

Prediksi Aktivitas Belajar Efektif Mahasiswa Menggunakan Algoritma Decision Tree

Ilham Syauqi Hizbullah^{1*}, Ardian Biahilil Badri², Rizqi Nur Hidayatullah³, Muthia Lutfi Qurata'ain⁴, Dafa Aminata⁵

¹ Teknik Informatika/Fakultas Ilmu
Komputer

Universitas Duta Bangsa

^{1*}240103133@mhs.udb.ac.id

² Teknik Informatika/Fakultas Ilmu
Komputer

Universitas Duta Bangsa

²240103254@mhs.udb.ac.id

³ Teknik Informatika/Fakultas Ilmu
Komputer

Universitas Duta Bangsa

³240103147@mhs.udb.ac.id

⁴ Teknik Informatika/Fakultas Ilmu
Komputer

Universitas Duta Bangsa

⁴240103142@mhs.udb.ac.id

⁵ Teknik Informatika/Fakultas Ilmu
Komputer

Universitas Duta Bangsa

⁵240103128@mhs.udb.ac.id

Abstrak— Proses pembelajaran di perguruan tinggi memerlukan evaluasi mendalam untuk memastikan efektivitasnya. Penelitian ini bertujuan untuk memprediksi efektivitas belajar mahasiswa menggunakan pendekatan *machine learning* dengan algoritma *Decision Tree*. Data penelitian diperoleh dari kuesioner yang melibatkan 900 responden mahasiswa Universitas Duta Bangsa (UDB). Variabel yang dianalisis dalam penelitian ini meliputi semester, gender, metode belajar, durasi belajar, gangguan digital, lingkungan pendukung, tingkat pemahaman materi, dan efektivitas belajar sebagai variabel target. Tahapan penelitian meliputi studi literatur, pengumpulan data, *preprocessing* data, pembagian dataset menjadi data latih dan data uji, pembangunan model *Decision Tree*, evaluasi model menggunakan *Confusion Matrix*, *Accuracy*, *Precision*, *Recall*, *F1-Score*, *ROC Curve*, *AUC-ROC*, serta *5-fold Cross Validation*, kemudian dilanjutkan dengan analisis *feature importance*. Hasil pengujian menunjukkan bahwa model *Decision Tree* mampu memprediksi efektivitas belajar dengan tingkat *accuracy* sebesar 83,33%, *precision* 94,87%, *recall* 82,22%, dan *F1-Score* sebesar 88,10%. Pengujian kurva karakteristik operasi penerima (*Receiver Operating Characteristic*) menghasilkan nilai AUC-ROC sebesar 0,8669, sementara validasi silang (*5-fold cross-validation*) memberikan rata-rata akurasi stabil di angka $81,89\% \pm 5,68\%$. Analisis kepentingan fitur menunjukkan bahwa metode belajar menjadi faktor yang paling dominan dalam menentukan efektivitas belajar mahasiswa. Penelitian ini membuktikan bahwa pendekatan berbasis data menggunakan *Decision Tree* dapat memberikan rekomendasi strategis bagi institusi pendidikan dalam mengoptimalkan sistem pembelajaran.

Kata kunci— *Machine Learning*, *Decision Tree*, *Efektivitas Belajar*, *Mahasiswa*, *Prediksi*.

Abstract— The learning process in higher education requires profound evaluation to ensure its effectiveness. This study aims to predict student learning effectiveness using a machine learning approach with the Decision Tree algorithm. The research data was gathered through questionnaires from 900 student respondents at Universitas Duta Bangsa (UDB). The variables analyzed in this study include semester level, gender, learning methods, learning duration, digital distractions, supportive environments, comprehension of materials, and learning effectiveness as the target variable. The research stages include literature study, data collection, data preprocessing, dataset division into training data and test data, Decision Tree model development, model evaluation using Confusion Matrix, Accuracy, Precision, Recall, F1-Score, ROC Curve, AUC-ROC, and 5-fold Cross Validation, then continued with feature important analysis. The evaluation results demonstrate that the Decision Tree model successfully predicts learning effectiveness with an accuracy of 83.33%, precision of 94.87%, recall of 82.22%, and an F1-Score of 88.10%. The Receiver Operating Characteristic curve analysis yielded an AUC-ROC value of 0.8669, while the 5-fold cross-validation maintained a stable average accuracy of $81.89\% \pm 5.68\%$. Feature importance analysis reveals that the learning method is the most dominant factor in determining students' learning effectiveness. This research proves that a data-driven approach using the Decision Tree can provide strategic recommendations for educational institutions to optimize their learning ecosystem.

