

PREDIKSI PERILAKU BELAJAR MATEMATIKA PADA SISWA SEKOLAH DASAR : PERSPEKTIF DARI MACHINE LEARNING

Sjaeful Irwan¹, Henny Noviana
Lubis²

¹Universitas Bani Saleh, sjaeful@ubs.ac.id

²SD Negeri Baru 01 Pagi Jakarta, hennynovianalubis@gmail.com

ABSTRAK

Dalam era digital, memahami perilaku belajar siswa sangat penting untuk meningkatkan kualitas pendidikan. Penelitian ini menggunakan algoritma *machine learning* untuk memprediksi perilaku belajar matematika siswa sekolah dasar berdasarkan data aktivitas belajar mereka, seperti waktu pengerjaan soal, tingkat keberhasilan, dan pola interaksi dalam pembelajaran berbasis teknologi. Dengan memanfaatkan algoritma Random Forest, penelitian ini berhasil mengidentifikasi faktor-faktor utama yang memengaruhi perilaku belajar siswa.

Penelitian ini bertujuan untuk memprediksi perilaku belajar siswa sekolah dasar menggunakan algoritma Random Forest yang diimplementasikan pada siswa Kelas 6-B, SD Negeri Baru 01 Pagi Jakarta. Fitur-fiturnya meliputi jumlah soal yang dikerjakan, waktu rata-rata pengerjaan, tingkat keberhasilan, dan frekuensi pengulangan digunakan untuk membangun model prediksi. Hasil penelitian menunjukkan model memiliki akurasi 100% pada data uji. Model Random Forest yang dikembangkan ini menunjukkan kemampuan model yang sangat baik dalam memprediksi perilaku belajar siswa berdasarkan fitur-fitur yang tersedia dalam dataset, dengan hasil detail: (1) Waktu Rata-rata memiliki kontribusi tertinggi (35.78%) dalam prediksi model; (2) Keberhasilan memiliki kontribusi sebesar 32.57%, menunjukkan bahwa tingkat keberhasilan siswa dalam menjawab soal menjadi faktor penting dalam memprediksi perilaku belajar; (3) Frekuensi Ulang memberikan kontribusi sebesar 20.46%, yang mencerminkan bagaimana ketekunan siswa dalam mengulang latihan soal turut memengaruhi prediksi perilaku belajar; dan (4) Jumlah Soal memiliki kontribusi paling rendah (11.19%), menunjukkan bahwa jumlah soal yang dikerjakan memiliki pengaruh yang lebih kecil dibandingkan fitur lainnya.

Hasil penelitian ini memberikan wawasan kepada pendidik untuk merancang strategi pembelajaran yang lebih efektif, termasuk intervensi personal untuk siswa yang berisiko rendah motivasi.

Kata Kunci:

Machine Learning, Pendidikan Dasar, Perilaku Belajar, Matematika, Prediksi Data Pendidikan

ABSTRACT

In the digital era, understanding students' learning behavior is crucial for improving the quality of education. This research employs machine learning algorithms to predict elementary students' mathematics learning behavior based on their learning activity data, such as problem-solving time, success rate, and interaction patterns in technology-based learning. By leveraging the Random Forest algorithm, this study successfully identifies key factors influencing students' learning behavior.

The study aims to predict the learning behavior of elementary students using the Random Forest algorithm, implemented on 6th-grade students from Class 6-B, SD Negeri Baru 01 Pagi Jakarta. Features including the number of problems solved, average solving time, success rate, and repetition frequency were utilized to build the prediction model. The results revealed that the model achieved 100% accuracy on test data. The developed Random Forest model demonstrated excellent performance in predicting students' learning behavior based on the available dataset features, with detailed findings as follows: (1) Average Solving Time contributed the most (35.78%) to the model's predictions; (2) Success Rate contributed 32.57%, indicating that students' success in solving

problems is a significant factor in predicting learning behavior; (3) Repetition Frequency accounted for 20.46%, reflecting how students' persistence in repeating exercises impacts learning behavior predictions; and (4) Number of Problems Solved had the lowest contribution (11.19%), suggesting that this feature has a smaller impact compared to others. The findings provide valuable insights for educators to design more effective learning strategies, including personalized interventions for students at risk of low motivation.

