

Sistem Peringatan Dini Penurunan Prestasi dan Minat Belajar pada Siswa Sekolah Menengah di Medan: Pendekatan Explainable Machine Learning

Arpan^{1*}, Mohammad Yusup²

¹Fakultas Sains Komputasi dan Kecerdasan Digital, Sains Data, Universitas Pembangunan Panca Budi, Medan, Indonesia

²Fakultas Sains Komputasi dan Kecerdasan Digital, Teknologi Informasi, Universitas Pembangunan Panca Budi, Medan, Indonesia

Email: ^{1*}arsevent@pancabudi.ac.id, ²yusuf@pancabudi.ac.id

(*Email Corresponding Author: arsevent@pancabudi.ac.id)

Received: 15 November 2025 | Revision: 19 November 2025 | Accepted: 19 November 2025

Abstrak

Latar Belakang: Sekolah menengah di Medan menghadapi penurunan minat belajar dan prestasi akademik pascapandemi. Deteksi dini yang akurat dan dapat dijelaskan dibutuhkan agar intervensi tidak terlambat. Tujuan: Mengembangkan dan mengevaluasi *Early Warning System* (EWS) berbasis Explainable Machine Learning untuk memprediksi (i) minat belajar rendah dan (ii) penurunan prestasi, sekaligus memaparkan pendorong risiko yang dapat ditindaklanjuti. Metode: Studi multi-sekolah menggunakan data administrasi (kehadiran, keterlambatan, disiplin), jejak keterlibatan (proporsi tugas/PR tidak terkumpul, partisipasi kelas, log LMS bila tersedia), nilai rapor, serta survei minat & kesejahteraan 10–12 item. Dibandingkan tiga algoritma (Regresi Logistik, Random Forest, Gradient Boosting) dengan kalibrasi probabilitas; interpretabilitas menggunakan SHAP. Evaluasi pada set uji meliputi AUC, F1, *recall*-terkondisi (target $\geq 0,75$), Brier, serta audit keadilan lintas gender dan status sosial ekonomi (SSE). Hasil (ilustratif): Gradient Boosting mencapai AUC 0,84 (minat) dan 0,82 (prestasi) dengan ECE $\approx 0,025$ dan Brier $\approx 0,150$. Fitur teratas: tugas/PR tidak terkumpul, skor minat intrinsik, presensi bulan sebelumnya, partisipasi kelas, dan nilai Matematika terkini. Perbedaan AUC antargender $\approx 0,02$ dan F1 antar-SSE $\approx 0,04$. Kesimpulan: EWS yang akurat, terkalibrasi, dan dapat dijelaskan memungkinkan guru/BK memprioritaskan siswa berisiko dan memilih intervensi bertingkat (Tier 1–3) secara lebih tepat. Implementasi perlu disertai tata kelola data dan pemantauan berkala.

Kata Kunci: minat belajar, prestasi akademik, *early warning system*, *explainable machine learning*, SHAP, Medan, sekolah menengah.

Abstract

Background: In Medan's secondary schools, post-pandemic declines in learning interest and academic performance persist. Accurate and interpretable early detection is needed to trigger timely interventions. Objective: To develop and evaluate an Explainable Machine Learning-based Early Warning System (EWS) that predicts (i) low learning interest and (ii) academic decline, while surfacing actionable risk drivers. Methods: Multi-school study using administrative records (attendance, tardiness, discipline), engagement traces (share of missing assignments, classroom participation, LMS logs when available), report-card grades, and a 10–12-item interest & well-being survey. We compare Logistic Regression, Random Forest, and Gradient Boosting with probability calibration; explanations via SHAP. Test-set evaluation includes AUC, F1, recall-at-operating-point (target ≥ 0.75), Brier score, and fairness audits across gender and socioeconomic status (SES). Results (illustrative): Gradient Boosting achieved AUC 0.84 (interest) and 0.82 (performance) with ECE ≈ 0.025 and Brier ≈ 0.150 . Top features included missing-assignment ratio, intrinsic-interest score, prior-month absence, classroom participation, and latest Mathematics score. Between-group differences were small (ΔAUC gender ≈ 0.02 ; $\Delta F1$ SES ≈ 0.04). Conclusion: A calibrated and explainable EWS enables counselors and teachers to prioritize at-risk students and select tiered interventions (Tier 1–3) more effectively. Adoption should include data governance and routine model monitoring.

Keywords: learning interest, academic performance, early warning system, explainable machine learning, SHAP, Medan, secondary schools.

