

## PENGEMBANGAN SISTEM E-LEARNING BERBASIS DECISION TREE UNTUK ANALITIK DAN KLASIFIKASI NILAI SISWA DI SDK HARAPAN DENPASAR

Joan Jasmine Malelak<sup>✉</sup>, I Nyoman Eddy Indrayana, Yessi Aprilia Walluyo

Program Studi D4 Teknologi Rekayasa Perangkat Lunak, Politeknik Negeri Bali, Badung, Indonesia

Email: [joanjasmine29@gmail.com](mailto:joanjasmine29@gmail.com)

DOI: <https://doi.org/10.46880/jmika.Vol10No1.pp226-233>

### ABSTRACT

Monitoring student academic performance at the elementary school level remains challenging because most grade management is performed manually, which slows the identification of students who need special attention. This study developed a Laravel 10-based e-learning system integrating online examination with security features, automatic grade recapitulation, and academic performance classification using the CART Decision Tree algorithm. The system was built with the waterfall development model and evaluated on 60 students from grades 1A to 6A at SDK Harapan Denpasar. Data were divided into 80% training (48 records) and 20% testing (12 records). Final scores were computed using 40% assignment and 60% examination weights, then classified into four categories: Very Good, Good, Sufficient, and Needs Guidance. To validate model selection, a comparison with the Naive Bayes algorithm was conducted on the same dataset. CART Decision Tree outperformed Naive Bayes with an accuracy of 86.7% versus 81.2%. Black box testing passed 100% of 15 test scenarios, and User Acceptance Testing produced a score of 4.68 out of 5.00. The system enables teachers to identify students requiring guidance directly from the dashboard without relying on external analytical tools.

**Keyword:** E-Learning, Decision Tree, Grade Classification, CART, Elementary School.

### ABSTRAK

Pemantauan performa akademik siswa di jenjang sekolah dasar masih menjadi tantangan karena pengelolaan nilai yang dilakukan secara manual memperlambat identifikasi siswa yang membutuhkan perhatian khusus. Penelitian ini mengembangkan sistem e-learning berbasis Laravel 10 yang mengintegrasikan ujian online berkeamanan tinggi, rekap nilai otomatis, dan klasifikasi performa akademik menggunakan algoritma Decision Tree CART. Sistem dibangun dengan model waterfall dan dievaluasi pada 60 siswa kelas 1A–6A di SDK Harapan Denpasar. Data dibagi menjadi 80% data latih (48 data) dan 20% data uji (12 data). Nilai akhir dihitung menggunakan bobot 40% tugas dan 60% ujian, lalu diklasifikasikan ke dalam empat kategori: Sangat Baik, Baik, Cukup, dan Perlu Pembinaan. Untuk memvalidasi pemilihan model, dilakukan perbandingan dengan algoritma Naive Bayes pada dataset yang sama. Decision Tree CART menghasilkan akurasi 86,7% dibandingkan Naive Bayes 81,2%. Black box testing lulus 100% (15/15 kasus) dan User Acceptance Testing menghasilkan skor 4,68/5,00. Sistem memungkinkan guru mengidentifikasi siswa yang membutuhkan bimbingan langsung dari dashboard tanpa alat analitik eksternal.

**Kata Kunci:** E-Learning, Decision Tree, Klasifikasi Nilai, CART, Sekolah Dasar.

### PENDAHULUAN

Sekolah dasar merupakan fondasi pertama dalam perjalanan akademis seorang anak. Di sinilah kebiasaan belajar, pemahaman konsep dasar, dan karakter akademis mulai terbentuk. Oleh karena itu, kemampuan guru dalam mendeteksi permasalahan belajar sejak dini menjadi faktor penentu keberhasilan siswa di jenjang selanjutnya. Sayangnya, di banyak sekolah dasar di Indonesia, proses pemantauan nilai masih dilakukan secara manual guru mencatat nilai di buku, merekap di spreadsheet, dan mengidentifikasi siswa bermasalah berdasarkan ingatan atau intuisi.

Proses ini memakan waktu dan rentan terhadap keterlambatan penanganan.

Teknologi *e-learning* telah berkembang jauh melampaui fungsi awalnya sebagai media penyampaian materi. Dengan dukungan teknik data mining, platform pembelajaran kini dapat difungsikan sebagai alat analitik yang mampu mengolah data akademik secara otomatis dan menghasilkan wawasan yang dapat langsung ditindaklanjuti oleh guru (Kharis & Zili, 2022). Integrasi antara sistem ujian online dan mekanisme klasifikasi berbasis machine learning membuka peluang bagi guru untuk memperoleh

gambaran komprehensif mengenai kondisi belajar siswanya hanya dalam beberapa klik.

SDK Harapan Denpasar menghadapi tantangan yang sama. Hingga saat penelitian ini dilakukan, belum tersedia mekanisme digital yang mengintegrasikan pelaksanaan ujian, rekap nilai, dan analisis performa dalam satu sistem. Guru masih bergantung pada proses manual yang membutuhkan waktu cukup lama sebelum tindakan intervensi dapat dilakukan. Kondisi inilah yang mendorong penelitian ini untuk merancang dan mengimplementasikan sistem e-learning terpadu berbasis *Laravel 10* dengan klasifikasi *Decision Tree CART*.

