

Penerapan *Regresi Robust* dalam *Educational Data Mining* (EDM) untuk Klasifikasi Tingkat Penalaran Abduktif Siswa

Nasruddin^{1*}, Nisa Miftachurohmah², Putri Rahayu Sianturi³, Irnawati⁴, Iwan⁵

^{1,3,4,5}Program Studi Pendidikan Matematika, FKIP, Universitas Sembilanbelas November Kolaka

²Program Studi Ilmu Komputer, Fakultas Teknologi Informasi, Universitas Sembilanbelas November Kolaka

E-mail*¹nash.matematika@gmail.com

Abstrak – Penalaran abduktif merupakan salah satu bentuk penalaran tingkat tinggi yang berperan penting dalam pemecahan masalah matematika, namun masih sulit dianalisis secara objektif karena karakteristik data penilaian yang heterogen dan mengandung nilai ekstrem. Penelitian ini bertujuan mengimplementasikan regresi robust dalam kerangka *Educational Data Mining* (EDM) untuk mengklasifikasikan tingkat penalaran abduktif siswa SMP berdasarkan indikator penalaran yang terukur. Data diperoleh dari jawaban tertulis 72 siswa di SMP Negeri 3 Samaturu, Kabupaten Kolaka, yang dianalisis menggunakan rubrik analitik dengan delapan indikator penalaran abduktif. Regresi robust digunakan sebagai tahap estimasi fitur untuk mereduksi pengaruh outlier sebelum dilakukan klasifikasi tingkat penalaran ke dalam tiga kategori, yaitu rendah, sedang, dan tinggi, menggunakan pendekatan tertile-based threshold. Evaluasi model dilakukan dengan 5-fold cross validation dan diukur menggunakan metrik akurasi, precision, recall, dan F1-score, serta dibandingkan dengan model berbasis regresi linier konvensional (OLS). Hasil penelitian menunjukkan bahwa regresi robust menghasilkan kinerja klasifikasi yang lebih baik dan stabil dibandingkan OLS, dengan peningkatan pada seluruh metrik evaluasi. Distribusi klasifikasi menunjukkan 21 siswa berada pada tingkat rendah, 36 siswa pada tingkat sedang, dan 15 siswa pada tingkat tinggi. Penelitian ini menghasilkan bahwa integrasi regresi robust dalam EDM efektif untuk klasifikasi tingkat penalaran abduktif yang lebih akurat dan bermakna secara pedagogis.

Kata Kunci-*Educational Data Mining*, regresi robust, penalaran abduktif, klasifikasi, pembelajaran matematika.

1. PENDAHULUAN

Kemampuan penalaran matematis merupakan salah satu kompetensi berpikir tingkat tinggi yang esensial dalam pembelajaran matematika, khususnya pada jenjang Sekolah Menengah Pertama (SMP). Salah satu bentuk penalaran yang berperan penting dalam proses pemecahan masalah adalah penalaran abduktif, yaitu kemampuan siswa dalam merumuskan dugaan solusi yang paling masuk akal berdasarkan informasi yang tersedia. Penalaran abduktif menjadi fondasi pembentukan hipotesis awal sebelum dilakukan proses verifikasi dan penalaran deduktif. Namun, hasil evaluasi internasional menunjukkan bahwa kemampuan penalaran matematis siswa masih berada pada kategori rendah hingga sedang, terutama pada soal-soal yang menuntut penalaran tingkat tinggi dan pemecahan masalah non-rutin [1]. Dalam praktik pembelajaran, penilaian penalaran abduktif siswa umumnya dilakukan melalui analisis jawaban tertulis menggunakan rubrik indikator tertentu. Data hasil penilaian tersebut bersifat heterogen dan sering kali mengandung nilai ekstrem (*outlier*) akibat perbedaan strategi berpikir siswa, ketidakkonsistenan antar indikator, maupun kesalahan konseptual. Penggunaan teknik statistik konvensional seperti *Ordinary Least Squares* (OLS) pada kondisi ini berpotensi menghasilkan estimasi yang bias karena metode tersebut sangat sensitif terhadap pencilan. Oleh karena itu, dibutuhkan pendekatan statistik yang mampu menghasilkan estimasi parameter yang stabil pada data pendidikan yang berisik dan tidak sepenuhnya memenuhi asumsi klasik.

