



## Penerapan Algoritma Machine Learning dalam Prediksi Prestasi Akademik Mahasiswa

Riska Rismaya<sup>1\*</sup>, Dwi Yuniarto<sup>2</sup>, David Setiadi<sup>3</sup>

<sup>1-3</sup> Universitas Sebelas April, Indonesia

Email: [a22100116@mhs.stmik-sumedang.ac.id](mailto:a22100116@mhs.stmik-sumedang.ac.id) \*

**Abstract,** *This study explores the application of machine learning algorithms, specifically Linear Regression and Decision Tree Regressor, for predicting student academic performance using academic grade data from Kaggle. The analyzed factors include attendance, assignment grades, midterm exam grades, and final exam grades. The research methodology encompasses data collection, preprocessing, model development, training, and validation. This study contributes to the field of educational data analytics by demonstrating how machine learning can provide actionable insights into students' learning patterns and academic outcomes. The findings emphasize the effectiveness of Linear Regression for linearly distributed data and Decision Tree Regressor for capturing complex, non-linear relationships. The implications of this research suggest that machine learning models can assist educators in identifying key factors influencing student performance, enabling targeted interventions to enhance learning outcomes. Future research should explore larger, more diverse datasets and incorporate ensemble methods, such as Random Forest or Gradient Boosting, to improve model generalization and prediction accuracy. Additionally, integrating socio-economic and psychological factors could provide a more holistic perspective on academic achievement.*

**Keywords:** *Machine Learning, Linear Regression, Decision Tree Regressor, Academic Achievement*

**Abstrak,** Penelitian ini mengeksplorasi penerapan algoritma machine learning, khususnya Linear Regression dan Decision Tree Regressor, untuk memprediksi kinerja akademik mahasiswa menggunakan data nilai akademik dari Kaggle. Faktor-faktor yang dianalisis meliputi kehadiran, nilai tugas, nilai ujian tengah semester, dan nilai ujian akhir. Metodologi penelitian meliputi pengumpulan data, preprocessing, pengembangan model, pelatihan, dan validasi. Penelitian ini berkontribusi pada bidang analisis data pendidikan dengan menunjukkan bagaimana pembelajaran mesin dapat memberikan wawasan yang dapat ditindaklanjuti ke dalam pola belajar siswa dan hasil akademik. Temuan ini menekankan efektivitas Regresi Linier untuk data yang terdistribusi secara linier dan Decision Tree Regressor untuk menangkap hubungan yang kompleks dan tidak linier. Implikasi dari penelitian ini menunjukkan bahwa model pembelajaran mesin dapat membantu para pendidik dalam mengidentifikasi faktor-faktor kunci yang mempengaruhi kinerja siswa, memungkinkan intervensi yang ditargetkan untuk meningkatkan hasil pembelajaran. Penelitian di masa depan harus mengeksplorasi set data yang lebih besar, lebih beragam, dan menggabungkan metode ensemble, seperti Random Forest atau Gradient Boosting, untuk meningkatkan generalisasi model dan akurasi prediksi. Selain itu, mengintegrasikan faktor sosial-ekonomi dan psikologis dapat memberikan perspektif yang lebih holistik tentang pencapaian akademik.

**Kata kunci:** Machine Learning, Regresi Linear, Decision Tree Regressor, Prestasi Akademik

### 1. PENDAHULUAN

Di era digital, analisis data telah menjadi elemen penting dalam berbagai bidang, termasuk pendidikan. Teknologi modern memungkinkan pengelolaan dan analisis data akademik yang lebih efektif untuk meningkatkan kualitas pembelajaran. Salah satu aplikasi dari teknologi ini adalah prediksi prestasi akademik siswa, yang bertujuan untuk membantu pendidik memahami pola belajar siswa dan mengambil tindakan proaktif untuk meningkatkan hasil belajar mereka. Faktor-faktor seperti kehadiran, nilai tugas, nilai ujian tengah semester (UTS), dan nilai ujian akhir semester (UAS) dikenal sebagai indikator utama mempengaruhi prestasi akademik siswa[1], [2].