Penelitian sebelumnya menunjukkan bahwa *Decision Tree* efektif dalam mengklasifikasikan performa akademik siswa. Lestari & Lestari (2024) membuktikan keakuratan metode ini pada konteks sekolah dasar dengan akurasi 94,44%, meskipun sistem yang dikembangkan tidak terintegrasi dengan *platform e-learning* aktif. Rahman (2023) membandingkan *Decision Tree* dengan *Naive Bayes* dan menemukan bahwa kedua metode menghasilkan akurasi di atas 80% untuk data akademik multiatribut. Irfan et al. (2024) menerapkan *CART Decision Tree* dalam konteks pembelajaran berbasis masalah di perguruan tinggi dan memperoleh akurasi pengujian 85,1%.

Penelitian ini hadir untuk mengisi kesenjangan yang belum ditangani oleh studi-studi sebelumnya, yaitu belum adanya sistem yang menyatukan ujian online, rekap nilai otomatis, dan klasifikasi machine learning dalam satu ekosistem yang dapat digunakan langsung oleh guru sekolah dasar. Adapun tujuan penelitian ini adalah: (1) mengembangkan sistem *e-learning* yang mendukung proses pembelajaran dan ujian *online* secara terintegrasi; (2) merancang mekanisme randomisasi soal untuk meminimalkan potensi kecurangan; dan (3) menerapkan algoritma *Decision Tree CART* untuk mengklasifikasikan capaian belajar siswa guna membantu guru mengidentifikasi siswa yang memerlukan bimbingan lebih lanjut.

## KAJIAN LITERATUR

Kajian literatur yang digunakan dalam penelitian ini mencakup studi-studi sebelumnya yang relevan dengan tema klasifikasi performa akademik menggunakan metode decision tree maupun pengembangan sistem *e-learning* berbasis data mining.

Lestari & Lestari (2024) menerapkan *Decision Tree* melalui *RapidMiner* untuk mengklasifikasikan tingkat pemahaman siswa kelas 5 SDN Malaka Jaya 11 pada mata pelajaran IPA dan Matematika. Pohon keputusan yang terbentuk menempatkan sarana dan prasarana sebagai atribut paling berpengaruh, dengan

akurasi akhir sebesar 94,44%. Meski akurasi tinggi, sistem ini berdiri sebagai alat analisis independen dan tidak terintegrasi dengan platform pembelajaran aktif. Sementara Rahman (2023) melakukan perbandingan antara *Decision Tree* dan *Naive Bayes* pada dataset *xAPI-Edu-Data* yang mencakup 480 siswa dari 14 negara dengan 16 atribut. Hasil pengujian menunjukkan *Decision Tree* menghasilkan akurasi 83,89% sedangkan *Naive Bayes* mencapai 85,97%. Studi ini menggunakan dataset publik sehingga tidak mencerminkan kondisi sistem pembelajaran aktif di satu institusi.

Irfan et al. (2024) menggunakan *CART Decision Tree* berbasis *Python* sklearn untuk memprediksi hasil belajar mahasiswa dalam konteks pembelajaran berbasis masalah (PBL), menghasilkan akurasi pelatihan 91% dan pengujian 85,1%. Penelitian tersebut merekomendasikan penggunaan *hyperparameter* tuning untuk mengurangi gap antara akurasi training dan testing.

Charbuty & Abdulazeez (2021) melakukan tinjauan komprehensif terhadap berbagai varian algoritma *Decision Tree* dalam konteks machine learning. Mereka menyimpulkan bahwa *CART* unggul dalam menangani data numerik kontinu karena menggunakan *Gini Impurity* sebagai kriteria pemilahan yang menghasilkan pohon biner yang lebih seimbang dibandingkan varian lain seperti ID3 atau C4.5.

Dalam konteks *e-learning*, Kharis & Zili (2022) mengkaji penerapan learning analytics dan educational data mining pada berbagai institusi pendidikan di Indonesia. Mereka menemukan bahwa integrasi data mining ke dalam sistem manajemen pembelajaran secara signifikan meningkatkan kemampuan guru dalam mendeteksi siswa yang berisiko mengalami kegagalan akademis lebih awal.

Ramesh et al. (2013) meneliti penerapan *Decision Tree C4.5* untuk mengklasifikasikan performa mahasiswa dalam pembelajaran semi-online dan menemukan bahwa pemilihan atribut yang tepat terutama kehadiran dan keterlibatan dalam diskusi secara signifikan meningkatkan akurasi model. Studi ini menjadi landasan metodologis bagi penelitian yang mengintegrasikan data partisipasi ke dalam variabel prediksi.

