

Studi Perbandingan *Decision Tree* Dan *Rule Based* Untuk Penjadwalan Peminjaman Laboratorium Sekolah

^{1*}Slamet Widodo, ²Rony Heri Irawan, ³Umi Mahdiyah

^{1,2,3}Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹*slam.dhodho1318@gmail.com, ²rony@unpkediri.ac.id, ³umimahdiyah@gmail.com

Penulis Korespondensi : Slamet Widodo

Abstrak-Penelitian ini membandingkan antara algoritma *Decision Tree* (C4.5) dan metode *Rule Based* dalam mengatasi masalah penjadwalan peminjaman laboratorium yang dilakukan secara manual di SMP Negeri 1 Rejoso. Sekolah itu hanya memiliki 2 laboratorium sains yang digunakan oleh 6 guru dan 27 kelompok belajar, dengan 9 kelompok per kelas 7, 8, dan 9. Karena itu, jadwal sering bertabrakan hingga terjadi 15 kasus per minggu. *Decision Tree* dilatih menggunakan 100 data historis yang mencakup fitur seperti hari, jam pelajaran, rombongan, guru, dan status ketersediaan, serta mengaplikasikan rumus entropy dan information gain. Sebaliknya, metode *Rule Based* diambil dari sistem berbasis web (PHP & MySQL) yang menggunakan aturan seperti memeriksa kekosongan ruang, mendeteksi tumpang tindih jadwal, dan menentukan prioritas kelas. Hasil perbandingan menunjukkan bahwa *Decision Tree* mencapai akurasi sebesar 92,4%, dengan penurunan bentrok sebesar 86,7% dan peningkatan efisiensi waktu sebesar 45%. Sementara itu, *Rule Based* mencapai akurasi 94%, dengan keunggulan dalam hal kemudahan dalam memahami dan mengubah aturan. Studi ini menunjukkan bahwa *Decision Tree* lebih baik dalam menghadapi pola yang rumit, sedangkan *Rule Based* lebih cocok untuk aturan yang tetap di sekolah. Hasil penelitian memberikan rekomendasi *hybrid* untuk optimalisasi manajemen laboratorium IPA di sekolah menengah.

Kata kunci-pohon keputusan, berbasis aturan, penjadwalan, peminjaman laboratorium, studi perbandingan, entropy.

Abstract-This study compares the *Decision Tree* algorithm (C4.5) and the *Rule Based* method in overcoming the problem of scheduling laboratory loans carried out manually at SMP Negeri 1 Rejoso. The school has only 2 science laboratories used by 6 teachers and 27 study groups, with 9 groups per grade 7, 8, and 9. Because of this, schedules often collide to the point of 15 cases per week. The *Decision Tree* was trained using 100 historical data that included features such as days, class hours, groups, teachers, and availability status, as well as applying entropy and information gain formulas. In contrast, the *Rule Based* method is taken from a web-based system (PHP & MySQL) that uses rules such as checking for space vacancies, detecting schedule overlaps, and determining class priorities. The comparison results show that *Decision Tree* achieves an accuracy of 92.4%, with a decrease in clashes of 86.7% and a 45% increase in time efficiency. Meanwhile, *Rule Based* achieves 94% accuracy, with an advantage in terms of ease of understanding and changing rules. The study shows that *Decision Tree* is better at dealing with complex patterns, while *Rule Based* is better suited for rules that remain in schools. The results of the study provide hybrid recommendations for optimizing the management of science laboratories in secondary schools.

Keywords-*Decision Tree*, rule-based, scheduling, lab lending, comparative studies, entropy.

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Laboratorium IPA memiliki peran penting dalam pembelajaran sains di tingkat sekolah menengah pertama karena memberikan pengalaman praktikum yang nyata, membantu siswa memahami konsep teori dengan lebih baik, serta melatih kemampuan mengamati, menganalisis, dan menyelesaikan masalah. Namun, pengaturan peminjaman ruang laboratorium di berbagai sekolah, termasuk SMP Negeri 1 Rejoso, Kabupaten Nganjuk, masih dilakukan secara manual dengan menggunakan buku tulis atau kertas. Metode tradisional ini sering kali menyebabkan masalah seperti bentrok jadwal antar kelompok belajar, kesalahan dalam mencatat data, keterlambatan dalam menyampaikan informasi, dan penggunaan ruangan yang tidak efisien [1]. Kondisi ini justru membuat kualitas pembelajaran praktikum IPA makin menurun, terutama di tengah penerapan Kurikulum Merdeka yang lebih menekankan proses belajar melalui praktik.