Keywords— *Machine Learning*, *Decision Tree*, *Learning Effectiveness*, *Students*, *Prediction*.

I. PENDAHULUAN

Perguruan tinggi memiliki peran yang sangat strategis dalam mencetak sumber daya

manusia berkualitas yang siap bersaing di era global [1]. Salah satu tolok ukur utama keberhasilan pendidikan di jenjang universitas adalah efektivitas proses belajar mahasiswa

[2]. Namun, mengukur dan memastikan efektivitas belajar bukanlah hal yang mudah karena dipengaruhi oleh karakteristik yang dinamis dan berbagai faktor eksternal maupun internal [3]. Beberapa faktor yang secara signifikan diyakini memengaruhi efektivitas belajar meliputi durasi belajar, dukungan lingkungan atau lokasi belajar, metode pembelajaran yang diterapkan, tingkat pemahaman materi [4], hingga intensitas gangguan digital (digital distraction) yang menjadi tantangan besar di era modern ini [5].

Untuk memahami pola dan faktor dominan yang mempengaruhi efektivitas belajar mahasiswa, pendekatan evaluasi tradisional seringkali tidak cukup. Maka dari itu, dibutuhkan suatu pendekatan yang berlandaskan analisis data yang dapat mengolah dan menemukan pola tersembunyi dari sekumpulan variabel yang kompleks. Machine learning, khususnya dalam ranah Educational Data Mining (EDM), telah menunjukkan keberhasilan sebagai solusi yang efisien untuk memecahkan masalah ini [6]. Salah satu algoritma klasifikasi yang sangat relevan dan andal untuk diterapkan adalah Decision Tree (Pohon Keputusan). Algoritma ini dipilih karena tidak hanya mampu memprediksi kelas dengan akurasi yang baik, tetapi juga menghasilkan aturan percabangan (decision rules) yang transparan dan mudah diinterpretasikan oleh pemangku kepentingan di bidang pendidikan [7].


Berdasarkan latar belakang tersebut, penelitian ini bertujuan untuk memprediksi tingkat efektivitas belajar mahasiswa dengan membangun model klasifikasi menggunakan algoritma Decision Tree. Penelitian ini memanfaatkan data primer yang dikumpulkan melalui kuesioner dari 900 responden mahasiswa Universitas Duta Bangsa (UDB) [8], [9]. Melalui penelitian ini, diharapkan dapat diidentifikasi faktor-faktor prediktor mana yang paling dominan dalam menentukan efektivitas belajar, sehingga hasilnya dapat dijadikan dasar pengambilan keputusan strategis bagi institusi pendidikan untuk menciptakan ekosistem pembelajaran yang

lebih optimal dan adaptif terhadap kebutuhan mahasiswa.

II. METODOLOGI PENELITIAN

Penelitian ini memakai pendekatan kuantitatif dengan data primer yang dikumpulkan lewat penyebaran kuesioner kepada mahasiswa Universitas Duta Bangsa (UDB). Total ada 900 responden yang datanya mencakup beberapa atribut terkait efektivitas belajar, antara lain semester, gender, durasi belajar, lingkungan belajar, metode belajar, gangguan digital (digital distraction), dan tingkat pemahaman materi, dengan efektivitas belajar sebagai variabel target. Data inilah yang kemudian diolah untuk menyusun model klasifikasi yang menggunakan algoritma Decision Tree, dengan tujuan untuk memprediksi sejauh mana efektivitas belajar mahasiswa [10].

Proses penelitian dilakukan melalui serangkaian tahapan yang saling berkaitan, mulai dari studi literatur hingga analisis hasil. Adapun alur tahapan penelitian yang digunakan dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

Tahap pertama, studi literatur [11]. Pada tahap awal ini, peneliti menelusuri berbagai jurnal, buku, prosiding, dan penelitian sebelumnya yang relevan dengan efektivitas belajar mahasiswa, machine learning, Educational Data Mining, algoritma Decision Tree, Confusion Matrix, ROC Curve, dan Cross Validation. Tujuannya untuk membangun dasar teori yang kuat sekaligus menentukan metode yang paling sesuai untuk penelitian ini [12].

