

BAB II

TINJAUAN PUSTAKA

2.1 Tinjauan Pustaka

Peninjauan terhadap penelitian-penelitian terdahulu menjadi langkah fundamental untuk memahami perkembangan analitika prediktif di bidang pendidikan, serta untuk memosisikan letak kebaruan (*novelty*) dari eksperimen ini. Penggunaan algoritma *machine learning* dan *Deep Learning* dalam memprediksi kinerja akademik telah dieksplorasi secara luas.

Penggunaan Feed-forward Multi-Layer Perceptron (MLP/FNN) pada data demografis untuk memprediksi capaian siswa, dan membuktikan bahwa jaringan saraf tiruan mampu mengekstraksi data tabular lebih baik daripada metode statistik klasik [11]. Hal ini menunjukkan bahwa Deep Learning sangat tangguh dalam menangani relasi non-linear yang kompleks dari variabel eksternal keseharian mahasiswa. Lebih jauh, literatur menyoroti pentingnya model Deep Learning sebagai fondasi Sistem Peringatan Dini (*Early Warning System*) agar institusi dapat mengambil langkah korektif di semester awal sebelum mahasiswa terancam dropout [7].

Seiring berkembangnya kompleksitas data, arsitektur Recurrent Neural Network (RNN) dan variannya mulai diadaptasi. Penelitian mengembangkan model Hybrid ANN-LSTM untuk kelas daring (MOOC) yang membuktikan bahwa mekanisme memori LSTM sangat efektif dalam membedah riwayat ketertinggalan belajar secara temporal [21]. Dengan adanya kapabilitas ini, eksplorasi tingkat lanjut mengimplementasikan Bi Directional LSTM (Bi LSTM) yang dipadukan dengan SHAP untuk memberikan penjelasan (*interpretability*) terhadap fitur akademik yang paling dominan [19]. Eksplorasi kerangka hibrida tingkat lanjut juga dikaji dengan mengusulkan CNN-LSTM untuk mengatasi noise pada data performa siswa yang fluktuatif [8].

2.1.1 Penelitian Terdahulu

Untuk mendapatkan referensi tentang pendekatan kalsifikasi dengan model FNN & LSTM, Berikut ini adalah hasil penelitian sebelumnya yang digunakan sebagai referensi dan panduan untuk melakukan penelitian ini.

Tabel 2.1 Daftar penelitian terdahulu

No	Penulis & Tahun	Algoritma & Metodologi	Hasil dan Relevansi Kritis
1	Thaher et al. (2020)	Feed-forward Multi-Layer Perceptron (MLP/FNN) pada data demografis sekolah.	Membuktikan FNN sangat baik dalam ekstraksi data tabular. Namun tidak menyentuh limitasi data yang sangat asimetris (class imbalance).
2	Wen et al. (2023)	Analitik prediktif berbasis Deep Learning untuk Sistem Peringatan Dini.	Menyoroti urgensi pembangunan profil prediktif mahasiswa di semester awal agar institusi dapat segera mengambil langkah korektif.
3	Al-azazi et al. (2023)	Hybrid ANN-LSTM untuk kelas daring MOOC.	Menunjukkan bahwa memori LSTM tangguh dalam membedah ketertinggalan belajar, walau data utamanya bersifat log time-series.
4	Airlangga et al. (2024)	Eksplorasi ragam model Deep Learning dalam klasifikasi status belajar mahasiswa.	Mengonfirmasi superioritas DL ketimbang machine learning konvensional pada relasi faktor eksternal multivariat.
5	Kalita et al. (2025)	Prediksi akademik menggunakan Bi-LSTM dengan penjas fitur SHAP.	Memperkuat argumen bahwa Bi-Directional LSTM memberikan pandangan dua arah yang memperkuat pembobotan attention model.
6	Adefemi et al. (2025)	Hybrid CNN-LSTM untuk prediksi performa siswa secara robust.	Menunjukkan bahwa abstraksi spasial fitur (CNN) dan temporal (LSTM) jika diselaraskan bisa mengatasi data yang sangat bising (noisy).
7	Arévalo-Cordovilla & Peña (2024)	Analisis komparatif model machine learning untuk	Menggunakan kombinasi data LMS dan faktor eksternal sebagai prediktor.

		memprediksi kesuksesan siswa.	
8	Boujmiraz et al. (2026)	Tinjauan komprehensif machine learning, deep learning, dan explainable AI.	Menyajikan metode evaluasi terkini untuk memprediksi performa siswa.
9	Li et al. (2022)	Prediksi pencapaian siswa menggunakan deep neural network.	Mengintegrasikan multi-source campus data untuk meningkatkan presisi.
10	Alkan et al. (2025)	Penggunaan machine learning untuk memprediksi outcome siswa.	Diaplikasikan khusus untuk intervensi dini dan penilaian formatif.
11	Ramazan (2026)	Pengembangan model <i>hybrid deep learning</i> berbasis <i>temporal attention</i> untuk memprediksi performa dan risiko akademik siswa.	Mengintegrasikan data perilaku temporal (aktivitas mingguan di platform pembelajaran) dengan karakteristik statis siswa (demografi) untuk meningkatkan akurasi deteksi dini pada siswa yang berisiko.

