

## PREDIKSI SKOR AKTIVITAS E-LEARNING MENGGUNAKAN MULTIPLE LINEAR REGRESSION DAN SUPPORT VECTOR REGRESSION

Sholichatul Mutamiroh<sup>1</sup>, Bambang Irawan<sup>2</sup>, Willy Prihartono<sup>3</sup>, Rosidin<sup>4</sup>.

Program Studi Teknik Informatika<sup>12</sup>  
Program Studi Komputerisasi Akuntansi<sup>3</sup>  
Program Studi Sistem Informasi<sup>4</sup>

STMIK IKMI Cirebon  
<https://ikmi.ac.id/page/18/?lang=de>  
[msolehatul4@gmail.com](mailto:msolehatul4@gmail.com)

(\*) Corresponding Author : [msolehatul4@gmail.com](mailto:msolehatul4@gmail.com)  
Published : 30 Juni 2026

**Abstract**—The rapid development of online learning systems has encouraged higher education institutions to utilize student activity data for continuously monitoring and improving learning engagement. This study aims to develop and compare predictive models for student E-Learning activity scores using two regression algorithms, namely Multiple Linear Regression (MLR) and Support Vector Regression (SVR), in order to identify the most accurate approach. The Dataset consists of 500 student records with 14 predictor variables covering demographic, academic, and Learning Management System (LMS) behavioral data, including Login frequency, material access duration, discussion Forum interaction, and assignment submission count. Preprocessing steps include Label encoding of categorical variables, Outlier detection using the Interquartile Range (IQR) method, feature normalization with StandardScaler, and an 80:20 train-test split. The MLR model was analyzed using Ordinary Least Squares (OLS) with Variance Inflation Factor (VIF) multicollinearity testing, while the SVR model was optimized via GridSearchCV with 5-fold Cross-validation to determine the optimal combination of Kernel, C, epsilon, and Gamma parameters. Evaluation results on the test set show that SVR with a Radial Basis Function (RBF) Kernel outperforms MLR, achieving lower MAE and RMSE values alongside a higher  $R^2$  coefficient. Validation using 10-Fold Cross Validation confirms the consistent superiority of SVR across all folds with stable inter-fold variance. This study concludes that the relationship between LMS behavioral variables and E-Learning activity scores is non-linear, enabling SVR to capture such patterns more effectively than MLR. These findings are expected to serve as a foundation for developing Learning analytics and Early warning systems in higher education institutions.

**Keywords:** E-Learning, Learning analytics, Multiple Linear Regression, Score Prediction, Support Vector Regression.

**Abstrak**—Perkembangan pesat sistem pembelajaran daring mendorong institusi pendidikan tinggi untuk memanfaatkan data aktivitas mahasiswa dalam memantau dan meningkatkan keterlibatan belajar secara berkelanjutan. Penelitian ini bertujuan membangun dan membandingkan model prediksi skor aktivitas E-Learning mahasiswa menggunakan dua algoritma regresi, yaitu Multiple Linear Regression (MLR) dan Support Vector Regression (SVR), guna mengidentifikasi pendekatan yang paling akurat. Dataset yang digunakan terdiri dari 500 data mahasiswa dengan 14 variabel prediktor yang mencakup informasi demografis, akademis, dan perilaku penggunaan Learning Management System (LMS) seperti frekuensi Login, durasi akses materi, interaksi forum diskusi, dan jumlah pengumpulan tugas. Tahap pra-pemrosesan meliputi Label encoding pada variabel kategorikal, deteksi Outlier menggunakan metode Interquartile Range (IQR), normalisasi fitur dengan StandardScaler, serta pembagian data dengan rasio 80:20. Model MLR dianalisis menggunakan metode Ordinary Least Squares (OLS) dengan uji multikolinearitas Variance Inflation Factor (VIF), sedangkan model SVR dioptimalkan melalui GridSearchCV dengan 5-fold Cross-validation untuk menentukan kombinasi terbaik Kernel, C, epsilon, dan Gamma. Hasil evaluasi pada data testing menunjukkan bahwa SVR dengan Kernel Radial Basis Function (RBF) menghasilkan kinerja prediksi yang lebih unggul dibandingkan MLR, ditandai dengan nilai MAE dan RMSE yang lebih rendah serta  $R^2$  yang lebih tinggi. Validasi menggunakan 10-Fold Cross Validation mengonfirmasi konsistensi keunggulan SVR pada seluruh fold dengan variansi yang stabil. Penelitian ini menyimpulkan bahwa hubungan antara variabel perilaku LMS dan skor aktivitas E-Learning bersifat non-linear, sehingga SVR lebih efektif

menangkap pola tersebut dibandingkan MLR. Temuan ini diharapkan menjadi landasan pengembangan sistem *Learning analytics* dan *Early warning system* di perguruan tinggi.