Seiring dengan meningkatnya ketersediaan data pendidikan, *Educational Data Mining* (EDM) berkembang sebagai bidang interdisipliner yang memanfaatkan teknik statistik, pembelajaran mesin, dan penambangan data untuk mengekstraksi tingkat tersembunyi dari data pendidikan. EDM telah digunakan secara luas untuk memprediksi performa akademik, mengelompokkan karakteristik siswa, serta menganalisis proses pembelajaran secara komputasional [3]. Tinjauan literatur menunjukkan bahwa teknik klasifikasi dan regresi merupakan metode yang paling dominan digunakan dalam EDM, khususnya untuk tujuan diagnosis kemampuan siswa dan prediksi hasil belajar [4]. Namun demikian, kualitas hasil analisis EDM sangat bergantung pada karakteristik data dan metode estimasi yang digunakan. Salah satu pendekatan yang direkomendasikan untuk menangani data dengan pencilan dan distribusi tidak normal adalah *regresi robust*. Regresi robust dirancang untuk mengurangi pengaruh outlier melalui penggunaan fungsi kerugian yang tidak terlalu sensitif terhadap residual besar, seperti *Huber loss* dan *Tukey's biweight*. Studi klasik oleh Huber menunjukkan bahwa regresi robust mampu menghasilkan estimasi parameter yang lebih reliabel dibandingkan OLS ketika data mengandung pencilan [2]. Kajian lanjutan oleh Rousseeuw dan Leroy juga menegaskan bahwa pendekatan robust sangat efektif untuk data nyata yang kompleks dan berisik, termasuk data sosial dan pendidikan [8]. Meskipun demikian, sebagian besar penelitian EDM masih

menggunakan model regresi atau klasifikasi standar yang relatif sensitif terhadap outlier dan asumsi distribusi normal. Padahal, data pendidikan yang diperoleh dari penilaian berbasis rubrik cenderung memiliki variasi tinggi dan ketidakseimbangan antar indikator. Beberapa studi EDM melaporkan bahwa penggunaan pendekatan robust dapat meningkatkan stabilitas model dan keandalan hasil analisis dibandingkan pendekatan konvensional [5]. Namun, penerapan regresi *robust* sebagai tahap estimasi fitur dalam klasifikasi tingkat penalaran matematis, khususnya penalaran abduktif siswa SMP, masih relatif terbatas dan belum banyak dieksplorasi.

Pemanfaatan pendekatan komputasi dan analisis kuantitatif dalam bidang pendidikan dan sistem informasi menunjukkan bahwa sistem komputasi berbasis inferensi mampu mengolah data multi-fitur secara efektif untuk proses klasifikasi dan pengambilan keputusan [6]. Pendekatan ini relevan secara metodologis dengan EDM karena sama-sama menekankan pentingnya pengolahan data yang kompleks dan heterogen. Selain itu, analisis kuantitatif dan regresi dapat digunakan secara efektif untuk mengkaji pengaruh variabel pembelajaran terhadap capaian akademik siswa [7]. Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengimplementasikan regresi *robust* dalam kerangka *Educational Data Mining* guna mengklasifikasikan tingkat penalaran abduktif siswa SMP berdasarkan indikator-indikator penalaran yang terukur. Regresi *robust* digunakan sebagai tahap estimasi fitur yang tahan terhadap *outlier* sebelum dilakukan proses klasifikasi tingkat penalaran.

2. METODE PENELITIAN

2.1 Jenis dan Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan desain Educational Data Mining (EDM). Desain EDM dipilih karena penelitian berfokus pada proses ekstraksi dan klasifikasi tingkat penalaran abduktif siswa berdasarkan data penilaian yang bersifat kompleks, heterogen, dan berpotensi mengandung outlier. Penelitian ini bersifat eksploratif-analitis, dengan tujuan utama memodelkan data penalaran siswa dan memetakan tingkat penalaran abduktif secara komputasional.

2.2 Subjek dan Sumber Data

Subjek penelitian adalah 72 siswa kelas VIII SMP Negeri yang berasal dari tiga kelas paralel. Data penelitian berupa jawaban tertulis siswa pada tes pemecahan masalah matematika yang dirancang untuk mengukur penalaran abduktif. Jumlah subjek ditetapkan dengan mempertimbangkan rasio antara jumlah indikator penalaran dan ukuran sampel agar memadai untuk penerapan regresi robust dan evaluasi klasifikasi.

