



Analitik Pendidikan 4.0: Penerapan Data Mining dalam Mengungkap Karakteristik Siswa

Tommy Jonathan Sinaga

Teknik Informatika, STIKOM Tunas Bangsa, Kota Pematangsiantar, Indonesia
E-Mail : tommyjonathansinaga@outlook.com

Article Info	ABSTRAK
Article history: Received Jun 15, 2025 Revised Jun 30, 2025 Accepted Jul 05, 2025	Salah satu tantangan paling menarik dan kompleks dalam Penambangan Data Pendidikan (EDM) adalah menganalisis kinerja siswa. Peneliti sangat tertarik pada bidang ini karena berbagai faktor yang memengaruhi hasil belajar, serta banyaknya data yang tersedia, terutama dalam konteks pembelajaran yang ditingkatkan teknologi. Meskipun banyak penelitian ada dalam EDM, hanya sedikit yang berfokus secara khusus pada evaluasi dan prediksi prestasi siswa. Sebagian besar survei bertujuan untuk mengidentifikasi pola atau faktor yang dapat memprediksi kinerja siswa. Studi ini mengusulkan penggunaan algoritma penambangan data untuk mengekstrak data yang relevan dan akurat untuk analisis lebih lanjut. Dalam tinjauan pustaka ini, penulis mengkaji pendekatan yang ada di bidang ini dan menyoroti bagaimana interaksi siswa dengan sistem manajemen pembelajaran dan data tugas penilaian dapat memberikan wawasan berharga untuk prediksi kinerja awal. Penulis juga mengidentifikasi peran penting yang dimainkan oleh jenis sistem pendidikan dalam membentuk proyeksi awal prestasi siswa.
Kata Kunci: Analitik Pendidikan Data Mining Karakteristik Siswa Teknologi Informasi Komunikasi	ABSTRACT <i>One of the most interesting and complex challenges in Educational Data Mining (EDM) is analyzing student performance. Researchers are very interested in this field because of the various factors that influence learning outcomes, as well as the large amount of data available, especially in the context of technology-enhanced learning. Although there is a lot of research in EDM, only a few focus specifically on evaluating and predicting student achievement. Most surveys aim to identify patterns or factors that can predict student performance. This study proposes the use of data mining algorithms to extract relevant and accurate data for further analysis. In this literature review, the author examines existing approaches in this field and highlights how student interactions with learning management systems and assessment task data can provide valuable insights for early performance prediction. The author also identifies the important role played by the type of education system in shaping early projections of student achievement.</i>
Keywords: Educational Analytics Data Mining Student Characteristics Information Technology Communication	<i>This is an open access article under the CC BY-NC license.</i>
Corresponding Author: Tommy Jonathan Sinaga, Informatika, STIKOM Tunas Bangsa Jl. Jendral Sudirman Blok A No.1,2,3 Pematangsiantar Email: tommyjonathansinaga@outlook.com	

1. PENDAHULUAN

Skenario *Online learning* (OL) secara bertahap menggantikan lingkungan pendidikan tradisional sebagai konsekuensi dari penggabungan (TIK) Teknologi Informasi dan komunikasi, ke dalam pembelajaran. Pengalaman belajar siswa ditingkatkan oleh sistem OL, yang juga meminimalkan persyaratan agar pendidik mereka terlibat secara langsung. Berbagai strategi *Decision-making* harus diterapkan ketika menganalisis data

ini untuk mengungkap konten yang relevan dan menyajikannya dalam pendekatan yang membuat pengambilan keputusan lebih sederhana dan mengoptimalkan efektivitas metode pembelajaran. Berbagai sumber, yang meliputi catatan pendaftaran, konten kursus, sistem pendidikan, dan pengetahuan tentang waktu kursus, mencapai berbagai jenis data. Sama seperti ini, serangkaian aplikasi lain yang dihosting di internet yang digunakan dalam regulasi pendidikan, seperti *game* edukasi, kuis dan tes *online*, alam semesta virtual, forum dan papan pengumuman, jaringan multimedia interaktif, log aktivitas pengguna, dan berbagai bentuk instruksi dan teks lainnya, juga memberikan berbagai jenis data (Marlina et al., 2024). Proses "*data mining*" menunjukkan teknik yang teratur dan ketat untuk mengambil pola dan detail tersembunyi, yang sebelumnya belum ditemukan, tetapi mungkin signifikan dari sejumlah besar data. Insinyur dapat merencanakan algoritma dan kerangka kerja baru dan organisasi perawatan kesehatan dapat menghasilkan obat dan *antibody* baru melalui *data mining*. Peneliti ini berpendapat bahwa *data mining* memberikan ide dan arahan baru untuk penyelidikan ilmuwan (Huang et al., 2021). Meskipun *data mining* memainkan peran penting dalam analitik bisnis, bidang ini terdiri dari lebih dari sekedar ekstraksi informasi. Saya mulai dengan menentukan istilah dan pemaknaannya. Setelah itu, saya memberikan sudut pandang saya tentang penanganan rantai pasokan sambil melihat bagaimana akademi literatur telah menyelidiki analitik bisnis, khususnya *data mining* (Nurhayati & Lawanda, 2023).