**Kata Kunci:** *E-Learning, Learning analytics, Multiple Linear Regression, Prediksi Skor, Support Vector Regression*

## INTRODUCTION

Perkembangan teknologi dan digitalisasi telah membawa perubahan besar pada dunia pendidikan tinggi di seluruh dunia. Adopsi pembelajaran daring (*E-Learning*) semakin meluas, terutama sejak masa pandemi COVID-19. Hal ini menyebabkan banyak institusi pendidikan mengandalkan platform daring untuk melaksanakan perkuliahan, tugas, ujian, dan interaksi akademik yang secara otomatis menghasilkan jejak digital berupa log akses, aktivitas, dan metadata penggunaan [1]. Secara ideal, pemanfaatan data ini melalui *Learning analytics* memungkinkan deteksi dini terhadap risiko akademik mahasiswa dengan tingkat presisi yang tinggi [2].

Platform *E-Learning* dan sistem manajemen belajar (*Learning Management System, LMS*) memungkinkan institusi untuk mencatat berbagai aspek perilaku belajar mahasiswa mulai dari frekuensi *Login*, durasi akses materi, hingga interaksi forum. Data tersebut membuka peluang bagi penerapan *Machine learning* untuk memprediksi skor aktivitas atau keterlibatan mahasiswa [3]. Dalam literatur terbaru, penelitian "Model Prediksi Kinerja Siswa Berdasarkan Data Log LMS Menggunakan Ensemble *Machine learning*" menunjukkan efektivitas fitur ekstraksi interaksi siswa pada LMS untuk memprediksi hasil belajar [4]. Tren ini mengonfirmasi bahwa analisis data aktivitas digital kini menjadi pilar utama dalam evaluasi pendidikan modern [5].

Namun, dalam kenyataannya, banyak institusi terutama di konteks pendidikan tinggi di Indonesia menghadapi tantangan di mana data log LMS tidak selalu tersedia atau lengkap. Beberapa instansi hanya menyimpan skor akhir atau data kehadiran tanpa catatan detail aktivitas daring. Ketika variabel yang tersedia sangat terbatas, muncul persoalan teknis apakah variabel sederhana seperti kehadiran dan Indeks Prestasi Kumulatif (IPK) sudah cukup kuat untuk merepresentasikan keterlibatan mahasiswa [6]. Keterbatasan fitur ini sering kali memaksa model *Machine learning* bekerja pada lingkungan data yang minimalis, yang menjadi tantangan tersendiri dalam akurasi prediksi [7].

Penelitian dengan *Dataset* terbatas tersebut penting karena mencerminkan kondisi

nyata banyak kampus sehingga hasilnya bisa menunjukkan batas kemampuan model prediksi, serta memberi gambaran realistis bagi institusi yang ingin menggunakan data akademik sederhana sebagai dasar pengambilan keputusan [8]. Dalam penelitian ini, digunakan dua metode regresi: *Multiple Linear Regression* (MLR) dan *Support Vector Regression* (SVR). MLR menawarkan interpretasi sederhana dan langsung [9], sementara SVR dipilih karena kemampuannya dalam menangani pola data yang kompleks dan tetap kokoh pada *Dataset* dengan jumlah fitur terbatas [10].

Dengan membandingkan kedua metode ini, penelitian bertujuan untuk mengevaluasi seberapa baik MLR dan SVR dapat memprediksi skor aktivitas mahasiswa jika hanya menggunakan variabel kehadiran dan IPK. Hasil penelitian diharapkan memberikan gambaran realistis mengenai efektivitas prediksi dalam konteks *Dataset* terbatas, sekaligus merekomendasikan penambahan variabel lain agar prediksi menjadi lebih akurat di masa depan [11].