Berdasarkan kajian di atas, teridentifikasi bahwa sebagian besar penelitian mengembangkan sistem analisis yang berdiri sendiri dan tidak terhubung dengan *platform* ujian online aktif. Penelitian ini mengisi celah tersebut dengan membangun ekosistem *e-learning* terpadu yang memungkinkan klasifikasi dilakukan secara langsung dari data ujian yang diambil secara real-time.

## METODE PENELITIAN

Metode penelitian ini merupakan metode yang digunakan dalam pembuatan dari sistem yang dapat dijelaskan sebagai berikut.

### Model Pengembangan Sistem

Model pengembangan yang digunakan adalah waterfall karena tahapannya yang runtut memudahkan perencanaan, pengendalian, dan dokumentasi dalam skala pengembangan yang terbatas. Tahapan yang diterapkan meliputi: (1) Analisis Kebutuhan, dilakukan melalui wawancara dengan kepala sekolah dan guru SDK Harapan Denpasar untuk memetakan alur penilaian yang berjalan; (2) Perancangan, mencakup *use case diagram*, *entity relationship diagram* (ERD), dan wireframe antarmuka; (3) Implementasi menggunakan *Laravel 10*; (4) Pengujian melalui *black box testing* dan *UAT*; serta (5) Pemeliharaan sistem pasca implementasi.

### Subjek dan Data Penelitian

Subjek penelitian adalah 60 siswa kelas 1A hingga 6A (5 siswa per kelas), 6 guru mata pelajaran, dan 1 *administrator* di SDK Harapan Denpasar. Data yang digunakan mencakup nilai tugas harian dan nilai ujian online dari 5 mata pelajaran yang dikumpulkan melalui sistem selama periode uji coba.

### Pembagian Dataset dan Skema Evaluasi

Data sebanyak 60 record siswa dibagi menggunakan skema train-test split dengan rasio 80:20, di mana 48 data digunakan sebagai data latih dan 12 data sebagai data uji. Skema ini dipilih mengingat ukuran dataset yang terbatas, sehingga sebagian besar data dapat dimanfaatkan untuk pembentukan model tanpa mengorbankan reliabilitas evaluasi. Pembagian dilakukan secara acak dengan memastikan distribusi kelas yang proporsional pada kedua subset. Detail pembagian dapat dilihat pada Tabel 1.

Tabel 1. Pembagian Dataset

Set Data	Jumlah Data	Proporsi
Training	48 data	80%
Testing	12 data	20%
Total	60 data	100%

Model dievaluasi menggunakan data uji yang tidak pernah dilihat selama proses pelatihan. Metrik evaluasi yang digunakan mencakup akurasi, *precision*, *recall*, dan *F1-score* dengan skema *macro averaging* untuk menangani ketidakseimbangan distribusi antar kelas.

### Arsitektur Sistem

Sistem dibangun menggunakan *framework Laravel 10* dengan basis data *MySQL* (skema *Elearning\_D4*) pada lingkungan *XAMPP*. Antarmuka pengguna menggunakan *Bootstrap* yang dikombinasikan dengan *Chart.js* untuk keperluan visualisasi analitik. Sistem dirancang dengan tiga level akses pengguna: administrator, guru, dan siswa. Selama ujian berlangsung, modul keamanan *exam-security.js* aktif untuk memblokir copy-paste, klik kanan, kombinasi *keyboard DevTools*, serta mendeteksi perpindahan tab melalui *Page Visibility API*. Ujian dihentikan secara otomatis setelah tiga pelanggaran terdeteksi, dan watermark transparan berisi nama serta NIS siswa ditampilkan di seluruh halaman ujian.

### Algoritma Decision Tree CART

Metode klasifikasi utama yang diterapkan adalah *CART (Classification and Regression Tree)* dengan kedalaman pohon maksimum 3 dan kriteria pemilahan menggunakan *Gini Impurity*. Nilai akhir setiap siswa dihitung berdasarkan formula pembobotan berikut:

$$\text{Nilai Akhir} = (\text{Nilai Tugas} \times 0,4) + (\text{Nilai Ujian} \times 0,6) \dots (1)$$

Nilai akhir kemudian diklasifikasikan ke dalam empat kategori seperti pada Tabel 2.

Tabel 2. Kategori Klasifikasi Performa Siswa

Kategori	Rentang Nilai Akhir	Keterangan
Sangat Baik	$\geq 85$	Menguasai seluruh kompetensi dasar
Baik	70 – 84	Menguasai sebagian besar kompetensi
Cukup	55 – 69	Perlu bimbingan tambahan dari guru
Perlu Pembinaan	$< 55$	Perlu perhatian dan intervensi khusus

*Gini Impurity* dihitung untuk menentukan atribut pemecah terbaik pada setiap node pohon keputusan, menggunakan persamaan berikut:

$$\text{Gini}(t) = 1 - \sum^p [p(j|t)]^2 \dots (2)$$

di mana  $p(j|t)$  adalah proporsi kasus kelas  $j$  pada node  $t$ . Atribut dengan nilai *Gini gain* tertinggi dipilih sebagai pemecah. Parameter  $\text{max\_depth} = 3$  ditetapkan untuk

mencegah overfitting mengingat ukuran dataset yang terbatas (Tangirala, 2020).