Salah satu metode kecerdasan buatan (AI) yang meniru kemampuan pemecahan masalah manusia adalah pembelajaran mesin. Tanpa bantuan manusia, metode ini memungkinkan robot untuk belajar dan berfungsi sendiri. Pembelajaran mesin adalah bidang ilmiah yang bertujuan untuk membuat komputer belajar tanpa pemrograman eksplisit, menurut pelopor AI asal Amerika, Arthur Samuel. Pembelajaran terawasi, pembelajaran tidak terawasi, dan pembelajaran penguatan adalah tiga kategori algoritmik utamanya [3].

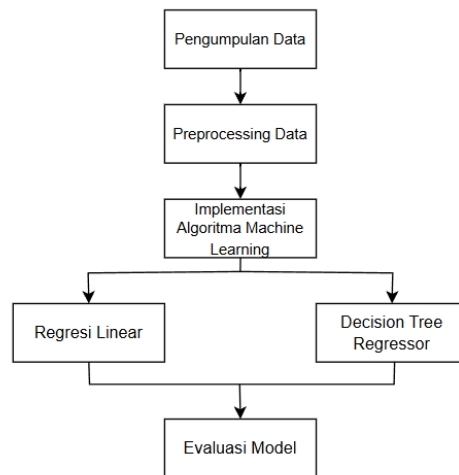
Untuk memilih algoritma yang optimal dalam menggambarkan hubungan antara variabel X dan Y, pembelajaran terawasi melatih algoritma dengan menggunakan pendekatan fungsi. Namun, sering kali mengandalkan asumsi membuat sulit untuk mengidentifikasi fungsi yang sesuai. Oleh karena itu, untuk mengurangi bias dan meningkatkan akurasi, data pelatihan harus akurat. Algoritma machine learning yang digunakan dalam penelitian ini adalah Decision Tree Regressor dan Regresi Linier. Salah satu teknik statistik yang meramalkan hubungan matematis antara variabel dependen dan independen adalah regresi linier, yang memungkinkan estimasi nilai variabel dependen berdasarkan variabel independen [4]. Prestasi akademik adalah variabel dependen, dan faktor independen meliputi kehadiran, nilai tugas, nilai ujian tengah semester, dan nilai ujian akhir. Pendekatan ini bekerja dengan baik dengan data yang mengikuti trend linier karena memberikan penjelasan yang jelas tentang bagaimana setiap faktor mempengaruhi hasil yang diprediksi. Penelitian menunjukkan, misalnya, bahwa regresi linier dapat menghasilkan perkiraan yang tepat berdasarkan data masa lalu, membantu dalam identifikasi variabel penting yang mempengaruhi hasil akademik[2], [5].

Metode yang lebih mudah beradaptasi untuk menangkap korelasi non-linear antar variabel disediakan oleh Decision Tree Regressor [6]. Pendekatan ini dapat mengidentifikasi pola-pola rumit dalam data yang tidak dapat ditangkap oleh regresi linier dengan membangun model berbasis pohon keputusan. Menurut penelitian, Decision Tree Regressor memiliki kinerja yang lebih baik daripada teknik yang lebih konvensional seperti regresi linier biasa ketika berhadapan dengan set data nonlinier. Manfaatnya termasuk menangani kualitas yang signifikan melalui proses konstruksi pohon dan beradaptasi dengan data dengan berbagai struktur.

Penelitian ini bertujuan untuk menerapkan algoritma regresi linier dan algoritma regresi pohon keputusan untuk memprediksi kinerja akademik siswa. Penelitian ini berfokus pada penerapan awal algoritma tanpa terlalu menekankan pada perbandingan hasil, sehingga menggambarkan potensi penggunaan teknologi pembelajaran mesin dalam dunia pendidikan.

## 2. METODE PENELITIAN

Metode tahapan penelitian yang dilakukan dalam penelitian ini dimulai dari pengumpulan data, preprocessing data, mengimplementasikan kedua model algoritma machine learning, setelah itu, melakukan evaluasi terhadap model prediksi. Metode penelitian ditunjukkan pada Gambar 1.