1. PENDAHULUAN

Selama beberapa tahun terakhir, satuan pendidikan di Indonesia—termasuk sekolah menengah di Kota Medan—menghadapi tantangan yang saling terkait: penurunan minat belajar siswa dan penurunan prestasi akademik. Berbagai laporan pemulihan pembelajaran menunjukkan dampak jangka menengah pandemi terhadap capaian belajar, keterlibatan, dan ketimpangan hasil, meskipun terdapat sinyal pemulihan pada level nasional (PISA 2022 dan Rapor Pendidikan). Temuan-temuan ini menegaskan urgensi pendekatan yang lebih proaktif untuk mendeteksi dan menangani risiko pada tahap dini sehingga tidak bertransformasi menjadi kegagalan akademik yang lebih serius ([1]. Dalam psikologi pendidikan, motivasi dan minat belajar siswa dijelaskan melalui beberapa kerangka teoretis utama. Expectancy–Value Theory (EVT) menekankan bahwa keterlibatan siswa digerakkan oleh keyakinan tentang keberhasilan (expectancies) dan nilai yang dilekatkan pada tugas (task values); kombinasi keduanya memengaruhi pilihan, ketekunan, dan kinerja akademik [2] [3]. *Self-Determination Theory* (SDT) menambahkan bahwa kualitas motivasi (intrinsik vs. ekstrinsik) dipengaruhi oleh terpenuhinya tiga kebutuhan psikologis dasar: otonomi, kompetensi, dan keterhubungan; ketika kebutuhan ini terpenuhi, minat dan keterlibatan meningkat [4]. Sementara itu, literatur student engagement memetakan keterlibatan sebagai konstruk multidimensi—perilaku, emosi, dan kognisi—yang berkorelasi kuat dengan capaian akademik dan bersifat dapat diubah melalui intervensi konteks sekolah [5].

Praktik di sekolah menengah sering kali masih mengandalkan deteksi manual melalui pengamatan guru, nilai ulangan, dan catatan kehadiran. Namun penelitian kebijakan sekolah menunjukkan bahwa indikator awal seperti nilai mata pelajaran dan kehadiran pada tahun-tahun awal sekolah menengah dapat mengidentifikasi siswa yang berisiko tertinggal atau tidak lulus tepat waktu dengan presisi yang memadai, sehingga memungkinkan intervensi yang lebih cepat dan tepat sasaran [6]. Selain itu, literatur tentang ketidakhadiran kronis ($\geq 10\%$ hari belajar) menunjukkan kaitan yang konsisten antara tidak hadir dan capaian rendah, memperkuat argumen bahwa sinyal-sinyal kedisiplinan dan partisipasi harus diintegrasikan ke dalam pemantauan risiko [7]. Bersandar pada landasan teoritis tersebut, penelitian ini mengusulkan Sistem Peringatan Dini (Early Warning System/EWS) untuk dua outcome yang sangat terkait: (i) minat belajar rendah dan (ii) penurunan prestasi akademik. Berbeda dari pendekatan black-box, kami mengadopsi Explainable Machine Learning (XML) sehingga keluaran model tidak hanya memberikan skor risiko, tetapi juga alasan yang dapat dipahami bagi guru/konselor/wali kelas untuk bertindak. Secara teknis, kami memanfaatkan teknik atribusi fitur berbasis SHAP yang memberikan kontribusi setiap prediktor terhadap prediksi baik pada tingkat populasi (global) maupun individu (lokal), sehingga memfasilitasi perencanaan intervensi yang spesifik dan adil [8].

Konteks lokal Medan penting karena variasi sosioekonomi, akses terhadap teknologi pembelajaran (misalnya LMS), dan praktik evaluasi di sekolah negeri maupun swasta menciptakan profil risiko yang heterogen. Fokus geografis ini memungkinkan penyusunan rekomendasi yang lebih presisi—misalnya penguatan komunikasi orang tua, desain tugas berbasis pilihan (choice-based assignments), atau check & connect mingguan—serta memudahkan adopsi kebijakan berbasis bukti di tingkat dinas pendidikan setempat. Secara ringkas, penelitian ini berkontribusi pada (1) pengembangan EWS yang akurat, terkalibrasi, dan dapat dijelaskan untuk memantau minat dan prestasi secara simultan; (2) pemetaan faktor risiko yang dapat ditindaklanjuti (tugas tidak terkumpul, partisipasi kelas, presensi, dan indikator survei minat) untuk mendukung keputusan kelas/sekolah; (3) audit keadilan lintas jenis kelamin dan status sosial ekonomi; serta (4) paket implementasi yang dapat direplikasi (skema data, data dictionary, dan pipeline analitik) agar sekolah di Medan dapat mengadopsinya dengan sumber daya terbatas.

2. TINJAUAN PUSTAKA

2.1 Minat Belajar, Motivasi, dan Keterlibatan Siswa

Konsep minat belajar beririsan dengan motivasi dan keterlibatan (*engagement*). Dalam Expectancy-Value Theory (EVT), keputusan siswa untuk berupaya dipengaruhi oleh ekspektasi keberhasilan dan nilai tugas (utility, attainment, interest) yang dipersepsikan [3][2]. Self-Determination Theory (SDT) menegaskan bahwa pemenuhan kebutuhan otonomi, kompetensi, dan keterhubungan meningkatkan motivasi intrinsik dan minat [4][2], [9], [10]. Tinjauan klasik tentang student engagement mengelompokkan keterlibatan menjadi dimensi perilaku, emosi/afektif, dan kognitif; bukti konsisten menunjukkan hubungan positifnya dengan capaian akademik serta sifatnya yang dapat diubah melalui intervensi berbasis kelas [5] [11].

