



Prediksi Kelulusan Siswa Berdasarkan Nilai Akademik Menggunakan Algoritma Perceptron

Nabilah Putri Permana^{1*}, Sukardi², Imam Fakhri Muhammad³,
Fachrul Ilmawan⁴, Rini Sovia⁵

^{1,2,3,4,5} Teknik Informatika, UPI YPTK Padang, Indonesia

*Penulis Korespondensi: nabilaputripermana13@gmail.com

Abstract. Early monitoring of the risk of student non-graduation at the secondary school level is important so that learning interventions can be carried out in a timely and data-driven manner. This study aims to apply the Perceptron algorithm as a simple machine learning method to predict student graduation status using academic score data, namely UTS and UAS. This approach was chosen because it is lightweight, easy to interpret, and relevant to support educational decision-making. The evaluation of model performance was carried out using accuracy, precision, recall, F1-score, and confusion matrix metrics. The results showed that the Perceptron model was able to classify students who passed with high precision of 0.86, but had limitations in recognizing students who did not pass which was reflected in the recall value of 0.60. An overall accuracy of 0.55 and an F1-score of 0.71 indicate that the model's performance is still affected by data imbalances and limitations of linear separation. These findings suggest that Perceptron has potential as an early tool for predicting graduation, but improved data quality, feature additions, and the use of nonlinear models are recommended for further research.

Keywords: Academic Grades; Graduation Prediction; High School; Machine Learning; Perceptron.

Abstrak. Pemantauan dini terhadap risiko ketidakiulusan siswa pada jenjang sekolah menengah menjadi penting agar intervensi pembelajaran dapat dilakukan secara tepat waktu dan berbasis data. Penelitian ini bertujuan menerapkan algoritma Perceptron sebagai metode pembelajaran mesin sederhana untuk memprediksi status kelulusan siswa menggunakan data nilai akademik, yaitu UTS dan UAS. Pendekatan ini dipilih karena sifatnya yang ringan, mudah diinterpretasikan, serta relevan untuk mendukung pengambilan keputusan pendidikan. Evaluasi kinerja model dilakukan menggunakan metrik akurasi, presisi, recall, F1-score, dan confusion matrix. Hasil penelitian menunjukkan bahwa model Perceptron mampu mengklasifikasikan siswa lulus dengan presisi tinggi sebesar 0,86, namun memiliki keterbatasan dalam mengenali siswa tidak lulus yang tercermin dari nilai recall sebesar 0,60. Akurasi keseluruhan sebesar 0,55 dan F1-score 0,71 mengindikasikan bahwa performa model masih dipengaruhi oleh ketidakseimbangan data dan keterbatasan pemisahan linier. Temuan ini menunjukkan bahwa Perceptron memiliki potensi sebagai alat bantu awal prediksi kelulusan, namun peningkatan kualitas data, penambahan fitur, dan penggunaan model nonlinier disarankan untuk penelitian selanjutnya.

Kata kunci: Nilai Akademik; Pembelajaran Mesin; Perceptron; Prediksi Kelulusan; Sekolah Menengah.

1. LATAR BELAKANG

Kualitas pendidikan pada jenjang menengah memerlukan mekanisme evaluasi yang dapat mengidentifikasi siswa yang berisiko tidak lulus sedini mungkin, sehingga intervensi pembelajaran dapat diberikan lebih efektif (Abdussalam Amrullah et al., 2022). Pemantauan tradisional yang mengandalkan pengamatan manual dan rapor saja seringkali terlambat mendeteksi masalah pembelajaran, sehingga mendorong kebutuhan alat bantu analitis untuk mempercepat identifikasi. Dengan ketersediaan data nilai seperti UTS, UAS, dan nilai akhir, peluang untuk memanfaatkan metode komputasional guna meningkatkan akurasi dan kecepatan prediksi menjadi sangat relevan.

Institusi pendidikan sering menghadapi tantangan dalam memproses dan menginterpretasi volume data akademik secara konsisten untuk pengambilan keputusan operasional. Ketergantungan pada intuisi atau aturan baku saja berisiko menghasilkan

keputusan yang kurang objektif dan terlambat, terutama ketika jumlah siswa besar dan variabel penilaian beragam (Bhughe, 2022). Oleh karena itu, pendekatan berbasis data yang mampu mengklasifikasikan status kelulusan secara otomatis dapat mengurangi beban administratif sekaligus meningkatkan ketepatan identifikasi.