Pertumbuhan pesat *platform* pendidikan berbasis *web* dalam beberapa tahun terakhir telah membuat kita harus melacak sejumlah besar informasi yang mungkin berguna dari berbagai sumber dalam berbagai bentuk dan tingkat kedetailan. Sejumlah besar data mengenai siswa juga dikumpulkan melalui regulasi pendidikan baru seperti pembelajaran berbasis game, pendidikan virtual/meningkat, pembelajaran elektronik, *Blended Learning* (BL), dsb. Meskipun ada sejumlah besar materi instruksional yang sangat berharga yang dihasilkan oleh semua sistem ini, mustahil untuk memeriksanya secara manual. Dengan demikian, meningkatnya kebutuhan akan alat untuk menilai data jenis ini secara cerdas berasal dari kenyataan bahwa data tersebut memberikan sejumlah besar informasi akademik yang dapat dianalisis dan digunakan untuk pemahaman yang lebih baik tentang cara siswa belajar (Gunasekara & Saarela, 2024).

Naskah ini menyajikan ringkasan menyeluruh dari setiap bagian dalam upaya penelitian yang dilakukan. Bagian 2 secara eksplisit menyoroti fokus utama penyelidikan, yaitu pada kajian-kajian terdahulu yang relevan. Selanjutnya, Bagian metode penelitian membahas karakteristik unik dari penerapan teknik *data mining* dalam menganalisis kinerja pendidikan siswa. Dalam bagian ini, ditekankan pentingnya aspek sistem proyek, analisis statistik, kerangka konseptual yang mudah dipahami, serta pendekatan berbasis grafik. Pendekatan *data mining* yang digunakan bertujuan untuk menghasilkan analisis data pendidikan yang efektif melalui algoritma-algoritma khusus. Visualisasi berupa grafik dan bagan yang mendukung pemahaman terhadap proses *data mining* ditampilkan secara komprehensif dalam Bagian Hasil dan Pembahasan. Sementara itu, Bagian Kesimpulan menyajikan pendekatan yang digunakan, berdasarkan hasil analisis yang diperoleh.

2. METODE PENELITIAN

2.1. Tinjauan Pustaka

Salah satu disiplin ilmu yang diakui dalam studi instruksional adalah penilaian perilaku terhadap prestasi siswa. Identifikasi awal pencapaian siswa memiliki keuntungan bagi organisasi dan pembelajaran. Peramalan prestasi siswa juga membantu dalam pemantauan sistematis terhadap peserta didik oleh sistem pendidikan. Para sarjana mendorong guru untuk menerapkan penambangan data untuk inspeksi prestasi siswa karena informasi digital semakin mudah didapatkan (Khan & Ghosh, 2018).

Tujuan utama dari penelitian ini adalah untuk menunjukkan ruang lingkup aplikasi data mining yang sangat besar untuk institusi pendidikan, terutama dalam hal penanganan aplikasi teknik dan metode *data mining* yang paling efektif untuk memeriksa data historis yang diperoleh secara cermat. Dalam istilah *data mining*, tujuan spesifik mengkategorikan tugas peserta didik universitas berdasarkan aspek pre-U mereka dan hasil akademik perguruan tinggi diyakini sebagai masalah analisis yang harus diselesaikan menggunakan informasi siswa yang saat ini tersedia. Karena model kategorisasi ini dihasilkan menggunakan detail di mana variabel yang diinginkan (atau *respons*) diketahui, aktivitas tersebut termasuk dalam kategori pembelajaran terawasi (Kabakchieva, 2013).

Dalam konteks penambangan data pendidikan, adalah konvensional untuk membuat estimasi tentang kemajuan pendidikan peserta didik. Berbagai teknik *data mining*, seperti kategorisasi, pengumpulan penambangan aturan asosiasi, dan analisis statistik, harus dipertimbangkan untuk membangun teknik pemodelan prediktif. Praktis semua studi penelitian hanya menggunakan satu pendekatan klasifikasi untuk memprediksi pencapaian pendidikan siswa. Penulis hanya memikirkan pohon keputusan, *Naive Bayes*, *Support Vector Machine* (SVM), *Artificial Neural Network* (ANN), *K-Nearest Neighbors*, *Sequential Minimal*

Optimization (SMO), *Statistik Linear*, *Random Forest*, *Random Tree*, J48, dll. Ada banyak teknik untuk klasifikasi yang tersedia untuk proyeksi (Kumar et al., 2017).

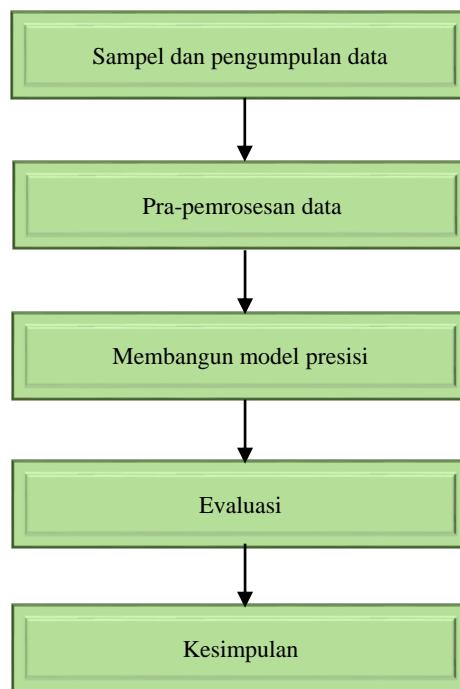
Institusi pendidikan tinggi menghadapi tantangan besar dalam mengoperasikan lingkungan pendidikan untuk melayani klien utama mereka, para pelajar, dalam semua aspek. Penerapan teknik *data mining* di bidang pendidikan memberikan (HHI) Hukum kemanusiaan internasional akses ke sudut pandang baru yang membantu mereka membuat keputusan yang lebih baik dan menemukan solusi untuk masalah apa pun yang muncul. Data studi sebelumnya menunjukkan bahwa masalah terkait *System Application and Product in data processing* (SAP) adalah subjek yang paling umum dipelajari. Penjelasannya adalah bahwa setiap sektor publik dan swasta membutuhkan pesaing yang kompeten untuk mengisi pekerjaan yang kosong. Oleh karena itu, ketika mencoba mengkategorikan SAP dan memfasilitasi tindakan lebih lanjut yang akan dilaksanakan untuk meningkatkan nilai siswa, prognosis SAP juga sangat penting (Aziz & Ahmad, 2014).