2.3 Instrumen dan Rubrik Penalaran Abduktif

Instrumen penelitian berupa soal pemecahan masalah matematika yang disusun berdasarkan kerangka penalaran abduktif. Jawaban siswa dianalisis menggunakan rubrik analitik yang terdiri atas delapan indikator, yaitu:

- I1: Mengidentifikasi komponen masalah
- I2: Mengumpulkan atau memperluas data yang relevan
- C1: Mengemukakan dugaan solusi yang masuk akal
- C2: Menyaring dugaan solusi yang tidak masuk akal
- C3: Menerima kemungkinan solusi alternatif lain
- S1: Memilih solusi terbaik
- S2: Memberikan alasan logis atas solusi yang dipilih
- D : Menarik kesimpulan akhir

Setiap indikator diberi skor pada skala 0–4, sehingga untuk setiap siswa diperoleh vektor fitur penalaran abduktif sebagai berikut:

$$X_i = [I1_i, I2_i, C1_i, C2_i, C3_i, S1_i, S2_i, D_i] \dots\dots\dots (1)$$

2.4 Pra-pemrosesan Data

Tahap pra-pemrosesan dilakukan untuk menjamin kualitas data sebelum pemodelan, meliputi:

- Pemeriksaan kelengkapan skor pada seluruh indikator.
- Normalisasi skor indikator agar berada pada skala yang sebanding.
- Identifikasi awal outlier berdasarkan sebaran skor dan ketidakkonsistenan antar indikator, sebagai dasar pemilihan metode regresi robust.

2.5 Pemodelan Regresi *Robust* Berbasis Indikator

2.5.1 Model Regresi

Skor agregat penalaran abduktif siswa ke- i , dinotasikan sebagai y_i dimodelkan sebagai kombinasi linear dari delapan indikator penalaran:

$$y_i = \beta_0 + \beta_1 I1_i + \beta_2 I2_i + \beta_3 C1_i + \beta_4 C2_i + \beta_5 C3_i + \beta_6 S1_i + \beta_7 S2_i + \beta_8 D_i + \varepsilon_i \quad \dots\dots\dots (2)$$

dengan β_0 konstanta, $\beta_1, \dots, \beta_8$ koefisien regresi, dan ε_i adalah residual.

2.5.2 Estimasi Parameter Regresi Robust

Parameter regresi diestimasi menggunakan regresi robust dengan meminimalkan fungsi kerugian *robust*:

$$\hat{\beta} = \arg \min_{\beta} \sum_{i=1}^n \rho \left(y_i - \left(\beta_0 + \sum_{k=1}^8 \beta_k X_{ik} \right) \right) \quad \dots\dots\dots (3)$$

dalam penelitian ini digunakan fungsi *Huber*, karena mampu menyeimbangkan sensitivitas terhadap residual kecil dan ketahanan terhadap residual ekstrem. Estimasi parameter dilakukan menggunakan pendekatan *Iteratively Reweighted Least Squares* (IRLS).

2.5.3 Skor Estimasi Penalaran Abduktif

Skor hasil estimasi regresi robust untuk setiap siswa dihitung sebagai:

$$\hat{y}_i = \hat{\beta}_0 + \hat{\beta}_1 I1_i + \hat{\beta}_2 I2_i + \hat{\beta}_3 C1_i + \hat{\beta}_4 C2_i + \hat{\beta}_5 C3_i + \hat{\beta}_6 S1_i + \hat{\beta}_7 S2_i + \hat{\beta}_8 D_i \quad \dots\dots\dots (4)$$

Nilai $\hat{y}_i$ merepresentasikan tingkat penalaran abduktif terestimasi dan digunakan sebagai dasar klasifikasi tingkat.

2.6 Rasio Penentuan Ambang Klasifikasi

Penelitian ini bertujuan memetakan penalaran abduktif siswa ke dalam tiga tingkat kemampuan, yaitu rendah, sedang, dan tinggi. Oleh karena itu, diperlukan dua nilai ambang untuk memisahkan ketiga kelompok tersebut. Karena skor $\hat{y}_i$ merupakan hasil estimasi regresi robust dan tidak diasumsikan berdistribusi normal, maka penentuan ambang dilakukan secara data-driven tanpa menggunakan batas nilai absolut. Pendekatan yang digunakan adalah pembagian distribusi skor ke dalam tiga bagian proporsional (*tertile-based classification*). Pendekatan ini umum digunakan dalam EDM untuk tujuan diagnosis kemampuan karena:

- Tidak bergantung pada asumsi distribusi data,
- Stabil terhadap pengaruh outlier,
- Menghasilkan kelompok yang relatif seimbang dan mudah diinterpretasikan secara pedagogis.

