

# Model Prediksi Kinerja Siswa Berdasarkan Data Log LMS Menggunakan *Ensemble Machine Learning*

Mifta Ardianti<sup>1\*</sup>, Oky Dwi Nurhayati<sup>2</sup>, Budi Warsito<sup>3</sup> 

<sup>1,2,3</sup> Magister Sistem Informasi, Universitas Diponegoro, Semarang, Indonesia

## ARTICLE INFO

### Article history:

Received March 20, 2023

Accepted October 13, 2023

Available online October 25, 2023

### Kata Kunci:

Model prediksi, bagging, boosting, voting.

### Keywords:

Prediction model, bagging, boosting, voting.



This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

Copyright © 2023 by Author. Published by Universitas Pendidikan Ganesha.

## ABSTRAK

Institusi pendidikan saat ini menerapkan Learning Management System (LMS) sebagai sarana pembelajaran online. LMS dapat merekam sejumlah besar data perilaku siswa pada log LMS. Data perilaku ini dapat dikumpulkan dan digunakan untuk memprediksi kinerja belajar siswa. Sehingga, diperlukan analisis yang dapat mengubah sejumlah data yang tersimpan tersebut menjadi sebuah pengetahuan yang dapat meningkatkan kualitas pengajaran pada institusi pendidikan. Pada penelitian ini, mengusulkan model prediksi kinerja belajar siswa menggunakan ensemble machine learning berdasarkan ekstraksi ciri yang berhubungan dengan interaksi siswa pada LMS. Pemodelan dilakukan dengan menerapkan tiga jenis ensemble machine learning yaitu ; bagging, boosting dan voting. Hasil penelitian menunjukkan bahwa model ensemble machine learning yaitu bagging, boosting dan voting berhasil digunakan untuk memprediksi kinerja siswa dengan accuracy sebesar 81.25% dengan precision 0.810, recall 0.812 dan f-measure 0.809 yang diperoleh model bagging. Temuan pada penelitian ini adalah ensemble machine learning dapat diterapkan sebagai model prediksi kinerja siswa berdasarkan data Log LMS. Institusi pendidikan baik sekolah maupun perguruan tinggi diharapkan dapat merancang sebuah kurikulum LMS untuk meningkatkan kualitas akademik institusi tersebut. Selain itu institusi pendidikan dapat memprediksi bagaimana kinerja siswanya, sehingga dapat meningkatkan prestasi akademik.

## ABSTRACT

Educational institutions are currently implementing Learning Management Systems (LMS) as online learning tools. LMS can record a large amount of student behavior data in LMS logs. This behavioral data can be collected and used to predict student learning performance. So, analysis is needed that can change the amount of stored data into knowledge that can improve the quality of teaching in educational institutions. In this research, we propose a prediction model for student learning performance using ensemble machine learning based on feature extraction related to student interactions in the LMS. Modeling is carried out by applying three types of machine learning ensembles, namely; bagging, boosting and voting. The research results show that the ensemble machine learning model, namely bagging, boosting and voting, was successfully used to predict student performance with an accuracy of 81.25% with a precision of 0.810, recall of 0.812 and f-measure of 0.809 obtained by the bagging model. The finding in this research is that ensemble machine learning can be applied as a student performance prediction model based on LMS Log data. Educational institutions, both schools and universities, are expected to be able to design an LMS curriculum to improve the academic quality of the institution. Apart from that, educational institutions can predict how their students will perform, so they can improve academic achievement.

## 1. PENDAHULUAN

Institusi pendidikan saat ini menerapkan *Learning Management System* (LMS) sebagai sarana dalam pembelajaran *online*. LMS merupakan aplikasi perangkat lunak atau teknologi berbasis web yang digunakan untuk merencanakan, melaksanakan, dan menilai proses pembelajaran tertentu. Selain menyediakan konten, LMS memungkinkan untuk manajemen dan evaluasi tugas, pelacakan, dan pelaporan siswa serta dapat menilai kinerja belajar siswa (Prada et al., 2020; Pratomo & Wahanisa, 2021). Sistem ini menyediakan kemampuan untuk merekam secara otomatis sejumlah besar data perilaku siswa pada *log* LMS. Data perilaku belajar merupakan data yang dihasilkan oleh interaksi siswa dengan LMS selama proses pembelajaran dan disimpan secara otomatis di *database*. Data perilaku siswa dapat dikumpulkan dan digunakan secara otomatis untuk klasifikasi dan prediksi kinerja belajar siswa (Pratomo & Wahanisa, 2021; Yan & Au, 2019). Dalam domain pendidikan, institusi tinggi menghasilkan sejumlah besar data yang dikumpulkan dari berbagai sumber salah satunya platform LMS. Secara khusus universitas atau sekolah, mengumpulkan data setiap tahun dari siswa, yang didalamnya termasuk rincian demografis (contohnya; usia, alamat, dan status sosial ekonomi) dan informasi lengkap tentang data

\*Corresponding author.

E-mail addresses: [mifta563@gmail.com](mailto:mifta563@gmail.com) (Mifta Ardianti)

penerimaan dan kinerja akademik (contohnya; asal sekolah dan hasil ujian) (Nugroho, 2020; Prada et al., 2020). Diperlukan analisis yang dapat mengubah data yang terkumpul menjadi sebuah pengetahuan. Menganalisis sejumlah besar data pendidikan yang tumbuh secara eksponensial adalah tantangan utama yang dihadapi lembaga pendidikan. Faktanya, metode analitik konvensional biasanya tidak praktis untuk mengekstrak korelasi, pola tersembunyi, dan wawasan lain yang dapat bermanfaat bagi administrator, guru, siswa, dan orangtua. Oleh karena itu, ada kebutuhan untuk mengeksplorasi alat analitik otomatis untuk menangani jenis data ini, yang dianggap sebagai tambang emas untuk mengekstrak pengetahuan pendidikan yang berguna. Pengetahuan itu dapat meningkatkan kualitas pengajaran dan pembelajaran juga dapat membantu siswa untuk berhasil dalam karir akademis (Alamri et al., 2020; Saputra, 2020).