Keywords:

Machine Learning, Basic Education, Learning Behavior, Mathematics, Educational Data Prediction

PENDAHULUAN

Matematika adalah salah satu mata pelajaran dasar yang penting dalam kurikulum pendidikan, karena berperan dalam mengembangkan kemampuan berpikir logis, analitis, dan sistematis pada siswa. Namun, kenyataannya, banyak siswa di sekolah dasar di Indonesia masih menghadapi kesulitan dalam memahami dan menguasai konsep-konsep matematika. Berbagai laporan nasional maupun internasional, seperti survei PISA (Programme for International Student Assessment), menunjukkan bahwa kemampuan matematika siswa Indonesia cenderung berada di bawah rata-rata dibandingkan negara lain. Situasi ini menunjukkan perlunya perhatian yang serius untuk mengidentifikasi faktor-faktor yang memengaruhi pembelajaran matematika siswa.

Perilaku belajar siswa di sekolah dasar dipengaruhi oleh berbagai aspek, seperti motivasi, lingkungan belajar, dukungan dari keluarga, dan pendekatan pengajaran. Guru sering mengalami kesulitan dalam mengenali siswa yang memerlukan perhatian khusus, terutama dengan keterbatasan waktu dan sumber daya yang tersedia. Dalam situasi ini, teknologi, khususnya penerapan metode machine learning, memberikan peluang besar untuk menganalisis dan memprediksi perilaku belajar siswa berdasarkan data yang tersedia.

Random Forest, sebagai salah satu metode machine learning yang andal dan mudah diinterpretasikan, mampu menganalisis data kompleks dan mengenali pola-pola penting dalam perilaku belajar siswa. Dengan memanfaatkan data seperti kehadiran, hasil ujian, partisipasi di kelas, dan umpan balik guru, metode ini dapat mengungkap faktor-faktor utama yang memengaruhi keberhasilan siswa dalam belajar matematika. Pendekatan ini juga mendukung sekolah dalam membuat keputusan yang berbasis data untuk meningkatkan kualitas proses pengajaran dan pembelajaran.

TINJAUAN PUSTAKA

1. Machine Learning dalam Pendidikan

Penerapan machine learning dalam pendidikan telah menjadi salah satu tren yang signifikan dalam beberapa tahun terakhir. Algoritma machine learning memungkinkan analisis data dalam jumlah besar untuk mengidentifikasi pola yang relevan dengan perilaku siswa, termasuk motivasi dan kinerja mereka dalam berbagai mata pelajaran, seperti matematika. Studi sebelumnya menunjukkan bahwa model berbasis machine learning dapat meningkatkan efektivitas pembelajaran melalui pendekatan personalisasi yang lebih baik (Jordan & Mitchell, 2015).

Metode Random Forest menjadi salah satu algoritma yang sering digunakan dalam penelitian pendidikan karena kemampuannya dalam menangani data yang kompleks, mengurangi risiko overfitting, dan memberikan hasil yang dapat diinterpretasikan melalui analisis pentingnya fitur (Breiman, 2001). Dalam konteks pembelajaran matematika, Random Forest memungkinkan pengidentifikasian faktor-faktor utama yang memengaruhi keberhasilan siswa, seperti waktu pengerjaan soal, tingkat keberhasilan, dan frekuensi pengulangan.

2. Random Forest sebagai Metode Prediksi

Random Forest merupakan metode ensemble learning yang menggabungkan prediksi dari beberapa pohon keputusan untuk meningkatkan akurasi model. Algoritma ini bekerja dengan membangun beberapa pohon keputusan berdasarkan subset acak dari data latih, kemudian menggabungkan hasilnya menggunakan voting mayoritas untuk klasifikasi atau rata-rata untuk regresi (Breiman, 2001). Dalam pendidikan, Random Forest sering digunakan untuk memprediksi hasil belajar, mendeteksi siswa yang berisiko gagal, dan mengidentifikasi fitur-fitur yang paling berpengaruh terhadap hasil pembelajaran (Lundberg & Lee, 2017).

3. Studi Perilaku Belajar Matematika

Perilaku belajar siswa dalam matematika melibatkan aspek kognitif, afektif, dan sosial. Penelitian menunjukkan bahwa faktor seperti durasi pengerjaan soal, tingkat keberhasilan, dan frekuensi pengulangan merupakan indikator penting dari perilaku belajar siswa (OECD, 2019). Selain itu, motivasi belajar sering kali menjadi penentu utama keberhasilan siswa dalam menyelesaikan soal matematika, di mana siswa dengan motivasi tinggi cenderung memiliki waktu pengerjaan yang lebih singkat dan tingkat keberhasilan yang lebih tinggi (Zimmerman, 2002).