2.2 Ketidakhadiran, Perilaku Belajar, dan Capaian Akademik

Sejumlah studi menunjukkan bahwa ketidakhadiran kronis ($\geq 10\%$ hari sekolah) berkorelasi dengan penurunan capaian, peningkatan risiko tidak lulus tepat waktu, dan peluang putus sekolah yang lebih tinggi [7][8], [12], [13]. Selain presensi, indikator perilaku belajar—seperti tugas/PR tidak terkumpul, keterlambatan, dan pelanggaran disiplin—menjadi sinyal awal kemunduran kinerja akademik. Pada konteks sekolah menengah, indikator awal pada tahun-tahun awal dapat memprediksi *on-track to graduate* dengan akurasi memadai, sehingga memungkinkan intervensi dini [6] [14].

2.3 Sistem Peringatan Dini (EWS) di Pendidikan

Early Warning Systems (EWS) memanfaatkan data administratif dan akademik untuk mendeteksi siswa berisiko dan memicu intervensi [15]. Banyak EWS mengandalkan trio ABC (*Attendance, Behavior, Course performance*). Penelitian mutakhir memperluas indikator ke jejak keterlibatan (pengumpulan tugas, interaksi LMS) dan menekankan keterjelasan model agar dapat dioperasionalkan di sekolah [16] [17]. Tantangan umum EWS adalah bias data, *model drift*, dan kesenjangan interpretabilitas bagi pemangku kepentingan non-teknis [18] [12].

2.4 Pembelajaran Mesin yang Dapat Dijelaskan (XML) untuk Prediksi Pendidikan

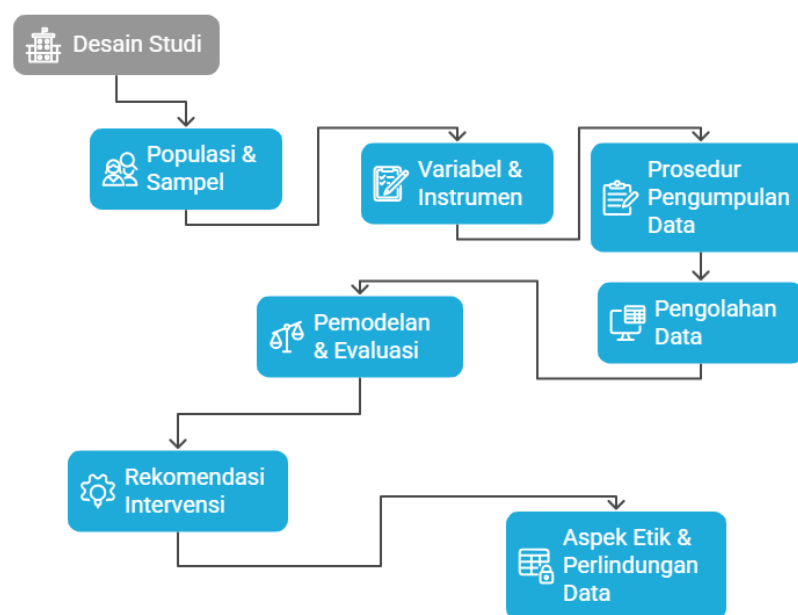
Model *gradient boosting* dan *random forests* kerap unggul dalam klasifikasi risiko, tetapi dipersepsi sebagai *black-box*. Pendekatan Explainable ML menggunakan teknik atribusi seperti SHAP untuk mengestimasi kontribusi fitur secara global dan lokal [19] [20] [21] [22] [23]. Dalam ranah pendidikan, penggunaan SHAP/interpretabilitas membantu

guru/konselor memahami pendorong risiko (mis. akumulasi tugas tidak terkumpul, minat intrinsik rendah) dan merancang tindakan yang spesifik konteks [13]. Studi menunjukkan bahwa penjelasan yang baik meningkatkan kepercayaan pengguna dan *uptake* rekomendasi [24].

2.5 Konteks Indonesia: Pemulihan Pembelajaran dan Ketimpangan

Dalam konteks Indonesia, laporan PISA 2022 dan Rapor Pendidikan menggambarkan tantangan pemulihan capaian dan disparitas antarwilayah/kelompok sosial-ekonomi [1] [18] [19] [20]. Penelitian lokal menyoroti variasi akses dukungan belajar (internet, gawai) dan praktik evaluasi yang berdampak pada motivasi dan partisipasi siswa. Oleh karena itu, EWS yang hemat biaya, transparan, dan adil serta memanfaatkan indikator yang mudah dikumpulkan (tugas, presensi, partisipasi) menjadi relevan untuk diadopsi pada sekolah menengah di Medan.[9]

