

ANALYSIS OF STUDENT LEARNING BEHAVIOR IN THE ARTIFICIAL INTELLIGENCE ERA USING DEEP LEARNING MODELS TABNET AND TABTRANSFORMER FOR THE DEVELOPMENT OF LEARNING STRATEGY RECOMMENDATIONS

ANALISIS PERILAKU BELAJAR SISWA DI ERA ARTIFICIAL INTELLIGENCE MENGGUNAKAN MODEL DEEP LEARNING TABNET DAN TABTRANSFORMER UNTUK PENGEMBANGAN REKOMENDASI STRATEGI PEMBELAJARAN

Ahmad Muhammad¹, Ahmad Musyafa², Tukiya³

Magister Teknik Informatika, Universitas Pamulang^{1,2,3}

ahmadmuhammad12@guru.sma.belajar.id¹, ahmad.musyafa@unpam.ac.id²,
dosen02711@unpam.ac.id³

ABSTRACT

The development of Artificial Intelligence (AI) technology has significantly changed students' learning behavior, particularly in how students access information, complete assignments, and develop independent learning strategies. This study aims to analyze students' learning behavior in the AI era using TabNet and TabTransformer deep learning models to predict academic achievement and develop adaptive learning strategy recommendations. This research employed a quantitative approach using tabular data collected from 2,052 students of SMA Plus PGRI Cibinong. The research variables included academic, digital, psychological, social, and AI-related learning aspects. The research stages consisted of data preprocessing, encoding, train-test split, modeling using TabNet and TabTransformer, model evaluation using RMSE, MAE, and R², and feature importance analysis for student segmentation. The results showed that TabTransformer outperformed TabNet in modeling the relationship between learning behavior and students' academic performance. Learning effort, AI-assisted material understanding, and learning motivation were identified as dominant factors affecting academic achievement. Furthermore, this study produced four student profile segmentations used as the basis for adaptive learning strategy recommendations. The findings indicate that AI acts as a supporting factor in learning, while self-regulation and learning effort remain the primary determinants of students' academic success.

Keywords: Artificial Intelligence, Tabnet, Tabtransformer, Learning Behavior, Deep Learning, Learning Recommendation.

ABSTRAK

Perkembangan teknologi kecerdasan artifisial (Artificial Intelligence/AI) telah membawa perubahan signifikan terhadap perilaku belajar siswa, terutama dalam cara siswa mengakses informasi, menyelesaikan tugas, dan membangun strategi belajar mandiri. Penelitian ini bertujuan untuk menganalisis perilaku belajar siswa di era AI menggunakan model deep learning TabNet dan TabTransformer untuk memprediksi capaian akademik siswa serta mengembangkan rekomendasi strategi pembelajaran yang adaptif. Penelitian menggunakan pendekatan kuantitatif dengan data tabular yang diperoleh dari 2.052 siswa SMA Plus PGRI Cibinong. Variabel penelitian mencakup aspek akademik, digital, psikologis, sosial, dan penggunaan AI dalam pembelajaran. Tahapan penelitian meliputi preprocessing data, encoding, pembagian data latih dan data uji, pemodelan menggunakan TabNet dan TabTransformer, evaluasi model menggunakan RMSE, MAE, dan R², serta analisis feature importance untuk segmentasi siswa. Hasil penelitian menunjukkan bahwa TabTransformer memiliki performa lebih baik dibandingkan TabNet dalam memodelkan hubungan antara perilaku belajar dan nilai akademik siswa. Variabel usaha belajar, penggunaan AI untuk memahami materi, dan motivasi belajar menjadi faktor dominan yang memengaruhi capaian akademik. Selain itu, penelitian menghasilkan empat segmentasi profil siswa yang digunakan sebagai dasar penyusunan rekomendasi strategi pembelajaran adaptif. Penelitian ini menunjukkan bahwa AI berperan sebagai faktor pendukung pembelajaran, sementara regulasi diri dan usaha belajar tetap menjadi faktor utama keberhasilan akademik siswa.

Kata Kunci: Artificial Intelligence, Tabnet, Tabtransformer, Perilaku Belajar, Deep Learning, Rekomendasi Pembelajaran.

PENDAHULUAN

Perkembangan teknologi kecerdasan artifisial (Artificial Intelligence/AI) telah memberikan dampak yang signifikan terhadap dunia pendidikan, khususnya terhadap perilaku belajar siswa. Kehadiran teknologi AI generatif seperti chatbot dan sistem pembelajaran cerdas memungkinkan siswa memperoleh informasi secara cepat, menyelesaikan tugas secara otomatis, serta memperoleh bantuan belajar secara instan. Perubahan tersebut menyebabkan terjadinya transformasi pola belajar siswa dari pendekatan konvensional menuju pembelajaran berbasis digital dan interaktif.