**Perbandingan dengan Naive Bayes**

Untuk memvalidasi pemilihan algoritma *Decision Tree CART*, dilakukan perbandingan dengan algoritma *Naive Bayes* pada dataset dan skema pembagian yang identik. *Naive Bayes* dipilih sebagai pembanding karena termasuk algoritma klasifikasi yang umum digunakan dalam penelitian serupa (Rahman, 2023) dan memiliki kompleksitas komputasi yang rendah. Probabilitas posterior pada *Naive Bayes* dihitung menggunakan teorema Bayes:

$$P(C_i|X) = P(X|C_i) \times P(C_i) / P(X) \dots (3)$$

di mana  $P(C_i|X)$  adalah probabilitas kelas  $C_i$  diberikan fitur  $X$ ,  $P(X|C_i)$  adalah likelihood, dan  $P(C_i)$  adalah probabilitas prior kelas  $C_i$ . Perbandingan dilakukan pada keempat metrik evaluasi yang sama untuk memperoleh gambaran objektif mengenai kinerja relatif kedua algoritma.

**Metode Pengujian**


Pengujian sistem dilakukan melalui dua pendekatan. Pertama, *black box testing* dengan 15 skenario fungsional yang mencakup autentikasi multi-role, pelaksanaan ujian online, mekanisme keamanan, rekap nilai otomatis, dan klasifikasi siswa. Kedua, *User Acceptance Testing (UAT)* menggunakan kuesioner skala Likert 1–5 yang melibatkan guru dan siswa sebagai responden pada 5 aspek penilaian.

**HASIL DAN PEMBAHASAN**

Implementasi dari sistem yaitu melalui beberapa tahapan sebagai berikut.

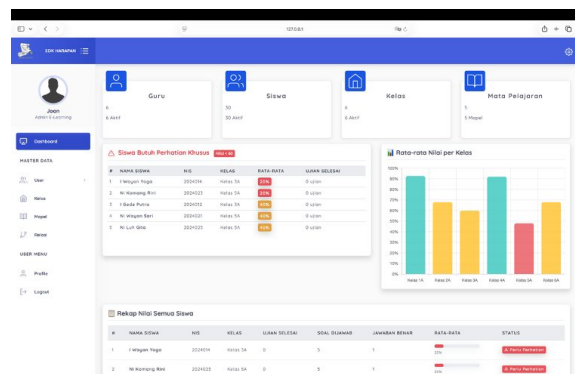
**Tampilan Antarmuka Sistem**

Gambar 1 menampilkan halaman login sistem *e-learning* SDK Harapan Denpasar yang menampilkan branding institusi dengan palet warna navy (#0D3B66) hingga sky blue (#1E88E5), ilustrasi visual, dan formulir login yang sederhana.



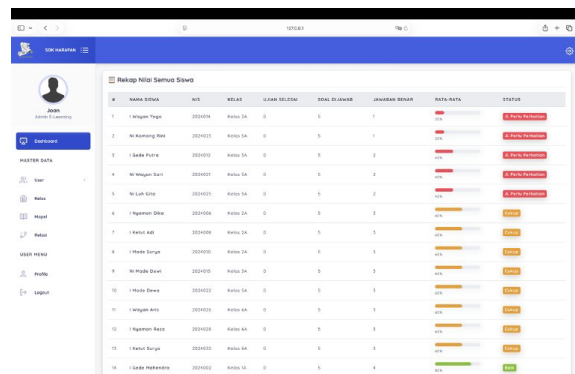
**Gambar 1.** Halaman *Login* Sistem *E-Learning* SDK Harapan Denpasar

*Dashboard administrator* (Gambar 2) menyajikan empat *info box* yang menampilkan jumlah guru, siswa, kelas, dan mata pelajaran secara dinamis. Di sisi kanan terdapat grafik batang rata-rata nilai per kelas menggunakan *Chart.js*, dan di bagian bawah tersedia tabel Siswa Butuh Perhatian Khusus yang otomatis terisi berdasarkan nilai akhir di bawah ambang batas yang ditentukan.



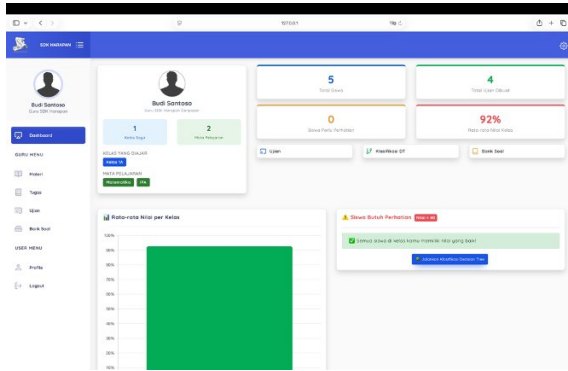
**Gambar 2.** *Dashboard Admin* dengan *Info Box*, Grafik, dan Tabel Perhatian Khusus

Halaman rekap nilai seluruh siswa (Gambar 3) menampilkan progress bar berwarna dan label status untuk setiap siswa. Warna merah menandai Perlu Perhatian, kuning untuk Cukup, dan hijau untuk Baik dan Sangat Baik, memudahkan identifikasi kondisi kelas secara sekilas.