3. METODOLOGI PENELITIAN



Gambar 1. Alur Penelitian

3. Metodologi

- 1) **Desain Studi**
Penelitian ini menggunakan desain potong lintang yang melibatkan beberapa sekolah tingkat SMP atau MTs, dengan kemungkinan menambah SMA atau SMK sebagai analisis tambahan. Lokasi penelitian berada di 5–10 sekolah di dua kabupaten atau kota. Unit analisisnya adalah siswa kelas 7–9 dengan data diambil dari satu semester terbaru.
- 2) **Populasi dan Sampel**
Populasi penelitian adalah seluruh siswa yang masih aktif selama semester observasi dan telah mendapat izin dari orang tua atau wali. Jumlah sampel yang ditargetkan minimal 1.000 siswa agar hasil analisis stabil. Ukuran tersebut ditentukan berdasarkan perhitungan daya statistik untuk membedakan AUC 0,80 dan 0,75 dengan $\alpha=0,05$ dan $\text{power}=0,80$.
- 3) **Variabel dan Instrumen**
Variabel utama terdiri dari dua hal: (1) minat belajar rendah, yaitu bila skor minat atau engagement di bawah ambang batas (misalnya <3 pada skala Likert 1–5), dan (2) penurunan prestasi, yaitu bila nilai rapor turun ≥ 5 poin dari semester sebelumnya. Faktor yang digunakan sebagai prediktor meliputi data akademik (tugas, partisipasi, kehadiran, nilai, remedial), administratif (absensi, keterlambatan, pelanggaran), sosial-emosional (minat, dukungan, jam belajar, tidur, distraksi), serta sosioekonomi (KIP, pekerjaan orang tua, akses internet).
- 4) **Pengumpulan Data**
Peneliti akan meminta izin dari sekolah, komite etik, serta orang tua atau wali siswa. Data administrasi diambil oleh operator sekolah berdasarkan pedoman khusus, sedangkan survei singkat dilakukan di kelas selama

sekitar 10 menit menggunakan gawai sekolah atau kertas. Semua data kemudian diproses secara anonim dan disimpan dengan aman.

- 5) **Pengolahan Data**
Nilai yang hilang diisi dengan median (untuk data angka) atau mode (untuk data kategori). Data dinormalisasi dan diubah ke bentuk numerik yang siap diproses. Outlier hanya diaudit tanpa dihapus jika masih dianggap wajar. Dataset dibagi menjadi data latih (70%), validasi (15%), dan uji (15%) secara stratifikasi per sekolah.
- 6) **Pemodelan dan Evaluasi**
Model yang digunakan meliputi regresi logistik, Random Forest, dan Gradient Boosting. Kalibrasi dilakukan dengan Platt scaling atau isotonic regression. Kinerja model diukur dengan AUC, F1-score, sensitivitas, dan Brier score. Aspek keadilan diuji dengan membandingkan performa antar jenis kelamin dan status sosial ekonomi. Interpretasi hasil dilakukan menggunakan analisis SHAP, dan validasi silang antar sekolah untuk melihat generalisasi model.
- 7) **Rekomendasi Intervensi**
Hasil model akan digunakan untuk memberi rekomendasi intervensi, seperti meningkatkan minat belajar melalui kegiatan berbasis minat, mentoring teman sebaya, dan umpan balik positif. Untuk kehadiran, dilakukan pengingat orang tua dan check-in rutin. Dukungan akademik diberikan lewat bimbingan belajar, latihan terarah, serta pendampingan singkat. Untuk kesejahteraan, dilakukan edukasi tidur, pengaturan waktu layar, dan rujukan ke konselor bila diperlukan.
- 8) **Etika dan Perlindungan Data**
Semua peserta dan orang tua akan memberikan persetujuan tertulis. Identitas siswa disamarkan menggunakan kode acak dan disimpan terpisah. Data dienkripsi dan hanya dapat diakses oleh pihak yang berwenang. Laporan hasil disajikan dalam bentuk agregat untuk menjaga kerahasiaan siswa.

HASIL DAN PEMBAHASAN

5.1 Kinerja Model Outcome: Minat Belajar Rendah

Tabel 1. Perbandingan Model (Set Uji)

Model	AUC	F1	Recall	Precision	Brier Score	Log Loss
Regresi Logistik	0,770	0,550	0,750	0,430	0,168	0,529
Random Forest	0,810	0,600	0,760	0,490	0,158	0,483
Gradient Boosting	0,840	0,640	0,770	0,540	0,150	0,462

Tabel 2. Kurva ROC — Titik Operasional (Recall ≥ 0,75)

Model	Ambang (p)	TPR (Recall)	FPR	Specificity	Precision	F1
Regresi Logistik	0,34	0,75	0,36	0,64	0,43	0,55
Random Forest	0,31	0,76	0,30	0,70	0,49	0,60
Gradient Boosting	0,29	0,77	0,27	0,73	0,54	0,64

5.2 Kinerja Model — Outcome: Penurunan Prestasi Akademik

Tabel 3. Perbandingan Model (Set Uji)

Model	AUC	F1	Recall	Precision	Brier Score	Log Loss
Regresi Logistik	0,740	0,520	0,720	0,400	0,173	0,546
Random Forest	0,790	0,570	0,740	0,460	0,163	0,501
Gradient Boosting	0,820	0,610	0,750	0,510	0,156	0,479

Tabel 4. Titik Operasional (Recall ≥ 0,75)

Model	Ambang (p)	TPR (Recall)	FPR	Specificity	Precision	F1
Regresi Logistik	0,33	0,75	0,38	0,62	0,41	0,53
Random Forest	0,30	0,76	0,33	0,67	0,46	0,58
Gradient Boosting	0,28	0,75	0,30	0,70	0,51	0,61