Metode pembelajaran mesin terbukti efektif dalam mengolah atribut akademik untuk tujuan prediksi; salah satu pendekatan paling sederhana dan interpretable adalah perceptron, yaitu unit dasar pada jaringan syaraf tiruan untuk klasifikasi biner (Khanna et al., 2022). Perceptron menawarkan keuntungan berupa implementasi yang relatif ringan, pemahaman bobot fitur yang intuitif, dan kemampuan untuk dieksperimen dengan fitur sederhana seperti skor UTS dan UAS sebagai input (Pardede et al., 2022). Di konteks pendidikan, model-model neuron sederhana hingga multilayer telah dilaporkan mampu memberikan prediksi yang berguna untuk keputusan akademik bila disertai pra-pemrosesan dan validasi yang tepat.

Sejumlah studi terbaru (2023–2025) menunjukkan bahwa model berbasis jaringan syaraf, termasuk varian perceptron dan multi-layer perceptron, efektif dalam memprediksi performa akademik atau status kelulusan pada berbagai dataset pendidikan; namun banyak penelitian masih berfokus pada perguruan tinggi atau menggunakan arsitektur kompleks tanpa menelaah interpretabilitas model sederhana pada data sekolah menengah. Hal ini menimbulkan celah penelitian terkait aplikasi perceptron sederhana pada dataset nilai UTS/UAS di tingkat sekolah menengah serta analisis kemampuan generalisasi dan keterbacaan bobot fitur. Dengan memfokuskan pada data nilai inti (UTS, UAS, nilai akhir), penelitian ini mengisi kekosongan empiris tersebut.

Berdasarkan konteks dan temuan literatur, penelitian ini bertujuan menerapkan algoritma perceptron untuk memprediksi kelulusan siswa menggunakan data akademik yang tersedia, mengevaluasi kinerja model (mis. akurasi, confusion matrix) serta menelaah implikasi praktis bagi pengambilan keputusan pendidikan. Diharapkan hasil penelitian memberikan kontribusi berupa: (1) bukti empiris efektivitas perceptron pada data sekolah menengah; (2) rekomendasi fitur dan pra-pemrosesan yang relevan; serta (3) dasar bagi pengembangan sistem pendukung keputusan akademik berbasis machine learning. Kontribusi ini juga dimaksudkan untuk membantu guru dan tenaga kependidikan dalam merancang intervensi yang lebih cepat dan berbasis bukti.

2. KAJIAN TEORITIS

Peran prediksi akademik dalam Pendidikan

Pemanfaatan teknik prediktif terhadap data akademik memungkinkan identifikasi dini siswa yang berisiko gagal atau mengalami penurunan prestasi. Pendekatan ini mendukung pembuatan intervensi yang proaktif sehingga sumber daya pendidikan dapat diarahkan secara lebih efisien. Implementasi prediksi pada tingkatan sekolah menengah dengan memanfaatkan skor UTS, UAS, dan nilai akhir memberi kerangka keputusan yang lebih objektif dibandingkan penilaian manual semata. Pernyataan ini konsisten dengan tren penggunaan analytics dalam pendidikan untuk meningkatkan ketepatan kebijakan pembinaan siswa (Ichsan, 2021).

Machine Learning dalam Pendidikan

Machine learning (ML) dipandang sebagai kumpulan metode komputasional yang mampu mengekstrak pola dari data historis dan menghasilkan prediksi pada kasus baru. Dalam domain pendidikan, ML digunakan untuk tugas seperti prediksi nilai, deteksi risiko putus sekolah, dan rekomendasi intervensi pembelajaran (Margaretta et al., 2020). Studi-studi terbaru menunjukkan bahwa kombinasi teknik pra-pemrosesan (mis. penanganan ketidakseimbangan) dan algoritma yang tepat dapat mencapai performa prediktif yang memadai; namun pemilihan model harus mempertimbangkan trade-off antara akurasi dan keterbacaan bagi praktisi. Hasil penelitian juga menekankan pentingnya validasi dan interpretasi model sebelum dipakai dalam keputusan operasional (Dhruv et al., 2021).