2.7 Penentuan Nilai Ambang τ_1 dan τ_2

Berdasarkan pendekatan tertile, nilai ambang klasifikasi ditentukan menggunakan kuantil distribusi skor estimasi $\hat{y}_i$ sebagai berikut:

$$\tau_1 = Q_{33}(\hat{y}), \quad \tau_2 = Q_{67}(\hat{y}) \quad \dots\dots\dots (5)$$

dengan:

Q_{33} adalah kuantil ke-33% dari distribusi skor estimasi,

Q_{67} adalah kuantil ke-67% dari distribusi skor estimasi.

Nilai τ_1 merepresentasikan batas antara tingkat penalaran rendah dan sedang, sedangkan τ_2 merepresentasikan batas antara tingkat sedang dan tinggi.

2.8 Klasifikasi Tingkat Penalaran Abduktif

Berdasarkan nilai ambang tersebut, tingkat penalaran abduktif siswa ke- i ditentukan sebagai:

$$\text{Tingkat Penalaran Abduktif (i)} = \begin{cases} \text{Rendah, } \hat{y}_i < \tau_1 \\ \text{Sedang, } \tau_1 \leq \hat{y}_i \leq \tau_2 \\ \text{Tinggi, } \hat{y}_i > \tau_2 \end{cases} \quad \dots\dots\dots (6)$$

2.9 Evaluasi Model

Evaluasi model dilakukan menggunakan *k-fold cross validation*. Kinerja klasifikasi diukur menggunakan *akurasi, precision, recall, dan F1-score*. Selain itu, dilakukan perbandingan hasil klasifikasi antara model berbasis regresi konvensional (OLS) dan regresi *robust* untuk menilai kontribusi pendekatan robust terhadap stabilitas dan kualitas klasifikasi tingkat penalaran abduktif.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pemodelan Regresi Robust

Pemodelan regresi dilakukan menggunakan dua pendekatan, yaitu regresi linier konvensional (OLS) sebagai pembandingan dan regresi *robust* (*Huber loss*) sebagai model utama. Variabel independen berupa delapan indikator penalaran abduktif ($I1 - D$), sedangkan variabel dependen adalah skor agregat penalaran abduktif siswa.

Tabel 1. Koefisien Regresi OLS dan Regresi *Robust*

Indikator	OLS (β)	Robust (β)
Konstanta	1,87	2,11
I1 – Identifikasi masalah	0,42	0,38
I2 – Pengumpulan data	0,36	0,33
C1 – Dugaan solusi masuk akal	0,51	0,47
C2 – Menyaring solusi tidak masuk akal	0,29	0,25
C3 – Menerima alternatif solusi	0,34	0,31
S1 – Memilih solusi terbaik	0,56	0,49
S2 – Alasan logis	0,61	0,52
D – Kesimpulan akhir	0,48	0,44

Tabel 1 menunjukkan bahwa koefisien regresi robust lebih stabil dan moderat dibandingkan OLS. Indikator tingkat lanjut (S1, S2, dan D) memiliki kontribusi terbesar terhadap skor penalaran abduktif. Perbedaan nilai koefisien menunjukkan bahwa OLS cenderung meng-overestimate pengaruh indikator tertentu akibat *outlier*.

3.2 Analisis Skor Estimasi Penalaran Abduktif

Berdasarkan hasil regresi robust, diperoleh skor estimasi penalaran abduktif $\hat{y}_i$ untuk setiap siswa. Statistik deskriptif skor estimasi disajikan pada Tabel 2.

Tabel 2. Statistik Deskriptif Skor Estimasi ($\hat{y}_i$)

Statistik	Nilai
Minimum	12,4
Maksimum	29,1
Rata-rata	21,6
Simpangan baku	4,2

Pada Tabel 2, sebaran skor menunjukkan variasi kemampuan penalaran yang cukup tinggi, yang menguatkan perlunya pendekatan robust dalam proses estimasi.

3.3 Penentuan Nilai Ambang τ_1 dan τ_2

Sesuai dengan pendekatan *tertile-based classification*, nilai ambang ditentukan berdasarkan kuantil distribusi skor estimasi.

$$\tau_1 = Q_{33}(\hat{y}) = 18.8, \quad \tau_2 = Q_{67}(\hat{y}) = 24.4$$

Nilai τ_1 dan τ_2 membagi siswa ke dalam tiga kelompok dengan proporsi relatif seimbang dan stabil terhadap pengaruh *outlier*.