Berdasarkan indikator kinerja siswa di tingkat Pre-U, universitas, dan data pribadi, beberapa artikel penelitian terkenal mengembangkan algoritma untuk memprediksi kemajuan akademik siswa. Penyelidikan tersebut menggabungkan data dari 10.330 siswa. Dua puluh atribut jenis kelamin, tahun lahir dan lokasi tempat tinggal, negara, tempat, dan total skor dari pendidikan sebelumnya, semester saat ini, dll. digunakan untuk mendeskripsikan setiap siswa. Siswa dibagi menjadi lima kategori menggunakan strategi *data mining*, termasuk *decision tree*, *Naive Bayes*, algoritma *Knearest Neighbors* (KNN), dll. Sangat Baik, Sangat Bagus, Baik, Rata-rata, atau Buruk. Dengan presisi keseluruhan tertinggi, prediksi *pick-up tree* melampaui kedua klasifikasi k-NN dan Jrip (Asif et al., 2017).

Tujuan dari penjelajah pengetahuan, pengambilan keputusan, dan pembuatan saran semuanya diatasi dalam berbagai pekerjaan terkait EDM yang menyampaikan banyak teknik dan strategi yang menarik. Penulis membahas beberapa di antaranya yang telah menyediakan data yang dibutuhkan untuk studi ini dalam bab-bab berikutnya. Metode *big data* dapat digunakan dalam berbagai cara untuk memfasilitasi analisis pendidikan, yang mencakup peramalan fungsionalitas, deteksi risiko yang menurun, visualisasi data, saran cerdas, dukungan mata kuliah, perhitungan keterampilan siswa, penyaringan perilaku, serta pengelompokan dan kerja sama siswa, dan sesuai dengan studi tentang pemanfaatan data dalam jumlah besar dalam pendidikan. Pentingnya analisis prediktif yang berfokus pada perkiraan perilaku, kemampuan, dan kinerja siswa ditunjukkan dalam studi ini (Fernández et al., 2019).

Dua aspek kinerja mahasiswa sarjana yang menerapkan prosedur *data mining* menjadi fokus utama studi saat ini. Bagian pertama berkaitan dengan penilaian prestasi akademik siswa pada kesimpulan dari program studi empiris empat tahun. Strategi selanjutnya adalah untuk memeriksa bagaimana anak muda berkembang dan memadukannya dengan hasil dari perkiraan. Penulis memisahkan siswa menjadi komunitas berdasarkan prestasi akademik : prestasi buruk serta prestasi tinggi. Menurut penelitian penulis, penting bagi instruktur untuk menghabiskan waktu pada serangkaian program tertentu yang menunjukkan kinerja yang sangat baik atau buruk. Hal ini memungkinkan mereka untuk membina para sarjana berprestasi tinggi dengan prospek dan bantuan, serta tindakan peringatan dan dukungan yang cepat bagi siswa yang gagal (Yağcı, 2022).

Diagram skematis dari tahapan prosedur *data mining* dapat dilihat pada Gambar 1 eksperimen melalui metode *data mining* akan berjalan sesuai dengan berbeda lintasan yang terdiri dari pengumpulan sampel dan data, pra-pemrosesan data, membangun sistem presisi, evaluasi, dan tahap akhir adalah kesimpulan.



Gambar 1. Tahapan Penelitian

2.2. Sampel dan Pengumpulan Data

Penelitian yang dilakukan oleh universitas vokasi dan sains di Indonesia pada akhir tahun ajaran perdana 2020–2021. Prosedur penilaian dan pendaftaran sekolah digunakan untuk mengumpulkan data untuk *prototype*. Siswa harus menggunakan teknologi pendaftaran sekolah untuk mengisi aplikasi terkomputerisasi dengan data pribadi mereka ketika pertama kali diterima di institusi. Kemudian, seiring setiap siswa maju melalui studi mereka, nilai dan prestasi mereka dimasukkan ke dalam sistem evaluasi sekolah. Selain itu, profil yang dipertahankan dari setiap siswa pada awal penelitian menggabungkan delapan belas variabel yang berkaitan dengan keadaan pribadi mereka dan satu parameter yang mencerminkan nilai rata-rata dari semua peringkat bidang yang berbeda, yang telah mereka capai di semester awal.

2.3. Pra-pemrosesan data

Penulis melakukan pembersihan data dan teknik harmonisasi data pada tahap pra-pemrosesan data. Setelah 18 variabel yang membentuk *output* (kinerja belajar) ditentukan, penulis mengurutkan data kategori dan memperbaiki kasus nilai yang hilang dalam tahap pembersihan data. Tahap ini mencakup pengkodean data grup dan penolakan contoh dengan nilai yang hilang. Persamaan (1) digunakan untuk menormalkan data pada tahap pemurnian data.

$$Y_{mon} = \frac{Y - Y_{min}}{Y_{max} - Y_{min}} \quad (1)$$

Dengan Y_{min} , Y_{max} , dan Y_{mon} menunjukkan nilai minimum, maksimum, dan yang dinormalisasi, secara berturut-turut.