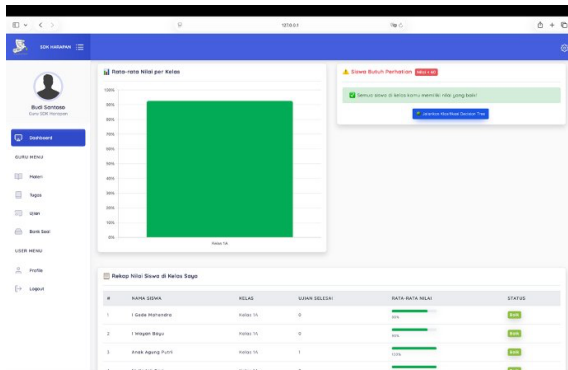
**Gambar 3.** Halaman Rekap Nilai Semua Siswa dengan Label Status Berwarna

*Dashboard guru* (Gambar 4) menampilkan kartu profil lengkap dengan kelas dan mata pelajaran yang diajar, empat stat card kelas, serta tombol shortcut ke modul Ujian, Klasifikasi DT, dan Bank Soal.



Gambar 4. Dashboard Guru dengan Stat Card dan Shortcut Fitur

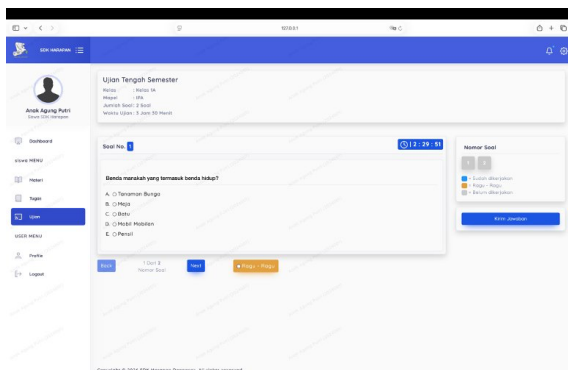
Bagian bawah dashboard guru (Gambar 5) menyajikan grafik rata-rata nilai per kelas dan tabel rekap nilai siswa di kelas yang diajar beserta indikator status masing-masing.



Gambar 5. Grafik Nilai dan Rekap Siswa di Dashboard Guru

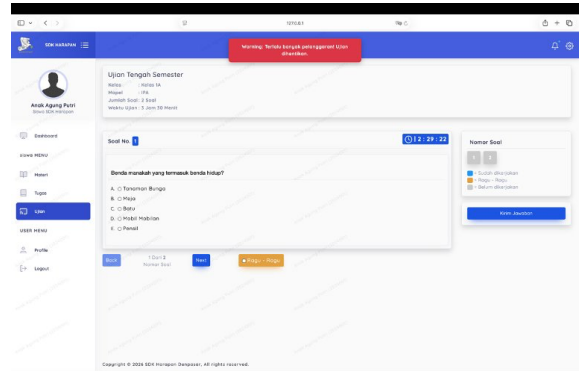
### Fitur Keamanan Ujian Online

Antarmuka ujian online (Gambar 6) menampilkan nomor soal, timer mundur, panel navigasi soal berwarna sesuai status pengerjaan, dan tombol kirim jawaban. Watermark transparan berisi nama dan NIS siswa ditampilkan di seluruh halaman sebagai penanda identitas.



Gambar 6. Antarmuka Ujian Online dengan Timer, Watermark, dan Navigasi Soal

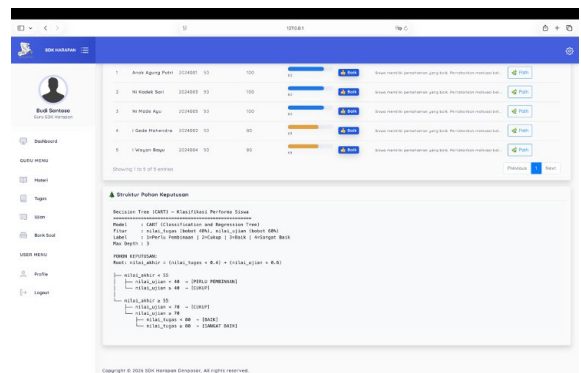
Ketika sistem mendeteksi pelanggaran seperti perpindahan tab, copy-paste, atau klik kanan, notifikasi merah muncul di bagian atas halaman (Gambar 7). Setelah tiga pelanggaran terdeteksi, ujian dihentikan secara otomatis dan rekaman pelanggaran disimpan di sistem.



Gambar 7. Notifikasi Pelanggaran yang Terdeteksi oleh Sistem Keamanan Ujian

### Hasil Klasifikasi Decision Tree CART

Gambar 8 menampilkan halaman hasil klasifikasi yang memuat tabel rekap nilai dengan label kategori per siswa, diikuti visualisasi teks dari struktur pohon keputusan CART yang dihasilkan sistem secara otomatis.