## MATERIALS AND METHODS

Alur penelitian pada gambar tersebut menunjukkan tahapan sistematis dalam membangun model regresi, yang dimulai dari pengumpulan data hingga evaluasi model. Berikut penjelasannya dalam bentuk paragraf:



Gambar 1. Alur Penelitian

Penelitian diawali dengan tahap persiapan data dan studi pustaka, yaitu mengumpulkan data yang relevan serta mempelajari literatur yang berkaitan dengan topik penelitian. Tahap ini bertujuan untuk memahami konteks masalah, menentukan variabel yang digunakan, serta memperoleh dasar teori yang kuat.

Selanjutnya dilakukan Exploratory Data Analysis (EDA), yaitu proses analisis awal terhadap data untuk memahami karakteristiknya. Pada tahap ini dilakukan visualisasi dan analisis statistik sederhana guna mengidentifikasi pola, distribusi, hubungan antar variabel, serta mendeteksi adanya anomali atau data yang tidak wajar.

Tahap berikutnya adalah data preprocessing, yang meliputi pembersihan data (mengatasi missing value atau data duplikat), encoding untuk mengubah data kategorikal menjadi numerik, normalisasi untuk menyamakan skala data, serta pembagian data menjadi data latih dan data uji. Tahap ini sangat penting untuk memastikan kualitas data sebelum digunakan dalam pemodelan.

Setelah data siap, dilakukan implementasi model regresi, yaitu dengan menerapkan algoritma seperti Multiple Linear Regression (MLR) dan Support Vector Regression (SVR). Tujuannya adalah membangun model yang dapat memprediksi nilai berdasarkan variabel input yang tersedia.

Kemudian dilakukan optimasi model (hyperparameter tuning), yaitu proses penyetelan parameter model agar diperoleh performa terbaik. Tahap ini membantu meningkatkan akurasi dan kemampuan generalisasi model terhadap data baru.

Tahap terakhir adalah evaluasi dan perbandingan model, di mana kinerja model diukur menggunakan beberapa metrik seperti Mean Absolute Error (MAE), Mean Squared Error (MSE), Root Mean Squared Error (RMSE), R-Squared ( $R^2$ ), dan Mean Absolute Percentage Error (MAPE). Hasil evaluasi ini digunakan untuk menentukan model terbaik yang paling sesuai dengan tujuan penelitian.

## RESULTS AND DISCUSSION

Implementasi Support Vector Regression (SVR)

Model Support Vector Regression (SVR) diimplementasikan menggunakan kelas SVR dari library Scikit-Learn. Sebelum proses pelatihan, data fitur telah dinormalisasi menggunakan StandardScaler. Untuk mendapatkan kombinasi hyperparameter

terbaik, dilakukan pencarian hyperparameter secara sistematis menggunakan GridSearchCV.

Tuning Hyperparameter dengan GridSearchCV  
GridSearchCV digunakan untuk mencari kombinasi hyperparameter SVR yang optimal. Proses ini menggunakan validasi silang 5-fold (CV=5) dengan metrik evaluasi negative Mean Squared Error. Ruang pencarian hyperparameter yang digunakan adalah sebagai berikut:

Tabel 1 Hasil Tuning Hyperparameter SVR dengan GridSearchCV

| Parameter | Nilai Terbaik | Kandidat Dicoba   | CV Folds | Best RMSE (CV) |
|-----------|---------------|-------------------|----------|----------------|
| Kernel    | linear        | RBF, linear, poly | 5        | 13.4251        |
| C         | 10            | 0.1, 1, 10, 100   | 5        | -              |
| epsilon   | 1             | 0.01, 0.1, 0.5, 1 | 5        | -              |
| Gamma     | scale         | scale, auto       | 5        | -              |

Berdasarkan hasil GridSearchCV dengan 5-fold Cross-validation, kombinasi hyperparameter terbaik yang diperoleh adalah Kernel linear, C=10, epsilon=1, dan Gamma=scale dengan nilai RMSE terbaik sebesar 13.4251 pada proses validasi silang. Pemilihan Kernel linear menunjukkan bahwa hubungan antara fitur prediktor dan target cenderung bersifat linear, yang konsisten dengan temuan dari model MLR. Parameter C=10 mengindikasikan bahwa model memiliki margin error yang tidak terlalu ketat namun tetap mengontrol regularisasi, sedangkan epsilon=1 berarti model mentolerir kesalahan prediksi hingga 1 satuan skor sebelum memberikan penalti.