2.4. Pra-pemrosesan data

Eksperimen yang termasuk dalam penelitian dilakukan menggunakan RAM 64 GB dan CPU *Intel* (R) *Xeon* (R) E-2174G 3.80 GHz yang menjalankan sistem operasi *Windows*. Tergantung pada MLP, RF, dan komputasi DT, empat model pembelajaran terkontrol dikembangkan. Python diimplementasikan untuk membuat model prediksi RF, sedangkan strategi C5.0 dan *CART* digunakan untuk menghasilkan model prediksi DT. Untuk semua model, investigasi dijalankan sebanyak lima kali. Nilai rata-rata dan standar *error* dari hasil pengurutan dalam setiap kasus kemudian digunakan sebagai dasar ketika menilai komputasi DT dan RF. Tujuan utama dari beberapa proyek penelitian adalah untuk menemukan atribut yang memiliki efek besar pada kinerja belajar siswa dan menganalisis serta membandingkan efektivitasnya dalam memprediksi keberhasilan akademis pendatang baru pada *dataset*.

Selain itu, investigasi saat ini menggabungkan tiga kemungkinan jenis informasi produk berikut :

1. Kasus 1 adalah dasar untuk hasil, yaitu klasifikasi Sangat Baik, Baik Sekali, Baik, Rata-rata, dan Buruk yang digunakan untuk menghitung keandalan perkiraan awal dan keseluruhan dari empat model.
2. Kasus 2 melibatkan penggabungan kelas Sangat Baik, Baik, dan Cukup dari sebagian besar keluaran menjadi kelas Standar untuk menentukan apakah dari keempat pendekatan tersebut ada yang dapat mempertimbangkan minoritas.
3. Kasus 3 mempersempit sorotan ke pencapaian periode yang lebih kecil, Luar Biasa dan Buruk.

2.5. Pohon Keputusan

Langkah-langkah yang disebutkan di atas adalah inti dari proses pengujian algoritma C5.0 untuk masing-masing dari tiga situasi dalam penyelidikan ini. Siapkan variabel pohon keputusan, membuat pendahuluan *Decision Tree*, membuat informasi dari pengujian dan pelatihan, pertahankan pohon, lalu saring pohon yang dipangkas untuk membuatnya lebih mudah dipahami. Sekarang pilih pohon yang menghasilkan yang terbaik di antara semua pohon yang dibuat. Kemudian ulangi langkah 1–6 untuk sepuluh pengujian dan gunakan standar deviasi dan median dari akurasi klasifikasi dalam sepuluh percobaan sebagai tolok ukur. Dengan menggunakan penyelidikan validasi silang 10-fold, penulis menghasilkan DT menggunakan prosedur C5.0 untuk setiap lipatan dalam kumpulan data. Sepuluh set berukuran sama dibuat dari set informasi yang diambil, dan setiap set berfungsi sebagai set pengujian secara bergantian. Bersamaan dengan set pengujian, penulis mengembangkan DT yang memanfaatkan sembilan set lainnya sebagai materi pelatihan penulis. Akibatnya, penulis memiliki sepuluh pohon. Setelah memilih pohon dengan efektivitas terbaik, semua karakteristik yang masih ada dinilai identik.

Investigasi saat ini menerapkan strategi *CART* dengan Python sebagai teknik lebih lanjut untuk menguji, mengukur, dan menginterpretasikan presisi prediksi dan pilihan fitur signifikan antara C5.0 dan *CART*, setelah mendapatkan hasil percobaan DT. Untuk setiap dari tiga situasi, sistem *CART* diverifikasi menggunakan teknik berikut: Hasilkan data pengujian dan pelatihan awalnya. Kemudian, perlu untuk mengkonfigurasi peraturan DT untuk memulai metode. Untuk prediksi yang akurat, analisis DT menggunakan validasi silang, pengujian, dan pelatihan. Memplot hasil dari ukuran kepentingan Gini adalah langkah selanjutnya. Sepanjang sepuluh percobaan, ulangi langkah 1–4 untuk hasil yang lebih baik. Manfaatkan nilai standar deviasi dan rata-rata dari kinerja kategorisasi dari uji lapangan sebagai tolok ukur.

2.6. Multilayer Perceptron (MLP)

Sebuah lapisan masukan, lapisan yang tidak terdeteksi, dan lapisan hasil membentuk arsitektur multi-lapisan dari *Multilayer Perceptron* (MLP). Subkumpulan data *Analytics* masukan mengakui masukan, lapisan yang menyembunyikan memeriksanya, dan lapisan hasil akhir menghasilkan produk akhir model. Langkah-langkah selanjutnya membentuk proses eksperimen MLP yang digunakan dalam penelitian saat ini. Lapisan masukan, lapisan tersembunyi, dan lapisan hasil membentuk kerangka kerja multi-lapisan dari program pembelajaran campuran (MLP). Lapisan masukan adalah tempat model mengenali masukan, lapisan penyembunyian menilainya, dan lapisan keluaran menghasilkan hasil model. Langkah-langkah selanjutnya membentuk proses eksperimen MLP yang digunakan dalam studi saat ini.

1. Pilih berat awal dan penyimpanan.
2. Pilih target dan informasi pelatihan.
3. Tetapkan perbedaan antara hasil yang diharapkan dan yang direncanakan.
4. Sesuaikan berat dan isi ulang berat seluruh jaringan.
5. Teruskan dari langkah (3) ke langkah (4) hingga pemahaman atau penyelarasan lengkap (Huynh-Cam et al., 2021).