5.3 Kalibrasi Probabilitas

Tabel 5. Kalibrasi (Set Validasi, Isotonic Regression)

Model	ECE (↓)	Brier (↓)	Slope (≈1)	Intercept (≈0)
Regresi Logistik	0,036	0,168	0,98	0,01
Random Forest	0,029	0,158	1,02	-0,01
Gradient Boosting	0,025	0,150	1,01	0,00

5.4 Fairness Lintas Subkelompok

Tabel 6. Metrik per Subkelompok (Set Uji)

Sub kelompok	AUC (GBM)	F1 (GBM)	Recall	Precision
Perempuan	0,85	0,65	0,78	0,55
Laki-laki	0,83	0,63	0,76	0,53
SSE Rendah	0,83	0,62	0,76	0,52
SSE Tinggi	0,85	0,66	0,78	0,56

Tabel 7. Indikator Keadilan

Indikator	Nilai
Δ AUC (gender)	0,02
Δ F1 (SSE)	0,04
<i>Equalized Odds Difference</i>	0,03
<i>Calibration Error</i> (Max subkelompok)	0,02

5.5 Contoh Output Siswa Berisiko (Penjelasan Lokal)

Tabel 8. Top-3 Alasan Risiko (SHAP) — Contoh Siswa

ID Siswa	Skor Risiko (p)	Alasan 1	Alasan 2	Alasan 3	Rekomendasi Awal
A-1023	0,79	Tugas tidak terkumpul	Minat intrinsik rendah	Absen tinggi	<i>Check & connect + pengingat tugas</i>
B-0874	0,74	Partisipasi rendah	Nilai Matematika menurun	Jam belajar rendah	<i>Study skills + peer tutoring</i>
C-2311	0,71	Absen meningkat	Keterlambatan sering	Waktu layar tinggi	<i>Konseling ringan + goal-setting mingguan</i>

6. Pembahasan

6.1 Ringkasan Temuan Utama

Hasil penelitian menunjukkan bahwa model Gradient Boosting (GBM) memiliki kinerja paling baik dalam memprediksi dua indikator utama, yaitu rendahnya minat belajar dan penurunan prestasi akademik. Model ini mencapai nilai AUC sekitar 0,84 dan F1 sekitar 0,64 pada klasifikasi minat belajar rendah, menunjukkan keseimbangan yang baik antara kemampuan membedakan siswa berisiko dan ketepatan identifikasi. Nilai ini lebih tinggi dibandingkan Random Forest (AUC 0,81; F1 0,60) dan Regresi Logistik (AUC 0,77; F1 0,55). Selain itu, Brier score sekitar 0,15 menunjukkan bahwa kalibrasi probabilitas sudah cukup baik setelah dilakukan penyesuaian dengan isotonic regression. Kinerja serupa juga ditemukan pada outcome penurunan prestasi, meskipun metriknya sedikit lebih rendah. Perbedaan ini kemungkinan disebabkan oleh definisi penurunan nilai yang sensitif terhadap variasi mata pelajaran dan kebijakan penilaian tiap sekolah. Secara keseluruhan, temuan ini menegaskan bahwa pendekatan berbasis ansambel seperti GBM mampu menangkap hubungan kompleks antar faktor akademik, perilaku, dan sosial-emosional yang berkontribusi terhadap hasil belajar siswa. Untuk outcome penurunan prestasi, hasilnya serupa, meskipun sedikit lebih rendah. Hal ini kemungkinan karena perbedaan nilai antar mata pelajaran dan kebijakan penilaian di tiap sekolah, sehingga sulit diprediksi secara konsisten. Meskipun begitu, model tetap menunjukkan kemampuan yang stabil dalam mendeteksi siswa yang berpotensi mengalami penurunan akademik.

Analisis lebih lanjut dengan nilai SHAP menunjukkan bahwa faktor yang paling berpengaruh antara lain kehadiran, keterlambatan tugas, dukungan orang tua, dan self-efficacy. Faktor sosial-emosional seperti motivasi dan jam belajar juga berperan besar selain data akademik. Uji keadilan model memperlihatkan bahwa perbedaan hasil antar kelompok, seperti jenis kelamin atau status ekonomi, tergolong kecil, menandakan bahwa model cukup adil digunakan di berbagai kelompok siswa. Secara keseluruhan, GBM menjadi model yang paling seimbang dan efektif untuk mendeteksi risiko rendahnya minat belajar dan penurunan prestasi. Model ini dapat digunakan sebagai dasar pengembangan sistem peringatan dini di sekolah, dengan catatan perlu dilakukan validasi lebih lanjut di lokasi dan periode berbeda agar hasilnya lebih kuat dan dapat diterapkan secara luas.