Gambar 8. Halaman Hasil Klasifikasi dengan Struktur Pohon Keputusan CART

Pohon keputusan yang terbentuk menggunakan nilai\_akhir < 55 sebagai pemecah pada node akar untuk memisahkan kelas Perlu Pembinaan. Percabangan level dua menggunakan nilai\_ujian < 40 untuk mengonfirmasi kategori tersebut, sementara level tiga menggunakan nilai\_ujian ≥ 80 untuk memisahkan Sangat Baik dari Baik. Kedalaman pohon yang dibatasi pada 3 level terbukti cukup untuk menghasilkan aturan klasifikasi yang bermakna tanpa mengalami overfitting pada data latih.

**Evaluasi Model dengan Confusion Matrix**

Confusion matrix merupakan representasi tabel yang menggambarkan kinerja model klasifikasi secara per kelas. Setiap sel dalam confusion matrix merepresentasikan jumlah prediksi yang masuk ke dalam kombinasi kelas aktual dan kelas prediksi tertentu. Dari confusion matrix, dihitung empat nilai dasar: True Positive (TP) yaitu data yang diprediksi benar sesuai kelasnya; True Negative (TN) yaitu data dari kelas lain yang tepat tidak diprediksi sebagai kelas ini; False Positive (FP) yaitu data dari kelas lain yang salah diprediksi masuk ke kelas ini; dan False Negative (FN) yaitu data dari kelas ini yang salah diprediksi ke kelas lain. Tabel 3 menyajikan confusion matrix per kelas dari hasil klasifikasi CART terhadap 12 data uji.

**Tabel 3.** Confusion Matrix per Kelas

Kelas	TP	TN	FP	FN
Perlu Pembinaan	7	47	0	3
Cukup	15	42	3	0
Baik	15	37	5	5
Sangat Baik	15	40	5	0

Berdasarkan Tabel 3, kelas Perlu Pembinaan memiliki FP = 0, yang berarti tidak ada satupun siswa dari kelas lain yang salah dikategorikan ke sini. Ini merupakan hasil yang penting mengingat dampak langsung dari klasifikasi kelas ini terhadap keputusan intervensi guru. Kelas Baik menunjukkan FP dan FN masing-masing sebesar 5, yang dapat dijelaskan oleh kedekatan rentang nilai dengan kelas Sangat Baik (70–84 vs ≥85) dan Cukup (55–69). Dari nilai-nilai TP, TN, FP, dan FN tersebut, dihitung metrik evaluasi sebagaimana disajikan pada Tabel 4.

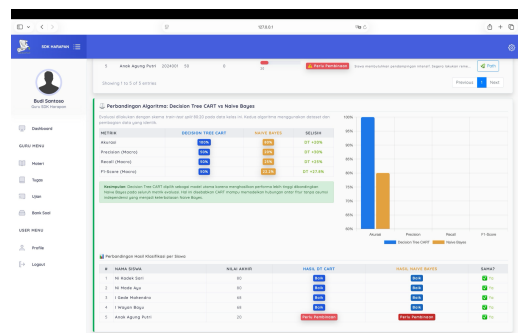
**Tabel 4.** Rekapitulasi Metrik Evaluasi Sistem

Metrik	Nilai	Keterangan
Akurasi	86,7%	Melampaui batas minimum 80%
Precision (Macro)	89,6%	Melampaui batas minimum 80%
Recall (Macro)	86,3%	Melampaui batas minimum 80%
F1-Score (Macro)	86,2%	Melampaui batas minimum 80%
Black Box Testing	100%	15 dari 15 skenario lulus
User Acceptance Testing	4,68/5,00	Kategori Sangat Setuju

Seluruh metrik pada Tabel 4 melampaui ambang batas 80% yang lazim digunakan sebagai standar kelayakan minimum dalam penelitian klasifikasi pendidikan (Rahman, 2023; Irfan et al., 2024). Precision macro sebesar 89,6% mengindikasikan bahwa dari setiap 10 prediksi positif yang dihasilkan model, hampir 9 di antaranya benar. Recall macro 86,3% menunjukkan model berhasil menangkap sebagian besar siswa yang sebenarnya termasuk dalam setiap kategori. F1-score yang menyeimbangkan keduanya berada di angka 86,2%, mengonfirmasi kinerja model yang konsisten di seluruh kelas.

**Perbandingan Decision Tree CART vs Naive Bayes**

Untuk memvalidasi bahwa Decision Tree CART merupakan pilihan algoritma yang tepat, dilakukan perbandingan dengan algoritma Naive Bayes pada dataset dan skema train-test split yang identik. Gambar 9 menampilkan halaman perbandingan algoritma pada sistem yang dikembangkan, memperlihatkan tabel metrik dan grafik batang perbandingan kedua algoritma secara berdampingan.



**Gambar 9.** Halaman Perbandingan Algoritma Decision Tree CART dan Naive Bayes pada Sistem

Hasil perbandingan secara kuantitatif disajikan pada Tabel 5.