2.7. Model Data Mining

Analisis regresi, serta klasifikasi, adalah tujuan *data mining* yang vital dan dualistik. Saling melibatkan pembelajaran yang diawasi, di mana prediksi dimodifikasi agar sesuai dengan satu set informasi dari $l \in \{1, \dots, L\}$ contoh masing-masing memplot vektor sebagai input (y_1^l, \dots, y_n^l) ke target yang ditentukan y^l . Dari persamaan di bawah ini (2), nilai-nilai yang diberikan disebutkan dengan jelas. Perbedaan utama berkaitan dengan penggambaran hasil, yang bersifat independen dalam kasus pengurutan dan tak berkesudahan dalam situasi regresi. *Root Mean Squared* (RMSE) adalah metrik yang umum digunakan dalam analisis regresi, sedangkan *Percentage of Correct Classifications* (PCC) sering digunakan dalam menilai model prediktif untuk kategorisasi. Klasifikasi yang baik ditunjukkan oleh PCC yang tinggi (yaitu, sangat mendekati 100%) (3), dan analisis regresi harus merekomendasikan kesalahan global yang rendah (yaitu, RMSE mendekati nol) menggunakan persamaan (4). Pengukuran ini dapat diperoleh dengan menggunakan persamaan:

$$\varphi(j) = \begin{cases} 1, & \text{if } z_j = \hat{z}_j \\ 0, & \text{else} \end{cases} \quad (2)$$

$$PCC = \sum_{j=1}^M \varphi(j)/0 \times 100(%) \quad (3)$$

$$RMSE = \sqrt{\sum_{j=1}^0 (z_j - \hat{z}_j)^2 / 0} \quad (4)$$

Di mana nilai yang diantisipasi untuk ilustrasi ke- j ditunjukkan oleh \hat{z}_j . Tiga metode pengawasan akan diterapkan saat memodelkan nilai Matematika dan bahasa Portugis dalam fungsi ini:

1. Klasifikasi biner : Siswa dianggap lulus jika nilai akhirnya (G3) 10 atau lebih, dan dianggap gagal jika nilainya di bawah 10.
2. Pengelompokan 5-Level : Nilai akhir siswa juga dikelompokkan ke dalam 5 level, berdasarkan konversi nilai Erasmus (lihat Tabel 1).
3. Analisis regresi : Digunakan untuk memprediksi nilai akhir (G3), yang bisa berada dalam rentang 0 sampai 20.

Tabel 1. Sistem klasifikasi lima tingkat

	I	II	III	IV	V
Negara	(sangat bagus/sangat baik)	(Bagus)	(Memuaskan)	(Memadai)	(Gagal)
Prancis	17-21	15-16	13-14	11-12	1-10
Indonesia	B	C	D	E	G

Untuk tugas klasifikasi dan analisis regresi, beberapa jenis teknik *data mining* telah diajukan, masing-masing dengan fitur dan tujuan yang berbeda. Satu set pedoman dilambangkan oleh *decision tree* (DT), pengaturan terurut yang menggunakan tingkatan hierarki untuk membedakan antara nilai. Satu set aturan *If-then* yang intuitif dapat ditarik dari representasi visual ini. Metode *data mining* yang belum lengkap, sebuah pengaturan yang dikenal sebagai *Random Forest* (RF). Pilihan fitur acak dari bagian keseluruhan pelatihan *bootstrap* merupakan dasar untuk setiap pohon, dan evaluasi RF dibuat dengan merata-ratakan hasil *Decision Tree*. Jika dibandingkan dengan hanya satu *data mining*, sinyal frekuensi radio lebih sulit untuk dipahami, tetapi tetap memungkinkan untuk memberikan data deskriptif tentang pentingnya nilai *input*. Untuk kewajiban *data mining*, metode *nonlinier* seperti *Support Vector Machine* (SVM) dan *Neural Network* (NN) juga telah ditawarkan; fungsi-fungsi tersebut berkinerja lebih efisien ketika ada tingkat ketidakteraturan yang tinggi. *Perceptron multilayer* (MLP) yang banyak digunakan berfungsi sebagai tulang punggung untuk model NN dalam penelitian ini, yang memiliki lapisan tersembunyi dan *node* H tersembunyi. SVM akan menggunakan penyaring gaussian yang memiliki satu hiperparameter (β). Perlu diakui bahwa NN dan SVM menggunakan ilustrasi model yang sulit dipahami oleh manusia. Selanjutnya, mengingat bahwa teknik *data mining*, *random forest* secara khusus mencapai pemilihan atribut internal, mereka kurang terpengaruh oleh bahan yang tidak signifikan dibandingkan dengan NN dan SVM (Gori, 2024).

3. HASIL DAN PEMBAHASAN

Pengklasifikasi yang paling andal digabungkan ke dalam program perangkat lunak yang sederhana untuk memprediksi prestasi siswa, sehingga lebih mudah bagi instruktur untuk mengenali siswa yang kesulitan dan menyarankan tindakan korektif.