2.2 Definisi Indikator Akademik & Faktor Eksternal

Pada penelitian ini, capaian akademik diwakili oleh Indeks Prestasi Kumulatif (IPK) yang berperan sebagai variabel target. Adapun yang dimaksud dengan faktor eksternal adalah berbagai variabel penentu yang berada di luar kemampuan kognitif alami mahasiswa. Faktor-faktor tersebut mencakup empat kelompok utama. Pertama, aspek finansial, yang terdiri dari besaran uang saku bulanan dan beban biaya hidup. Kedua, aspek keluarga, meliputi keutuhan struktur keluarga serta dukungan emosional yang diterima. Ketiga, aspek lingkungan dan fasilitas, yakni kepemilikan perangkat penunjang seperti laptop dan kualitas akses internet. Keempat, aspek manajemen diri, yang mencakup keterlibatan dalam organisasi kampus (baik intra maupun ekstra), durasi kerja paruh waktu, dan kualitas waktu tidur. Keterkaitan antarfaktor inilah yang kerap luput tertangkap oleh kuesioner konvensional. Pola hubungan yang kompleks tersebut baru dapat terungkap apabila data diolah menggunakan pemodelan komputasi yang lebih canggih.

2.3 Arsitektur Feedforward Neural Network (FNN)

Feedforward Neural Network (FNN) merupakan representasi paling dasar dari *Artificial Neural Network* (ANN), di mana aliran informasi bergerak searah (*feedforward*) dari lapisan masukan (*input layer*), melewati satu atau lebih lapisan tersembunyi (*hidden layers*), menuju lapisan keluaran (*output layer*) tanpa adanya siklus atau umpan balik (*loop*). Secara matematis, untuk sebuah lapisan tersembunyi, nilai komputasi pra aktivasi $z^{[l]}$ dan keluaran pasca aktivasi $a^{[l]}$ pada jaringan FNN didefinisikan melalui persamaan:

$$z^{[l]} = W^{[l]}a^{[l-1]} + b^{[l]}$$

$$a^{[l]} = \sigma(z^{[l]})$$

Di mana $W^{[l]}$ merepresentasikan matriks bobot (*weights*), $a^{[l-1]}$ adalah vektor keluaran dari lapisan sebelumnya, $b^{[l]}$ merepresentasikan vektor bias, dan σ adalah fungsi aktivasi non-linear. Pada penelitian ini, fungsi aktivasi *Rectified Linear Unit* (ReLU) digunakan pada *hidden layers* untuk mencegah hilangnya gradien (*vanishing gradient*), yang dirumuskan sebagai:

$$f(x) = \max(0, x)$$

Meskipun FNN handal dalam memetakan relasi spasial dari data tabular, arsitektur ini memproses seluruh vektor fitur secara simultan (dimensi ruang datar). Kondisi ini menyebabkan model FNN tidak mampu mendeteksi korelasi urutan sebab-akibat antar variabel, yang pada dataset survei sering kali memicu stagnasi kemampuan prediktif yang dikenal sebagai *Signal Ceiling*.

2.4 Arsitektur Long Short-Term Memory (LSTM) dan Sekuensial

Untuk mengatasi keterbatasan FNN dalam memproses ketergantungan antar-atribut, diimplementasikan arsitektur Long Short-Term Memory (LSTM). LSTM adalah varian canggih dari Recurrent Neural Network (RNN) yang dirancang secara khusus untuk menyimpan informasi jangka panjang melalui modifikasi struktur gerbang (gates). Keunggulan LSTM dalam menangkap pola sekuensial yang panjang telah dibuktikan pada berbagai disiplin, termasuk dalam riset [1] yang menggunakan LSTM untuk ekstraksi fitur musik berbasis ketukan. Pada penelitian ini, konsep sekuensial diadaptasi menjadi Sekuens Tematik, di mana 8 domain kehidupan mahasiswa dibaca sebagai deret langkah waktu (timestep).