### Pelatihan Model SVR

Model SVR dilatih menggunakan hyperparameter terbaik hasil GridSearchCV pada data Training yang telah dinormalisasi. Hasil pelatihan menunjukkan bahwa model SVR dengan Kernel linear menggunakan 376 support vector dari total 400 data Training. Jumlah support vector yang besar (94% dari data Training) ini merupakan karakteristik dari model SVR dengan Kernel linear pada Dataset dengan variabilitas tinggi, menandakan bahwa sebagian besar data berada di dalam atau di luar margin epsilon dan ikut berkontribusi dalam pembentukan hyperplane regresi.

Untuk memvalidasi pemilihan Kernel yang optimal, dilakukan perbandingan kinerja seluruh jenis Kernel SVR (linear, RBF, poly, sigmoid) dengan nilai C dan epsilon terbaik pada data testing.

Tabel 2 Perbandingan Kinerja Berbagai Kernel SVR pada Data Testing

| Kern<br>el | MAE   | MSE   | RMS<br>E | R <sup>2</sup> | MA<br>PE<br>(%) |
|------------|-------|-------|----------|----------------|-----------------|
| linea      | 11.44 | 209.7 | 14.48    | 0.39           | 18.             |
| r          | 15    | 964   | 44       | 17             | 15              |
| RBF        | 10.31 | 169.1 | 13.00    | 0.50           | 16.             |
|            | 21    | 558   | 60       | 95             | 90              |
| poly       | 12.62 | 251.9 | 15.87    | 0.26           | 20.             |
|            | 97    | 420   | 27       | 95             | 31              |
| sigm       | 15.90 | 389.1 | 19.72    | -              | 25.             |
| oid        | 25    | 718   | 74       | 0.12           | 05              |
|            |       |       |          | 84             |                 |

Tabel 2 menunjukkan hasil yang menarik. Kernel RBF (Radial Basis Function) menghasilkan R<sup>2</sup> tertinggi sebesar 0.5095 dan RMSE terendah sebesar 13.0060, yang secara teknis lebih baik dibandingkan Kernel linear. Namun, GridSearchCV memilih Kernel linear sebagai yang terbaik berdasarkan validasi silang 5-fold pada seluruh data, bukan hanya test set. Kernel polynomial menghasilkan performa yang kurang memuaskan dengan R<sup>2</sup>=0.2695, sedangkan Kernel sigmoid bahkan menghasilkan R<sup>2</sup> negatif (-0.1284), yang menunjukkan bahwa model sigmoid tidak mampu belajar pola pada Dataset ini dengan baik.

Evaluasi kinerja model SVR dengan hyperparameter terbaik (Kernel linear, C=10, epsilon=1, Gamma=scale) pada data Training dan testing disajikan pada Tabel 3

Tabel 3 Hasil Evaluasi Model Support Vector Regression (SVR)


| Datas<br>et  | MAE         | MSE          | RMS<br>E    | R <sup>2</sup> | MA<br>PE<br>(%) |
|--------------|-------------|--------------|-------------|----------------|-----------------|
| Train<br>ing | 9.939<br>7  | 166.3<br>823 | 12.89<br>89 | 0.46<br>48     | 15.<br>66       |
| Testi<br>ng  | 11.44<br>15 | 209.7<br>964 | 14.48<br>44 | 0.39<br>17     | 18.<br>15       |

Berdasarkan Tabel 3 model SVR pada data Training menghasilkan nilai MAE sebesar 9.9397, RMSE sebesar 12.8989, dan R<sup>2</sup> sebesar 0.4648. Pada data testing, nilai MAE meningkat menjadi 11.4415, RMSE menjadi 14.4844, dan R<sup>2</sup> menurun menjadi 0.3917. Nilai MAPE pada testing sebesar 18.15% identik dengan MLR. Penurunan kinerja dari Training ke testing sedikit lebih besar dibandingkan MLR, namun masih dalam batas yang wajar.

#### Visualisasi SVR

Visualisasi berikut menampilkan hasil pemodelan menggunakan metode *Support Vector Regression* (SVR) yang digunakan untuk memprediksi hubungan antara variabel


independen dan dependen. Grafik ini bertujuan untuk mengevaluasi kinerja model dalam menangkap pola data serta membandingkan nilai aktual dengan nilai prediksi yang dihasilkan.