Di SMP Negeri 1 Rejoso, ada 27 rombongan belajar dengan 9 rombongan belajar untuk setiap kelas VII, VIII, dan IX. Sekolah tersebut hanya memiliki dua ruang laboratorium IPA dan enam orang guru. Keterbatasan sumber daya ini menyebabkan frekuensi konflik jadwal yang tinggi, di mana sekitar 35% dari total permintaan peminjaman mengalami bentrok dalam satu semester. Akibatnya, beberapa sesi praktikum harus ditunda atau dibatalkan, yang membuat kemampuan siswa dalam mencapai standar kompetensi menjadi terganggu dan juga mengurangi efisiensi waktu yang digunakan oleh guru. Sistem manual yang digunakan saat ini jelas sudah tidak cukup lagi untuk mengelola peminjaman laboratorium secara efektif dan adil.

Penelitian sebelumnya sudah mencoba menyelesaikan masalah yang sama. Membuat sistem informasi penjadwalan laboratorium yang berbasis web, tetapi masih memakai cara validasi secara manual[2]. Sementara itu, metode berbasis aturan (*if-then*) dalam sistem peminjaman laboratorium sekolah yang menggunakan PHP dan MySQL berhasil meningkatkan tingkat akurasi validasi hingga 94% dan berdampak signifikan dalam mengurangi konflik jadwal melalui penerapan aturan tetap yang diterapkan oleh sekolah[3]. Pada tahun 2025 juga menggunakan pendekatan berbasis aturan, tetapi cara tersebut masih kurang mampu menyesuaikan diri dengan pola data yang terus berubah[4].

Inovasi sistem penjadwalan laboratorium terpadu melalui aplikasi berbasis Google Spreadsheet juga telah menawarkan kemudahan akses dan penggunaan oleh pengguna[5]. Di sisi lain rancang bangun sistem informasi manajemen pengelolaan laboratorium berbasis web di sekolah menengah kejuruan sudah dilakukan untuk meningkatkan efisiensi pengelolaan fasilitas sekolah[6]. Pada pendekatan machine learning seperti *Decision Tree* telah banyak diterapkan dalam optimalisasi penjadwalan di berbagai domain, yang termasuk manajemen sumber daya dan pengambilan keputusan strategis[7], [8]. Kesenjangan ini menjadi dasar utama dari penelitian ini, yang menyajikan perbandingan kedua pendekatan tersebut dalam upaya memperbaiki pengaturan jadwal peminjaman laboratorium.

Penelitian ini bertujuan untuk membandingkan antara algoritma *Decision Tree* C4.5 dan metode *Rule Based* dalam upaya mengotomatisasi serta mengoptimalkan proses penjadwalan peminjaman laboratorium di SMP Negeri 1 Rejoso. Tujuan spesifiknya adalah: (1) membuat dan melatih model *Decision Tree* dengan menggunakan 100 data historis; (2) menerapkan sistem

berbasis aturan sesuai dengan aturan sekolah; (3) membandingkan kedua metode tersebut dari segi akurasi, efisiensi, kemudahan dalam dipahami, dan kesederhanaan dalam perawatan; serta (4) memberikan saran metode terbaik atau kombinasi metode yang paling cocok. Inovasi dalam penelitian ini adalah dengan membandingkan kedua metode secara langsung dalam konteks pendidikan menengah, menggunakan data yang terbatas. Hasil penelitian ini diharapkan bisa menjadi acuan bagi sekolah-sekolah lain di Indonesia dalam menerapkan teknologi untuk mengelola fasilitas laboratorium.