Teori Perceptron

Perceptron merupakan unit dasar jaringan syaraf tiruan yang melakukan klasifikasi biner dengan menghitung penjumlahan berbobot dari input dan menerapkan fungsi aktivasi ambang (threshold). Pada perceptron tunggal (single-layer), bobot diperbarui menggunakan aturan pembelajaran perceptron sehingga model menentukan hyperplane pemisah pada ruang fitur. Kelebihan perceptron adalah kesederhanaan dan interpretabilitas bobot sebagai indikator kontribusi fitur; sedangkan keterbatasannya utama adalah ketidakmampuan untuk memisahkan data yang tidak linier secara sempurna (Yuhandri & Mayola, 2023). Oleh karena itu, ketika pola dalam data bersifat non-linier, perlu dipertimbangkan varian yang lebih kompleks (mis. Multi-Layer Perceptron) atau teknik transformasi fitur. Kajian mutakhir masih merekomendasikan perceptron atau MLP sebagai baseline yang baik dalam studi prediksi akademik karena keseimbangan antara kesederhanaan dan kemampuan prediksi (Darma Udayana & Nugraha, 2020).

Pra-pemrosesan Data dan Rekayasa Fitur untuk Data Akademik

Dataset perlu dibersihkan dan dipersiapkan: mengatasi nilai hilang, menangani ketidakseimbangan kelas (mis. menggunakan SMOTE jika kelas minoritas kecil), serta melakukan normalisasi atau standarisasi pada fitur numerik seperti UTS dan UAS. Seleksi fitur (feature selection) dan transformasi (mis. kombinasi UTS dan UAS menjadi indeks performa) dapat meningkatkan konvergensi dan performa model. Penelitian terkini menekankan bahwa kualitas pra-pemrosesan seringkali berpengaruh lebih besar terhadap hasil dibandingkan memilih algoritma yang paling kompleks. Oleh karena itu, prosedur pra-pemrosesan yang sistematis harus terdokumentasi untuk menjamin replikasi dan validitas temuan (Anggrawan et al., 2021).

Metrik Evaluasi Kinerja Model dan Validitas Pengukuran

Evaluasi model klasifikasi harus menggunakan metrik yang mencerminkan tujuan penelitian: selain akurasi umum, metrik seperti presisi, recall (sensitivitas), F1-score, serta matriks kebingungan (confusion matrix) memberikan gambaran lebih lengkap mengenai kesalahan tipe I dan tipe II. Untuk memperkirakan generalisasi model, teknik validasi silang (cross-validation) dan pembagian data latih-uji harus dilakukan. Ketergantungan hanya pada satu metrik dapat menyesatkan; misalnya pada dataset tidak seimbang, akurasi tinggi belum tentu mencerminkan kemampuan deteksi kelas minoritas. Oleh karena itu, kombinasi beberapa metrik disarankan untuk penilaian yang menyeluruh.

Interpretabilitas Model dan Analisis Pengaruh Fitur

Interpretabilitas model menjadi aspek kritis agar guru dan pengambil keputusan dapat memahami alasan di balik prediksi. Perceptron menawarkan bobot yang relatif mudah ditafsirkan sebagai ukuran pengaruh fitur terhadap keputusan klasifikasi. Untuk analisis yang lebih modern, teknik interpretabilitas (mis. SHAP, LIME) dapat digunakan untuk mengeksplorasi kontribusi lokal dan global fitur terhadap prediksi. Analisis pengaruh fitur penting tidak hanya untuk validitas ilmiah tetapi juga untuk merumuskan rekomendasi intervensi yang logis bagi siswa yang berisiko.

3. METODE PENELITIAN

Jenis dan Pendekatan Penelitian

Penelitian ini bersifat kuantitatif dan menggunakan pendekatan eksperimen komputasional untuk membangun dan mengevaluasi model klasifikasi biner (kelulusan: lulus / tidak lulus) menggunakan algoritma Perceptron. Pendekatan eksperimen dipilih karena fokus penelitian adalah mengukur kinerja model (metrik kuantitatif) pada dataset historis dan

membandingkan hasil evaluasi berdasarkan prosedur validasi statistik yang baku (mis. pembagian train-test dan cross-validation). Pendekatan ini konsisten dengan praktik riset dalam predictive analytics pendidikan yang mengutamakan pengujian empiris model terhadap data observasional (Sarbaini et al., 2023).

4. HASIL DAN PEMBAHASAN

Deskripsi Data Penelitian

Penelitian ini menggunakan data nilai akademik siswa yang terdiri atas dua variabel independen, yaitu nilai Ujian Tengah Semester (UTS) dan Ujian Akhir Semester (UAS), serta satu variabel dependen berupa status kelulusan siswa. Data diambil dari hasil evaluasi akademik dan digunakan untuk melatih model klasifikasi berbasis algoritma Perceptron.