Di sisi lain, penggunaan AI dalam pembelajaran tidak selalu memberikan dampak positif secara langsung terhadap capaian akademik siswa. Kemudahan akses terhadap teknologi AI dapat meningkatkan efektivitas belajar, namun juga berpotensi menurunkan regulasi diri, kemandirian belajar, dan usaha belajar siswa apabila digunakan secara tidak tepat. Oleh karena itu, diperlukan pendekatan analisis berbasis data untuk memahami bagaimana perilaku belajar siswa di era AI memengaruhi hasil akademik.

Penelitian sebelumnya umumnya masih berfokus pada analisis perilaku belajar menggunakan metode statistik konvensional atau machine learning tradisional. Pendekatan tersebut memiliki keterbatasan dalam memodelkan hubungan kompleks antar variabel tabular yang bersifat multidimensional. Selain itu, penelitian yang mengintegrasikan analisis perilaku belajar siswa, penggunaan AI, deep learning, dan rekomendasi strategi pembelajaran adaptif masih relatif terbatas.

Berdasarkan kondisi tersebut, penelitian ini menggunakan model deep learning TabNet dan TabTransformer untuk menganalisis perilaku belajar siswa di era AI. Kedua model dipilih karena memiliki kemampuan dalam memproses data tabular secara lebih efektif dibandingkan metode tradisional. Penelitian ini tidak hanya berfokus pada prediksi nilai akademik

siswa, tetapi juga pada identifikasi faktor dominan, segmentasi profil siswa, serta pengembangan rekomendasi strategi pembelajaran yang adaptif dan berbasis data.

Tujuan penelitian ini adalah: 1. Menganalisis perilaku belajar siswa di era AI berdasarkan data tabular. 2. Membandingkan performa model TabNet dan TabTransformer dalam memprediksi nilai akademik siswa. 3. Mengidentifikasi faktor dominan yang memengaruhi capaian akademik siswa. 4. Mengembangkan segmentasi siswa dan rekomendasi strategi pembelajaran adaptif.

TINJAUAN PUSTAKA

Perilaku Belajar

Perilaku belajar (*learning behavior*) merupakan pola tindakan, respons, strategi, dan kebiasaan yang ditunjukkan siswa selama mengikuti proses pembelajaran. (Hendriana et al., 2025) menjelaskan bahwa motivasi belajar siswa berpengaruh signifikan terhadap keberhasilan akademik, di mana siswa dengan motivasi tinggi cenderung menunjukkan prestasi belajar yang lebih baik dibandingkan siswa dengan motivasi rendah. (Waseem & Aslam, 2020) menyatakan bahwa teori belajar seperti behaviorisme, kognitivisme, dan konstruktivisme memberikan dasar konseptual yang berbeda dalam memahami proses belajar dan sangat memengaruhi perancangan desain pembelajaran modern. Integrasi berbagai teori tersebut memungkinkan desain instruksional yang lebih efektif, adaptif, dan berpusat pada peserta didik, khususnya dalam konteks pembelajaran berbasis teknologi. Sedangkan (Judd, 2012) yang menyoroti berbagai konsep utama dalam psikologi pendidikan, termasuk perkembangan kognitif, motivasi belajar, strategi pembelajaran, serta faktor sosial dan emosional yang memengaruhi proses belajar siswa. Ulasan ini menegaskan bahwa psikologi pendidikan memberikan kerangka teoritis yang komprehensif untuk memahami bagaimana siswa belajar,

bagaimana guru dapat merancang pembelajaran yang efektif, dan bagaimana lingkungan pendidikan memengaruhi hasil belajar. Selain itu, artikel ini menekankan pentingnya integrasi teori psikologi pendidikan dengan praktik pembelajaran modern untuk meningkatkan kualitas proses dan hasil pembelajaran. Dengan demikian, perilaku belajar siswa merupakan hasil interaksi dinamis antara kondisi personal dan konteks pembelajaran yang melingkupinya.

Machine Learning

Machine Learning (ML) merupakan cabang dari kecerdasan buatan (*Artificial Intelligence*) yang mempelajari metode dan algoritma yang memungkinkan sistem komputer untuk belajar dari data dan pengalaman guna menghasilkan prediksi, klasifikasi, atau rekomendasi secara otomatis. Dalam konteks pendidikan di era kecerdasan buatan, machine learning berperan penting dalam menganalisis perilaku belajar siswa berdasarkan data akademik dan non-akademik yang bersifat tabular.