Tahap kedua, pengumpulan data. Data dikumpulkan melalui kuesioner yang disebar kepada mahasiswa aktif UDB. Dari 900 responden yang berpartisipasi, terbentuklah dataset yang memuat informasi semester, gender, durasi belajar, lingkungan belajar, metode belajar, gangguan digital, tingkat pemahaman materi, dan efektivitas belajar. Dataset inilah yang jadi bahan utama dalam membangun model klasifikasi.

Tahap ketiga, preprocessing data. Sebelum dipakai untuk pemodelan, data diperiksa kualitasnya lebih dulu. Pemeriksaan ini meliputi pengecekan missing value, data duplikat, konsistensi data, sekaligus mengonversi data kategorikal ke dalam bentuk numerik melalui proses encoding. Tujuannya supaya data benar-benar bersih dan bisa diproses secara optimal oleh algoritma Decision Tree.

Tahap keempat, pembagian dataset. Setelah preprocessing selesai dataset dibagi menjadi dua bagian, yakni data latih (training data) dan data uji (testing data). Data latih dimanfaatkan sebagai fondasi dalam membangun model, sedangkan data uji dipakai untuk mengukur sejauh mana model mampu memprediksi data baru yang belum "dilihat" model sebelumnya.

Tahap kelima, pembuatan model. Model dibangun dengan algoritma Decision Tree, memanfaatkan atribut semester, gender, durasi belajar, lingkungan belajar, metode belajar, gangguan digital, dan tingkat pemahaman materi sebagai variabel prediktor. Algoritma ini lalu menyusun struktur pohon keputusan mengacu pada atribut-atribut yang

memberikan pengaruh terhadap efektivitas belajar mahasiswa.

Tahap keenam, evaluasi model. Performa model diukur menggunakan Confusion Matrix, yang kemudian menghasilkan nilai Accuracy, Precision, Recall, dan F1-Score untuk melihat seberapa akurat model dalam mengklasifikasikan efektivitas belajar mahasiswa [13].

Accuracy dipakai untuk mengukur ketepatan model secara keseluruhan, dengan rumus:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \times 100\%$$

Keterangannya :

- TP (True Positive)
Data yang diprediksi oleh model sebagai kelas positif dan prediksi tersebut sesuai dengan kondisi nyatanya.
- TN (True Negative)
Data yang diprediksi oleh model sebagai kelas negatif dan prediksi tersebut juga sesuai dengan kondisi nyatanya.
- FP (False Positive)
Data yang oleh model diklasifikasikan sebagai positif, namun kenyataannya data tersebut termasuk kelas negatif.
- FN (False Negative)
Data yang oleh model diklasifikasikan sebagai negatif, namun kenyataannya data tersebut termasuk kelas positif.

Selain Accuracy, ada juga Precision yang mengukur ketepatan model saat memprediksi suatu kelas tertentu:

$$\text{Precision} = \frac{TP}{TP+FP}$$

Sementara Recall mengukur kemampuan model dalam menangkap seluruh data yang sebenarnya memang masuk ke kelas tersebut:

$$\text{Recall} = \frac{TP}{TP+FN}$$

Dan terakhir, F1-Score dipakai untuk melihat seberapa seimbang Precision dan Recall yang dihasilkan model:

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

Tahap ketujuh, analisis hasil [14]. Hasil pengujian model dianalisis lebih jauh berdasarkan nilai Accuracy, Precision, Recall, F1-Score, Confusion Matrix, ROC Curve, AUC-ROC, 5-Fold Cross Validation, serta Feature Importance [15]. Analisis ini bertujuan mengetahui sejauh mana performa model serta mengidentifikasi faktor-faktor yang paling berpengaruh terhadap efektivitas belajar mahasiswa, sehingga hasilnya bisa jadi dasar rekomendasi untuk meningkatkan kualitas proses pembelajaran.

III. HASIL DAN PEMBAHASAN

A. Pengumpulan Data

Data dikumpulkan melalui kuesioner yang disebar ke mahasiswa aktif Universitas Duta Bangsa, dan sebanyak 900 responden berhasil mengisinya secara lengkap. Dataset yang terbentuk mencakup atribut Semester, Gender, Durasi Belajar, Lingkungan Dukung, Metode Belajar, Gangguan Digital, dan Tingkat Pemahaman Materi, dengan Efektivitas Belajar sebagai variabel target.