Informasi yang dikumpulkan dalam set penelitian mencakup pencapaian siswa Universitas tahun pertama dalam matematika, khususnya mereka yang berusia antara 14 dan 15 tahun. Lyceum swasta "Avgoulea-Linardatou" mengumpulkan data, yang mencakup 279 struktur berbeda, antara tahun 2007 dan 2010. Fitur-fitur tersebut termasuk data mengenai pencapaian siswa, yang melibatkan nilai dari ujian lisan, dan penilaian akhir. Kumpulan fitur yang disediakan dalam Tabel 2 dapat dibagi menjadi dua kelompok utama berdasarkan kinerja siswa selama semester pertama dan kedua, sesuai. Selain itu, menurut sistem pengelompokan yang diterapkan pada evaluasi instruksional di sekolah-sekolah Yunani, siswa dipisahkan menjadi empat tingkatan :

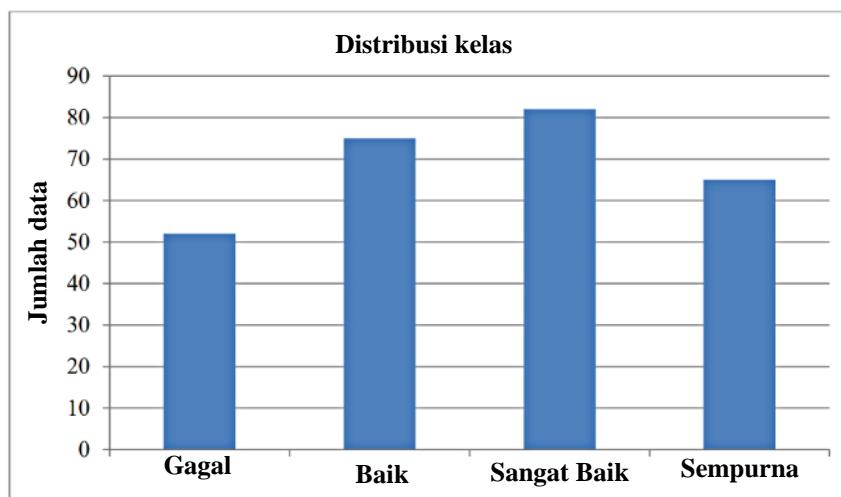
1. Nilai "Gagal" mewakili skor siswa antara 0 dan 9.
2. Nilai "Baik" menunjukkan pencapaian individu dalam hierarki 10 hingga 14.
3. Pencapaian akademik siswa antara 15 dan 17 dianggap nilai "sangat baik."
4. Setiap pencapaian siswa antara 18 dan 20 dapat dianggap nilai "sangat baik."

Tabel 2. Daftar parameter yang digunakan dalam studi penelitian

Atribut Mahasiswa ½ Semester	Rentang Nilai
Nilai lisan	[0,30]
Nilai Ujian 1	[0,30]
Nilai Ujian 2	[0,30]
Nilai ujian akhir	[0,30]
Nilai penutup	[0,30]

Penyebaran kelas terlihat pada Gambar 2, yang menampilkan bagian-bagian yang dikategorikan sebagai nilai "Gagal" (53 kasus), nilai "Baik" (76 kasus), nilai "Sangat baik" (85 kasus), dan nilai "Sempurna" (65 kasus). Dua set data telah dirancang dengan bantuan distribusi kelas dan ciri-ciri yang ditunjukkan dalam Tabel 1. karena informasi ini penting bagi seorang guru untuk mengetahui siswa yang kurang baik di tengah semester pendidikan.

1. *DATA_A*: Ini menggabungkan kualitas yang memengaruhi pencapaian semester pertama siswa.
2. *DATA_{AB}*: Termasuk atribut yang terkait dengan pencapaian semester pertama dan kedua siswa. Anda akan melihat bahwa setiap kumpulan data dalam investigasi penulis digunakan untuk membangun pengklasifikasi individual yang membedakan siswa yang sedang berjuang.