Machine learning memungkinkan sistem untuk mengidentifikasi pola hubungan antara berbagai faktor pembelajaran, seperti kehadiran, aktivitas belajar, motivasi, hasil evaluasi, dan interaksi siswa dengan teknologi pembelajaran. Pola-pola tersebut selanjutnya dapat dimanfaatkan untuk mendukung pengambilan keputusan berbasis data dalam pengembangan strategi pembelajaran yang adaptif dan personal.


Deep Learning

Pendekatan analisis berbasis *deep learning* digunakan dalam penelitian ini sebagai sarana untuk memodelkan dan menganalisis data perilaku belajar siswa secara komprehensif. *Deep learning* merupakan bagian dari machine learning yang mampu mempelajari pola kompleks dan hubungan nonlinier antar variabel melalui jaringan saraf berlapis. Dalam konteks pendidikan, pendekatan ini relevan

untuk menganalisis data perilaku belajar siswa yang bersifat multidimensional dan heterogen.

Model TabNet

Menurut (Arik & Pfister, 2021) TabNet merupakan salah satu arsitektur *deep learning* modern yang dirancang khusus untuk menangani data tabular. Berbeda dengan model *deep learning* konvensional yang cenderung kurang optimal pada data tabular, TabNet memanfaatkan mekanisme *sequential attention* melalui *feature masks* yang ditentukan secara adaptif pada setiap *decision step*. Melalui mekanisme ini, model dapat memilih fitur yang paling relevan secara berurutan, sehingga proses ekstraksi informasi menjadi lebih efisien dan terarah.



Gambar 2. 1 Arsitektur TabNet
Sumber: Arik et al. (2021)

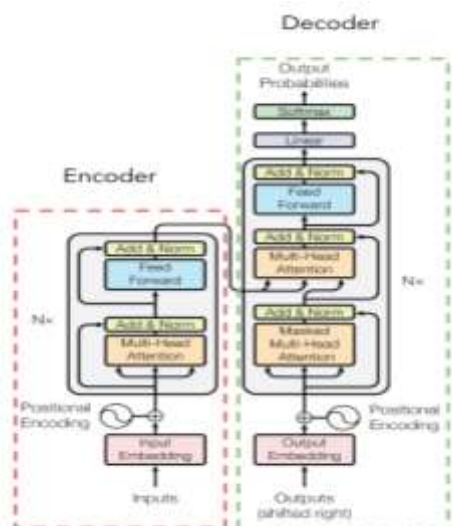
Arsitektur TabNet mengombinasikan beberapa konsep penting, yakni seleksi fitur secara berurutan (*sequential feature selection*), representasi yang bersifat *sparse*, serta kemampuan memberikan interpretasi visual terhadap fitur-fitur yang berpengaruh dalam pengambilan keputusan model. Dengan pendekatan tersebut, TabNet mampu menonjolkan fitur penting dan menekan fitur yang tidak relevan, sehingga performa model dapat meningkat tanpa kehilangan transparansi.

Model TabTransformer

(Huang et al., 2020) menjelaskan bahwa TabTransformer merupakan salah satu pengembangan model *deep learning* berbasis *Transformer encoder* yang dirancang secara khusus untuk memproses

data tabular, terutama ketika dataset memiliki banyak fitur kategorikal. Berbeda dengan pendekatan tradisional seperti *one-hot encoding* atau *embedding* sederhana, TabTransformer melakukan pemrosesan fitur kategori melalui mekanisme *self-attention* sehingga setiap kategori dapat dibaca secara lebih kontekstual. Dengan pendekatan ini, informasi kategori tidak hanya diperlakukan sebagai simbol, tetapi dipahami berdasarkan hubungan antar kategori seperti gaya belajar, preferensi siswa, atau pola interaksi tertentu yang kompleks.

Pada tahap awal, TabTransformer mengubah setiap fitur kategorikal ke dalam bentuk *embedding* yang merepresentasikan kategori sebagai vektor numerik berdimensi tertentu. Embedding tersebut kemudian diproses oleh blok *Transformer encoder* melalui mekanisme *multi-head self-attention* untuk menangkap hubungan lintas fitur. Proses ini menciptakan *contextual embeddings*, yaitu representasi kategori yang telah mempertimbangkan konteks fitur lain dalam dataset. Dengan kata lain, nilai suatu kategori tidak lagi berdiri sendiri, tetapi dipengaruhi oleh relasi antar fitur kategorikal lainnya, sehingga menghasilkan representasi yang lebih informatif dan bermakna.