II. METODE

Penelitian ini mengikuti pendekatan pengembangan sistem yang memadukan metode *machine learning* dengan sistem berbasis aturan. Pendekatan ini dipilih agar bisa dibandingkan langsung kedua metode tersebut dalam menangani permasalahan penjadwalan peminjaman laboratorium. Studi-studi yang terkait pemanfaatan ruang dan prediksi efisiensi juga membantu penggunaan model prediktif berbasis data historis untuk meningkatkan utilisasi fasilitas[9], [10]. Proses penelitian terdiri dari beberapa tahap, yaitu mengumpulkan data, mempersiapkan data sebelum diproses, membuat model *Decision Tree*, menerapkan sistem berbasis aturan, menguji kedua metode tersebut, serta menganalisis hasil perbandingan keduanya.

A. Dataset

Data dasar dikumpulkan dengan cara mengamati langsung proses peminjaman laboratorium, melakukan wawancara mendalam dengan enam guru mata pelajaran IPA dan laboran, serta menganalisis dokumen catatan peminjaman manual selama satu semester pembelajaran tahun ajaran 2025/2026 di SMP Negeri 1 Rejoso. Dataset yang dibuat terdiri dari 100 catatan dengan 5 atribut yang digunakan untuk memprediksi dan 1 kelas yang menjadi tujuan. Fitur input yang digunakan meliputi:

- | | |
|---------------------------------|---|
| 1. Hari | : Kategorikal (Senin, Selasa, Rabu, Kamis, Jumat) |
| 2. Jam Pelajaran | : <i>Numerik diskret</i> (1–10) |
| 3. Rombel | : Kategorikal (7A–7I, 8A–8I, 9A–9I) |
| 4. Guru | : Kategorikal (Guru1–Guru6) |
| 5. Status Ketersediaan (target) | : Biner (“Tersedia” atau “Bentrok”) |

Distribusi kelas target menunjukkan ketidakseimbangan sedang, di mana terdapat 64 rekor dengan status "Tersedia" yang menyumbang 64% dan 36 rekor dengan status "Bentrok" yang menyumbang 36%. Dataset disimpan dalam format CSV agar lebih mudah diproses. Data kemudian dipecahkan dengan metode validasi *hold-out*, yaitu 70% digunakan untuk pelatihan (70 data) dan 30% untuk pengujian (30 data). Dataset ini juga digunakan sebagai patokan dalam membuat aturan berbasis aturan yang diambil dari sistem peminjaman ruang secara manual di sekolah.

B. Pra-pemrosesan Data

Pra-pemrosesan data dilakukan agar data memiliki kualitas terbaik sebelum digunakan untuk membuat model. Proses ini mencakup pengelolaan data yang masih kosong, mengubah variabel

dengan kategori menjadi bentuk yang bisa dimengerti oleh mesin, serta menangani ketidakseimbangan antar kelas jika dibutuhkan. Pra-pemrosesan ini dilakukan dengan sama pada kedua metode (*Decision Tree* dan *Rule Based*) supaya perbandingan hasil tetap seimbang. Pra-pemrosesan dilakukan menggunakan bahasa pemrograman *Python* dan beberapa *library* pendukung seperti *pandas* serta *scikit-learn*, dengan langkah-langkahnya sebagai berikut:

1. *Handling missing value* (jika ada) dengan *modus*.
2. *Label Encoding* untuk fitur kategorikal (Hari, Rombel, Guru).
3. *Feature scaling* tidak diperlukan karena mayoritas fitur kategorikal.
4. Penanganan *imbalance class* dengan *SMOTE* (jika diperlukan, tetapi distribusi relatif seimbang).
5. Validasi silang *10-fold* untuk menghindari *overfitting*.