Salah satu teknik yang dapat digunakan untuk analisis klasifikasi dan prediksi kinerja belajar siswa adalah *data mining* (Hendrian, 2018; Sutoyo & Almaarif, 2020). *Data mining* atau penambangan data adalah serangkaian proses untuk mendapatkan pola dari kumpulan data (Sutoyo & Almaarif, 2020; Syahril et al., 2020). *Data mining* akan menganalisis data yang sudah ada dalam *database*. *Data mining* juga dikenal dengan *Knowledge Discovey in Database* (KDD) yaitu suatu aktivitas yang meliputi pengumpulan, penggunaan data historis untuk menemukan pola reguler, menemukan pola yang besar dalam kumpulan data yang besar. *Data mining* dapat mengeksplorasi, memvisualisasikan dan menganalisis data dengan tujuan untuk mengidentifikasi pola yang berguna untuk memahami kinerja dan perilaku belajar siswa (Kadoic & Oreski, 2018; Syahra et al., 2019). *Educational data mining* (EDM) merupakan proses yang digunakan untuk mengekstrak informasi yang berguna dan mengenali pola dari *database* pendidikan yang jumlahnya besar. EDM merupakan ranah penelitian yang penting, karena dapat membantu untuk meningkatkan kualitas pendidikan dan dapat mengukur keberhasilan dari suatu pembelajaran pada LMS. EDM mengeksplorasi berbagai jenis data dengan menggunakan berbagai algoritma *machine learning* untuk mengekstrak pengetahuan yang mendukung pengambilan keputusan dan pengembangan sektor akademik. EDM menggunakan berbagai teknik untuk analisis, pemrosesan data, identifikasi pola, konstruksi model dan prediksi hasil (Jamhur, 2020; Tüfekci & Yilmaz, 2020). Implementasi EDM untuk memprediksi kinerja siswa dapat membantu entitas yang bertanggung jawab untuk mengidentifikasi siswa yang mungkin membutuhkan lebih banyak bantuan (Fernandes et al., 2018; Jamhur, 2020). Tujuan EDM adalah untuk mengembangkan metode dan menerapkan teknik *data mining*, statistik, dan *machine learning* untuk menganalisis data yang dikumpulkan selama proses pembelajaran (Hendrian, 2018; Qazdar et al., 2019).

Penelitian yang dilakukan oleh peneliti serupa untuk memprediksi kinerja akademik siswa sehingga meningkatkan hasil akademik yang lebih baik. Penelitian tersebut menggunakan algoritma dan teknik klasifikasi *Support vector machine* (SVM) dan *Random Forest* (RF) (Adriansyah et al., 2022; Alamri et al., 2020). *Dataset* terdiri dari 369 dari pelajaran matematika dan 649 dari pelajaran bahasa portugis. Hasilnya percobaan untuk algoritma SVM dan RF yang diterapkan pada kedua *dataset* menunjukkan bahwa akurasi dalam kasus klasifikasi biner mencapai akurasi prediksi sebesar 93%, sedangkan pada regresi RMSE terendah adalah 1.13 dalam kasus RF (Adriansyah et al., 2022; Alamri et al., 2020). Efisiensi penggunaan metode *machine learning* untuk memprediksi kesulitan yang dihadapi siswa pada semester berikutnya telah dianalisis oleh (Hussain et al., 2018; Qazdar et al., 2019), hasilnya dapat mengklasifikasi siswa sesuai dengan tingkat kesulitannya. Algoritma *machine learning* yang diterapkan untuk proses prediksi, yaitu *artificial neural network* (ANN), *logstic regression* (LR), *naive bayes* (NB), *support vector machine* (SVM), dan *decisison tree* (DT) (Hussain et al., 2018; Qazdar et al., 2019). Evaluasi menggunakan teknik RMSE dan *Cohen's kappa cooefficient*. Pemilihan fitur menggunakan *alpha investing* untuk pemeringkatan fitur input yang akan digunakan dalam model prediksi kinerja siswa. Hasil penelitian menunjukkan bahwa SVM dan ANN adalah model yang paling cocok untuk memprediksi kinerja siswa (Hussain et al., 2018; Qazdar et al., 2019). Penelitian tentang model prediktif untuk menganalisis masalah yang dihadapi oleh siswa selama menggunakan *platform* pembelajaran *online* dilakukan oleh, model predktif tersebut dapat membantu instruktur mengidentifikasi siswa yang beresiko diawal untuk dapat menghindari kasus putus sekolah. Penggunaan algoritma *machine learning* (ML) dan *deep learning* (DL) untuk mengklasifikasi perilaku belajar siswa sesuai dengan variabel belajarnya. Selanjutnya, performa dari berbagai algoritma ML tersebut dibandingkan dengan menggunakan akurasi, presisi, *recall* dan *f1 score*. Hasil menunjukkan bahwa nilai siswa, waktu menggunakan *paltform* dan banyaknya keterlibatan siswa merupakan faktor penting dalam pembelajaran *online*. Hasil penelitian menunjukkan bahwa model prediksi yang dilatih menggunakan *random forest* (RF) memberikan hasil terbaik dengan rata-rata *precision* 0.92%, *recall* 0.91%, *f1-score* = 0.91% dan akurasi sebesar 80%.

Selain menggunakan teknik klasifikasi *machine learning* tunggal, beberapa penelitian menggunakan teknik *ensemble machine learning*. Teknik *ensemble machine learning* memiliki kelebihan dapat memperbaiki algoritma *machine learning* tunggal yang digunakan sehingga memperoleh akurasi terbaik (Fahd et al., 2021; Rawat & Malhan, 2019). Analisis hubungan antara kinerja siswa pada *e-learning*