Dengan menggunakan algoritma pembelajaran mesin, pola belajar siswa dapat diperkirakan dengan lebih efisien. Prediksi ini memberikan informasi berharga bagi pendidik untuk menyusun strategi pembelajaran yang lebih adaptif dan optimal.

4. Pentingnya Analisis Pentingnya Fitur

Salah satu keuntungan utama dari penggunaan Random Forest adalah kemampuan algoritma ini untuk mengukur pentingnya fitur (*feature importance*). Analisis ini memungkinkan pendidik untuk memahami faktor-faktor mana yang paling berkontribusi terhadap perilaku belajar siswa. Misalnya, penelitian menunjukkan bahwa waktu pengerjaan soal dan tingkat keberhasilan sering kali menjadi fitur paling signifikan dalam memprediksi motivasi siswa (Lundberg & Lee, 2017). Dengan mengetahui fitur-fitur penting, pendidik dapat mengambil keputusan yang lebih terarah untuk meningkatkan kualitas pembelajaran.

METODE PENELITIAN

1. Desain Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksploratif-prediktif. Algoritma Random Forest diterapkan untuk memproyeksikan perilaku belajar siswa dalam pelajaran matematika berdasarkan berbagai variabel terkait. Pendekatan ini dirancang untuk menganalisis pola perilaku siswa serta memberikan pemahaman kepada pendidik mengenai faktor-faktor yang memengaruhi motivasi belajar.

2. Populasi dan Sampel

- Populasi: Siswa Kelas 6-B SD Negeri Baru 01 Pagi Jakarta yang terlibat dalam pembelajaran berbasis teknologi dan menyelesaikan latihan soal matematika secara terstruktur.
- Sampel: Dataset terdiri dari 30 sampel siswa, yang dipilih menggunakan teknik purposive sampling berdasarkan kriteria:
 - 1) Siswa yang memiliki catatan lengkap mengenai jumlah soal yang dikerjakan.
 - 2) Data waktu pengerjaan rata-rata, keberhasilan, dan frekuensi pengulangan soal.

3. Variabel Penelitian

- 1) Variabel Bebas (Independent Variables):
 - Jumlah Soal: Total soal yang dikerjakan siswa.

- Waktu Rata-rata: Durasi rata-rata pengerjaan soal (dalam menit).
 - Keberhasilan: Persentase soal yang dijawab dengan benar.
 - Frekuensi Ulang: Jumlah pengulangan soal yang salah.
- 2) Variabel Terikat (Dependent Variable):
- Perilaku Belajar: Diklasifikasikan menjadi tiga kategori:
 - "Motivasi Tinggi"
 - "Motivasi Sedang"
 - "Motivasi Rendah"

4. Pengumpulan Data

Data dikumpulkan melalui aktivitas siswa dalam pengerjaan soal matematika menggunakan sistem pembelajaran luring. Data mencakup:

- Jumlah Soal: Jumlah soal yang dikerjakan oleh siswa selama periode waktu tertentu.
- Waktu Rata-rata: Rata-rata waktu pengerjaan soal yang dihitung per siswa.
- Keberhasilan: Persentase jawaban benar dari total soal yang dikerjakan.
- Frekuensi Ulang: Jumlah pengulangan soal yang dilakukan siswa. Data ini direkam dalam format tabel menggunakan pustaka Python, pandas.

5. Prosedur Penelitian

Tahap 1: Penyusunan Dataset

- Dataset simulasi diorganisasikan ke dalam format DataFrame.
- Contoh data simulasi:

Jumlah_Soal	Waktu_Rata-rata	Keberhasilan	Frekuensi_Ulang	Perilaku_Belajar
20	1.0	90	1	Motivasi Tinggi
12	2.0	90	1	Motivasi Tinggi
15	4.0	75	2	Motivasi Sedang

Tahap 2: Pemisahan Fitur dan Label

- Fitur (X): Variabel input (Jumlah Soal, Waktu Rata-rata, Keberhasilan, Frekuensi Ulang).
- Label (y): Variabel target (Perilaku Belajar).

Tahap 3: Pembagian Data. Dataset dibagi menjadi data latih (70%) dan data uji (30%) menggunakan fungsi `train_test_split` dari pustaka `scikit-learn`. Parameter `random_state=42` digunakan untuk memastikan hasil pembagian data konsisten.