3.4 Hasil Klasifikasi Tingkat Penalaran Abduktif

Tabel 3 menunjukkan bahwa mayoritas siswa berada pada kategori sedang, sementara hampir sepertiga siswa masih berada pada tingkat penalaran rendah.

Tabel 3. Distribusi Tingkat Penalaran Abduktif Siswa

Tingkat Penalaran	Interval Skor	Jumlah Siswa	Persentase
Rendah	$\hat{y}_i < \tau_1$	21	29.2%
Sedang	$\tau_1 \leq \hat{y}_i \leq \tau_2$	36	50.0%
Tinggi	$\hat{y}_i > \tau_2$	15	20.8%
Total	–	72	100%

Distribusi ini menunjukkan bahwa setengah dari siswa berada pada tingkat penalaran sedang, sementara sekitar 29.2% masih berada pada tingkat rendah, dan hanya sekitar 20.8% yang telah mencapai tingkat penalaran tinggi.




Gambar 1(a). Scatter Plot Skor Tingkat Penalaran Abduktif; (b). Histogram Tingkat Penalaran Abduktif

Gambar 1(a) merupakan *scatter plot* sebaran skor estimasi penalaran abduktif siswa hasil regresi *robust* dengan pengelompokan tingkat rendah, sedang, dan tinggi berdasarkan ambang τ_1 dan τ_2 . Sedangkan Gambar 1(b) menunjukkan histogram skor estimasi penalaran abduktif dengan batas τ_1 dan τ_2 .

3.5 Evaluasi Model Klasifikasi

Evaluasi model dilakukan menggunakan *5-fold cross validation*. Kinerja klasifikasi diukur menggunakan akurasi, *precision*, *recall*, dan *F1-score*.



Gambar 2(a). Confusion Matrix – OLS; (b). Confusion Matrix – Regresi *Robust*

Gambar 2(a) menunjukkan bahwa ada kesalahan klasifikasi cukup tinggi pada kelas Sedang (banyak bergeser ke Rendah/Tinggi). Kelas Tinggi masih sering salah diprediksi. Mengindikasikan batas kelas kurang stabil akibat sensitivitas terhadap *outlier*. Sedangkan Gambar 2(b) menunjukkan Diagonal lebih dominan (prediksi benar meningkat) pada ketiga kelas. Reduksi kesalahan silang terutama pada kelas Rendah dan Tinggi (kelas kritis secara pedagogis), hal ini menunjukkan pemisahan kelas yang lebih konsisten.

Tabel 4. Kinerja Klasifikasi OLS vs Regresi *Robust*

Model	Akurasi	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
OLS	0,70	0,68	0,67	0,67
Regresi <i>Robust</i>	0,80	0,79	0,77	0,78

Regresi *robust* unggul pada semua metrik evaluasi. Kenaikan paling terlihat pada *F1-score*, menandakan keseimbangan *precision–recall* yang lebih baik untuk klasifikasi multikelas, serta menguatkan klaim stabilitas dan kualitas klasifikasi yang lebih tinggi [9]. Berdasarkan hasil *confusion matrix* menunjukkan bahwa model berbasis regresi *robust* menghasilkan prediksi yang lebih akurat dan konsisten pada ketiga kelas tingkat penalaran dibandingkan OLS. Penurunan kesalahan silang antar kelas, khususnya pada kelas rendah dan tinggi, menegaskan bahwa pendekatan *robust* efektif mereduksi pengaruh *outlier*. Hal ini diperkuat oleh grafik perbandingan metrik yang menunjukkan peningkatan akurasi dan *F1-score* pada model *robust*, sehingga lebih sesuai untuk analisis data pendidikan yang heterogen.