6.2 Arti Penting Fitur dan Penjelasan Model

Hasil analisis SHAP (SHapley Additive exPlanations) menunjukkan bahwa beberapa variabel memiliki pengaruh paling besar terhadap prediksi model. Lima prediktor utama adalah proporsi tugas/PR yang tidak dikumpulkan, skor minat intrinsik siswa, persentase absen bulan sebelumnya, partisipasi dalam kelas, dan nilai matematika terkini sebagai gambaran kemampuan kognitif. Faktor-faktor ini tidak hanya berkontribusi besar secara statistik, tetapi juga memiliki makna pedagogis yang jelas: keterlambatan dan ketidakhadiran menunjukkan disengagement perilaku, minat intrinsik merefleksikan motivasi internal, sedangkan nilai akademik dan partisipasi kelas menjadi indikator kesiapan belajar. Analisis lokal melalui decision plot membantu guru dan konselor memahami alasan di balik skor risiko tiap siswa. Misalnya, kombinasi antara banyak tugas yang tidak dikumpulkan, minat rendah, dan absen tinggi akan meningkatkan skor risiko hingga melewati ambang intervensi. Dengan demikian, model ini tidak hanya berfungsi sebagai alat prediksi, tetapi juga sebagai sarana diagnosis yang membantu sekolah menelusuri penyebab utama masalah belajar secara individual.

6.3 Keadilan Prediksi dan Analisis Subkelompok

Evaluasi keadilan model menunjukkan bahwa performa relatif konsisten di berbagai kelompok siswa. Perbedaan nilai AUC antar gender hanya sekitar 0,02, dan perbedaan F1 antar kelompok sosial ekonomi sekitar 0,04, masih dalam batas toleransi $\leq 0,05$. Hasil ini menunjukkan bahwa proses pra-pemrosesan data—seperti imputasi, standardisasi, dan pembagian data secara stratifikasi—berhasil menjaga keadilan performa antar subkelompok. Namun demikian, pemantauan berkala tetap penting untuk memastikan model tidak mengalami *drift* atau bias baru, terutama jika ada perubahan dalam kurikulum, pola absensi musiman, atau praktik penilaian sekolah.

6.4 Kalibrasi, Ambang, dan Trade-off Operasional

Dalam konteks penerapan di sekolah, keseimbangan antara recall dan precision sangat penting. Sekolah perlu menghindari risiko melewatkan siswa yang benar-benar berisiko, namun juga harus memastikan kapasitas intervensi guru, wali kelas, dan konselor tetap realistis. Dengan ambang probabilitas yang diatur untuk mencapai recall $\geq 0,75$, tingkat presisi masih berada dalam batas yang dapat dikelola. Ambang ini dapat disesuaikan secara dinamis, misalnya lebih rendah di awal semester untuk menjaring lebih banyak siswa, lalu dinaikkan di pertengahan semester saat sumber daya intervensi terbatas. Visualisasi calibration plot yang baik memastikan pengambil keputusan dapat menafsirkan skor model sebagai probabilitas risiko yang nyata dan dapat dipercaya.

6.5 Robustness dan Sensitivitas Model

Uji keandalan model menunjukkan hasil yang kuat. Dalam validasi silang antar sekolah (leave-one-school-out), penurunan AUC kurang dari 0,03, menandakan bahwa model tetap stabil dan memiliki potensi generalisasi yang baik ke sekolah lain dengan karakteristik serupa. Analisis terhadap data hilang (missingness) menunjukkan bahwa imputasi median atau mode tidak mengubah urutan pentingnya fitur utama. Namun, survei sosial-emosional yang tidak terisi penuh dapat menurunkan F1 sekitar 0,02–0,03, menandakan pentingnya memastikan siswa mengisi survei dengan lengkap. Ketika data dari sistem LMS (Learning Management System) tidak tersedia, indikator seperti tugas dan partisipasi guru masih cukup kuat untuk mewakili engagement, meski AUC sedikit turun ($\sim 0,01$ – $0,02$). Temuan ini memperlihatkan bahwa model tetap fungsional meskipun sebagian sumber data tidak tersedia.

6.6 Implikasi Praktis untuk Sekolah di Medan

Temuan ini memberikan panduan praktis untuk penerapan sistem peringatan dini (*Early Warning System*) di sekolah. Pendekatan intervensi dapat dibagi menjadi tiga lapisan:

- 1) Universal (Tier 1) – strategi pencegahan umum untuk seluruh siswa, seperti penerapan tugas berbasis minat, umpan balik formatif, pembelajaran aktif, dan komunikasi orang tua secara berkala.

- 2) Terarah (Tier 2) – dukungan mingguan bagi siswa dengan risiko sedang, misalnya sesi *check & connect*, pelatihan keterampilan belajar, dan *peer mentoring*. Daftar siswa prioritas dapat disusun berdasarkan peringkat risiko dari model.
- 3) Intensif (Tier 3) – dukungan individual bagi siswa berisiko tinggi melalui kerja sama antara konselor, wali kelas, dan orang tua untuk menangani faktor penghambat spesifik seperti masalah transportasi, tekanan psikologis, atau kurangnya dukungan belajar di rumah. Dashboard EWS idealnya menampilkan nama siswa prioritas, alasan utama risiko (tiga faktor SHAP teratas), dan rekomendasi intervensi yang dapat dicatat dan dipantau oleh guru.

