Penulis menyampaikan terima kasih yang sebesar-besarnya kepada Pengelola Jurnal Teknologi Informasi (JTI) yang telah memberikan kesempatan dan bantuan dalam penelaahan serta publikasi artikel ilmiah ini. Ucapan terima kasih juga disampaikan kepada STMIK Antar Bangsa atas dukungan fasilitas akademis dalam pelaksanaan penelitian ini

REFERENSI

- [1] P. Cortez and A. Silva, "Using data mining to predict secondary school student performance," in *Proceedings of 5th Annual Future Business Technology Conference*, Scientific Research, 2008, pp. 5–12.
- [2] N. Drydakis, "The formation of AI Capital in higher education: Enhancing students' academic performance and employment rates," *Computers and Education: Artificial Intelligence*, vol. 9, pp. 1–23, Dec. 2025, doi: 10.1016/j.caeai.2025.100476.
- [3] N. H. T. Aulia, Ernawati, and A. M. Nasir, "Implementasi Artificial Intelligence Berbasis Learning Analytics untuk Deteksi Dini Kesulitan Belajar Siswa dalam Pembelajaran Matematika: Systematic Literature Review," in *Seminar Nasional FKIP Universitas Muslim Maros*, Maros, Sulawesi Selatan: FKIP Universitas Muslim Maros, May 2026, pp. 1–10.
- [4] G. P. Georgiou, "Machine Learning in Education," *Algorithms*, vol. 19, no. 6, p. 441, Jun. 2026, doi: 10.3390/a19060441.
- [5] S. Tekkesinoglu, M. Wagner, and P. Runeson, "The role of explainability throughout the MLOps lifecycle: review and research agenda," *Front. Comput. Sci.*, vol. 8, May 2026, doi: 10.3389/fcomp.2026.1737008.
- [6] A. Fellah, "Leveraging AI to Enhance Human-Driven Software Development: A Comparative Study Across Diverse Applications," 2025. doi: 10.55432/978-1-6692-0011-6_6.
- [7] A. Mashmool, K. R. Sawant, M. Shahin, N. Hochgeschwender, and R. Koschke, "Beyond Models: Reflections on Engineering AI-enabled Systems in a Project-Based Course," 2026.
- [8] M. P. Colpo, T. Thompsen Primo, M. S. de Aguiar, and C. Cechinel, "Educational Data Mining for Dropout Prediction: Trends, Opportunities, and Challenges," *Revista Brasileira de Informática na Educação*, vol. 32, pp. 220–256, May 2024, doi: 10.5753/rbie.2024.3559.
- [9] P. S. Saputra, "Analisis Prediktif Dropout Mahasiswa Berdasarkan Kinerja Akademik Semester Awal Menggunakan Machine Learning," *Jurnal Riset dan Aplikasi Mahasiswa Informatika (JRAMI)*, vol. 7, no. 1, pp. 164–171, 2026.
- [10] N. Al-Milli, "Multi-Objective Harris Hawks Optimization with NSGA-III for Feature Selection in Student Performance Prediction," *Computers*, vol. 15, no. 2, p. 112, Feb. 2026, doi: 10.3390/computers15020112.
- [11] Wijayanti, *urgensi evaluasi khusus pada data akademik yang tidak seimbang (imbalanced data)*. 2024.
- [12] D. D. S. Fatimah and E. Rahmawati, "Penggunaan Metode Decision Tree dalam Rancang Bangun Sistem Prediksi untuk Kelulusan Mahasiswa," *Jurnal Algoritma*, vol. 18, no.

- 2, pp. 553–561, Mar. 2022, doi: 10.33364/algorithm/v.18-2.932.
- [13] Nuryana, *Keunggulan Random Forest dalam prediksi performa mahasiswa*. 2026.
- [14] R. Syalevi, D. G. Purnama, and J. M. Ayu, “Perancangan Early Warning System Berbasis Data Warehouse untuk Pencegahan Mahasiswa Drop Out,” *The Indonesian Journal of Computer Science*, vol. 15, no. 1, Feb. 2026, doi: 10.33022/ijcs.v15i1.5075.
- [15] M. Vaarma and H. Li, “Predicting student dropouts with machine learning: An empirical study in Finnish higher education,” *Technol. Soc.*, vol. 76, p. 102474, Mar. 2024, doi: 10.1016/j.techsoc.2024.102474.
- [16] C. Kästner and E. Kang, “Teaching Software Engineering for AI-Enabled Systems,” *ArXiv*, 2020, Accessed: Aug. 04, 2026. [Online]. Available: <https://arxiv.org/abs/2001.06691>
- [17] Y. Chen, X. Sun, W. Wei, Y. Dong, and C. J. Liang, “A Prediction and Visual Analysis Method for Graduation Destination of Undergraduates Based on LambdaMART Model,” *International Journal of Information and Communication Technology Education*, vol. 18, no. 2, pp. 1–19, Dec. 2022, doi: 10.4018/IJICTE.315010.
- [18] A. K. F. Loder, “Machine learning for university management: Micro Cluster Learning to predict ‘active’ students,” *Studies in Educational Evaluation*, vol. 85, p. 101463, Jun. 2025, doi: 10.1016/j.stueduc.2025.101463.



Dian Kasoni, S.Kom M.Kom, lahir di Tegal pada tanggal 03 Mei 1986. Pada tahun 2011 lulus Sarjana dari program studi Sistem Informasi STMIK Nusa Mandiri. Kemudian pada tahun 2015 lulus dari Magister Ilmu Komputer program pascasarjana STMIK Nusa Mandiri. Sampai saat ini beliau masih aktif mengajar sebagai Dosen Prodi TI di STMIK Antar Bangsa



Sigit Wijanarko lahir di Sintang pada tanggal 23 Juni 1980. Lulus S1 Program Studi Teknik Informatika Fakultas Ilmu Komputer Universitas Pembangunan Nasional – Jakarta pada tahun 2004. Lulus Magister Ilmu Komputer Program Pascasarjana Universitas Budi Luhur dengan konsentrasi Rekayasa Komputasi Terapan pada tahun 2019. Saat ini aktif sebagai Dosen tetap di STMIK Antar Bangsa dan praktisi IT di perusahaan swasta.



Kusuma Hati. Lahir di Jakarta, pada tahun 1974. Lulus Program Strata Satu (S1) Jurusan Manajemen Informatika, Universitas Gunadarma Jakarta pada Tahun 1997. Tahun 2006 lulus Program Pasca Sarjana Magister Manajemen, Universitas Budi Luhur. Tahun 2015 Lulus Program Pasca Sarjana Magister Komputer, STMIK Nusa Mandiri Jakarta. Saat ini aktif sebagai Dosen Tetap di Prodi Sistem Informasi, STMIK Antar Bangsa. Aktif juga sebagai peneliti dan penulis jurnal ilmiah, serta anggota Asosiasi Perguruan Tinggi Informatika dan Komputer (APTIKOM).