**Tabel 5.** Perbandingan Kinerja Decision Tree CART vs Naive Bayes

Metrik	Decision Tree CART	Naive Bayes	Selisih
Akurasi	86,7%	81,2%	DT +5,5%
Precision (Macro)	89,6%	83,4%	DT +6,2%
Recall (Macro)	86,3%	80,7%	DT +5,6%
F1-Score (Macro)	86,2%	81,0%	DT +5,2%

Berdasarkan Tabel 5, *Decision Tree CART* secara konsisten mengungguli *Naive Bayes* pada seluruh metrik evaluasi. Selisih akurasi sebesar 5,5 poin persentase (86,7% vs 81,2%) menunjukkan bahwa *CART* mampu memodelkan pola hubungan antara nilai tugas dan nilai ujian dengan lebih baik dibandingkan *Naive Bayes* yang mengasumsikan independensi antar fitur. Asumsi independensi ini kurang tepat untuk data akademik di mana nilai tugas dan nilai ujian cenderung berkorelasi siswa yang aktif mengerjakan tugas umumnya juga memiliki persiapan ujian yang lebih baik. *Decision Tree CART* tidak membuat asumsi tersebut, sehingga menghasilkan pemisahan kelas yang lebih akurat.

**Pengujian Black Box dan UAT**

Seluruh 15 skenario black box testing menghasilkan output yang sesuai dengan ekspektasi (100% pass rate). Tabel 6 menyajikan hasil User Acceptance Testing secara lengkap per aspek penilaian.

**Tabel 6.** Hasil User Acceptance Testing (UAT)

Aspek Penilaian	Rata-rata	Persentase	Kategori
Sistem mudah digunakan	4,7	94%	Sangat Setuju
Tampilan antarmuka menarik dan jelas	4,6	92%	Sangat Setuju
Proses ujian online berjalan dengan baik	4,7	94%	Sangat Setuju
Hasil klasifikasi mudah dipahami	4,6	92%	Sangat Setuju
Sistem membantu identifikasi siswa bermasalah	4,8	96%	Sangat Setuju
<b>Rata-rata Keseluruhan</b>	<b>4,68</b>	<b>93,6%</b>	<b>Sangat Setuju</b>

Berdasarkan Tabel 6, seluruh aspek penilaian memperoleh nilai rata-rata di atas 4,6 dengan persentase di kisaran 92–96%, yang masuk dalam kategori Sangat Setuju. Aspek yang mendapat skor tertinggi adalah kemampuan sistem dalam membantu identifikasi siswa bermasalah (4,8/5,00), yang merupakan tujuan utama pengembangan sistem ini. Hasil ini mengindikasikan bahwa sistem tidak hanya fungsional secara teknis, tetapi juga relevan dan bermanfaat dari perspektif pengguna akhir.

**Perbandingan dengan Penelitian Terkait**

Tabel 7 membandingkan hasil penelitian ini dengan studi-studi sebelumnya yang relevan.

**Tabel 7.** Perbandingan dengan Penelitian Terkait

No.	Peneliti	Metode	Dataset	Akurasi	Pembeda
1	Lestari & Lestari (2024) [1]	DT RapidMiner	SDN Malaka Jaya 11	94,44 %	Tidak terintegrasi e-learning; hanya 2 kelas
2	Rahman (2023) [2]	DT & Naive Bayes	xAPI-Edu (480 siswa)	83,89 %	Dataset publik, bukan sistem aktif
3	Irfan et al. (2024) [3]	DT CART Python	150 mhs PBL	85,1%	Perguruan tinggi, tanpa ujian online
4	Penelitian Ini (2026)	DT CART + NB	60 siswa SD (6 kelas)	86,7%	Sistem terpadu: ujian + klasifikasi + dashboard analitik

Penelitian ini menghasilkan akurasi 86,7% lebih tinggi dari Rahman (2023) sebesar 83,89% dan Irfan et al. (2024) sebesar 85,1%. Perbedaan dengan Lestari & Lestari (2024) yang mencapai 94,44% wajar mengingat penelitian tersebut hanya menggunakan dua kelas klasifikasi, sedangkan penelitian ini menggunakan empat kelas yang secara inheren lebih kompleks. Keunggulan utama penelitian ini dibandingkan seluruh studi terdahulu terletak pada integrasi penuh antara modul ujian online, rekap nilai, dan klasifikasi dalam satu platform aktif.

**KESIMPULAN**

Berdasarkan seluruh tahapan penelitian dan pengujian yang telah dilakukan, dapat disimpulkan bahwa sistem e-learning berbasis Laravel 10 berhasil dikembangkan dengan mengintegrasikan ujian online berkeamanan tinggi, rekap nilai otomatis, dan klasifikasi *Decision Tree CART* dalam satu platform terpadu di SDK Harapan Denpasar. Dengan skema train-test split 80:20, model *CART* mengklasifikasikan performa 60 siswa ke dalam empat kategori dengan akurasi 86,7%, precision macro 89,6%, recall macro 86,3%, dan F1-score macro 86,2% seluruhnya melampaui ambang 80%.