Gambar 2. 2 Arsitektur TabTransformer
Sumber: (Huang et al., 2020)

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode supervised learning berbasis deep learning. Dataset penelitian diperoleh dari siswa SMA Plus PGRI Cibinong sebanyak 2.052 responden melalui instrumen kuesioner dan data akademik siswa.

Variabel independen (X) terdiri dari variabel perilaku belajar siswa yang mencakup aspek akademik, digital, psikologis, sosial, dan penggunaan AI dalam pembelajaran. Variabel dependen (Y) adalah nilai akademik siswa yang digunakan sebagai target prediksi.

Tahapan penelitian meliputi: 1. Pengumpulan data. 2. Preprocessing data. 3. Encoding variabel kategorikal. 4. Pembagian data menjadi training set dan testing set. 5. Pemodelan menggunakan TabNet dan TabTransformer. 6. Evaluasi model. 7. Analisis feature importance. 8. Segmentasi siswa dan penyusunan rekomendasi pembelajaran.

Preprocessing Data

Tahapan preprocessing dilakukan melalui pembersihan data, penanganan missing value, encoding data kategorikal, dan normalisasi data numerik. Proses ini dilakukan agar data dapat diproses secara optimal oleh model deep learning.

Dataset dibagi menjadi data latih dan data uji dengan proporsi 80:20 menggunakan metode train-test split. Data latih digunakan untuk melatih model, sedangkan data uji digunakan untuk mengevaluasi performa model.

Evaluasi Model

Evaluasi model dilakukan menggunakan metrik Root Mean Square Error (RMSE), Mean Absolute Error (MAE) dan R-Squared (R^2). RMSE dan MAE digunakan untuk mengukur tingkat kesalahan prediksi model, sedangkan R^2 digunakan untuk mengukur kemampuan model dalam menjelaskan variasi nilai akademik siswa.

Segmentasi Siswa

Segmentasi siswa dilakukan menggunakan pendekatan rule-based berdasarkan pola dominansi feature importance yang dihasilkan oleh model. Segmentasi ini digunakan untuk mengelompokkan siswa berdasarkan karakteristik perilaku belajar yang serupa sebagai dasar penyusunan rekomendasi strategi pembelajaran.

HASIL DAN PEMBAHASAN

Deskripsi Data

Hasil analisis deskriptif menunjukkan bahwa sebagian besar siswa memiliki motivasi belajar dan usaha belajar yang berada pada kategori cukup baik. Penggunaan AI dalam pembelajaran juga menunjukkan intensitas yang cukup tinggi, terutama untuk membantu memahami materi dan menyelesaikan tugas akademik.

Hasil Evaluasi Model

Hasil evaluasi model menunjukkan bahwa TabTransformer memiliki performa yang lebih baik dibandingkan TabNet dalam memprediksi nilai akademik siswa.

Model	RMSE	MAE	R ²
TabNet	18.000	14.401	0.019
TabTransformer	17.839	14.033	0.036

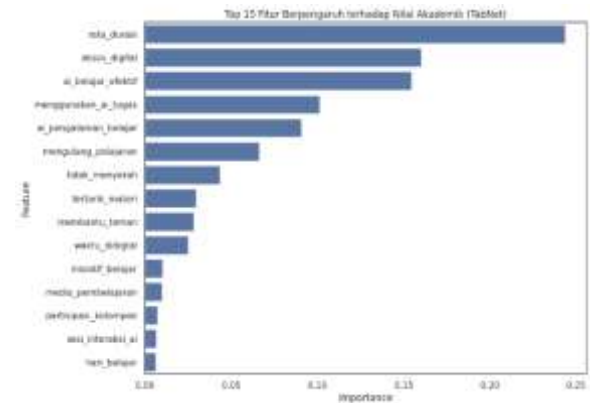
Hasil tersebut menunjukkan bahwa TabTransformer lebih efektif dalam memodelkan hubungan kompleks antar variabel perilaku belajar siswa. Mekanisme self-attention pada TabTransformer memungkinkan model memahami hubungan antar fitur secara lebih kontekstual dibandingkan TabNet.