Sel memori LSTM terdiri dari tiga gerbang utama: Forget gate f_t , Input gate i_t , dan Output gate o_t . Operasi matematis pada sebuah sel LSTM pada waktu ke t dijabarkan sebagai berikut:

Forget Gate: Menentukan informasi masa lalu dari status sel sebelumnya C_{t-1} yang harus dibuang.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

Input Gate & Candidate Cell: Menentukan informasi baru yang akan ditambahkan ke status sel.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

Cell State Update: Memperbarui status memori internal.

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

Output Gate: Menentukan keluaran (hidden state h_t) yang akan diteruskan ke iterasi berikutnya.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

Dalam kerangka optimasi, penelitian ini menggunakan *Bidirectional LSTM* (*BiLSTM*) agar model mengevaluasi sekuens faktor eksternal dari arah depan (finansial menuju akademik) dan arah belakang (akademik merunut ke finansial) secara bersamaan. Lapisan mekanisme atensi (*Attention Mechanism*) turut diintegrasikan agar algoritma secara otomatis memberikan bobot (*weight penalty*) lebih tinggi pada timestep yang paling destruktif bagi probabilitas IPK.

2.5 Pruned Binary Classification dan Tata Kelola Evaluasi

Salah satu tantangan terbesar dalam klasifikasi berbasis survei adalah distribusi kelas yang sangat asimetris. Fenomena inflasi nilai menyebabkan data mahasiswa menumpuk di area skor tinggi (*top-heavy*). Dalam literatur medis dan biometrika, pendekatan *Ensemble Deep Learning* dengan teknik sintesis kelas minoritas seperti SMOTE lazim digunakan, sebagaimana dibuktikan oleh [2] dan [3]. Namun, pada data survei yang sarat akan persepsi subjektif (*noisy data*), pembuatan data sintetik (SMOTE) berisiko mendistorsi keaslian realitas.

Sebagai alternatif yang lebih definitif, penelitian ini mengusulkan **Pruned Binary Classification**. Teknik ini memangkas (menghapus) sampel pada zona ambang netral/ambigu (contoh: IPK 3,50 – 3,67) guna menciptakan jarak *margin* (hiperbidang pemisah) yang mutlak antara kelas mahasiswa *CumLaude* dan kelas rentan (*Non-CumLaude*). Strategi pemangkasan ini diiringi dengan injeksi parameter *class weight* otomatis pada fungsi *loss binary cross-entropy* untuk memaksa model lebih berhati-hati terhadap kesalahan prediksi kelas minoritas.

Selain itu, mengacu pada kajian penggunaan metrik akurasi tunggal terbukti bias dan menyesatkan pada distribusi data yang tidak seimbang. Oleh sebab itu, tata kelola evaluasi (*governance evaluation*) pada penelitian ini ditegakkan menggunakan metrik *Area Under Receiver Operating Characteristic Curve* (ROC-AUC), serta perumusan *Hybrid Score* yang menggabungkan *Matthews Correlation Coefficient* (MCC) dan *F1-Score (Macro)* untuk menjamin presisi dan *recall* yangimbang di semua skenario lipatan validasi silang.

2.6 Research Gap (Kesenjangan Penelitian)

Berdasarkan sintesis kajian literatur (*state-of-the-art*), terlihat pola yang jelas bahwa sebagian besar penelitian terkait prediksi kinerja mahasiswa sangat bergantung pada data interaksi akademis historis (seperti *log LMS*, durasi akses materi) atau demografi statis saat pendaftaran masuk. *Deep learning* konvensional seperti ANN dan MLP [4] dan [5] umumnya mampu memproses data tabular tersebut, namun terbatas pada pembacaan pola spasial yang datar.

Celah kosong (*research gap*) pertama terletak pada sangat minimnya pemanfaatan variabel determinan "gaya hidup eksternal murni" seperti rasio jam tidur terhadap komitmen magang, atau tekanan finansial di tempat tinggal sebagai prediktor utama. *Research gap* kedua adalah kurangnya inovasi struktural terhadap data survei tabular. Model prediksi yang memaksakan data gaya hidup mahasiswa ke dalam representasi ruang dimensi-datar rentan mengalami kebingungan relasi informasi (*Signal Ceiling*). Penelitian ini hadir untuk mengisi kesenjangan tersebut dengan mengajukan kebaruan metode Sekuens Tematik pada arsitektur LSTM, di mana fitur non-temporal disulap menjadi deret waktu logis sehingga relasi domino kehidupan mahasiswa dapat dianalisis secara akurat oleh jaringan memori buatan.