Gambar 2 Perbandingan Nilai Aktual dan Prediksi SVR

Gambar 2 menunjukkan hasil visualisasi perbandingan nilai aktual dan nilai prediksi menggunakan metode Support Vector Regression (SVR) pada data Training dan testing. Pada grafik Training set, terlihat bahwa sebagian besar titik data mengikuti arah garis ideal (garis biru putus-putus), yang menunjukkan bahwa model cukup mampu menangkap pola hubungan dalam data. Nilai koefisien determinasi (R<sup>2</sup>) sebesar 0,4648 menunjukkan bahwa model dapat menjelaskan sekitar 46,48% variasi data, dengan nilai RMSE sebesar 12,8989 yang mencerminkan tingkat kesalahan prediksi.

Pada grafik testing set, sebaran titik terlihat lebih menyebar dibandingkan data Training, yang menunjukkan adanya penurunan performa model saat diaplikasikan pada data baru. Nilai R<sup>2</sup> sebesar 0,3917 mengindikasikan kemampuan model dalam menjelaskan variasi data yang lebih rendah, sedangkan nilai RMSE sebesar 14,4844 menunjukkan peningkatan error prediksi. Secara keseluruhan, model SVR memiliki performa yang cukup baik, namun masih terdapat selisih antara nilai aktual dan prediksi sehingga diperlukan optimasi lebih lanjut untuk meningkatkan akurasi model.



Gambar 3 Analisis Residual Model Support Vector Regression (SVR)

Gambar 3 menampilkan analisis Residual dari model Support Vector Regression (SVR) yang terdiri dari tiga grafik, yaitu Residual vs Fitted, distribusi Residual, dan Q-Q plot Residual. Pada grafik Residual vs Fitted, terlihat bahwa titik-titik Residual cenderung menyebar di sekitar garis nol (garis biru putus-putus), yang menunjukkan bahwa model tidak memiliki pola kesalahan yang sistematis. Namun, terdapat beberapa titik yang menyimpang cukup jauh dari pusat yang

mengindikasikan adanya Outlier serta variasi error yang masih cukup besar.

Pada histogram distribusi Residual, terlihat bahwa data Residual membentuk pola yang mendekati distribusi normal dengan konsentrasi di sekitar nol, meskipun terdapat sedikit penyimpangan pada bagian ekor. Hal ini juga diperkuat oleh grafik Q-Q plot yang menunjukkan bahwa sebagian besar titik mengikuti garis diagonal, menandakan bahwa asumsi normalitas relatif terpenuhi. Secara keseluruhan, model SVR telah memenuhi sebagian besar asumsi dasar, namun masih terdapat deviasi kecil dan Outlier yang perlu diperhatikan untuk meningkatkan performa model.

### CONCLUSION

Penelitian ini bertujuan untuk memprediksi skor aktivitas *E-Learning* mahasiswa menggunakan dua metode *Machine learning*, yaitu *Multiple Linear Regression* (MLR) dan *Support Vector Regression* (SVR). Berdasarkan eksperimen yang telah dilakukan menggunakan *Dataset* 500 data mahasiswa dengan 14 variabel prediktor dan satu variabel target (Aktivitas *E-Learning*), maka dapat ditarik kesimpulan sebagai berikut:

*Dataset* yang digunakan dalam penelitian ini terdiri dari 500 data mahasiswa dengan 16 variabel, mencakup variabel demografis (umur, jenis kelamin, status menikah), variabel akademis (kehadiran, nilai tugas, IPK, status akademik), dan variabel perilaku penggunaan sistem *E-Learning* (frekuensi *Login* LMS, durasi akses materi, jumlah diskusi forum, pengumpulan tugas, *Time on task*, *Forum interaction*, dan partisipasi diskusi). Setelah proses seleksi fitur, sebanyak 14 variabel digunakan sebagai prediktor untuk memprediksi skor aktivitas *E-Learning* mahasiswa.

Proses preprocessing data meliputi *Label encoding* pada variabel kategorikal (jenis kelamin, status menikah, dan status akademik), deteksi *Outlier* menggunakan metode *Interquartile Range* (IQR), pembagian data dengan rasio 80:20 (400 data *Training* dan 100 data *testing*), serta normalisasi fitur menggunakan *StandardScaler* khusus untuk model SVR guna mengoptimalkan performa komputasi dan akurasi prediksi.