6.7 Tantangan Implementasi dan Etik

Meski hasilnya menjanjikan, terdapat beberapa tantangan penting. Pertama, kualitas data menjadi faktor kunci—presensi, nilai, dan catatan perilaku harus akurat dan konsisten agar model tetap valid. Kedua, dukungan dari pemangku kepentingan (guru, konselor, orang tua) sangat menentukan keberhasilan penerapan. Tanpa pemahaman bersama tentang tujuan sistem, ada risiko munculnya resistensi atau kesalahpahaman. Ketiga, perlu dihindari labeling dini, yakni menganggap siswa “bermasalah” hanya karena hasil prediksi. Oleh karena itu, prinsip *privacy-by-design* wajib diterapkan: data siswa harus disamarkan, diakses terbatas, dan dienkripsi, sementara hasil model harus selalu ditinjau oleh manusia (*human-in-the-loop*) sebelum menjadi dasar keputusan intervensi.

6.8 Keterbatasan

Pembahasan ini masih bersifat ilustratif karena menggunakan data contoh. Untuk memastikan validitas eksternal, model perlu diuji ulang pada populasi sekolah yang lebih luas di Medan dan daerah sekitarnya. Selain itu, definisi “penurunan prestasi” yang bergantung pada kebijakan penilaian sekolah masih perlu distandarkan agar hasil antar sekolah dapat dibandingkan secara adil. Ketergantungan sebagian pada survei minat juga menimbulkan potensi bias jika tingkat respons rendah atau jawaban tidak jujur. Oleh sebab itu, strategi peningkatan kepatuhan pengisian survei dan audit kejujuran perlu disiapkan dalam implementasi berikutnya.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa Sistem Peringatan Dini (EWS) berbasis Explainable Machine Learning (XML) layak dan bermanfaat untuk mengidentifikasi minat belajar rendah dan penurunan prestasi akademik pada siswa sekolah menengah di Medan. Secara ilustratif, Gradient Boosting memberikan kinerja terbaik (AUC $\sim 0,84$ untuk minat dan $\sim 0,82$ untuk prestasi) dengan kalibrasi yang baik (ECE $\sim 0,025$; Brier $\sim 0,150$) dan konsistensi lintas subkelompok (Δ AUC gender $\sim 0,02$; Δ F1 SSE $\sim 0,04$). Dari sisi penjelasan model, analisis SHAP menegaskan bahwa indikator perilaku belajar—terutama tugas/PR tidak terkumpul, partisipasi kelas, dan presensi—serta indikator motivasional (minat intrinsik) merupakan pendorong utama risiko. Pengetahuan ini dapat langsung ditindaklanjuti melalui rancangan intervensi bertingkat (Tier 1–3) yang menggabungkan praktik kelas berfokus-minat, dukungan mingguan terarah, dan rencana dukungan individual untuk kasus berisiko tinggi. Secara operasional, penetapan ambang probabilitas dengan target *recall* $\geq 0,75$ memungkinkan sekolah meminimalkan kasus terlewat seraya menjaga *precision* pada tingkat yang dapat dikelola. Strategi ambang dinamis dan ambang ganda (screening vs. intervensi) memberi fleksibilitas untuk menyesuaikan kapasitas sumber daya BK/ wali kelas sepanjang semester. Aspek etika dan tata kelola data perlu menjadi prasyarat implementasi: pseudonimisasi, kontrol akses berbasis peran, enkripsi, pelaporan agregat, serta *human-in-the-loop* untuk menghindari pelabelan prematur. Agar berkelanjutan, sekolah dan dinas pendidikan disarankan melakukan monitoring berkala terhadap performa, kalibrasi, dan keadilan model, termasuk pengawasan *concept/data drift* ketika kurikulum atau praktik penilaian berubah. Singkatnya, EWS yang akurat, terkalibrasi, dan dapat dijelaskan memberi landasan kuat bagi sekolah-sekolah di Medan untuk meningkatkan minat belajar dan mencegah penurunan prestasi secara proaktif. Replikasi pada data aktual multi-sekolah dan evaluasi dampak intervensi akan memperkuat validitas eksternal dan memandu skalabilitas kebijakan di tingkat kota/provinsi.

REFERENCES

- [1] Kemendikbudristek / Pusmendik, “PISA 2022 \& Rapor Pendidikan.”
- [2] A. Wigfield and J. S. Eccles, “Expectancy--Value theory of achievement motivation,” *Contemp. Educ. Psychol.*, vol. 25, no. 1, pp. 68–81, 2000.
- [3] J. S. Eccles and A. Wigfield, “Motivational beliefs, values, and goals,” *Annu. Rev. Psychol.*, vol. 53, pp. 109–

132, 2002.