Tabel 1. Deskripsi Variabel Dataset

Variabel	Keterangan
Semester	Semester Mahasiswa
Gender	Jenis Kelamin Mahasiswa
Durasi	Lama Waktu Belajar
Lingkungan Pendukung	Kondisi Lingkungan Belajar
Metode	Metode Belajar yang digunakan
Gangguan	Tingkat Gangguan Digital
Pemahaman	Tingkat Pemahaman Materi
Efektivitas Belajar	Kategori Efektif atau Tidak Efektif

Dari ketujuh variabel pada Tabel 1, Semester, Gender, Durasi, LingkunganDukung, Metode, Gangguan, dan Pemahaman berperan sebagai variabel prediktor, sementara Efektivitas Belajar menjadi variabel target yang akan diprediksi oleh model Decision Tree.

Tabel 2. Visualisasi Dataset

Semester	Gender	Durasi	Lingkungan	Metode	Gangguan	Pemahaman	Jumlah
4	0	2,5	2,5	3,0	3,0	1	1

6	1	4,5	4,5	4,5	5,0	1	1
4	1	4,0	4,0	3,5	3,0	1	1
...	...	...	...	...	...	...	...
2	0	3,0	3,5	3,5	4,0	0	1

Tabel 2, hanya menyajikan tiga baris data awal dan satu baris data akhir sebagai gambaran umum dari keseluruhan dataset yang digunakan. Untuk variabel Gender, dilakukan pengkodean dengan ketentuan 0 mewakili Perempuan dan 1 mewakili Laki-laki. Sementara itu, variabel Pemahaman dan Efektivitas masing-masing dikodekan menjadi nilai 0 dan 1 berdasarkan hasil proses encoding yang telah dilakukan.

B. Preprocessing Data

Sebelum data dipakai untuk melatih model, dilakukan pengecekan kualitas data lebih dulu, mulai dari missing value, data duplikat, konsistensi data, hingga proses encoding untuk mengubah data kategorikal menjadi numerik. Hasilnya, data yang ada terbukti dalam kondisi baik dan siap dipakai untuk proses klasifikasi.

Tabel 3. Hasil Pemeriksaan Dataset

Keterangan	Jumlah
Total Data	900
Missing Value	0
Data Duplikat	0
Data Valid	900

Sesuai Tabel 3, tidak ditemukan satu pun data kosong atau duplikat, sehingga seluruh 900 data dinyatakan valid dan layak digunakan dalam proses pembangunan model.

C. Pembagian Data

dataset dibagi menjadi dua bagian, yakni data latih (training data) dan data uji (testing data). Data latih digunakan sebagai bahan untuk melatih model Decision Tree, sedangkan data uji berperan untuk menguji seberapa baik model dalam menangani data baru yang belum pernah dikenalnya sebelumnya.

Tabel 4. Pembagian Dataset


Jenis Data	Jumlah
Training Data	720
Testing Data	180
Total Data	900

Sesuai Tabel 4, Pembagian dilakukan dengan rasio 80:20, sehingga didapat 720 data untuk pelatihan dan 180 data untuk pengujian. Rasio ini dipilih agar model punya cukup data untuk belajar, namun

tetap tersedia data yang memadai untuk diuji.

D. Pembuatan Model Decision Tree

Model klasifikasi dibangun menggunakan algoritma Decision Tree, dengan variabel Semester, Gender, Durasi, LingkunganDukung, Metode, Gangguan, dan Pemahaman sebagai atribut prediktor.




Gambar 2. Visualisasi Pohon Keputusan Decision Tree

Dari Gambar 2, terlihat bahwa variabel Metode menjadi root node atau akar pohon. Apabila nilai Metode $\leq 3,25$, klasifikasi selanjutnya akan mempertimbangkan variabel Gangguan dan Semester. Sebaliknya, jika nilai Metode $> 3,25$, proses klasifikasi berlanjut dengan mempertimbangkan Durasi, LingkunganDukung, dan Pemahaman. Pola ini menegaskan bahwa metode belajar menjadi faktor paling menentukan dalam membedakan efektivitas belajar mahasiswa.