**Gambar 1. Metode Penelitian [7]**

Penelitian ini mengambil data dari situs resmi Kaggle (<https://www.kaggle.com/datasets/yossica25/data-nilai-semester-mahasiswa>). Dataset tersebut memiliki 260 record data dan 8 variabel yaitu, NISN, Nama, Jenis Kelamin, Kehadiran, Nilai Tugas, nilai ujian tengah semester, nilai ujian akhir semester dan variabel target Nilai Akhir yang akan diprediksi. Proses pengumpulannya meliputi pengunduhan dataset dan pemilihan fitur yang relevan untuk dianalisis dalam penelitian [8]. Dataset akademik mahasiswa ditunjukkan pada Tabel 1.

**Tabel 1. Dataset Akademik Siswa**

No	NISN	Nama	Jenis Kelamin	Kehadiran	Nilai Tugas	UTS	UAS	Nilai Akhir
1	M3975515	Abbidal miftah						
2	2	alfahqri	M	25	60	71	0	35.8
2	A6388877	Abyan khairi						
8	8	risha	M	99	84	72	70	76.3
3	W615545							
39	39	Aldeva oktana	M	100	84	71	70	76.1
4	I45177882	Allya azzahra dira	F	100	88	76	77	81.2

5	V0325987 3	Annisa nur shadrina	M	100	84	70	70	75.8
6	K2147061 5	Camelio dafinza	M	100	84	70	71	76.2
7	H6217302 6	Dirly ayla azzura	F	100	84	71	72	76.9
..	..	..	..	..	..	..	..	..
..	..	..	..	..	..	..	..	..
26 0	J50415968	Wiqi muhammad athallah	M	97	68	81	54	69.2

Selanjutnya, cleaning dilakukan untuk menangani missing value jika ada, transformasi atribut kategorikal seperti jenis kelamin ke bentuk numerik dengan menggunakan teknik encoding[9], dan normalisasi data numerik agar memiliki skala yang seragam. Setelah itu, dataset dibagi menjadi dua bagian, yaitu data training untuk melatih model dan data testing untuk menguji efisiensi model[10]. Pada tahap ini digunakan dua algoritma, yaitu Linear Regression dan Decision Tree Regressor. Kedua algoritma ini diterapkan untuk memprediksi nilai akhir mahasiswa berdasarkan atribut-atribut input yang tersedia. Proses ini dilakukan dengan menggunakan data training untuk melatih model dan data testing untuk mengukur kinerjanya[11], [12].

### 1. Regresi Linier

Regresi linier menggunakan korelasi matematis linier antara variabel independen dan variabel target untuk menghasilkan prediksi yang sederhana namun kuat, terutama pada data yang terdistribusi linier. Algoritme ini melibatkan proses pelatihan untuk menemukan garis terbaik yang meminimalkan kesalahan, seperti Mean Squared Error (MSE)[13], [14]. Pendekatan ini cocok untuk prediksi kontinu, seperti nilai akademik siswa, asalkan hubungan antar variabel tidak kompleks atau nonlinier.