menggunakan *data mining* sebagaimana dilakukan oleh (Almutairi et al., 2019; Prasetyo & Nurhidayah, 2021), menentukan faktor utama yang mempengaruhi kinerja siswa dipilih dengan menggunakan metode seleksi fitur. Metode *machine learning* yang digunakan dan diuji untuk memprediksi kinerja siswa yaitu *random forest*, *logstic regression*, XGBoost, MLP dan *ensemble learning* juga menggunakan *bagging* dan *voting*. Dari semua metode tersebut *random forest* mendapatkan akurasi tertinggi mencapai 77%. Hasilnya menunjukkan bahwa *data mining* dapat secara akurat memprediksi tingkat kinerja siswa (Almutairi et al., 2019; Hendrian, 2018). Penelitian serupa dilakukan untuk membangun model klasifikasi *hybrid (voting)* yang digunakan untuk menganalisis kinerja siswa dengan temuan bahwa model klasifikasi *hybird* lebih efisien untuk prediksi kinerja siswa berdasarkan data terkait dengan akurasi sebesar 98% (Indahyanti et al., 2022; Rawat & Malhan, 2019). Penelitian *ensemble technique* yaitu *bagging* dan *boosting* untuk meningkatkan performa dari algoritma *machine learning* dilakukan oleh, hasilnya dari semua algoritma *machine learning* dan teknik *ensemble* diuji dengan berbagai faktor seperti akurasi, sensitivitas, dan *f1-score* diperoleh nilai akurasi terbaik diantara algoritma klasifikasi *machine learning* sebesar 86.83% dari *Naive Bayesian* dan 91.76% dari *ensemble tachnique boosting*. Penelitian terkait prediksi kinerja siswa berdasarkan fitur perilaku belajar pada *e-learning* yang diusulkan oleh peneliti serupa yang menemukan bahwa ada hubungan yang kuat antara perilaku belajar pada *e-learning* dengan prestasi akademik (Amrieh et al., 2016; Suhartono, 2017). Algoritma *machine learning* yang digunakan, yaitu *artificial neural network*, *naive bayes* dan *decision tree*. Metode *ensemble bagging*, *boosting* dan *random forest* diterapkan untuk meningkatkan kinerja algoritma *machine learning*. Hasil akurasi model yang diusulkan mencapai akurasi lebih dari 80%. Oleh karena itu, pada penelitian ini, teknik *ensemble machine learning* akan digunakan untuk prediksi kinerja belajar siswa berdasarkan perilaku belajar pada LMS. Penelitian ini juga akan mencari korelasi antar variabel dan *feature importance* pada data perilaku belajar siswa (*students performance dataset*). Selanjutnya, susunan dari makalah ini adalah sebagai berikut. Bagian 2 menjelaskan tentang metode penelitian, teori *ensemble machine learning*, matriks pengukuran performa algoritma, dan penjelasan mengenai *dataset* beserta metadata-nya. Selanjutnya, pada bagian 3 akan dijelaskan hasil dan pembahasan penelitian yang berisi performansi *ensemble machine learning*, korelasi antar variabel, *feature importance* dan detail pembahasannya. Terakhir, kesimpulan dari penelitian ini disajikan pada bagian 4.

## 2. METODE

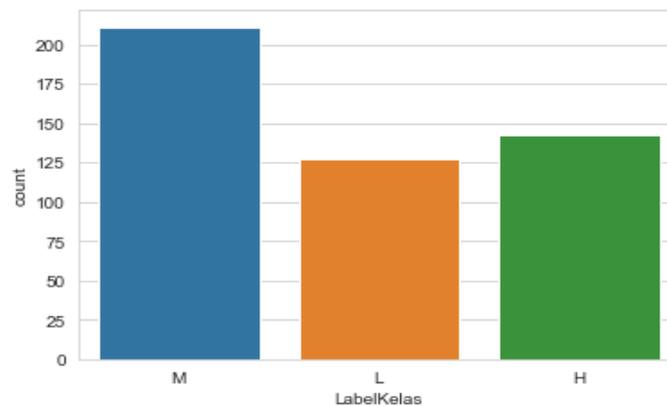
Jenis penelitian ini adalah penelitian eksperimen. *Dataset* yang digunakan dalam penelitian ini dikumpulkan dari sebuah LMS yang dikenal dengan Kalboard 360. Terdapat 16 fitur dan tiga kelas yaitu *low*, *medium*, dan *high*. Dalam penelitian ini menggunakan tiga kelas tersebut untuk klasifikasi kinerja akademik siswa. *Dataset* tersebut diklasifikasikan ke dalam tiga kategori utama yaitu: (1) Demografi; (2) Latar belakang akademik; dan (3) Perilaku siswa dalam penggunaan LMS (Amrieh et al., 2016; Injadat et al., 2020). Tabel 1 menunjukkan fitur dan deskripsi pada *dataset*.

Tabel 1. Fitur dan deskripsi *dataset*

Kategori fitur	Fitur	Deskripsi
Fitur Demografi	Kebangsaan	Kebangsaan
	Jenis Kelamin	P / L
	Tempat Lahir	Tempat Lahir
Fitur Latar Belakang Pendidikan	Relasi	Orang tua
	Tahap	Dasar, Menengah, Atas
	Tingkat kelas	Tingkat kelas
	ID Kelas	Kelas A, B, C
	Semester	Semester 1 atau 2
	Topik	Kursus yang diambil
Fitur Perilaku	Kehadiran	Kehadiran siswa
	Diskusi grup	
	Mengunjungi situs	Perilaku siswa
	Raise hands	selama menggunakan LMS.
	Melihat pengumuman	

Proses diskritisasi untuk mengubah *dataset* dari kategorikal menjadi nilai numerik, yang mewakili label kelas dari kasus klasifikasi. Kemudian *dataset* tersebut dibagi menjadi tiga interval nominal (*high-level*, *medium-level*, dan *low level*) berdasarkan total nilai. *Low-level* mencakup nilai 0

smapai 69, *medium-level* mencakup nilai 70 sampai 89, dan interval *high-level* mencakup nilai 90-100 (Amrieh et al., 2016; Injadat et al., 2020). Gambar 2 menunjukkan pembagian *dataset* kedalam tiga label kelas.



Gambar 1. Pembagian *Dataset* ke dalam Tiga Kelas

Selanjutnya diterapkan normalisasi data untuk menskalakan nilai atribut ke dalam rentang kecil (0,0 hingga 1,0). Hal ini dilakukan untuk memprecepat proses *learning* dengan mencegah atribut dengan rentang yang besar. Setelah itu diterapkan seleksi fitur untuk mengidentifikasi fitur apa saja yang penting dalam prediksi kinerja siswa. Penelitian ini menggunakan teknik *feature importance* dari algoritma *random forest* untuk seleksi fitur. Kemudian dari 480 *dataset* dibagi menjadi data *training* dan *test*, selanjutnya masuk ke tahap proses data untuk mengimplementasikan model *ensemble machine learning*. Metode *ensemble* adalah teknik pembelajaran mesin yang menggabungkan beberapa model dasar untuk menghasilkan satu model prediksi yang optimal, karena *ensemble model* menggunakan lebih dari satu model untuk dilatih menggunakan teknik tertentu sehingga mengurangi tingkat kesalahan dan meningkatkan kinerja model (Ashraf et al., 2020; Fahd et al., 2021). Terdapat tiga teknik yang populer untuk menggabungkan prediksi dari model yang berbeda, yaitu : *bagging*, *boosting* dan *voting* (Almutairi et al., 2019; Kamal & Ahuja, 2019). Penelitian ini menggunakan model *bagging boosting*, dan *voting*.