Analisis Feature Importance

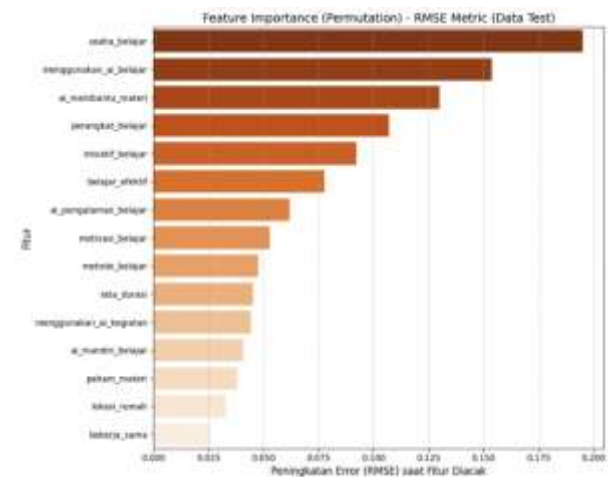
Berdasarkan hasil feature importance, variabel usaha belajar menjadi faktor paling dominan yang memengaruhi capaian akademik siswa. Selain itu, penggunaan AI untuk memahami materi, motivasi belajar, dan inisiatif belajar juga memberikan kontribusi penting terhadap hasil akademik.

Temuan ini menunjukkan bahwa AI berperan sebagai faktor pendukung

pembelajaran, sementara regulasi diri dan usaha belajar tetap menjadi faktor utama keberhasilan akademik siswa.



Gambar 4. 11 Feature Importance TabNet



Gambar 4. 12 Feature Importance TabTransformer

Segmentasi Profil Siswa

Berdasarkan hasil analisis perilaku belajar dan feature importance, diperoleh empat segmentasi profil siswa:

Profil	Karakteristik
Pembelajar AI yang Mengatur Diri Sendiri / <i>Self-Regulated AI Learner</i>	<ol style="list-style-type: none"> Usaha belajar tinggi Inisiatif belajar tinggi Penggunaan AI tinggi dan terarah Motivasi intrinsik kuat
Pembelajar yang Bergantung pada	<ol style="list-style-type: none"> Penggunaan AI tinggi

Profil	Karakteristik
AI / AI- <i>Dependent Learner</i>	<ol style="list-style-type: none"> 2. Usaha belajar relatif sedang/rendah 3. Inisiatif belajar rendah 4. Pemahaman konseptual kurang mendalam
Pembelajar dengan Keterlibatan Rendah/ <i>Low Engagement Learner</i>	<ol style="list-style-type: none"> 1. Usaha belajar rendah 2. Motivasi rendah 3. Inisiatif rendah 4. Penggunaan AI rendah
Pembelajar yang Terbatas Sumber Daya tetapi Termotivasi/ <i>Resource-Limited but Motivated Learner</i>	<ol style="list-style-type: none"> 1. Usaha belajar tinggi 2. Motivasi tinggi 3. Akses perangkat atau infrastruktur terbatas 4. Penggunaan AI rendah bukan karena pilihan, tetapi keterbatasan

Segmentasi tersebut digunakan sebagai dasar penyusunan strategi pembelajaran yang lebih adaptif dan sesuai dengan karakteristik siswa.

Rekomendasi Strategi Pembelajaran

Berdasarkan segmentasi siswa, penelitian ini menghasilkan rekomendasi strategi pembelajaran adaptif, antara lain:

1. Penguatan regulasi diri siswa.
2. Optimalisasi penggunaan AI dalam pembelajaran.
3. Pendampingan belajar untuk siswa dengan keterlibatan rendah.
4. Penyediaan akses pembelajaran digital yang lebih merata.

Hasil penelitian menunjukkan bahwa pendekatan pembelajaran berbasis data dapat membantu sekolah dan guru dalam merancang strategi pembelajaran yang lebih kontekstual dan efektif.

PENUTUP

Kesimpulan

Penelitian ini berhasil menganalisis perilaku belajar siswa di era AI menggunakan model deep learning TabNet dan TabTransformer. Hasil penelitian menunjukkan bahwa TabTransformer memiliki performa yang lebih baik dibandingkan TabNet dalam memprediksi nilai akademik siswa.

Variabel usaha belajar, motivasi belajar, dan penggunaan AI untuk memahami materi menjadi faktor dominan yang memengaruhi capaian akademik siswa. Selain itu, penelitian ini menghasilkan empat segmentasi profil siswa yang digunakan sebagai dasar penyusunan rekomendasi strategi pembelajaran adaptif.

Penelitian ini menegaskan bahwa penggunaan AI dalam pendidikan perlu diimbangi dengan penguatan regulasi diri dan usaha belajar siswa. Pendekatan pembelajaran berbasis data dan deep learning dapat menjadi solusi strategis dalam pengembangan pembelajaran yang lebih adaptif di era digital.