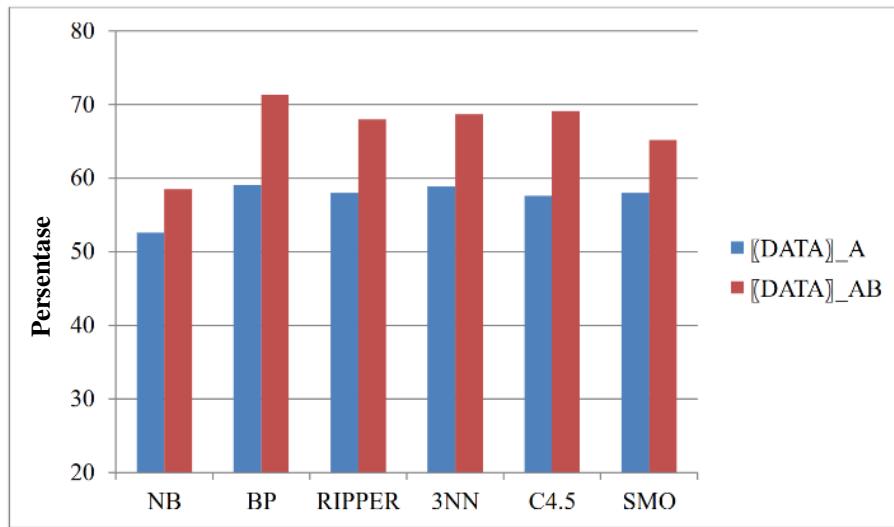
Gambar 2. Distribusi kelas

Setelah itu, penulis melakukan berbagai pengujian untuk mengetahui sistem pembelajaran mana yang paling baik mengantisipasi nilai siswa (yaitu, "Gagal," "Baik," "Sangat baik," atau "Sangat baik") menggunakan nilai mereka dari semester akademik dan ekstrakurikuler. Akibatnya, penulis memilih teknik yang paling banyak dinikmati dan sering diajukan untuk setiap prosedur *machine learning* yang telah dieksplorasi. Implementasi khas algoritma *Bayesian* adalah pendekatan *Naive Bayes* (NB), yang paling sering diterapkan. Diberikan keadaan fitur kelas, ini adalah teknik pembelajaran langsung yang mengasumsikan bahwa setiap karakteristik tidak memengaruhi yang lain. Algoritma pembelajaran yang dibangun untuk menghasilkan jaringan saraf, algoritma *backpropagation* (BP) dengan momentum, adalah representasi yang efektif dari *ANNs*. Karena teknik *Ripper* adalah salah satu teknik yang paling umum digunakan untuk memberikan aturan klasifikasi, telah dipilih sebagai ilustrasi strategi aturan pembelajaran. Operasi perolehan data adalah intuisi pertumbuhan yang digunakan oleh *Ripper*, yang menghasilkan aturan dengan terus-menerus mengembangkan dan memotong. Sementara itu, penulis menggunakan teknik *3-Nearest Neighbors* (3NN) sebagai audiens berbasis contoh, menggunakan Jarak Euclidean sebagai sistem metrik pengukuran. Dengan algoritma C4.5 adalah yang lebih khas dalam tinjauan penulis yang diambil dari pohon keputusan. Algoritma C4.5 memilih elemen mana yang paling baik memecah contoh pelatihan pada setiap tahap proses pemisahan dengan menggunakan properti empiris yang disebut perolehan pengetahuan. Tabel 3 menawarkan ikhtisar pencapaian setiap pengklasifikasi berdasarkan jumlah urutan yang diklasifikasikan dengan benar dalam kumpulan data yang disediakan. Jelas bahwa tidak ada algoritma yang dapat terus-menerus melampaui yang lain dalam hal pencapaian. Lebih khusus lagi, BP (*backpropagation*) menunjukkan proporsi terbesar dari contoh yang diidentifikasi dengan benar tentang *dataset DATA_A*, sementara 3NN menunjukkan hasil terbaik dalam hal *dataset DATA_{AB}*.

Tabel 3. Akurasi klasifikasi pada setiap dataset

Klasifikasi	Dataset	
	(%) <i>DATA_A</i>	(%) <i>DATA_{AB}</i>
NB	52.6	58.5
BP	59.1	71.3
Ripper	58.0	68.0
3NN	58.9	68.7
C4.5	57.6	69.1
SMO	58.0	65.2

Akurasi pengklasifikasi juga direpresentasikan menggunakan grafik berikut pada Gambar 3 yang akan memberikan detail jelas mengenai akurasi pengklasifikasi.



Gambar 3. Histogram untuk akurasi Klasifikasi

Tujuan utama penulis adalah untuk mengembangkan klasifikasi kejadian yang lebih spesifik dan benar, jadi penulis menggunakan pemungutan suara, peraturan, dan metodologi penilaian untuk menggabungkan hasil yang diantisipasi dari berbagai prosedur pada *dataset* yang telah ditetapkan. Kalimat berikutnya menunjukkan fungsi dari strategi yang tercantum di kolom pertama Tabel 4:

1. (BestCV) *Best Cross-Validation* adalah singkatan dari prosedur preferensi unggul pengklasifikasi.
2. *Voting* menunjukkan metode pemungutan suara yang mudah relatif yang mengintegrasikan estimasi dari berbagai teknik yang ditunjukkan dalam Tabel 3.
3. *Stacked Generalization* adalah singkatan dari prosedur *stacking*, yang menggunakan *Multiple Linear Regression* (MLR) sebagai algoritma meta-level dan pengklasifikasi dasar yang seperti pemilihan.
4. *Grading* adalah bentuk singkat dari prosedur *grading* yang memanfaatkan pengklasifikasi utama situasi *10-Nearest Neighbors* sebagai pengklasifikasi meta-level dan pengklasifikasi dasar seperti *voting*.
5. *Voting** menyiratkan proses pemungutan suara yang relatif mudah yang terdiri dari SMO, BP, 3NN, dan Ripper sebagai pengklasifikasi dasar.
6. Kata "*stacking*" sesuai dengan metodologi *stacking* yang melibatkan penggunaan MLR sebagai pengklasifikasi meta-level dan pengklasifikasi titik awal dengan *Voting*.
7. *Grading** mengacu pada prosedur evaluasi yang menggunakan 10-NN sebagai pengklasifikasi dasar contoh dan *Voting* sebagai kerangka kerja untuk algoritma meta-level.

Tabel 4. Presisi Akurasi untuk setiap *dataset*

Klasifikasi	Dataset	
	(%) <i>DATA_A</i>	(%) <i>DATA_{AB}</i>
Best CV	60.9	71.4
Voting	59.2	87.1
Stacking	57.7	69.6

Klasifikasi	Dataset	
	(%) <i>DATA_A</i>	(%) <i>DATA_{AB}</i>
<i>Grading</i>	58.8	72.8
<i>Voting*</i>	61.7	91.4
<i>Stacking*</i>	58.8	72.8

Berdasarkan pemahaman Tabel 4, pendekatan *Voting* melampaui kombinasi lainnya dalam hal akurasi, dengan *Voting Technique Method* mengonfirmasi efektivitas terbaik di seluruh bidang untuk kedua *dataset* (Livieris et al., 2016).