*Bagging* adalah gabungan dari *bootstrap* dan *agregating*, tujuannya untuk mengurangi *varians* dari *classifier decision tree*. Metode *bagging* membagi *dataset* menjadi berbagai subset untuk *training* yang dipilih secara acak dengan substitusi. Selanjutnya subset data ini dilatih menggunakan *decision tree* (Almutairi et al., 2019; Amrieh et al., 2016). Rata-rata hasil yang diperoleh dari setiap subset data diambil yang memberikan hasil terbaik dibandingkan dengan *classifier* tunggal. Salah satu algoritma yang termasuk tipe *bagging* adalah *random forest*. *Boosting* merupakan salah satu metode *ensemble* untuk meningkatkan *performance* pada suatu algoritma dengan mengkombinasikan *classifier* yang lemah menjadi *classifier* yang kuat (Ashraf et al., 2020; Saleem et al., 2021). Penelitian ini, menggunakan *AdaBoost* sebagai algoritma dasar pada model *ensemble boosting* karena *AdaBoost* merupakan salah satu algoritma *boosting* yang dapat diterapkan dalam kombinasi algoritma *machine learning* lainnya. *Voting ensemble learning* adalah metodologi *ensemble machine learning* yang menggunakan banyak metode sebagai pengganti metode klasifikasi tunggal untuk meningkatkan kinerja model (Ashraf et al., 2020; Injadat et al., 2020). *Voting* dapat membangun beberapa model (dari tipe yang berbeda) dan statistik sederhana (seperti menghitung rata-rata) digunakan untuk menggabungkan model prediksi. Penelitian ini menggunakan algoritma *logstic regression* dan *support vector machine* (SVM) yang digabungkan pada model *voting*. Keseluruhan analisis dan kinerja model dijelaskan pada bagian hasil dan pembahasan. Perhitungan kinerja model dalam *confusion matrix* berdasarkan nilai *true positif* (TP), *true negative* (TN), *false positive* (FP) dan *false negative* (FN). Nilai TP merupakan data positif yang diprediksi benar, nilai TN adalah data negatif yang diprediksi benar, nilai FP merupakan data negatif namun diprediksi sebagai data positif dan nilai FN merupakan data positif namun dipredksi sebagai negatif (Safitri et al., 2022; Utami et al., 2021). Bentuk dari *confusion matrix* ditampilkan pada Tabel 2.

Tabel 2. *Confusion Matrix*

Aktual	Prediksi	
	True	False
True	TP (True Positive)	FP (False Positive)
False	FN (False Negative)	TN (True Negative)

Berdasarkan tabel *confusion matrix*, dapat dievaluasi dengan menghitung nilai akurasi, *recall*, dan *precision*. Nilai akurasi menggambarkan seberapa akurat sistem dapat mengklasifikasikan data secara benar (Safitri et al., 2022; Utami et al., 2021). Perhitungan akurasi dengan persamaan 1, berikut ini :

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \tag{1}$$

Nilai *precision* adalah nilai perbandingan dari data yang diprediksi benar positif dibandingkan dengan keseluruhan hasil yang diprediksi positif. Perhitungan nilai *precision* dapat dilakukan dengan persamaan 2, berikut ini :

$$Precision = \frac{(TP)}{(TP+FP)} \times 100\% \tag{2}$$

Nilai *recall* (sensitifitas) adalah nilai perbandingan dari data yang diprediksi benar positif dibandingkan dengan keseluruhan data yang benar positif. Perhitungan nilai *recall* dapat dilakukan dengan persamaan 3 :

$$Recall = \frac{(TP)}{(TP+FN)} \times 100\% \tag{3}$$

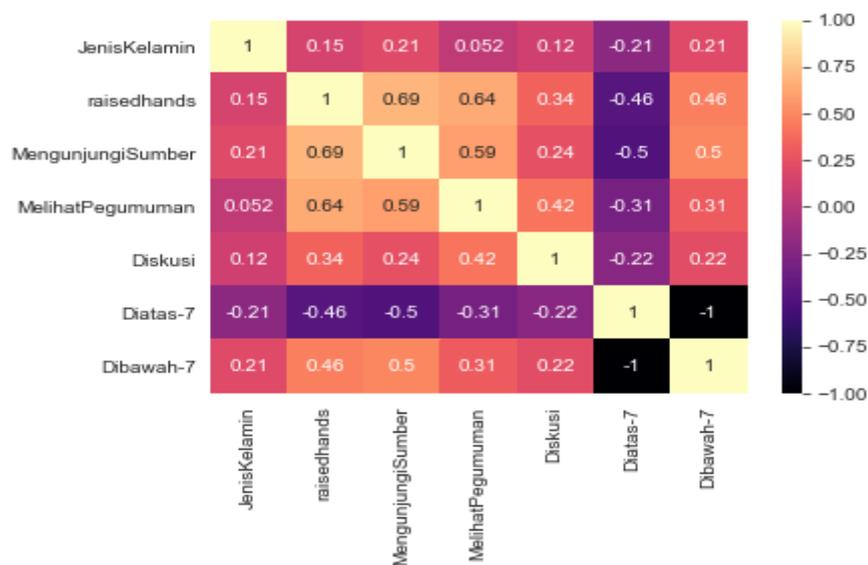
Nilai *f-Measure* adalah nilai timbal balik yang diperoleh dari perhitungan *recall* dan presisi. Perhitungan *f-Measure* dapat dilakukan dengan persamaan 4 :

$$F_{Measure} = 2 \times \frac{precision \times recall}{precision+recall} \times 100\% \tag{4}$$