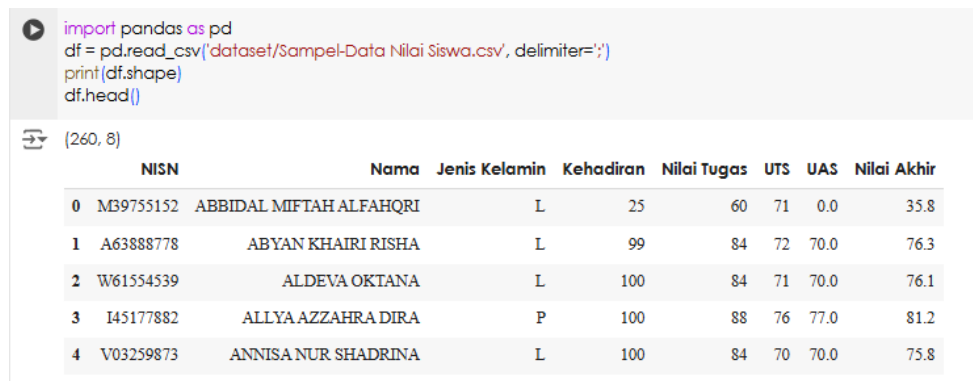
### 2. Decision Tree Regressor

Decision tree regressor bekerja dengan membagi data ke dalam himpunan bagian berbasis aturan keputusan yang paling informatif. Algoritma ini unggul dalam menangani data dengan pola nonlinier atau data kategorik [5], [15], meskipun memiliki risiko overfitting jika tidak dilakukan pemangkasan. Sebagai contoh, penelitian mengenai prediksi penjualan Lookma Boutique menunjukkan bahwa kedua algoritma

ini dapat dibandingkan dengan menggunakan metrik seperti MAE, MSE, dan  $R^2$  untuk menilai akurasi dan kestabilan prediksinya[13], [16]. Implementasi kedua algoritma dalam konteks akademis melibatkan langkah-langkah seperti prapemrosesan data, pelatihan model, dan evaluasi hasil, sehingga memungkinkan analisis yang lebih mendalam mengenai faktor-faktor yang mempengaruhi prestasi siswa.

### 3. HASIL DAN PEMBAHASAN

Dataset yang digunakan berasal dari Kaggle dengan 260 data dan 8 atribut. Data tersebut diberi nama 'Sample-Data Nilai Siswa.csv', atribut data ditunjukkan pada Gambar 2.



```
import pandas as pd
df = pd.read_csv('dataset/Sampel-Data Nilai Siswa.csv', delimiter=',')
print(df.shape)
df.head()
```

(260, 8)

	NISN	Nama	Jenis Kelamin	Kehadiran	Nilai Tugas	UTS	UAS	Nilai Akhir
0	M39755152	ABBIDAL MIFTAH ALFAHQRI	L	25	60	71	0.0	35.8
1	A63888778	ABYAN KHAIRI RISHA	L	99	84	72	70.0	76.3
2	W61554539	ALDEVA OKTANA	L	100	84	71	70.0	76.1
3	I45177882	ALLYA AZZAHRA DIRA	P	100	88	76	77.0	81.2
4	V03259873	ANNISA NUR SHADRINA	L	100	84	70	70.0	75.8

**Gambar 2. Dataset**

Program di atas menampilkan lima baris data pertama dengan menggunakan 'df.head()'. Kolom-kolom pada dataset ini mencakup berbagai informasi data mahasiswa seperti ID mahasiswa, nama, jenis kelamin, kehadiran, nilai tugas, nilai uts, nilai uas, dan nilai akhir. Setelah pengumpulan data, peneliti melakukan pra-pemrosesan untuk memastikan kualitas data. Pada tahap ini, pengecekan tipe data dilakukan untuk mengidentifikasi jenis data dalam dataset. Selanjutnya, analisis statistik dilakukan untuk menghitung parameter statistik seperti persentil, mean, dan standar deviasi dari nilai numerik dataset. Peneliti juga memeriksa nilai-nilai kosong untuk mengidentifikasi data yang tidak lengkap atau tidak sesuai. Hasil dari ketiga tahap tersebut kemudian dipresentasikan untuk mendapatkan pemahaman yang lebih mendalam tentang karakteristik data.

Terdapat 3 tipe data, yaitu object untuk variabel (NISN, Nama, Jenis Kelamin,), int64 untuk variabel (Kehadiran, Nilai Tugas dan Nilai UTS) dan float64 untuk variabel (Nilai UAS dan Nilai Akhir). Seperti pada Gambar 3.