E. Evaluasi Model

Setelah model selesai dibangun, tahap berikutnya adalah mengevaluasi performa model menggunakan Confusion Matrix untuk melihat seberapa baik algoritma Decision Tree mengklasifikasikan efektivitas belajar mahasiswa. Evaluasi ini mengacu pada nilai Accuracy, Precision, Recall, F1-Score, Confusion Matrix, dan Classification Report yang dihasilkan model, dengan tujuan mengetahui seberapa tepat model membedakan kategori Efektif dan Tidak Efektif berdasarkan atribut semester, gender, durasi belajar, lingkungan belajar, metode belajar, gangguan digital, dan tingkat pemahaman materi.



Gambar 3. Confusion Matrix

Dari Gambar 3, hasil Confusion Matrix, model berhasil mengenali dengan benar 39 data kategori Tidak Efektif dan 111 data kategori Efektif. Namun, masih ada 6 data Tidak Efektif yang justru diprediksi sebagai Efektif, dan 24 data Efektif yang diprediksi sebagai Tidak Efektif.

Tabel 5 . Hasil Evaluasi Model

Metrik	Nilai
Accuracy	83,33%
Precision	94,87%
Recall	82,22%
F1-Score	88,10%

Dari Tabel 5, terlihat bahwa model mampu mengklasifikasikan sebagian besar data dengan tepat. Accuracy sebesar 83,33% berarti sebagian besar data uji berhasil diklasifikasikan secara benar. Precision sebesar 94,87% menunjukkan tingkat ketepatan prediksi yang sangat tinggi, sedangkan Recall sebesar 82,22% menandakan model cukup mampu mengenali mahasiswa yang memang benar-benar masuk kategori Efektif. Adapun F1-Score sebesar 88,10% mencerminkan keseimbangan yang baik antara Precision dan Recall tadi.

Tabel 6. Classification Report

Kategori	Precision	Recall	F1-Score
Tidak Efektif	0,62	0,87	0,72
Efektif	0,95	0,82	0,88


Mengacu pada Tabel 6, kategori Efektif menunjukkan performa klasifikasi yang lebih unggul, dengan Precision 0,95 dan F1-Score 0,88 artinya model sangat andal dalam mengenali mahasiswa dengan efektivitas belajar tinggi. Sebaliknya, kategori Tidak

Efektif hanya memperoleh F1-Score 0,72. Kesenjangan performa ini mengindikasikan bahwa model masih agak kesulitan memisahkan data yang karakteristiknya berada di "wilayah abu-abu", yakni mendekati batas antara kedua kategori tersebut.

Secara umum, hasil evaluasi ini memperlihatkan bahwa algoritma Decision Tree cukup andal dalam mengklasifikasikan efektivitas belajar mahasiswa. Nilai Accuracy yang tinggi, didukung Precision, Recall, dan F1-Score yang juga memadai, menunjukkan bahwa model ini layak dipakai sebagai alat bantu untuk menganalisis dan memprediksi efektivitas belajar mahasiswa secara cukup akurat.

F. Analisis Hasil

Untuk melihat lebih dalam kemampuan model serta faktor apa saja yang paling berpengaruh, dilakukan analisis lanjutan menggunakan ROC Curve, AUC-ROC, dan Feature Importance.



Gambar 4. Kurva ROC


Hasil pengujian menunjukkan nilai AUC-ROC sebesar 0,867, yang berarti model cukup handal dalam membedakan kelas Efektif dari Tidak Efektif. Bentuk kurva ROC yang mendekati sudut kiri atas juga mengindikasikan bahwa model punya sensitivitas dan spesifisitas yang tinggi.

Tabel 7. Hasil 5-Fold Cross Validation

Pengujian	Nilai
Rata-Rata Akurasi	81,89%
Standar Deviasi	$\pm 5,68\%$

Mengacu pada Tabel 7, pengujian dengan teknik 5-Fold Cross Validation menghasilkan

akurasi rata-rata sebesar 81,89%, dengan variasi antar lipatan (fold) yang relatif kecil, yaitu $\pm 5,68\%$. Hal ini menunjukkan bahwa model Decision Tree yang dibangun tidak hanya akurat, tetapi juga konsisten performanya di berbagai subset data, sehingga dapat diandalkan untuk melakukan generalisasi pada data baru yang belum pernah dikenali sebelumnya.