### 3. HASIL DAN PEMBAHASAN

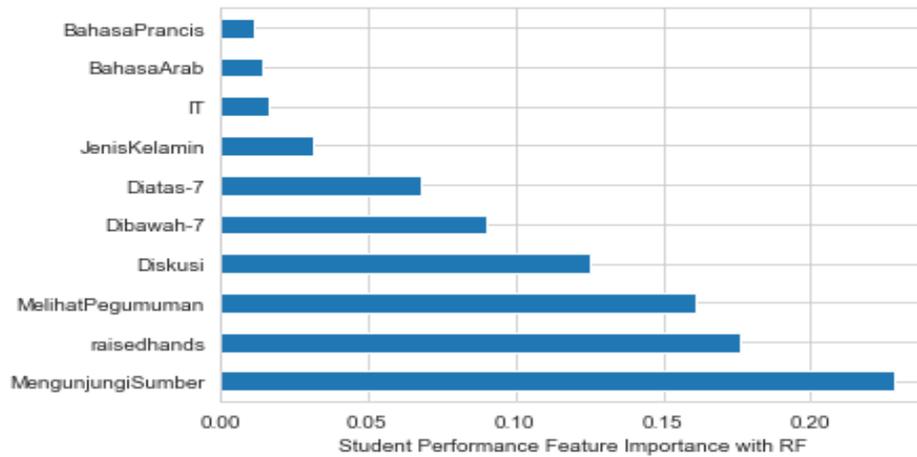
#### Hasil

*Dataset* yang telah diolah pada tahap *preprocessing* kemudian dibagi dua menjadi data *training* dan *test*. Pembagiannya yakni data *training* sebanyak 384 data dan *test* sebanyak 96 data dengan porsi besar pada data *training*. Hubungan antar variabel pada *dataset*, dianalisis menggunakan korelasi *pearson*. Pada Gambar 3 menunjukkan korelasi positif yang sangat kuat antar atribut *Mengunjungi Sumber* dengan atribut *raisedhands* yaitu sebesar 0.69. Artinya, semakin sering mengunjungi sumber, maka frekuensi *raisedhands* akan semakin besar. Selain itu atribut *raisedhands* juga memiliki korelasi positif dengan atribut *MelihatPegumuman* yaitu sebesar 0.64.



Gambar 2. Hasil Korelasi Variabel

Selanjutnya adalah analisis fitur untuk mengidentifikasi fitur apa saja yang penting dalam prediksi kinerja siswa. Seleksi fitur pada penelitian ini menggunakan metode *embedded* dengan teknik *random forest importance*. Hasil seleksi fitur ditunjukkan pada Gambar 4. Fitur *MengunjungiSumber* memiliki nilai yang paling tinggi. Artinya fitur tersebut paling berpengaruh. Sedangkan fitur yang termasuk dalam topik pembelajaran seperti IT, BahasaArab, dan BahasaPrancis memiliki nilai paling rendah sehingga fitur tersebut dapat diabaikan.



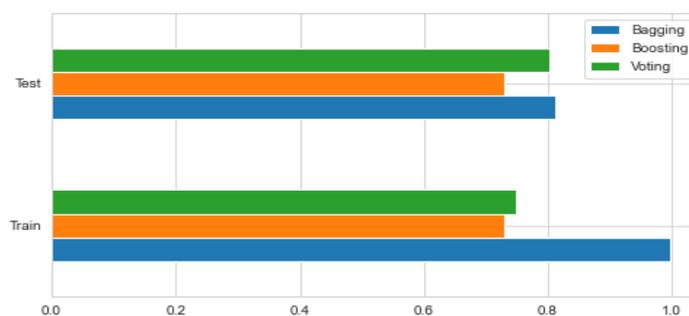
Gambar 3. Hasil Seleksi Fitur

Berdasarkan hasil model *training* didapatkan bahwa nilai akurasi terbaik menggunakan model *bagging*. Model *training* dilakukan menggunakan nilai parameter *default* pada setiap algoritma. Setelah dilakukan *training*, maka tahap selanjutnya adalah *testing* untuk melihat seberapa baik performa model tersebut menggunakan data yang tidak ada di data *training*. Hasil akurasi pada tahap *training* dan *testing* dapat dilihat pada Tabel 3.

Tabel 3. Hasil Akurasi *Training* Dan *Testing*

Model EL	Akurasi Skor	
	Training	Testing
Bagging	0.9974	0.8125
Boosting	0.7292	0.7292
Voting	0.7474	0.8021

Nilai akurasi terbaik ditunjukkan pada model *bagging* dengan nilai akurasi skor *testing* sebesar 81.25%. Hasil tersebut menunjukkan bahwa model *bagging* dapat digunakan sebagai model untuk prediksi kinerja siswa, walaupun nilai akurasi yang didapatkan belum memuaskan. Oleh karena itu, penelitian lebih lanjut di masa depan perlu dilakukan guna memperbaiki tingkat akurasinya. Gambar 4 menampilkan perbandingan hasil prediksi kinerja siswa dari model *training* dan *test*, dari masing-masing model *ensemble machine learning*.



Gambar 4. Hasil Akurasi Model *Ensemble Machine Learning*

### Pembahasan

LMS merupakan aplikasi perangkat lunak atau teknologi berbasis web yang digunakan untuk merencanakan, melaksanakan, dan menilai proses pembelajaran tertentu. Selain menyediakan konten, LMS memungkinkan untuk manajemen dan evaluasi tugas, pelacakan, dan pelaporan siswa serta dapat menilai kinerja belajar siswa (Prada et al., 2020; Pratomo & Wahanisa, 2021). Sistem ini menyediakan kemampuan untuk merekam secara otomatis sejumlah besar data perilaku siswa pada *log* LMS. Data perilaku belajar merupakan data yang dihasilkan oleh interaksi siswa dengan LMS selama proses pembelajaran dan disimpan secara otomatis di *database*. Data perilaku siswa dapat dikumpulkan dan

digunakan secara otomatis untuk klasifikasi dan prediksi kinerja belajar siswa (Pratomo & Wahanisa, 2021; Yan & Au, 2019). Dalam domain pendidikan, institusi tinggi menghasilkan sejumlah besar data yang dikumpulkan dari berbagai sumber salah satunya platform LMS. Secara khusus universitas atau sekolah, mengumpulkan data setiap tahun dari siswa, yang didalamnya termasuk rincian demografis (contohnya; usia, alamat, dan status sosial ekonomi) dan informasi lengkap tentang data penerimaan dan kinerja akademik (contohnya; asal sekolah dan hasil ujian) (Nugroho, 2020; Prada et al., 2020). Diperlukan analisis yang dapat mengubah data yang terkumpul menjadi sebuah pengetahuan. Menganalisis sejumlah besar data pendidikan yang tumbuh secara eksponensial adalah tantangan utama yang dihadapi lembaga pendidikan. Faktanya, metode analitik konvensional biasanya tidak praktis untuk mengekstrak korelasi, pola tersembunyi, dan wawasan lain yang dapat bermanfaat bagi administrator, guru, siswa, dan orangtua. Oleh karena itu, ada kebutuhan untuk mengeksplorasi alat analitik otomatis untuk menangani jenis data ini, yang dianggap sebagai tambang emas untuk mengekstrak pengetahuan pendidikan yang berguna. Pengetahuan itu dapat meningkatkan kualitas pengajaran dan pembelajaran juga dapat membantu siswa untuk berhasil dalam karir akademis (Alamri et al., 2020; Saputra, 2020).