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 260 entries, 0 to 259
Data columns (total 8 columns):
# Column      Non-Null Count  Dtype
---  -
0 NISN        260 non-null   object
1 Nama        260 non-null   object
2 Jenis Kelamin 260 non-null   object
3 Kehadiran   260 non-null   int64
4 Nilai Tugas  260 non-null   int64
5 UTS         260 non-null   int64
6 UAS         260 non-null   float64
7 Nilai Akhir  260 non-null   float64
dtypes: float64(2), int64(3), object(3)
memory usage: 16.4+ KB
```

**Gambar 3. Data Type Dataset**

Dalam analisis statistik, metode data deskripsi digunakan untuk menghitung statistik dasar, seperti jumlah, rata-rata, deviasi standar, dan persentil, untuk mengidentifikasi pola dan karakteristik set data. Gambar 4 menunjukkan deskripsi data untuk set data.

	Kehadiran	Nilai Tugas	UTS	UAS	Nilai Akhir
<b>count</b>	260.000000	260.000000	260.000000	260.000000	260.000000
<b>mean</b>	93.223077	78.261538	73.715385	71.990385	75.885385
<b>std</b>	9.260090	14.532644	14.048583	16.276535	10.536904
<b>min</b>	25.000000	0.000000	0.000000	0.000000	10.000000
<b>25%</b>	86.000000	74.750000	71.000000	69.000000	75.375000
<b>50%</b>	99.000000	84.000000	71.000000	71.000000	76.100000
<b>75%</b>	100.000000	84.000000	81.250000	79.000000	80.300000
<b>max</b>	100.000000	100.000000	100.000000	100.000000	94.100000

**Gambar 4. Describe Data Dataset**

Gambar 5 adalah program untuk memprediksi dua model, Regresi Linier dan Decision Tree Regressor. Proses ini bertujuan untuk mengecek bagaimana model yang telah dilatih memprediksi data uji yang belum pernah digunakan dalam pelatihan model. Nilai prediksi ini nantinya akan dibandingkan dengan nilai aktual pada data uji untuk mengevaluasi kinerja model dengan metrik evaluasi Mean Squared Error (MSE), Root Mean Squared Error (RMSE), dan R-squared ( $R^2$ ).

```
[ ] y_pred_lin_reg = lin_reg.predict(X_test)
    y_pred_tree_reg = tree_reg.predict(X_test)
```

**Gambar 5. Prediksi Kedua Model**

```
[ ] import numpy as np
from sklearn.metrics import mean_squared_error, r2_score
mse_lin_reg = mean_squared_error(y_test, y_pred_lin_reg)
rmse_lin_reg = np.sqrt(mse_lin_reg)
r2_lin_reg = r2_score(y_test, y_pred_lin_reg)

print("Regresi Linier:")
print(f"MSE: {mse_lin_reg}")
print(f"RMSE: {rmse_lin_reg}")
print(f"R²: {r2_lin_reg}")
```

↗ Regresi Linier:  
MSE: 5.936403011331025e-31  
RMSE: 7.704805650586538e-16  
R²: 1.0

**Gambar 6. Evaluasi Model Regresi Linear**

Hasil evaluasi model Regresi Linier pada Gambar 6, menunjukkan nilai MSE sebesar 5.93, RMSE sebesar 7.7, dan nilai  $R^2$  sebesar 1.0. Nilai  $R^2$  sebesar 1.0 menunjukkan bahwa model Regresi Linier memiliki kemampuan prediksi yang sempurna terhadap data uji, tanpa adanya kesalahan prediksi.

```
[ ] mse_tree_reg = mean_squared_error(y_test, y_pred_tree_reg)
rmse_tree_reg = np.sqrt(mse_tree_reg)
r2_tree_reg = r2_score(y_test, y_pred_tree_reg)