Tahap 4: Pelatihan Model. Algoritma Random Forest dilatih menggunakan parameter: (1) `n_estimators=100`: Jumlah pohon keputusan yang digunakan dan (2) `random_state=42`: Untuk memastikan hasil replikasi.

Tahap 5: Evaluasi Model. Model dievaluasi menggunakan: (1) Akurasi: Mengukur proporsi prediksi yang benar terhadap total sampel; dan (2) Laporan Klasifikasi: Precision, recall, dan F1-score dihitung untuk setiap kategori perilaku belajar.

Tahap 6: Analisis Pentingnya Fitur. Pentingnya fitur dihitung menggunakan atribut `feature_importances_` pada model Random Forest. Hasil divisualisasikan menggunakan diagram batang horizontal (`matplotlib`).

Tahap 7: Prediksi Data Baru. Data baru dimasukkan ke dalam model untuk memprediksi motivasi belajar siswa berdasarkan fitur input yang sama.

6. Analisis Data

- 1) Evaluasi Kinerja Model. Model menghasilkan akurasi dengan skor tertentu pada data uji. Laporan klasifikasi memberikan wawasan tentang kemampuan model dalam memprediksi setiap kategori.
- 2) Analisis Pentingnya Fitur. Menunjukkan kontribusi relatif dari setiap fitur terhadap prediksi model.

- 3) Prediksi Data Baru. Model diuji pada data siswa baru, menghasilkan output motivasi belajar.
- 4) Implementasi Teknologi. Penelitian dilakukan menggunakan perangkat lunak Python, dengan pustaka:
 - pandas: Untuk manipulasi data.
 - scikit-learn: Untuk pengembangan model Random Forest.
 - matplotlib: Untuk visualisasi hasil analisis.
 - Validasi dan Replikasi. Model divalidasi menggunakan teknik cross-validation untuk memastikan generalisasi. Model disimpan dalam format .pkl menggunakan pustaka joblib untuk mendukung replikasi dan penggunaan ulang.

HASIL DAN PEMBAHASAN

Berdasarkan data penelitian yang dilakukan, tersusun dalam format coding Bahasa Python seperti ditunjukkan di bawah ini.

```
data = {
    "Jumlah_Soal": [20, 12, 15, 14, 8, 18, 17, 14, 7, 19, 16, 18, 15, 18, 20, 15, 10, 18, 12, 11, 10, 11, 17, 13, 18,
    10, 9, 14, 8, 16],
    "Waktu_Rata-rata": [1, 2, 4.2, 3.8, 6, 2, 2, 4.2, 6, 2, 3, 1.5, 1, 5, 5, 6, 6, 3, 3, 4, 1.5, 5, 6, 2, 1, 6, 8, 3, 8, 3],
    "Keberhasilan": [90, 90, 75, 75, 50, 90, 90, 78, 50, 90, 80, 90, 90, 80, 80, 65, 50, 88, 88, 80, 90, 60, 60, 90,
    90, 50, 30, 88, 30, 80],
    "Frekuensi_Ulang": [1, 1, 2, 3, 6, 1, 1, 3, 5, 1, 3, 1, 1, 4, 3, 3, 6, 2, 2, 2, 1, 4, 4, 1, 1, 5, 6, 2, 6, 3],
    "Perilaku_Belajar": ["Motivasi Tinggi", "Motivasi Tinggi", "Motivasi Sedang", "Motivasi Sedang",
    "Motivasi Rendah", "Motivasi Tinggi", "Motivasi Tinggi", "Motivasi Sedang", "Motivasi Rendah", "Motivasi
    Tinggi", "Motivasi Sedang", "Motivasi Tinggi", "Motivasi Tinggi", "Motivasi Sedang", "Motivasi Sedang",
    "Motivasi Sedang", "Motivasi Rendah", "Motivasi Tinggi", "Motivasi Tinggi", "Motivasi Sedang", "Motivasi
    Tinggi", "Motivasi Sedang", "Motivasi Sedang", "Motivasi Tinggi", "Motivasi Tinggi", "Motivasi Rendah",
    "Motivasi Rendah", "Motivasi Sedang", "Motivasi Rendah", "Motivasi Sedang"]
}
```

Dari data yang diperoleh dilakukan latihan data berdasarkan variabel bebas (x) secara acak dan variabel tak bebas (y) yang terkait.