Salah satu teknik yang dapat digunakan untuk analisis klasifikasi dan prediksi kinerja belajar siswa adalah *data mining* (Hendrian, 2018; Sutoyo & Almaarif, 2020). *Data mining* atau penambangan data adalah serangkaian proses untuk mendapatkan pola dari kumpulan data (Sutoyo & Almaarif, 2020; Syahril et al., 2020). *Data mining* akan menganalisis data yang sudah ada dalam *database*. *Data mining* juga dikenal dengan *Knowledge Discovery in Database* (KDD) yaitu suatu aktivitas yang meliputi pengumpulan, penggunaan data historis untuk menemukan pola reguler, menemukan pola yang besar dalam kumpulan data yang besar. *Data mining* dapat mengeksplorasi, memvisualisasikan dan menganalisis data dengan tujuan untuk mengidentifikasi pola yang berguna untuk memahami kinerja dan perilaku belajar siswa (Kadoic & Oreski, 2018; Syahra et al., 2019). *Educational data mining* (EDM) merupakan proses yang digunakan untuk mengekstrak informasi yang berguna dan mengenali pola dari *database* pendidikan yang jumlahnya besar. EDM merupakan ranah penelitian yang penting, karena dapat membantu untuk meningkatkan kualitas pendidikan dan dapat mengukur keberhasilan dari suatu pembelajaran pada LMS. EDM mengeksplorasi berbagai jenis data dengan menggunakan berbagai algoritma *machine learning* untuk mengekstrak pengetahuan yang mendukung pengambilan keputusan dan pengembangan sektor akademik. EDM menggunakan berbagai teknik untuk analisis, pemrosesan data, identifikasi pola, konstruksi model dan prediksi hasil (Jamhur, 2020; Tüfekci & Yilmaz, 2020). Implementasi EDM untuk memprediksi kinerja siswa dapat membantu entitas yang bertanggung jawab untuk mengidentifikasi siswa yang mungkin membutuhkan lebih banyak bantuan (Fernandes et al., 2018; Jamhur, 2020). Tujuan EDM adalah untuk mengembangkan metode dan menerapkan teknik *data mining*, statistik, dan *machine learning* untuk menganalisis data yang dikumpulkan selama proses pembelajaran (Hendrian, 2018; Qazdar et al., 2019).

Penelitian yang dilakukan oleh peneliti serupa untuk memprediksi kinerja akademik siswa sehingga meningkatkan hasil akademik yang lebih baik. Penelitian tersebut menggunakan algoritma dan teknik klasifikasi *Support vector machine* (SVM) dan *Random Forest* (RF) (Adriansyah et al., 2022; Alamri et al., 2020). *Dataset* terdiri dari 369 dari pelajaran matematika dan 649 dari pelajaran bahasa portugis. Hasilnya percobaan untuk algoritma SVM dan RF yang diterapkan pada kedua *dataset* menunjukkan bahwa akurasi dalam kasus klasifikasi biner mencapai akurasi prediksi sebesar 93%, sedangkan pada regresi RMSE terendah adalah 1.13 dalam kasus RF (Adriansyah et al., 2022; Alamri et al., 2020). Efisiensi penggunaan metode *machine learning* untuk memprediksi kesulitan yang dihadapi siswa pada semester berikutnya telah dianalisis oleh (Hussain et al., 2018; Qazdar et al., 2019), hasilnya dapat mengklasifikasi siswa sesuai dengan tingkat kesulitannya. Algoritma *machine learning* yang diterapkan untuk proses prediksi, yaitu *artificial neural network* (ANN), *logistic regression* (LR), *naive bayes* (NB), *support vector machine* (SVM), dan *decision tree* (DT) (Hussain et al., 2018; Qazdar et al., 2019). Evaluasi menggunakan teknik RMSE dan *Cohen's kappa coefficient*. Pemilihan fitur menggunakan *alpha investing* untuk pemeringkatan fitur input yang akan digunakan dalam model prediksi kinerja siswa. Hasil penelitian menunjukkan bahwa SVM dan ANN adalah model yang paling cocok untuk memprediksi kinerja siswa (Hussain et al., 2018; Qazdar et al., 2019). Penelitian tentang model prediktif untuk menganalisis masalah yang dihadapi oleh siswa selama menggunakan platform pembelajaran online dilakukan oleh, model prediktif tersebut dapat membantu instruktur mengidentifikasi siswa yang beresiko diawal untuk dapat menghindari kasus putus sekolah. Penggunaan algoritma *machine learning* (ML) dan *deep learning* (DL) untuk mengklasifikasi perilaku belajar siswa sesuai dengan variabel belajarnya. Selanjutnya, performa dari berbagai algoritma ML tersebut dibandingkan dengan menggunakan akurasi, presisi, *recall* dan *f1 score*. Hasil menunjukkan bahwa nilai siswa, waktu menggunakan platform dan banyaknya keterlibatan siswa merupakan faktor penting dalam pembelajaran online. Hasil penelitian menunjukkan bahwa model prediksi yang dilatih menggunakan *random forest* (RF) memberikan hasil terbaik dengan rata-rata

*precision* 0.92%, *recall* 0.91%, *f1-score* = 0.91% dan akurasi sebesar 80%. Selain menggunakan teknik klasifikasi *machine learning* tunggal, beberapa penelitian menggunakan teknik *ensemble machine learning*. Teknik *ensemble machine learning* memiliki kelebihan dapat memperbaiki algoritma *machine learning* tunggal yang digunakan sehingga memperoleh akurasi terbaik (Fahd et al., 2021; Rawat & Malhan, 2019). Analisis hubungan antara kinerja siswa pada *e-learning* menggunakan *data mining* sebagaimana dilakukan oleh (Almutairi et al., 2019; Prasetyo & Nurhidayah, 2021), menentukan faktor utama yang mempengaruhi kinerja siswa dipilih dengan menggunakan metode seleksi fitur. Metode *machine learning* yang digunakan dan diuji untuk memprediksi kinerja siswa yaitu *random forest*, *logistic regression*, XGBoost, MLP dan *ensemble learning* juga menggunakan *bagging* dan *voting*. Dari semua metode tersebut *random forest* mendapatkan akurasi tertinggi mencapai 77%.