Gambar 5. Feature Importance

Berdasarkan Gambar 5, terlihat bahwa Metode Belajar menjadi faktor paling dominan, dengan kontribusi sebesar 74,7% terhadap efektivitas belajar mahasiswa. Angka ini jauh melampaui variabel-variabel lainnya, seperti Durasi Belajar (10,0%), Semester (5,4%), Gangguan Digital (5,0%), Lingkungan Dukung (2,8%), dan Pemahaman Materi (2,0%). Dengan demikian, dapat disimpulkan bahwa cara atau metode yang digunakan mahasiswa dalam belajar memberikan pengaruh yang jauh lebih besar dibandingkan faktor-faktor lain dalam menentukan seberapa efektif proses belajar mereka berlangsung.

Tabel 8. Tingkat Kepentingan Fitur

Variabel	Impotance
Metode	74,7%
Durasi	10,0%
Semester	5,4%
Gangguan	5,0%
Lingkungan	2,8%
Pemahaman	2,0%

Sesuai Tabel 8, Metode Belajar memiliki tingkat kepentingan sebesar 74,7%, disusul oleh Durasi Belajar (10,0%), Semester (5,4%), Gangguan Digital (5,0%), Lingkungan Dukung (2,8%), dan terakhir Pemahaman Materi (2,0%). Temuan ini semakin menegaskan bahwa metode belajar

adalah faktor paling besar pengaruhnya terhadap efektivitas belajar mahasiswa. Secara keseluruhan, algoritma Decision Tree terbukti mampu memprediksi efektivitas belajar mahasiswa dengan performa yang cukup baik, sekaligus menghasilkan model yang relatif mudah dipahami dan diinterpretasikan

IV. KESIMPULAN

Penerapan algoritma Decision Tree untuk memprediksi efektivitas belajar mahasiswa berhasil dilakukan dengan performa klasifikasi yang baik, ditunjukkan oleh nilai Accuracy 83,33%, Precision 94,87%, Recall 82,22%, dan F1-Score 88,10%. Nilai AUC-ROC sebesar 0,8669 menegaskan model cukup andal membedakan kategori Efektif dan Tidak Efektif, sementara hasil 5-Fold Cross Validation dengan rata-rata akurasi 81,89% membuktikan model cukup stabil pada berbagai pembagian data.

Hasil Feature Importance dan struktur pohon keputusan menunjukkan bahwa metode belajar merupakan faktor paling dominan (74,7%) dalam menentukan efektivitas belajar mahasiswa, diikuti oleh durasi belajar, semester, gangguan digital, lingkungan pendukung, dan tingkat pemahaman materi. Temuan ini menegaskan bahwa pemilihan metode belajar yang tepat sangat berperan dalam meningkatkan efektivitas pembelajaran, sekaligus membuktikan bahwa Decision Tree efektif digunakan untuk memprediksi efektivitas belajar mahasiswa sekaligus mengidentifikasi faktor-faktor yang memengaruhinya.

Pada penelitian berikutnya, disarankan untuk membandingkan hasil model dengan algoritma lainnya seperti Random Forest, XGBoost, SVM, maupun ANN; memperluas jumlah dan keragaman responden agar model lebih general; serta menambahkan variabel lain seperti motivasi belajar, stres akademik, dukungan keluarga, kondisi ekonomi, dan aktivitas organisasi mahasiswa agar gambaran faktor-faktor

yang memengaruhi efektivitas belajar menjadi lebih komprehensif.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada seluruh anggota tim atas kerja sama dalam pengumpulan data, pengolahan data, pembangunan model Decision Tree, hingga analisis hasil penelitian ini. Terima kasih juga disampaikan kepada Universitas Duta Bangsa Surakarta, khususnya Fakultas Ilmu Komputer, atas fasilitas dan dukungan akademik yang diberikan. Penghargaan khusus disampaikan kepada Bapak Sunneng Sandino B, M.Kom., Ph.D. selaku dosen pengampu, atas arahan, bimbingan, dan motivasi yang membuat penelitian ini dapat terselesaikan dengan baik.