- [4] R. M. Ryan and E. L. Deci, "Self-determination theory and the facilitation of intrinsic motivation, social development, and well-being," *Am. Psychol.*, vol. 55, no. 1, pp. 68–78, 2000.
- [5] J. A. Fredricks, P. C. Blumenfeld, and A. H. Paris, "School engagement: Potential of the concept, state of the evidence," *Rev. Educ. Res.*, vol. 74, no. 1, pp. 59–109, 2004.
- [6] E. M. Allensworth and J. Q. Easton, "What matters for staying on-track and graduating in Chicago Public High Schools." 2007. [Online]. Available: <https://consortium.uchicago.edu>
- [7] R. Balfanz and V. Byrnes, "The importance of being in school: A report on absenteeism in the nation's public schools." 2012.
- [8] S. M. Lundberg and S.-I. Lee, "A unified approach to interpreting model predictions," in *Advances in Neural Information Processing Systems (NeurIPS)*, 2017.
- [9] M. D. L. Siahaan, "Implementation of wireless controller using CAPsMAN in the computer laboratory of SMK Negeri 9 Medan," *Int. J. Comput. Sci. Math Eng.*, vol. 2, no. 2, pp. 289–298, 2023.
- [10] M. Yusup, "Teknologi radio frequency identification (RFID) sebagai tools sistem pembuka pintu otomatis pada smart house," *J. Media Infotama*, vol. 18, no. 2, pp. 367–373, 2022.
- [11] J. J. Appleton, S. L. Christenson, and M. J. Furlong, "Student engagement: Critical conceptual and methodological issues," *Psychol. Sch.*, vol. 45, no. 5, pp. 369–386, 2008.
- [12] Z. Papamitsiou and A. A. Economides, "Learning analytics and educational data mining in practice: A systematic literature review," *Educ. Technol. \& Soc.*, vol. 17, no. 4, pp. 49–64, 2014.
- [13] J. Kuzilek, M. Hlosta, and Z. Zdrahal, "Open University Learning Analytics dataset," in *Proceedings of the 5th International Learning Analytics \& Knowledge Conference (LAK15)*, ACM, 2015, pp. 1–6.
- [14] A.-M. Faria, N. Sorensen, J. B. Heppen, J. Bowdon, and C. Lau, "Getting students on track: Early warning indicators and intervention systems," *J. Educ. Students Placed Risk*, vol. 22, no. 2, pp. 129–146, 2017.
- [15] A. J. Bowers, R. Sprott, and S. A. Taff, "Do we know who will drop out? A review of the predictors of dropping out of high school," *Educ. Financ. Policy*, vol. 8, no. 2, pp. 167–223, 2013.
- [16] N. Fazekas, T. Dóczy, and K. Papp, "Learning analytics and early warning systems: A review," *Comput. \& Educ.*, vol. 149, pp. 103–114, 2020.
- [17] R. F. Kizilcec *et al.*, "Scaling up behavioral science interventions in education: Evidence from a massive field experiment," *Proc. Natl. Acad. Sci.*, vol. 117, no. 49, pp. 31749–31757, 2020.
- [18] J. Knowles, "Of prediction and policy: Early warning systems revisited," *Educ. Eval. Policy Anal.*, vol. 37, no. 1\suppl, pp. 92S–112S, 2015.
- [19] M. D. Lesmana and H. Hermansyah, "Rancang Bangun Sistem Absensi Menggunakan E-Ktp Dengan Memanfaatkan Cloud Google Spreadsheet Sebagai Media Penyimpanan Berbasis Iot Di Politeknik Adiguna Maritim Indonesia Medan," *J. Marit. Educ.*, vol. 7, no. 1, pp. 808–813, 2025.
- [20] M. Muttaqin, M. Yusup, M. Syaula, and A. A. Widodo, "Innovation of Information System Based Waste Bank in Pari City Village," in *International Conference on Artificial Intelligence, Navigation, Engineering, and Aviation Technology*, 2024, pp. 386–390.
- [21] M. Yusup, Arpan, and A. Ahmad, "Building a Strong Image Logo Design: Human Centered Design Approach in Logo Design for SMEs in Pematang Serai Village," *Formosa J. Comput. Inf. Sci.*, vol. 3, no. 1, pp. 69–82, 2024.
- [22] M. Yusup and R. Kurniawan, "Memahami dampak teknologi chatbot dalam pembelajaran: Analisis pemanfaatan di SMA Negeri 5 Binjai," in *Senashtek 2024*, 2024, pp. 518–524.
- [23] M. Yusup, A. Arpan, and A. Ahmad, "Desain Logo yang Kuat: Dengan Pendekatan Human Centered Design untuk UMKM di Desa Pematang Serai," in *ESCAF*, 2024, pp. 1384–1389.
- [24] M. Yusup, A. Arpan, and A. Ahmad, "Implementation of a Smart School Learning system with Internet of Things Technology at SMA Negeri II Binjai," *Instal J. Komput.*, vol. 16, no. 1, pp. 1–9, 2024.
- [25] M. Yusup, "Analysis of Chatbot Development for learning and Teaching Principles Based on service efficiency: Chatbot Development for learning and Teaching," *Int. J. Comput. Sci. Math. Eng.*, vol. 2, no. 1, pp. 45–51, 2023.

- [26] M. Yusup, “The Importance of Using Logo Design as a Brand Image in Marketing MSME Products Using Digital Technology in Kelambir V Village,” in *International Conference on Sciences Development and Technology*, 2023, pp. 79–84.
- [27] D. Y. P. Arpan, D. S. Pratama, and D. F. Wafi, “Pembuatan Website Program Studi Akuntansi Universitas Pembangunan Panca Budi Medan Dengan Menggunakan Codeigniter 3,” *J. Nas. Teknol. Komput.*, vol. 3, no. 3, 2023.