Hasilnya menunjukkan bahwa *data mining* dapat secara akurat memprediksi tingkat kinerja siswa (Almutairi et al., 2019; Hendrian, 2018). Penelitian serupa dilakukan untuk membangun model klasifikasi *hybrid (voting)* yang digunakan untuk menganalisis kinerja siswa dengan temuan bahwa model klasifikasi *hybird* lebih efisien untuk prediksi kinerja siswa berdasarkan data terkait dengan akurasi sebesar 98% (Indahyanti et al., 2022; Rawat & Malhan, 2019). Penelitian *ensemble technique* yaitu *bagging* dan *boosting* untuk meningkatkan performa dari algoritma *machine learning* dilakukan oleh, hasilnya dari semua algoritma *machine learning* dan teknik *ensemble* diuji dengan berbagai faktor seperti akurasi, sensitivitas, dan *f1-score* diperoleh nilai akurasi terbaik diantara algoritma klasifikasi *machine learning* sebesar 86.83% dari *Naive Bayesian* dan 91.76% dari *ensemble technique boosting*. Penelitian terkait prediksi kinerja siswa berdasarkan fitur perilaku belajar pada *e-learning* yang diusulkan oleh peneliti serupa yang menemukan bahwa ada hubungan yang kuat antara perilaku belajar pada *e-learning* dengan prestasi akademik (Amrieh et al., 2016; Suhartono, 2017). Algoritma *machine learning* yang digunakan, yaitu *artificial neural network*, *naive bayes* dan *decision tree*. Metode *ensemble bagging*, *boosting* dan *random forest* diterapkan untuk meningkatkan kinerja algoritma *machine learning*. Hasil akurasi model yang diusulkan mencapai akurasi lebih dari 80%. Oleh karena itu, pada penelitian ini, teknik *ensemble machine learning* akan digunakan untuk prediksi kinerja belajar siswa berdasarkan perilaku belajar pada LMS. Penelitian ini juga akan mencari korelasi antar variabel dan *feature importance* pada data perilaku belajar siswa (*students performance dataset*).

#### 4. SIMPULAN

Pada penelitian ini mengimplementasikan metode *ensemble machine learning* untuk prediksi kinerja siswa berdasarkan data *log LMS* telah dilakukan. Penelitian ini menggunakan *dataset* dari sebuah LMS yaitu Kalboard 360, yang berisi 480 data dengan 16 variabel. Setelah dilakukan pengolahan data, variabel yang digunakan sebanyak tujuh (7) variabel yaitu ; *Jenis kelamin*, *raisehands*, *MengunjungiSumber*, *MelihatPengumuman*, *diskusi*, *jumlah kehadiran diatas-7 atau dibawah-7* dan label kelas *high*, *medium*, dan *low* sebagai label *output*. *Korelasi pearson* yang diterapkan pada penelitian ini menghasilkan variabel *MengunjungiSumber* memiliki korelasi positif dengan variabel *raisehands*. Selanjutnya pada analisis *feature importance* variabel *MengunjungiSumber* memiliki nilai yang paling tinggi. Hasil penelitian menunjukkan bahwa model *ensemble machine learning* yaitu *bagging*, *boosting* dan *voting* berhasil digunakan untuk memprediksi kinerja siswa dengan *accuracy* sebesar 81.25% dengan *percision* 0.810, *recall* 0.812 dan *f-measure* 0.809 yang diperoleh model *bagging*. Institusi pendidikan baik sekolah maupun perguruan tinggi diharapkan dapat merancang sebuah kurikulum LMS untuk meningkatkan kualitas akademik institusi tersebut. Selain itu institusi pendidikan dapat memprediksi bagaimana kinerja siswanya, sehingga dapat meningkatkan prestasi akademik.

#### 5. DAFTAR PUSTAKA

- Adriansyah, I., Mahendra, M. D., Rasywir, E., & Pratama, Y. (2022). Perbandingan Metode Random Forest Classifier dan SVM Pada Klasifikasi Kemampuan Level Beradaptasi Pembelajaran Jarak Jauh Siswa. *Bulletin of Informatics and Data Science*, 1(2), 98–103. <https://doi.org/10.61944/bids.v1i2.49>.
- Alamri, L. H., Almuslim, R. S., Alotibi, M. S., Alkadi, D. K., Ullah Khan, I., & Aslam, N. (2020). Predicting Student Academic Performance using Support Vector Machine and Random Forest. *PervasiveHealth: Pervasive Computing Technologies for Healthcare, PartF16898*, 100–107. <https://doi.org/10.1145/3446590.3446607>.
- Almutairi, S., Shaiba, H., & Bezbradica, M. (2019). Predicting Students' Academic Performance and Main Behavioral Features Using Data Mining Techniques. *Communications in Computer and Information Science, 1097 CCIS*, 245–259. [https://doi.org/10.1007/978-3-030-36365-9\\_21](https://doi.org/10.1007/978-3-030-36365-9_21).