print("\nDecision Tree Regressor:")
print(f"MSE: {mse_tree_reg}")
print(f"RMSE: {rmse_tree_reg}")
print(f"R²: {r2_tree_reg}")
```

↗ Decision Tree Regressor:  
MSE: 0.06512419779529456  
RMSE: 0.25519443135635733  
R²: 0.9407658413618667

**Gambar 7. Evaluasi Model Decision Tree Regressor**

Sedangkan hasil evaluasi model Decision Tree Regressor pada Gambar 7, menunjukkan angka Mean Squared Error (MSE) sebesar 0.065, Root Mean Squared Error (RMSE) sebesar 0.25, dan koefisien determinasi ( $R^2$ ) sebesar 0.94. Meskipun nilai  $R^2$  lebih rendah dari Regresi Linier, hasilnya masih menunjukkan bahwa model Decision Tree berkinerja baik dengan sebagian besar variabilitas data target berhasil dijelaskan oleh fitur-fiturnya.

#### 4. KESIMPULAN

Penelitian ini menunjukkan bahwa algoritma Linear Regression dan Decision Tree Regressor efektif dalam memprediksi kinerja akademik siswa berdasarkan atribut akademik seperti kehadiran, nilai tugas, nilai ujian tengah semester, dan nilai ujian akhir semester. Regresi Linier unggul dalam memproses data dengan pola linier, menawarkan wawasan yang jelas tentang hubungan antar variabel. Di sisi lain, Decision Tree Regressor lebih fleksibel, mampu menangkap hubungan non-linear dan menangani struktur data yang beragam. Hasil

penelitian menyoroti bahwa setiap algoritma memiliki kekuatan dan keterbatasan yang unik, sehingga pilihan model bergantung pada karakteristik dataset dan tujuan spesifik analisis. Temuan ini berkontribusi dalam memajukan analisis data pendidikan dengan menampilkan aplikasi praktis pembelajaran mesin dalam mengidentifikasi faktor kinerja akademik utama. Dari perspektif pendidikan, penggunaan model pembelajaran mesin dapat mendukung pengambilan keputusan berbasis data bagi para pendidik, memungkinkan strategi pembelajaran yang dipersonalisasi dan intervensi dini untuk meningkatkan hasil belajar siswa. Penelitian di masa depan harus bertujuan untuk meningkatkan akurasi prediksi dengan memanfaatkan kumpulan data yang lebih besar dan beragam. Selain itu, mengeksplorasi metode ensemble yang lebih canggih seperti Random Forest, Gradient Boosting, atau model pembelajaran mendalam dapat meningkatkan generalisasi dan stabilitas. Mengintegrasikan atribut sosio-ekonomi, psikologis, dan perilaku ke dalam analisis juga dapat memberikan pemahaman yang lebih komprehensif tentang faktor-faktor yang memengaruhi keberhasilan akademik.

## REFERENCES

- B. Nurina, “Prediksi Performa Akademik Siswa Pada Pelajaran Matematika Menggunakan Bayesian Networks dan Algoritma Klasifikasi Machine Learning,” 2017. [Online]. Available: <https://publikasiilmiah.ums.ac.id/bitstream/handle/11617/8818/PM-19%20Betha%20Nurina%20Sari%20hal%20397-405.pdf?sequence=1>
- A. Frananda Alfonsus Naibaho and A. Zahra, “Prediksi Kelulusan Siswa Sekolah Menengah Pertama Menggunakan Machine Learning Learning,” *JITET: Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, 2023, <https://doi:10.23960/jitet.v11i3.3056>.
- A. Wijoyo, A. Y. Saputra, S. Ristanti, S. R. Sya’Ban, M. Amalia, and R. Febriansyah, “Pembelajaran Machine Learning,” *OKTAL : Jurnal Ilmu Komputer dan Sains*, vol. 3, no. 02, pp. 375–380, 2024, [Online]. Available: <https://journal.mediapublikasi.id/index.php/oktal/article/view/2305>