Ucapan Terima Kasih

Penulis mengucapkan puji syukur kepada Allah SWT atas segala rahmat dan karunia-Nya sehingga penelitian ini dapat diselesaikan dengan baik. Penulis menyampaikan terima kasih kepada pihak universitas, program pascasarjana Teknik Informatika atas dukungan akademik yang diberikan. Ucapan terima kasih juga disampaikan kepada dosen pembimbing atas arahan dan bimbingan selama proses penelitian. Selain itu, penulis mengapresiasi SMA Plus PGRI Cibinong beserta jajaran manajemen dan seluruh siswa yang menjadi responden yang telah memberikan izin serta dukungan data

dalam penelitian ini. Penulis juga mengucapkan terima kasih kepada seluruh dosen, rekan sejawat, dan semua pihak yang telah membantu secara langsung maupun tidak langsung. Terakhir, penulis menyampaikan penghargaan kepada keluarga atas doa, dukungan, dan motivasi yang diberikan selama proses penyelesaian penelitian ini.

DAFTAR PUSTAKA

- Abubakari, M. S., & Suprpto, S. (2021). Educational Data Mining to Predict Students Performance Based on Deep Learning Neural Network. *Proceeding International Conference On Health, Social Sciences And Technology*, 1(1), 13–16. <https://ojs.poltekkespalembang.ac.id/index.php/icohsst/article/view/697>
- Adekunle, K. O., Adebisi, M., Adebisi, A. A., & Aroba, O. J. (2025). A High-Accuracy Interpretable Model for Academic Performance Prediction Using Augmented Attention in Tabular Neural Networks. *NIPES - Journal of Science and Technology Research*, 7(1 Special Issue), 1810–1824. <https://doi.org/10.37933/nipes/7.4.2025.SI210>
- Al-Tameemi, G., Xue, J., Ali, I. H., & Ajit, S. (2024). A Hybrid Machine Learning Approach for Predicting Student Performance Using Multi-class Educational Datasets. *Procedia Computer Science*, 238(2019), 888–895. <https://doi.org/10.1016/j.procs.2024.06.108>
- Andika, A. Wira, Nurhakim, L., & Andas, Netty Huzniati. (2024). Penggunaan Deep Learning Untuk Memprediksi Using Deep Learning To Predict Academic Performance and. *Jurnal Ilmiah Bidang Sosial Ekonomi Budaya Teknologi Dan Pendidikan*, 4(7), 1647–1664.
- Arik, S., & Pfister, T. (2021). TabNet: Attentive Interpretable Tabular Learning. *35th AAAI Conference on Artificial Intelligence, AAAI 2021*, 8A, 6679–6687. <https://doi.org/10.1609/aaai.v35i8.16826>
- Bacak, F. Ü., & Tünkler, V. (2025). Thematic content analysis of studies on inquiry-based learning in education. *ODÜ Sosyal Bilimler Araştırmaları Dergisi (ODÜSOBİAD)*, 15(4), 2015–2037. <https://doi.org/10.48146/odusobiad.1637024>
- Constructivism, S., & Sohail, M. (2025). *Dialogue Social Science Review (DSSR) An Analysis of Mind in Preschoolers Through Dialogue Social Science Review (DSSR)*. 3(5), 577–582.
- Farchan, A. (2025). Integration of Coding and Artificial Intelligence (AI) Subjects in Primary School Curriculum as an Effort to Improve 21st Century Skills. *Jurnal Penelitian Pendidikan*, 42(2), 238–242. <https://doi.org/10.15294/jpp.v42i2.30457>
- Furfari(tony), F. A. (2002). The Transformer. *IEEE Industry Applications Magazine*, 8(1), 8–15. <https://doi.org/10.1109/2943.974352>
- Goodfellow I, Bengio Y, C. A. (2016). Deep learning. *The MIT Press, Cambridge, MA, USA*, 22(4), 351–354.
- Hair Jr et al. (2021). Partial least squares structural equation modeling (PLS-SEM) using R: A workbook (p. 197). Springer Nature. In *Structural Equation Modeling: A Multidisciplinary Journal* (Vol. 30, Number July).
- Harahap, E. Y., Negeri, S. D., & Batu, B. (2025). *Implementation of Contextual Approach in Improving Learning Outcomes of Clean and Healthy Living Material for Grade 2 Students of SD Negeri 0209 Bahal Batu*. 1(1), 181–191.
- Hariyanto, Kristianingsih, F. X. D., &