- Amrieh, E. A., Hamtini, T., & Aljarah, I. (2016). Mining Educational Data to Predict Student's academic Performance using Ensemble Methods. *International Journal of Database Theory and Application*, 9(8), 119–136. <https://doi.org/10.14257/ijtda.2016.9.8.13>.
- Ashraf, M., Zaman, M., & Ahmed, M. (2020). An Intelligent Prediction System for Educational Data Mining Based on Ensemble and Filtering approaches. *Procedia Computer Science*, 167(2019), 1471–1483. <https://doi.org/10.1016/j.procs.2020.03.358>.
- Fahd, K., Miah, S. J., & Ahmed, K. (2021). Predicting student performance in a blended learning environment using learning management system interaction data. *Applied Computing and Informatics*. <https://doi.org/10.1108/ACI-06-2021-0150>.
- Fernandes, E., Holanda, M., Victorino, R., & Erven, G. (2018). Educational data mining : Predictive analysis of Academic Performance of Public School Students in the Capital of Brazil. *Journal of Business Research*, 94, 335–343. <https://doi.org/10.1016/j.jbusres.2018.02.012>.
- Hendrian, S. (2018). Algoritma Klasifikasi Data Mining Untuk Memprediksi Siswa Dalam Memperoleh Bantuan Dana Pendidikan. *Faktor Exacta*, 11(3). <https://doi.org/10.30998/faktorexacta.v11i3.2777>.
- Hussain, S., Dahan, N. A., Ba-alwi, F. M., & Ribata, N. (2018). Educational Data Mining and Analysis of Students ' Academic Performance Using WEKA. *Indonesian Journal of Electrical Engineering and Computer Science*, 9(2), 447–459. <https://doi.org/10.11591/ijeecs.v9.i2.pp447-459>.
- Indahyanti, U., Azizah, N. L., & Setiawan, H. (2022). Educational Data Mining on Student Academic Performance Prediction: A Survey. *Procedia of Social Sciences and Humanities*, 3, 1442–1447. <https://doi.org/10.21070/pssh.v3i.344>.
- Injadat, M., Moubayed, A., Nassif, A. B., & Shami, A. (2020). Systematic ensemble model selection approach for educational data mining. *Knowledge-Based Systems*, 200, 105992. <https://doi.org/10.1016/j.knsys.2020.105992>.
- Jamhur, H. (2020). Pemodelan Prediksi Predikat Kelulusan Mahasiswa Menggunakan Fuzzy C-Means Berbasis Particle Swarm Optimization. *TeknoIS: Jurnal Ilmiah Teknologi Informasi Dan Sains*, 10(1), 13–24. <https://doi.org/10.36350/jbs.v10i1.79>.
- Kadoic, N., & Oreski, D. (2018). Analysis of student behavior and success based on logs in Moodle. *2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics, MIPRO 2018 - Proceedings*, 654–659. <https://doi.org/10.23919/MIPRO.2018.8400123>.
- Kamal, P., & Ahuja, S. (2019). An ensemble-based model for prediction of academic performance of students in undergrad professional course. *Journal of Engineering, Design and Technology*, 17(4), 769–781. <https://doi.org/10.1108/JEDT-11-2018-0204>.
- Nugroho, M. Y. A. (2020). Metode, media, dan problematika pembelajaran pai berbasis daring di tingkat madrasah aliyah. *Paramurobi: Jurnal Pendidikan Agama Islam*, 3(2), 1–14. <https://doi.org/10.32699/paramurobi.v3i2.1573>.
- Prada, M. A., Dominguez, M., Vicario, J. L., Alves, P. A. V., Barbu, M., Podpora, M., Spagnolini, U., Pereira, M. J. V., & Vilanova, R. (2020). Educational Data Mining for Tutoring Support in Higher Education: A Web-Based Tool Case Study in Engineering Degrees. *IEEE Access*, 8, 212818–212836. <https://doi.org/10.1109/ACCESS.2020.3040858>.
- Prasetyo, M. M., & Nurhidayah, N. (2021). The effect of internet use on improving student learning outcomes. *Journal of Education Technology*, 5(4), 511–519. <https://doi.org/10.23887/jet.v5i4.40748>.
- Pratomo, I. W. P., & Wahanisa, R. (2021). Pemanfaatan Teknologi Learning Management System (LMS) di Unnes Masa Pandemi Covid-19: Utilization of Learning Management System (LMS) Technology at Unnes during the Covid-19 Pandemic. *Seminar Nasional Hukum Universitas Negeri Semarang*, 7(2), 547–560. <https://doi.org/10.15294/snhunnes.v7i2.730>.
- Qazdar, A., Er-Raha, B., Cherkaoui, C., & Mammass, D. (2019). A machine learning algorithm framework for predicting students performance: A case study of baccalaureate students in Morocco. *Education and Information Technologies*, 24(6), 3577–3589. <https://doi.org/10.1007/s10639-019-09946-8>.
- Rawat, K. S., & Malhan, I. V. (2019). A Hybrid Classification Method Based on Machine Learning Classifiers to Predict Performance in Educational Data Mining. In *Lecture Notes in Networks and Systems* (Vol. 46). Springer Singapore. [https://doi.org/10.1007/978-981-13-1217-5\\_67](https://doi.org/10.1007/978-981-13-1217-5_67).
- Safitri, S. N., Setiadi, H., & Suryani, E. (2022). *Educational Data Mining Using Cluster Analysis Methods and Decision*. 5(158), 448–456. <https://doi.org/10.29207/resti.v6i3.3935>.
- Saleem, F., Ullah, Z., Fakieh, B., & Kateb, F. (2021). Intelligent decision support system for predicting student's e-learning performance using ensemble machine learning. In *Mathematics* (Vol. 9, Issue 17). <https://doi.org/10.3390/math9172078>.

- Saputra, A. (2020). Pendidikan Dan Teknologi: Tantangan Dan Kesempatan. *Indonesian Journal of Islamic Educational Management*, 3(1), 21–33. <https://doi.org/10.24014/ijiem.v3i1.9095>.
- Suhartono, E. (2017). Systematic Literatur Review (SLR): Metode, Manfaat, Dan Tantangan Learning Analytics Dengan Metode Data Mining di Dunia Pendidikan Tinggi. *Jurnal Ilmiah INFOKAM*, 13(1). <https://doi.org/10.53845/infokam.v13i1.123>.
- Sutoyo, E., & Almaarif, A. (2020). Educational Data Mining untuk Prediksi Kelulusan Mahasiswa Menggunakan Algoritme Naïve Bayes Classifier. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 4(1), 95–101. <https://doi.org/10.29207/RESTI.V4I1.1502>.
- Syakra, Y., Syahril, M., & Yusnidah, Y. (2019). Implementasi data mining dengan menggunakan algoritma fuzzy subtractive clustering dalam pengelompokan nilai untuk menentukan minat belajar siswa smp primbana Medan. *Jurnal SAINTIKOM (Jurnal Sains Manajemen Informatika Dan Komputer)*, 17(1), 54–63. <https://doi.org/10.53513/jis.v17i1.113>.
- Syahril, M., Erwansyah, K., & Yetri, M. (2020). Penerapan Data Mining untuk menentukan pola penjualan peralatan sekolah pada brand wigglo dengan menggunakan algoritma apriori. *Jurnal Teknologi Sistem Informasi Dan Sistem Komputer TGD*, 3(1), 118–136. <https://doi.org/10.53513/jsk.v3i1.202>.
- Tüfekci, A., & Yılmaz, E. A. G. (2020). Educational Data Mining. *Engineering Education Trends in the Digital Era*, 70–82. <https://doi.org/10.4018/978-1-7998-2562-3.ch004>.
- Utami, D. Y., Nurlalah, E., & Hasan, F. N. (2021). Comparison of Neural Network Algorithms, Naive Bayes and Logistic Regression to predict diabetes. *Journal of Informatics and Telecommunication Engineering*, 5(1), 53–64. <https://doi.org/10.31289/jite.v5i1.5201>.
- Yan, N., & Au, O. T.-S. (2019). Online learning behavior analysis based on machine learning. *Asian Association of Open Universities Journal*, 14(2), 97–106. <https://doi.org/10.1108/aaouj-08-2019-0029>.