- N. Nailil Amani, M. Martanto, and U. Hayati, “Penggunaan Algoritma Decision Tree untuk Prediksi Prestasi Siswa di Sekolah Dasar Negeri 3 Bayalangu Kidul,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 1, pp. 473–479, Feb. 2024, <https://doi:10.36040/jati.v8i1.8355>.
- S. C. Esananda, B. Nugroho, and F. Anggraeny, “Penerapan Algoritma Decision Tree Dalam Menentukan Prestasi Akademik Siswa,” *Jurnal Informatika dan Sistem Informasi*, vol. 2, no. 2, pp. 413–424, 2021, <https://doi:10.33005/jifosi.v2i2.311>.
- B. Yusuf, M. Qalbi, B. Basrul, I. Dwitawati, M. Malahayati, and M. Ellyadi, “Implementasi Algoritma Naive Bayes dan Random Forest Dalam Memprediksi Prestasi Akademik Mahasiswa Universitas Islam Negeri Ar-Raniry Banda Aceh,” *Cyberspace: Jurnal Pendidikan Teknologi Informasi*, vol. 4, no. 1, p. 50, Jul. 2020, <https://doi:10.22373/cj.v4i1.7247>.



- Z. Fadilla, M. Ketut Ngurah Ardiawan, M. Eka Sari Karimuddin Abdullah, M. Jannah Ummul Aiman, and S. Hasda, *Metodologi Penelitian Kuantitatif*. [Online]. Available: <http://penerbitzaini.com>
- S. A. Rajagukguk, “Tinjauan Pustaka Sistematis: Prediksi Prestasi Belajar Peserta Didik Dengan Algoritma Pembelajaran Mesin,” *Jurnal Sains, Nalar, dan Aplikasi Teknologi Informasi*, vol. 1, no. 1, Aug. 2021, <https://doi:10.20885/snati.v1i1.4>.
- T. Gori, “Preprocessing Data dan Klasifikasi untuk Prediksi Kinerja Akademik Siswa,” *Jurnal Teknologi Informasi dan Ilmu Komputer/Jurnal teknologi informasi dan ilmu komputer*, vol. 11, no. 1, pp. 215–224, 2024, <https://doi:10.25126/jtiik.20241118074>.
- C. L. Saranya, S. Rao, and E. Ijmtst, “Predicting the Student Performance by using Machine Learning,” *International Journal for Modern Trends in Science and Technology*, vol. 9, no. 8, pp. 19–23, 2023, <https://doi:10.46501/IJMTST0908004>.
- A. O. Oyedeji, A. M. Salami, O. Folorunsho, and O. R. Abolade, “Analysis and Prediction of Student Academic Performance Using Machine Learning,” *JITCE (Journal of Information Technology and Computer Engineering)*, vol. 4, no. 01, pp. 10–15, Mar. 2020, <https://doi:10.25077/jitce.4.01.10-15.2020>.
- A. Nurhidayat, A. Asmunin, and D. F. Suyatno, “Prediksi Kinerja Akademik Mahasiswa Menggunakan Machine Learning dengan Sequential Minimal Optimization untuk Pengelola Program Studi,” *Journal of Information Engineering and Educational Technology*, vol. 5, no. 2, pp. 84–91, Dec. 2021, <https://doi:10.26740/jieet.v5n2.p84-91>.
- T. W.J., “Analisa Algoritma Regresi Linear dan Decision Tree Dalam Prediksi Penjualan Produk (Studi Kasus: Lookma Boutique).” [Online]. Available: <https://lib.mercubuana.ac.id/>
- R. T. Dagdagui, “Predicting Students’ Academic Performance Using Regression Analysis,” *Am J Educ Res*, vol. 10, no. 11, pp. 640–646, Nov. 2022, <https://doi:10.12691/education-10-11-2>.
- Salsabila Citra Esananda, B. Nugroho, and F. Anggraeny, “Penerapan Algoritma Decision Tree Dalam Menentukan Prestasi Akademik Siswa,” *Jurnal Informatika dan Sistem Informasi*, vol. 2, no. 2, pp. 413–424, Jul. 2021, <https://doi:10.33005/jifosi.v2i2.311>.
- N. N. Amani, M. Martanto, and U. Hayati, “Penggunaan Algoritma Decision Tree untuk Prediksi Prestasi Siswa di Sekolah Dasar Negeri 3 Bayalangu Kidul,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 1, pp. 473–479, 2024, <https://doi:10.36040/jati.v8i1.8355>.