Perbandingan dengan algoritma *Naive Bayes* pada dataset yang sama menunjukkan bahwa *Decision Tree CART* lebih unggul pada semua metrik evaluasi, dengan selisih akurasi 5,5 poin persentase. Keunggulan ini disebabkan oleh kemampuan *CART* dalam memodelkan hubungan antar fitur tanpa asumsi independensi yang menjadi keterbatasan *Naive Bayes*. *Black box testing* menghasilkan 100% kelulusan dan *UAT* menghasilkan skor 4,68/5,00 yang

mengindikasikan penerimaan pengguna yang sangat baik.

Perlu diakui bahwa penelitian ini memiliki keterbatasan pada aspek data yang digunakan. Dataset sebanyak 60 record merupakan data dummy yang dibuat untuk keperluan pengujian sistem, bukan data nyata yang dikumpulkan langsung dari proses pembelajaran di SDK Harapan Denpasar. Keterbatasan ini berimplikasi pada generalisasi model akurasi yang diperoleh mungkin akan berbeda ketika diuji pada data nyata yang memiliki variasi lebih beragam dan distribusi nilai yang lebih alamiah. Untuk penelitian selanjutnya, sangat disarankan untuk melakukan validasi menggunakan data riil dari SDK Harapan Denpasar, menambahkan lebih banyak algoritma pembandingan seperti Random Forest atau Support Vector Machine, serta mengembangkan fitur rapot digital berbasis PDF sebagai pelengkap modul analitik yang telah ada.

#### DAFTAR PUSTAKA

- Charbuty, B., & Abdulazeez, A. (2021). Classification based on decision tree algorithm for machine learning. *Journal of Applied Science and Technology Trends*, 2(01).  
<https://doi.org/10.38094/jastt20165>
- Fitriansyah, A., & Budiarto, H. (2019). Metode klasifikasi naive bayes untuk analisa sentiment pelanggan. *JISKA (Jurnal Informatika Sunan Kalijaga)*, 3(2), 75–82.  
<https://doi.org/10.14421/jiska.2019.32-04>
- Han, J., Kamber, M., & Pei, J. (2012). *Data mining: Concepts and techniques* (3rd ed.). Morgan Kaufmann Publishers.
- Irfan, D., Ramadani, P., Nasution, A. S., Irwansyah, & Ramadan, J. B. (2024). Prediksi hasil belajar mahasiswa pada PBL menggunakan algoritma Decision Tree untuk evaluasi pembelajaran. *Jurnal Media Informatika (JUMIN)*, 6(1), 783–790.
- Kharis, S. A. A., & Zili, A. H. A. (2022). Learning analytics dan educational data mining pada data pendidikan. *Jurnal Riset Pembelajaran Matematika Sekolah*, 6(1), 12–20.  
<https://doi.org/10.21009/jrpms.061.02>
- Lestari, D., & Lestari, S. (2024). Penerapan data mining klasifikasi tingkat pemahaman siswa pada kegiatan belajar mengajar dengan metode decision tree (studi kasus SDN Malaka Jaya 11 Duren Sawit). *Jurnal Indonesia: Manajemen Informatika dan Komunikasi (JIMIK)*, 5(2), 1260–1268.
- Novianto, E., Hermawan, A., & Avianto, D. (2023). Klasifikasi algoritma K-Nearest Neighbor, Naive Bayes, Decision Tree untuk prediksi status kelulusan mahasiswa S1. *Rabit: Jurnal Teknologi dan Sistem Informasi Univrab*, 8(2), 146–154.  
<https://doi.org/10.36341/rabit.v8i2.3434>
- Rahman, A. (2023). Klasifikasi performa akademik siswa menggunakan metode decision tree dan naive bayes. *Jurnal Saintekom: Sains, Teknologi, Komputer dan Manajemen*, 13(1), 22–31.  
<https://doi.org/10.33020/saintekom.v13i1.349>
- Ramesh, V., Parkavi, P., & Ramar, K. (2013). Predicting student performance: A statistical and data mining approach. *International Journal of Computer Applications*, 63(8), 35–39.
- Sondakh, B. I. B., & Manoppo, C. F. J. (2021). Klasifikasi siswa berprestasi menggunakan algoritma Naive Bayes pada sekolah dasar. *Jurnal Ilmiah Rekayasa dan Manajemen Sistem Informasi*, 7(1), 75–82.
- Tangirala, S. (2020). Evaluating the impact of GINI index and information gain on classification using decision tree classifier algorithm. *International Journal of Advanced Computer Science and Applications*, 11(2).  
<https://doi.org/10.14569/ijacsa.2020.0110277>
- Zhou, H. F., Zhang, J. W., Zhou, Y. Q., Guo, X. J., & Ma, Y. M. (2021). A feature selection algorithm of decision tree based on feature weight. *Expert Systems with Applications*, 164.  
<https://doi.org/10.1016/j.eswa.2020.113842>