4. SIMPULAN

Penelitian ini menunjukkan bahwa integrasi regresi *robust* dalam kerangka *Educational Data Mining* (EDM) efektif untuk mengklasifikasikan tingkat penalaran abduktif siswa SMP berdasarkan indikator penalaran yang terukur. Penggunaan regresi *robust* mampu menghasilkan estimasi skor penalaran yang lebih stabil dibandingkan regresi linier konvensional (OLS), terutama pada data pendidikan yang heterogen dan mengandung *outlier*. Hasil klasifikasi menunjukkan bahwa dari 72 siswa, 21 siswa (29.2%) berada pada tingkat penalaran rendah, 36 siswa (50.0%) berada pada tingkat sedang, dan 15 siswa (20.8%) berada pada tingkat tinggi. Distribusi ini mengindikasikan bahwa sebagian besar siswa telah mencapai tahap penalaran transisi, namun masih memerlukan penguatan pada aspek justifikasi dan pemilihan solusi. Evaluasi model menggunakan *5-fold cross validation* memperlihatkan bahwa model berbasis regresi *robust* memberikan kinerja yang lebih baik dibandingkan OLS, dengan peningkatan pada seluruh metrik evaluasi, khususnya akurasi dan *F1-score*. *Confusion matrix* juga menunjukkan bahwa regresi *robust* mampu mengurangi kesalahan klasifikasi antar kelas, terutama pada kelas rendah dan tinggi, sehingga menghasilkan pemetaan tingkat penalaran yang lebih konsisten dan dapat diandalkan. Secara keseluruhan, hasil penelitian ini menegaskan bahwa regresi *robust* tidak hanya unggul secara teknis, tetapi juga relevan secara pedagogis dalam mendukung diagnosis kemampuan penalaran siswa dan pengambilan keputusan berbasis data dalam pembelajaran matematika.

5. SARAN

Hasil penelitian ini dapat dimanfaatkan guru sebagai dasar perancangan pembelajaran diferensiatif berbasis tingkat penalaran abduktif, khususnya untuk memberikan pendampingan terarah bagi siswa dengan tingkat rendah dan penguatan justifikasi bagi siswa pada tingkat sedang. Penelitian selanjutnya disarankan melibatkan subjek dan konteks sekolah yang lebih beragam guna meningkatkan validitas eksternal, serta mengeksplorasi algoritma klasifikasi lain dalam kerangka *Educational Data Mining*. Selain itu, integrasi pendekatan regresi *robust* dengan *learning analytics* atau *natural language processing* berpotensi memperkaya analisis penalaran dari data jawaban tertulis dan mendukung pengembangan sistem pendukung keputusan pembelajaran.

DAFTAR PUSTAKA

- [1]. OECD, *PISA 2022 Results (Volume I): The State of Learning and Equity in Education*, Paris, France: OECD Publishing, 2023, doi: 10.1787/53f23881-en.
- [2]. P. J. Huber, "Robust estimation of a location parameter," *Annals of Mathematical Statistics*, vol. 35, no. 1, pp. 73–101, 1964, doi: 10.1214/aoms/1177703732.
- [3]. C. Romero and S. Ventura, "Educational data mining: A review of the state of the art," *IEEE Trans. Syst., Man, Cybern. C*, vol. 40, no. 6, pp. 601–618, 2010, doi: 10.1109/TSMCC.2010.2053532.
- [4]. E. Kalita *et al.*, "Educational data mining: A 10-year review," *Discover Computing*, vol. 28, no. 1, 2025, doi: 10.1007/s10791-025-09589-z.
- [5]. H. Aldowah *et al.*, "Educational data mining and learning analytics for 21st century higher education," *Telematics and Informatics*, vol. 37, pp. 13–49, 2019, doi: 10.1016/j.tele.2019.01.007.
- [6]. Yiyuni, N. Miftachurohmah, *et al.*, "Expert system for identification of symptoms and diseases in lobsters using backward chaining," *Media of Computer Science*, vol. 2, no. 1, pp. 37–50, 2025, doi: 10.69616/mcs.v2i1.232.
- [7]. N. Nasruddin and N. Miftachurohmah, "The effect of integrative curriculum implementation and character education on academic success," *West Science Social and Humanities Studies*, vol. 2, no. 8, pp. 1346–1354, 2024, doi: 10.58812/wsshs.v2i08.1192.
- [8]. P. J. Rousseeuw and A. M. Leroy, *Robust Regression and Outlier Detection*. Hoboken, NJ, USA: Wiley, 2003, doi: 10.1002/0471725382.
- [9]. M. Ilyas and S. Salahuddin, "An Evaluation of the Impact of Multicollinearity on the Performance of Various Robust Regression Methods," *Indian Journal of Science and Technology*, vol. 12, no. 26, p. 1, Jul. 2019, doi: 10.17485/ijst/2019/v12i26/145300.