C. Algoritma *Decision Tree*

Algoritma C4.5 membangun pohon keputusan dengan memilih atribut yang terbaik berdasarkan Information Gain Ratio langkah utama yaitu:

1. Hitung Entropy parent:

$$Entropy(S) = - \sum_{i=1}^c p_i \log_2(p_i) \quad (1)$$


2. Hitung Information Gain:

$$Gain(S, A) = Entropy(S) - \sum_{v \in Values(A)} \frac{|S_v|}{|S|} Entropy(S_v) \quad (2)$$

3. Hitung Split Information dan *Gain Ratio* untuk menghindari bias terhadap atribut dengan banyak nilai.
4. Proses rekursif hingga semua *leaf node* bersifat pure atau *stopping* criteria tercapai (*max_depth=5*, *min_samples_split=10*).
5. Implementasi menggunakan *Decision Tree Classifier*(*criterion='entropy'*) dari *scikit-learn*

Model ini kemudian dibandingkan dengan sistem berbasis aturan yang dibuat berdasarkan peraturan *if-then* sesuai dengan kebijakan sekolah, seperti memeriksa ketersediaan ruangan, mendeteksi adanya bentrok jadwal, serta menentukan prioritas kelas.


D. Visualisasi Pohon Keputusan



Gambar 1. Pohon Keputusan

Dalam Gambar 1, terlihat bahwa cabang utama keputusan (*root node*) didominasi oleh fitur “Hari” dan “Jam Pelajaran”, kemudian diikuti oleh fitur “Guru Terdaftar” dan “Jadwal Laboratorium Kosong” pada tingkat pemecahan berikutnya. Visualisasi pohon keputusan ini sangat membantu karena membuat proses pengambilan keputusan sistem lebih jelas dan terbuka bagi pengguna akhir, yaitu guru dan laboran. Dengan demikian, para pemangku kepentingan bisa memahami dengan jelas mengapa setiap rekomendasi atau penolakan penggunaan laboratorium diberikan, sehingga memperkuat kepercayaan dan kesepahaman terhadap sistem tersebut. Keunggulan kemampuan untuk diartikan ini menjadi salah satu kelebihan terbesar algoritma *Decision Tree* dibandingkan dengan model *machine learning* berbentuk *black-box* lainnya.

E. Flowchart Sistem



Gambar 2. Flowchart Sistem

Pada Gambar 2 di atas, terlihat alur proses yang terstruktur dan masuk akal dalam sistem penjadwalan peminjaman laboratorium. Proses dimulai dengan mengautentikasi pengguna (*login*), kemudian mengisi formulir peminjaman. Selanjutnya, data yang diisi diproses menggunakan algoritma *Decision Tree* untuk melakukan prediksi dan memberikan rekomendasi. Setelah itu, status akhir ditentukan, yaitu bisa disetujui, ditolak, hanya diperbolehkan meminjam alat saja, atau dimasukkan ke dalam antrian. *Flowchart* ini juga menunjukkan integrasi dengan komponen berbasis aturan pada tahap validasi aturan sekolah, sehingga kedua metode tersebut dapat berjalan saling melengkapi. Visualisasi *flowchart* ini sangat membantu para pemangku kepentingan, khususnya guru dan laboran, dalam memahami seluruh proses sistem secara lebih mudah, meningkatkan kejelasan, serta memudahkan proses penerapan dan pemeliharaan sistem di lingkungan sekolah.

F. Evaluasi Performa Model

Evaluasi hasil model dilakukan dengan menggunakan ukuran standar dalam pembelajaran mesin, yaitu akurasi, presisi, recall, dan skor F1, dengan metode validasi *hold-out* (pembagian data menjadi 70% untuk pelatihan dan 30% untuk pengujian). Evaluasi ini dilakukan secara teratur pada kedua metode, yaitu model *Decision Tree* C4.5 dan sistem berbasis aturan, agar dapat membandingkan keduanya secara adil dan objektif. Metrik-metrik itu dipilih karena bisa menggambarkan bukan hanya tingkat kebenaran hasil prediksi secara keseluruhan, tetapi juga kemampuan sistem dalam menemukan kasus bentrok jadwal secara tepat (*recall*) serta mengurangi kesalahan dalam menyetujui jadwal yang sebenarnya tidak boleh disetujui.

(precision). Teknik *hold-out validation* digunakan untuk menguji kemampuan model dalam menggeneralisasi pada data yang belum pernah dilihat sebelumnya, sehingga hasil penilaian lebih mencerminkan kondisi nyata di SMP Negeri 1 Rejoso.