- Maharani, R. (2025). Artificial intelligence in adaptive education: a systematic review of techniques for personalized learning. *Discover Education*, 4(1), 458. <https://doi.org/10.1007/s44217-025-00908-6>
- Hendrilia, Y., Stie, S., Kerinci, S. A., Judijanto, L., Nahdaltul, U., Cirebon, U., & Fauzi, M. S. (2025). Learning Motivation as a Predictor of Academic Success: A Literature Review in Educational Psychology. *TOFEDU: The Future of Education Journal*, 4(6), 1841–1846. <https://journal.tofedu.or.id/index.php/journal/article/view/697>
- Hrastinski, S. (2009). A theory of online learning as online participation. *Computers and Education*, 52(1), 78–82. <https://doi.org/10.1016/j.compedu.2008.06.009>
- Huang, X., Khetan, A., Cvitkovic, M., & Karnin, Z. (2019). *TabTransformer: Tabular Data Modeling Using Contextual Embeddings*. (Rong 2014).
- Huang, X., Khetan, A., Cvitkovic, M., & Karnin, Z. (2020). *TabTransformer: Tabular Data Modeling Using Contextual Embeddings*. (Rong 2014). <http://arxiv.org/abs/2012.06678>
- Judd, C. H. (2012). Educational psychology. *Educational Psychology*, 62(2), 1–566. <https://doi.org/10.4324/9780203806197>
- Karim-Abdallah, B., Ayitey Junior, M., Appiahene, P., Harris, E., & Binful, D. K. (2025). Application of Machine Learning Algorithms in Predicting Academic Performance of Students in Higher Education Institutes (Heis): a Systematic Review and Bibliographic Analysis. *African Journal of Applied Research*, 11(1), 536–559. <https://doi.org/10.26437/ajar.v11i1.869>
- Khan, M. F., Lu, L., Toseef, M., Musyafa, A., & Amin, A. (2023). NotifyMiner: rule based user behavioral machine learning approach for context wise personalized notification services. *Journal of Ambient Intelligence and Humanized Computing*, 14(10), 13301–13317. <https://doi.org/10.1007/s12652-022-03785-1>
- Kim, B. H., Vizitei, E., & Ganapathi, V. (2018). GritNet: Student performance prediction with deep learning. *Proceedings of the 11th International Conference on Educational Data Mining, EDM 2018*.
- Korchi, A., Messaoudi, F., Abatal, A., & Manzali, Y. (2023). Machine Learning and Deep Learning-Based Students' Grade Prediction. *Operations Research Forum*, 4(4), 87. <https://doi.org/10.1007/s43069-023-00267-8>
- Lee, H. P. (Hank), Sarkar, A., Tankelevitch, L., Drosos, I., Rintel, S., Banks, R., & Wilson, N. (2025). The Impact of Generative AI on Critical Thinking: Self-Reported Reductions in Cognitive Effort and Confidence Effects From a Survey of Knowledge Workers. *Conference on Human Factors in Computing Systems - Proceedings*, (February). <https://doi.org/10.1145/3706598.3713778>
- Li, G. (2023). E-Learning Intelligence Model with Artificial Intelligence to Improve Learning Performance of Students. *Journal of Computer Allied Intelligence*, 1(1), 14–26. <https://doi.org/10.69996/jcai.2023002>
- Lin, Y., Chen, H., Xia, W., Lin, F., Wang, Z., & Liu, Y. (2025). A Comprehensive Survey on Deep Learning Techniques in Educational Data Mining. *Data Science and Engineering*, 10(4), 564–590. <https://doi.org/10.1007/s41019-025-00908-6>