Data Latih (X_train):					Label Latih (y_train):	
	Jumlah_Soal	Waktu_Rata-rata	Keberhasilan	Frekuensi_Ulang		
0	20	1.0	90	1	0	Motivasi Tinggi
4	8	7.0	50	6	4	Motivasi Rendah
16	10	6.0	50	6	16	Motivasi Rendah
5	18	2.0	90	1	5	Motivasi Tinggi
13	18	4.0	80	4	13	Motivasi Sedang
11	18	1.5	90	1	11	Motivasi Tinggi
22	17	4.0	60	4	22	Motivasi Sedang
1	12	2.0	90	1	1	Motivasi Tinggi
2	15	4.0	75	2	2	Motivasi Sedang
25	10	7.0	50	5	25	Motivasi Rendah
3	14	3.0	75	3	3	Motivasi Sedang
21	11	4.0	60	4	21	Motivasi Sedang
26	9	8.0	30	6	26	Motivasi Rendah
18	12	2.0	88	2	18	Motivasi Tinggi
29	16	3.0	80	3	29	Motivasi Sedang
20	10	1.5	90	1	20	Motivasi Tinggi
7	14	3.0	78	3	7	Motivasi Sedang
10	16	3.0	80	3	10	Motivasi Sedang
14	20	4.0	80	3	14	Motivasi Sedang
19	11	4.0	80	2	19	Motivasi Sedang
6	17	2.0	90	1	6	Motivasi Tinggi


Serta dilakukan uji terhadap data yang diperoleh dari penelitian, seperti yang ditunjukkan berikut ini.

Data Uji (X_test):					Label Uji (y_test):	
	Jumlah_Soal	Waktu_Rata-rata	Keberhasilan	Frekuensi_Ulang		
27	14	3.0	88	2	27	Motivasi Sedang
15	15	4.0	65	3	15	Motivasi Sedang
23	13	2.0	90	1	23	Motivasi Tinggi
17	18	2.0	88	2	17	Motivasi Tinggi
8	7	7.0	50	5	8	Motivasi Rendah
9	19	2.0	90	1	9	Motivasi Tinggi
28	8	8.0	30	6	28	Motivasi Rendah
24	18	1.0	90	1	24	Motivasi Tinggi
12	15	1.0	90	1	12	Motivasi Tinggi

Tahapan ini memberikan hasil uji dengan akurasi sebesar 100%.

Secara keseluruhan hasil penelitian ini menghasilkan informasi sebagai berikut.

Laporan Klasifikasi:				
	precision	recall	f1-score	support
Motivasi Rendah	1.00	1.00	1.00	2
Motivasi Sedang	1.00	1.00	1.00	2
Motivasi Tinggi	1.00	1.00	1.00	5
accuracy			1.00	9
macro avg	1.00	1.00	1.00	9
weighted avg	1.00	1.00	1.00	9



Jumlah_Soal: 0.1119
 Waktu_Rata-rata: 0.3578
 Keberhasilan: 0.3257
 Frekuensi_Ulang: 0.2046

Informasi di atas menunjukkan bahwa:

- 1) Frekuensi_Ulang (Skor: 0.2046). Mengukur berapa kali siswa mengulang latihan soal, berkontribusi sekitar 20.46% terhadap prediksi model.
- 2) Keberhasilan (Skor: 0.3257). Persentase soal yang dijawab dengan benar oleh siswa, berkontribusi sekitar 32.57%, menunjukkan bahwa tingkat keberhasilan siswa sangat penting untuk memprediksi perilaku belajar.
- 3) Waktu_Rata-rata (Skor: 0.3578). Waktu rata-rata yang dihabiskan siswa untuk menyelesaikan soal, fitur ini memiliki kontribusi tertinggi (35.78%), menunjukkan bahwa waktu pengerjaan soal merupakan indikator penting dalam perilaku belajar siswa.
- 4) Jumlah_Soal (Skor: 0.1119). Jumlah soal yang dikerjakan siswa selama proses pembelajaran, memiliki skor kontribusi terendah (11.19%), menunjukkan pengaruh yang lebih kecil dibandingkan fitur lainnya.