REFERENSI

- [1] F. Martin, S. Long, K. Haywood, and K. Xie, "Digital distractions in education: a systematic review of research on causes, consequences and prevention strategies," *Educ. Technol. Res. Dev.*, vol. 73, no. 6, pp. 3423–3451, 2025, doi: 10.1007/s11423-025-10550-6.
- [2] J. B. Manulat, "Key predictors of academic success in flexible learning environments: a PLS-SEM analysis," *Front. Educ.*, vol. 10, no. October, 2025, doi: 10.3389/educ.2025.1633040.
- [3] J. Li et al., "The multi-parameter optimized belief rule base for predicting student performance with interpretability," *Sci. Rep.*, no. 1, pp. 1–23, 2026, doi: 10.1038/s41598-026-35950-3.
- [4] S. Boujmiraz, H. Darhmaoui, and A. Drissi el maliani, "Predicting student performance: A comprehensive review of machine learning, deep learning, and explainable AI approaches," *Comput. Educ. Artif. Intell.*, vol. 10, no. July 2025, p. 100548, 2026, doi: 10.1016/j.caeai.2026.100548.
- [5] C. Liu and S. Yu, "Students' stress prediction and explainable analysis based on improved decision trees," *Front. Psychol.*, vol. 16, no. January, pp. 1–18, 2026, doi: 10.3389/fpsyg.2025.1684529.
- [6] R. Guevara-Reyes, I. Ortiz-Garcés, R. Andrade, F. Cox-Riquetti, and W. Villegas-Ch, "Machine learning models for academic performance prediction: interpretability and application in educational decision-making," *Front. Educ.*, vol. 10, no. August, pp. 1–27, 2025, doi: 10.3389/educ.2025.1632315.
- [7] E. Ahmed, "Student Performance Prediction Using Machine Learning Algorithms," *Appl. Comput. Intell. Soft Comput.*, vol. 2024, 2024, doi: 10.1155/2024/4067721.
- [8] A. T. Wahyono, D. J. Novianto, T. A. Nugroho, and F. Agusti, "Optimalisasi Rute Perjalanan Menuju Kampus Universitas Duta Bangsa Surakarta Dengan Metode Dynamic Programming," *J. Sci. Innov. Technol.*, vol. 4, no. 2, pp. 14–19, 2024, doi: 10.47701/sintech.v4i2.3924.
- [9] C. Satifa, E. Purwanto, and H. Permatasari, "Sistem Informasi Monitoring Pembelajaran Berbasis Web Pada Rumah Belajar Al Maarif Sukoharjo," *Duta.com J. Ilm. Teknol. Inf. dan Komun.*, vol. 18, no. 1, pp. 13–19, 2025, doi: 10.47701/dutacom.v18i1.5682.
- [10] S. Alvian Setiono and E. Purwanto, "Prediksi Kelulusan Mahasiswa Menggunakan Algoritma Decision Tree," *Pros.*

- Semin. Nas. Teknol. Inf. dan Bisnis*, pp. 401–406, 2025, doi: 10.47701/4q3z9j41.
- [11] P. Studi *et al.*, “Konsep Teknologi Machine Learning Dalam Prediksi Kebutuhan Belajar Mahasiswa,” no. 2, pp. 155–165, 2025, doi: 10.25126/jtiik.2025129190.
- [12] M. H. Arief, M. A. W. Saputra, K. Afandi, D. Novtahaning, and N. A. Ranggianto, “Optimalisasi Klasifikasi Performa Akademik Mahasiswa dengan Pendekatan Metaheuristik Berbasis Educational Data Mining,” *Remik*, vol. 9, no. 3, pp. 943–951, 2025, doi: 10.33395/remik.v9i3.15168.
- [13] G. Zeng, “Invariance Properties and Evaluation Metrics Derived from the Confusion Matrix in Multiclass Classification,” *Mathematics*, vol. 13, no. 16, 2025, doi: 10.3390/math13162609.
- [14] R. Susmaga, “Confusion Matrix Visualization,” *Intell. Inf. Process. Web Min.*, pp. 107–116, 2004, doi: 10.1007/978-3-540-39985-8_12.
- [15] E. G. Dandamudi *et al.*, “Performance of transformer-convolutional neural network ensemble for melanoma diagnosis on segmented 3D total body photography data: Cross-Validation stratified K-fold,” *Biosens. Bioelectron. X*, vol. 27, no. November, p. 100714, 2025, doi: 10.1016/j.biosx.2025.100714.