4. KESIMPULAN

Memanfaatkan metode matematika pembelajaran mesin dan penambangan data untuk estimasi adalah instrumen efektif yang membantu instruktur dalam mengenali siswa yang cenderung berkinerja buruk sejak dini dan merupakan awal yang tak ternilai dalam strategi intervensi mereka. Penulis membangun studi kasus tentang ujian matematika akhir tahun pertama Universitas, serta alat pendukung keputusan yang mudah digunakan untuk meramalkan kinerja siswa dalam proyek ini. Untuk memprediksi efektivitas belajar siswa, penulis menggunakan elemen latar belakang keluarga dalam penelitian ini, yang dapat diperoleh pada awal musim mahasiswa baru. Segera setelah pendatang baru memulai sekolah, penulis dapat menggunakan model yang ada untuk memperkirakan kinerja akademis mereka. Dengan bantuan pendekatan *Data Mining* ini, sangat mudah untuk memeriksa kelas yang diperoleh pelajar untuk kegiatan akademis maupun ekstrakurikuler. *Decision Tree* (DT), *Random Forest* (RF), *Neural Network* (NN), dan *Support Vector Machine* (SVM) adalah empat metode DM yang dievaluasi. Tiga tujuan *Data Mining* independen (klasifikasi 5 tingkat dan regresi) juga diperiksa. Berbagai opsi masukan (seperti menggabungkan atau menghapus nilai sebelumnya) juga dieksplorasi. Temuan yang dikumpulkan menunjukkan bahwa jika hasil untuk kerangka waktu sekolah pertama dan atau kedua dapat diakses, prediksi yang sangat akurat dapat dicapai. Ini membantu temuan penelitian bahwa pertunjukan sebelumnya memiliki panduan penting tentang pencapaian bagi siswa. Untuk meningkatkan basis data siswa, penulis juga akan memperluas pengujian penelitian ke institusi pendidikan dan tahun kelas lainnya. Sebagai konsekuensi dari penggunaan teknik *data mining* ini, penyelidikan data pendidikan siswa menjadi tepat dan jelas.

REFERENCES

- Asif, R., Merceron, A., Ali, S. A., & Haider, N. G. (2017). Analyzing undergraduate students' performance using educational data mining. *Comput. Educ.*, 113, 177–194. <https://api.semanticscholar.org/CorpusID:26870758>
- Aziz, A. B. A., & Ahmad, N. (2014). *First Semester Computer Science Students ' Academic Performances Analysis by Using Data Mining Classification Algorithms*. <https://api.semanticscholar.org/CorpusID:111383032>
- Buenaño-Fernández, D., Gil, D., & Luján-Mora, S. (2019). Application of Machine Learning in Predicting Performance for Computer Engineering Students: A Case Study. *Sustainability*. <https://api.semanticscholar.org/CorpusID:181333905>
- Gori, T. (2024). Preprocessing Data dan Klasifikasi untuk Prediksi Kinerja Akademik Siswa. *Jurnal Teknologi Informasi Dan Ilmu Komputer*. <https://api.semanticscholar.org/CorpusID:268197786>
- Gunasekara, S., & Saarela, M. (2024). Explainability in Educational Data Mining and Learning Analytics: An Umbrella Review. *Educational Data Mining*. <https://api.semanticscholar.org/CorpusID:273692026>
- Huang, Y., Liu, H., & Pan, J. (2021). Identification of data mining research frontier based on conference papers. *Int. J. Crowd Sci.*, 5, 143–153. <https://api.semanticscholar.org/CorpusID:236284849>
- Huynh-Cam, T.-T., Chen, L.-S., & Le, H. (2021). Using Decision Trees and Random Forest Algorithms to Predict and Determine Factors Contributing to First-Year University Students' Learning Performance. *Algorithms*, 14, 318. <https://api.semanticscholar.org/CorpusID:240473868>
- Kabakchieva, D. (2013). *Predicting Student Performance by Using Data Mining Methods for Classification*. <https://api.semanticscholar.org/CorpusID:7641809>
- Khan, A., & Ghosh, S. K. (2018). Data mining based analysis to explore the effect of teaching on student performance. *Education and Information Technologies*, 23, 1677–1697. <https://api.semanticscholar.org/CorpusID:7919350>
- Kumar, M., Singh, Prof. A. J., & Handa, D. (2017). Literature Survey on Student's Performance Prediction in Education using Data Mining Techniques. *International Journal of Education and Management Engineering*, 7, 40–49. <https://api.semanticscholar.org/CorpusID:67421239>

- Livieris, I. E., Mikropoulos, T., & Pintelas, P. E. (2016). *A decision support system for predicting students' performance*. <https://api.semanticscholar.org/CorpusID:4092776>
- Marlina, R., Zaharuddin, Ngemba, H. R., Smith, J., Perangkat, P., Efisiensi, L., Keamanan, O., & Infrastruktur, D. O. (2024). Manfaat Integrasi IoT dalam Pengembangan Perangkat Lunak di Sektor Pendidikan. *Jurnal MENTARI: Manajemen, Pendidikan Dan Teknologi Informasi*. <https://api.semanticscholar.org/CorpusID:277158450>
- Nurhayati, E. S., & Lawanda, I. I. (2023). Perkembangan dan Tren Penelitian Global tentang Research Data Management. *Lentera Pustaka: Jurnal Kajian Ilmu Perpustakaan, Informasi Dan Kearsipan*. <https://api.semanticscholar.org/CorpusID:267129157>
- Yağcı, M. (2022). Educational data mining: prediction of students' academic performance using machine learning algorithms. *Smart Learning Environments*, 9. <https://api.semanticscholar.org/CorpusID:247233325>