PENUTUP

Simpulan

1. Model Random Forest yang dikembangkan memiliki akurasi **100% (1.0)**, menunjukkan kemampuan model yang sangat baik dalam memprediksi perilaku belajar siswa berdasarkan fitur-fitur yang tersedia dalam dataset.
2. **Pentingnya Fitur (Feature Importance)**
 - o **Waktu Rata-rata** memiliki kontribusi tertinggi (35.78%) dalam prediksi model, menandakan bahwa durasi pengerjaan soal merupakan indikator utama yang memengaruhi motivasi belajar siswa.
 - o **Keberhasilan** memiliki kontribusi sebesar 32.57%, menunjukkan bahwa tingkat keberhasilan siswa dalam menjawab soal menjadi faktor penting dalam memprediksi perilaku belajar.
 - o **Frekuensi Ulang** memberikan kontribusi sebesar 20.46%, yang mencerminkan bagaimana ketekunan siswa dalam mengulang latihan soal turut memengaruhi prediksi perilaku belajar.
 - o **Jumlah Soal** memiliki kontribusi paling rendah (11.19%), menunjukkan bahwa

jumlah soal yang dikerjakan memiliki pengaruh yang lebih kecil dibandingkan fitur lainnya.

3. Hubungan antara Fitur dan Perilaku Belajar

- Waktu pengerjaan yang lebih singkat dan tingkat keberhasilan yang lebih tinggi cenderung menunjukkan siswa dengan motivasi tinggi.
 - Frekuensi pengulangan yang tinggi dapat mengindikasikan motivasi sedang atau rendah, tergantung pada tingkat keberhasilan siswa.
 - Jumlah soal tidak memiliki hubungan yang signifikan terhadap motivasi, sehingga dapat dipertimbangkan untuk tidak menjadi fokus utama dalam pengambilan keputusan berbasis model.
4. Model ini memberikan wawasan yang dapat membantu pendidik memahami faktor-faktor penting yang memengaruhi motivasi belajar siswa, sehingga strategi pengajaran dapat disesuaikan untuk meningkatkan hasil pembelajaran.

Saran

1. Optimalisasi Strategi Pengajaran

- Berdasarkan hasil analisis, guru disarankan untuk memonitor waktu pengerjaan soal siswa secara berkala. Siswa yang membutuhkan waktu lebih lama dari rata-rata dapat diberikan perhatian lebih atau penyesuaian dalam metode pengajaran.
- Keberhasilan siswa dalam menjawab soal harus menjadi prioritas utama. Guru dapat memberikan umpan balik yang lebih cepat dan spesifik untuk membantu siswa memahami materi lebih baik.

2. Pemanfaatan Teknologi

- Sistem pembelajaran berbasis teknologi dapat diintegrasikan dengan model prediksi ini untuk memantau dan menganalisis perilaku belajar siswa secara real-time.
- Hasil prediksi model dapat digunakan untuk memberikan rekomendasi otomatis kepada guru mengenai tindakan yang perlu diambil, seperti pemberian soal tambahan untuk siswa dengan motivasi rendah atau sedang.

3. Pengembangan Dataset

- Walaupun akurasi model tinggi, dataset yang digunakan relatif kecil (30 sampel). Untuk meningkatkan validitas hasil, disarankan untuk menggunakan dataset yang lebih besar dan beragam.
- Penambahan fitur baru, seperti data emosional atau tingkat keterlibatan siswa, dapat meningkatkan akurasi dan generalisasi model.

4. Intervensi Berdasarkan Perilaku Belajar

- Siswa dengan frekuensi ulang yang tinggi dapat diarahkan untuk memanfaatkan materi pengayaan atau bimbingan tambahan agar lebih percaya diri dalam menyelesaikan soal.
- Siswa dengan motivasi rendah dapat diberikan insentif atau dorongan tambahan untuk meningkatkan minat mereka dalam pembelajaran.

5. Pengembangan Penelitian Lanjutan

- Model ini dapat diperluas untuk mencakup mata pelajaran lain selain matematika, sehingga memberikan wawasan menyeluruh tentang perilaku belajar siswa di berbagai aspek.
- Penelitian lebih lanjut dapat mengeksplorasi hubungan antara motivasi belajar siswa dengan hasil akademik jangka panjang, seperti nilai ujian akhir atau keberhasilan dalam mencapai target pembelajaran.

REFERENSI

- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260. <https://doi.org/10.1126/science.aaa8415>
- Lundberg, S. M., & Lee, S. I. (2017). A Unified Approach to Interpretable Model Predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774.
- OECD. (2019). *PISA 2018 Results (Volume I): What Students Know and Can Do*. Paris: OECD Publishing. <https://doi.org/10.1787/5f07c754-en>
- 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