- 00303-z
Liu, Y., Mittal, A., Yang, D., & Bruckman, A. (2022). Will AI Console Me when I Lose my Pet? Understanding Perceptions of AI-Mediated Email Writing. *Conference on Human Factors in Computing Systems - Proceedings*, (February). <https://doi.org/10.1145/3491102.3517731>
- Morales, E. F., & Escalante, H. J. (2022). A brief introduction to supervised, unsupervised, and reinforcement learning. In *Biosignal Processing and Classification Using Computational Learning and Intelligence* (pp. 111–129). Elsevier. <https://doi.org/10.1016/B978-0-12-820125-1.00017-8>
- Mufron, A., Maharjan, K., Mark, E., & Xavier, E. (2024). The Impact of Technology Integration in Learning on Increasing Student Engagement. *Journal Emerging Technologies in Education*, 2(3), 254–266. <https://doi.org/10.70177/jete.v2i3.1070>
- Ouyang, F., Wu, M., Zheng, L., Zhang, L., & Jiao, P. (2023). Integration of artificial intelligence performance prediction and learning analytics to improve student learning in online engineering course. *International Journal of Educational Technology in Higher Education*, 20(1), 1–23. <https://doi.org/10.1186/s41239-022-00372-4>
- Pradani, D. A., Zukhrufurrohmah, Z., & Rahayu, L. (2023). Peningkatan kemampuan berpikir kritis dan kemandirian belajar menggunakan model PBL pada mata pelajaran matematika. *Jurnal Pendidikan Profesi Guru*, 4(3), 135–147. <https://doi.org/10.22219/jppg.v4i3.27064>
- Qu, Y., Li, F., Li, L., Dou, X., & Wang, H. (2022). Can We Predict Student Performance Based on Tabular and Textual Data? *IEEE Access*, 10(August), 86008–86019. <https://doi.org/10.1109/ACCESS.2022.3198682>
- Rawat, K. S., & Malhan, I. V. (2019). A Hybrid Classification Method Based on Machine Learning Classifiers to Predict Performance in Educational Data Mining (pp. 677–684). https://doi.org/10.1007/978-981-13-1217-5_67
- Rivas, A., González-Briones, A., Hernández, G., Prieto, J., & Chamoso, P. (2021). Artificial neural network analysis of the academic performance of students in virtual learning environments. *Neurocomputing*, 423(xxxx), 713–720. <https://doi.org/10.1016/j.neucom.2020.02.125>
- Sahabuddin, I., Rasyid, A., & Maming, K. (2025). Behaviorism Approach through Operant Conditioning: Motivating Students in English Speaking Class. *Journal of English Language and Education*, 10(6), 812–821. <https://jele.or.id/index.php/jele/article/view/1682/934>
- Simbolon, I., Aditya, P., & Br Purba, E. (2025). Prediksi Performa Akademik Siswa Berdasarkan Kehadiran dan Aktivitas E-Learning Menggunakan Algoritma Decision Tree. *RIGGS: Journal of Artificial Intelligence and Digital Business*, 4(2), 4899–4910. <https://doi.org/10.31004/riggs.v4i2.1352>
- Somvanshi, S., Das, S., Javed, S. A., Antariksa, G., & Hossain, A. (2024). A Survey on Deep Tabular Learning. 1(1). <http://arxiv.org/abs/2410.12034>
- Tang, B., Li, S., & Zhao, C. (2024). Predicting the Performance of Students Using Deep Ensemble Learning. *Journal of Intelligence*, 12(12). <https://doi.org/10.3390/jintelligence12120124>
- Villar, A., & de Andrade, C. R. V. (2024).

- Supervised machine learning algorithms for predicting student dropout and academic success: a comparative study. *Discover Artificial Intelligence*, 4(1). <https://doi.org/10.1007/s44163-023-00079-z>
- Vimala, S., Arockia, G., & Sheela, S. (2025). A Comparative Study of Artificial Intelligence, Machine Learning, and Deep Learning Approaches in Predicting Academic Performance. *International Multidisciplinary Research Journal Reviews (IMRJR) A Peer-Reviewed Journal*, 2(10), 64–69. <https://doi.org/10.17148/IMRJR.2025.021008>
- Vimarsha, K., Prakash, S. P. S., Krinkin, K., & Shichkina, Y. A. (2024). Student Performance Prediction: A Co-Evolutionary Hybrid Intelligence model. *Procedia Computer Science*, 235, 436–446. <https://doi.org/10.1016/j.procs.2024.04.043>
- Vyas, T. K. (2024). *Deep Learning with Tabular Data: A Self-supervised Approach*. <http://arxiv.org/abs/2401.15238>
- Waheed, H., Hassan, S. U., Aljohani, N. R., Hardman, J., Alelyani, S., & Nawaz, R. (2020). Predicting academic performance of students from VLE big data using deep learning models. *Computers in Human Behavior*, 104. <https://doi.org/10.1016/j.chb.2019.10.6189>
- Waseem, T., & Aslam, F. (2020). Educational Learning Theories & Their Implications in Modern Instructional Designs. *Health Professions Educator Journal*, 3(2), 25–31. <https://doi.org/10.53708/hpej.v3i2.9>
- Yang, Y., Zhao, S., An, S., Li, X., & Zhang, Y. (2025). Student academic performance prediction via hypergraph and TabNet. *Journal of Big Data*, 1–24. <https://doi.org/10.1186/s40537-025-01170-1>
- Yunita, A., Santoso, H. B., & Hasibuan, Z. A. (2019). Deep Learning for Predicting Students' Academic Performance. 2019 *Fourth International Conference on Informatics and Computing (ICIC)*, 1–6. <https://doi.org/10.1109/ICIC47613.2019.8985721>
- Zhang, M. (2024). Integrating Deep Learning into Educational Big Data Analytics for Enhanced Intelligent Learning Platforms. *Information Technology and Control*, 53(4), 1060–1073. <https://doi.org/10.5755/j01.itc.53.4.36968>
- Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory into Practice*, 41(2), 64–70. https://doi.org/10.1207/s15430421tip4102_2