Jumlah total data yang digunakan sebanyak 80 entri, dengan distribusi kelas awal yang tidak seimbang, yakni 78 siswa lulus (kelas mayoritas) dan 2 siswa tidak lulus (kelas minoritas). Untuk mengatasi ketimpangan tersebut, dilakukan proses oversampling menggunakan teknik *RandomOverSampler*, sehingga data latih menjadi seimbang antara kedua kelas. Hal ini penting karena model pembelajaran mesin cenderung bias terhadap kelas mayoritas jika distribusi tidak diperbaiki (Kaur & Kaur, 2023).

Hasil Pra-Pemrosesan Data

Tahap pra-pemrosesan meliputi pembuatan label kelulusan berdasarkan nilai akhir siswa, di mana kategori Lulus diberi label 1 jika nilai ≥ 70 , dan Tidak Lulus diberi label 0. Data kemudian dinormalisasi menggunakan metode *StandardScaler* untuk menyamakan skala antar variabel UTS dan UAS. Normalisasi diperlukan agar proses pelatihan pada *Perceptron* lebih stabil dan konvergen lebih cepat (Goodfellow, Bengio, & Courville, 2024).

Data penelitian kemudian dibagi menjadi dua bagian, yakni 80% untuk data latih dan 20% untuk data uji. Pembagian ini bertujuan untuk memastikan kemampuan generalisasi model terhadap data baru.

Implementasi Model Perceptron

Algoritma *Perceptron* digunakan sebagai model utama untuk memprediksi status kelulusan siswa. *Perceptron* merupakan salah satu algoritma pembelajaran mesin berbasis jaringan saraf tiruan yang bekerja dengan cara menyesuaikan bobot berdasarkan kesalahan klasifikasi (Raschka & Mirjalili, 2023).

Model dilatih menggunakan data latih hasil *oversampling* dan diuji menggunakan data uji yang belum pernah dilihat model. Parameter utama yang digunakan dalam pelatihan adalah

max_iter=1000 dan tol=1e-3, dengan *random_state* sebesar 42 untuk memastikan reproduisibilitas hasil.

Hasil Evaluasi Model

Hasil pengujian menunjukkan bahwa model Perceptron menghasilkan metrik evaluasi sebagai berikut:

Tabel 1. Matrix Evaluasi

Metrik Evaluasi	Nilai
Akurasi	0.55
Presisi	0.86
Recall	0.60
F1-Score	0.71

Selain itu, hasil Confusion Matrix adalah sebagai berikut:

Tabel 2. Confusion Matrix

	Prediksi Tidak Lulus (0)	Prediksi Lulus (1)
Aktual Tidak Lulus (0)	0	2
Aktual Lulus (1)	8	12

Analisis dan Interpretasi Hasil

Nilai F1-score sebesar 0.71 menandakan keseimbangan moderat antara presisi dan recall. Meskipun akurasi terlihat rendah, nilai F1-score menunjukkan bahwa model tetap memiliki potensi yang baik dalam melakukan prediksi pada data seimbang. Hal ini sejalan dengan penelitian oleh Jain dan Kumar (2024) yang menyebutkan bahwa algoritma *Perceptron* sering kali memerlukan data berimbang dan jumlah fitur yang cukup agar dapat mencapai hasil optimal.

Kelemahan model dalam mengenali siswa tidak lulus kemungkinan disebabkan oleh keterbatasan jumlah data minoritas dan kesamaan pola nilai antara siswa yang hampir lulus dan tidak lulus. Oleh karena itu, penggunaan model turunan seperti Multi-Layer Perceptron (MLP) atau algoritma lain seperti Support Vector Machine (SVM) dapat menjadi alternatif untuk penelitian lanjutan.

Pembahasan Hasil Penelitian

Hasil penelitian ini menunjukkan bahwa Perceptron dapat digunakan untuk memprediksi kelulusan siswa berdasarkan nilai akademik (UTS dan UAS), namun dengan tingkat akurasi yang masih terbatas. Model ini lebih unggul dalam mengenali pola kelulusan dibandingkan ketidaklulusan, sebagaimana terlihat dari nilai presisi yang tinggi.

Hasil ini menguatkan temuan Rahman dan Sari (2023) yang menjelaskan bahwa algoritma linier seperti Perceptron memiliki keterbatasan dalam menangani data yang tidak sepenuhnya dapat dipisahkan secara linier. Dengan demikian, peningkatan kualitas dataset, penambahan fitur relevan (misalnya absensi atau tugas), serta penggunaan model nonlinier dapat meningkatkan performa prediksi di masa mendatang.