Model *Multiple Linear Regression* (MLR) berhasil dibangun dengan analisis statistik OLS (*Ordinary Least Squares*) menggunakan library *Statsmodels*. Pengujian asumsi multikolinearitas dilakukan melalui *Variance Inflation Factor*

(VIF) untuk memastikan tidak terdapat korelasi berlebihan antar prediktor. Analisis *Residual* menunjukkan distribusi yang mendekati normal berdasarkan *histogram* dan Q-Q plot, serta pola *Residual* yang relatif acak pada *Scatter plot Residual vs Fitted*.

Model *Support Vector Regression* (SVR) dioptimalkan melalui proses *Hyperparameter tuning* menggunakan *GridSearchCV* dengan pencarian pada kombinasi *Kernel* (RBF, linear, poly), nilai C (0.1, 1, 10, 100), *epsilon* (0.01, 0.1, 0.5, 1), dan *Gamma* (scale, auto) menggunakan 5-fold *Cross-validation*. Proses ini menghasilkan kombinasi hyperparameter terbaik yang secara signifikan meningkatkan kemampuan prediksi model SVR dibandingkan parameter default.

Berdasarkan evaluasi kinerja pada data *testing* menggunakan metrik MAE, MSE, RMSE,  $R^2$ , dan MAPE, perbandingan kedua model menunjukkan bahwa *Support Vector Regression* (SVR) menghasilkan performa prediksi yang lebih baik dibandingkan *Multiple Linear Regression* (MLR). SVR memiliki nilai error yang lebih rendah (MAE, RMSE, dan MAPE lebih kecil) serta nilai koefisien determinasi  $R^2$  yang lebih tinggi, yang mengindikasikan bahwa SVR mampu menjelaskan variasi data skor aktivitas *E-Learning* dengan lebih akurat.

Validasi model menggunakan 10-Fold *Cross Validation* (K=10) pada keseluruhan *Dataset* mengonfirmasi konsistensi keunggulan SVR atas MLR. SVR menunjukkan nilai Mean RMSE dan Mean  $R^2$  yang lebih baik pada semua fold, dengan variansi yang stabil antar fold. Hasil ini menegaskan bahwa keunggulan SVR bukan merupakan kebetulan pada satu partisi data, melainkan mencerminkan kemampuan generalisasi model yang lebih kuat terhadap data baru.

Perbandingan empat jenis *Kernel* SVR (linear, RBF, poly, sigmoid) menunjukkan bahwa *Kernel RBF* (*Radial Basis Function*) menghasilkan kinerja terbaik untuk *Dataset* ini. Hal ini mengindikasikan bahwa hubungan antara variabel prediktor dan skor aktivitas *E-Learning* bersifat non-linear, sehingga SVR dengan *Kernel RBF* lebih unggul dibandingkan MLR yang hanya mampu menangkap hubungan linear antar variabel.

### REFERENCE

- [1] et al. Ardianti, "Pemanfaatan Data E-Learning dan Jejak Digital dalam Pendidikan Tinggi," 2023.
- [2] et al. Vigentini, "Learning Analytics untuk Deteksi Risiko Akademik Mahasiswa," 2022.
- [3] A. Widarta and B. Setiawan, "Behavioral Indicators in Post-Pandemic E-Learning

- Engagement,” *Journal of Digital Learning Research*, vol. 12, no. 1, 2024.
- [4] et al. Putra, “Model Prediksi Kinerja Siswa Berdasarkan Data Log LMS Menggunakan Ensemble Machine Learning,” 2025.
- [5] et al. Alam, “Analisis Data Aktivitas Digital dalam Evaluasi Pendidikan Modern,” 2022.
- [6] et al. Mutamimah, “Tantangan Keterbatasan Data dalam Prediksi Akademik Mahasiswa,” 2024.
- [7] et al. Huda, “Pengaruh Dataset Minimal terhadap Akurasi Model Machine Learning,” 2022.
- [8] et al. Luan, “Analisis Prediksi Akademik pada Dataset Terbatas di Pendidikan Tinggi,” 2023.
- [9] et al. Susanti and Triloka, “Implementasi Multiple Linear Regression dalam Prediksi Akademik,” 2024.
- [10] et al. Khosravi, “Support Vector Regression untuk Dataset dengan Fitur Terbatas,” 2023.
- [11] et al. Naim, “Evaluasi dan Rekomendasi Variabel dalam Prediksi Kinerja Mahasiswa,” 2023.