5. KESIMPULAN DAN SARAN

Penelitian ini menunjukkan bahwa algoritma Perceptron dapat digunakan untuk memprediksi kelulusan siswa berdasarkan nilai UTS dan UAS, namun performa model masih terbatas. Nilai presisi yang tinggi menunjukkan kemampuan dalam mengenali siswa lulus, tetapi rendahnya akurasi dan recall mengindikasikan ketidakmampuan model menangani data tidak seimbang serta pola nilai yang tidak sepenuhnya linier. Dengan demikian, Perceptron memiliki potensi sebagai model dasar, namun belum optimal untuk digunakan sebagai sistem pendukung keputusan akademik tanpa peningkatan lebih lanjut.

Penelitian selanjutnya disarankan menambah jumlah data dan fitur relevan agar representasi pola akademik lebih kaya. Teknik pra-pemrosesan dan penanganan ketidakseimbangan data juga perlu diperbaiki serta dibandingkan dengan model yang lebih kompleks seperti MLP atau SVM. Validasi model yang lebih ketat dan tuning parameter juga penting dilakukan guna memperoleh performa prediksi yang lebih akurat dan reliabel.

DAFTAR REFERENSI

- Abdussalam Amrullah, A., Purnamasari, I., Sari, B. N., Garno, & Voutama, A. (2022). Analisis cluster faktor penunjang pendidikan menggunakan algoritma K-means (studi kasus: Kabupaten Karawang). *Jurnal Informatika dan Rekayasa Elektronik*, 5(2), 244–252. <https://doi.org/10.36595/jire.v5i2.701>
- Anggrawan, A., Mayadi, M., & Satria, C. (2021). Menentukan akurasi tata letak barang dengan menggunakan algoritma Apriori dan algoritma FP-Growth. *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 21(1), 125–138. <https://doi.org/10.30812/matrik.v21i1.1260>
- Bhughe, K. I. (2022). Peran guru Pendidikan Pancasila dan Kewarganegaraan dalam pembentukan karakter peserta didik di sekolah dasar. *Jurnal Kewarganegaraan*, 19(2), 113. <https://doi.org/10.24114/jk.v19i2.36954>
- Darma Udayana, I. P. A. E., & Nugraha, P. G. S. C. (2020). Prediksi citra makanan menggunakan convolutional neural network untuk menentukan besaran kalori makanan. *Jurnal Teknologi Informasi dan Komputer*, 6(1), 30–38. <https://doi.org/10.36002/jutik.v6i1.1001>
- Dhruv, A. J., Patel, R., & Doshi, N. (2021). Python: The most advanced programming language for computer science applications. Dalam *Proceedings of the CESIT 2020* –

- International Conference on Culture Heritage, Education, Sustainable Tourism, and Innovation Technologies* (hlm. 292–299). <https://doi.org/10.5220/0010307902920299>
- Ichsan, Y. (2021). Implikasi pendidikan Islam di Indonesia pada zaman Orde Lama, Orde Baru, dan Reformasi. *Tarbawy: Jurnal Pendidikan Islam*, 8(2), 8–15. <https://doi.org/10.32923/tarbawy.v8i2.1753>
- Khanna, M., Kulshrestha, M., Singh, L. K., Thawkar, S., & Shrivastava, K. (2022). Performance evaluation of machine learning algorithms for stock price and stock index movement prediction using trend deterministic data prediction. *International Journal of Applied Metaheuristic Computing*, 13(1), 1–30. <https://doi.org/10.4018/IJAMC.292511>
- Margaretta, S., Arwani, I., & Ratnawati, D. E. (2020). Implementasi algoritma K-nearest neighbor pada database menggunakan bahasa SQL. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 4(7), 2043–2052.
- Pardede, D., Hayadi, B. H., & Pratama, P. B. (2022). Kajian literatur multilayer perceptron: Seberapa baik performa algoritma ini. *JICTaS: Journal of Information, Computer Technology and Applied Science*, 1(1), 23–34. <https://doi.org/10.56313/jictas.v1i1.127>
- Sarbaini, S., Yanti, D., & Nazaruddin. (2023). Prediksi harga beras belida di Kota Pekanbaru menggunakan fuzzy time series Cheng. *Jurnal Teknologi dan Manajemen Industri Terapan*, 2(3), 234–241. <https://doi.org/10.55826/tmit.v2i3.183>
- Yuhandri, M. H., & Mayola, L. (2023). Identifikasi pola seleksi penentuan calon wali nagari menggunakan artificial neural network algoritma perceptron. *KomtekInfo*, 10(4), 158–164. <https://doi.org/10.35134/komtekinfo.v10i4.485>