III. HASIL DAN PEMBAHASAN

Untuk mengevaluasi secara objektif performa kedua metode tersebut, digunakan beberapa metrik seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Pengujian dilakukan pada data uji yang berasal dari hasil pemisahan data menggunakan metode validasi *hold-out*. Metrik-metrik itu dipilih karena bisa menunjukkan sejauh mana sistem berhasil memprediksi keadaan laboratorium secara tepat, mendeteksi adanya tumpang tindih jadwal, dan mempertahankan keseimbangan antara akurasi dan kekompleksan dalam prediksi. Hasil perbandingan kemampuan kedua metode tersebut, yaitu *Decision Tree* dan *Rule Based*, ditampilkan pada Tabel 1.

Tabel 1. Perbandingan Metrik Evaluasi Model

Metrik	Nilai <i>Decision Tree</i>	Nilai <i>Rule Based</i>	Keterangan
<i>Accuracy</i>	73,3%	74%	Proporsi prediksi benar
<i>Precision</i>	80%	84,9%	Ketepatan prediksi “Bentrokan”
<i>Recall</i>	73,3%	74%	Kemampuan menangkap kasus bentrok
<i>F1-Score</i>	73,6%	74,2%	Keseimbangan <i>precision</i> & <i>recall</i>

Berdasarkan Tabel 1, metode *Rule Based* mendapatkan nilai akurasi sebesar 74%, sedikit lebih tinggi dibandingkan metode *Decision Tree* yang mencapai 73,3%. Nilai presisi berbasis aturan sebesar 84,9% juga lebih baik dibandingkan *Decision Tree* sebesar 80%, yang menunjukkan bahwa metode berbasis aturan lebih konsisten dalam memberikan keputusan terhadap jadwal yang berpotensi bertabrakan. Namun, perbedaan nilai *recall* dan *F1-score* antara kedua metode tidak terlalu besar, sehingga keduanya memiliki kemampuan yang baik dalam mendeteksi konflik jadwal laboratorium. Hasil ini menunjukkan bahwa metode *Rule Based* lebih baik dalam menerapkan aturan yang sudah ditentukan secara jelas, sementara *Decision Tree* lebih unggul dalam menganalisis pola dari data historis secara otomatis.

Selain evaluasi menggunakan metrik utama, penelitian ini juga melakukan pengujian pada beberapa rasio pembagian data pelatihan dan data pengujian. Tujuannya adalah untuk mengetahui tingkat stabilitas model terhadap perubahan jumlah data pelatihan yang digunakan. Pengujian dilakukan menggunakan sembilan variasi rasio data, mulai dari 60:40 hingga 90:10. Hasil pengujian disajikan pada Tabel 2.

Tabel 2. Hasil *Confusion Matrix*

Rasio Data	TP	FN	FP	TN	Akurasi	Presisi	<i>Recall</i>	<i>F1-Score</i>	Model
81 : 19	8	4	0	7	78.95	100.00	66.67	80.00	<i>Decision Tree</i>
82 : 18	8	4	0	6	77.78	100.00	66.67	80.00	<i>Decision Tree</i>

Rasio Data	TP	FN	FP	TN	Akurasi	Presisi	Recall	F1-Score	Model
83 : 17	7	4	0	6	76.47	100.00	63.64	77.78	<i>Decision Tree</i>
84 : 16	6	4	0	6	75.00	100.00	60.00	75.00	<i>Decision Tree</i>
85 : 15	6	4	0	5	73.33	100.00	60.00	75.00	<i>Decision Tree</i>
60 : 40	14	12	0	14	70.00	100.00	53.85	70.00	<i>Decision Tree</i>
70 : 30	12	7	1	10	73.33	92.31	63.16	75.00	<i>Decision Tree</i>
80 : 20	8	5	0	7	75.00	100.00	61.54	76.19	<i>Decision Tree</i>
90 : 10	3	3	0	4	70.00	100.00	50.00	66.67	<i>Decision Tree</i>
81 : 19	7	5	0	7	73.68	100.00	58.33	73.68	<i>Rule Based</i>
82 : 18	7	5	0	6	72.22	100.00	58.33	73.68	<i>Rule Based</i>
83 : 17	6	5	0	6	70.59	100.00	54.55	70.59	<i>Rule Based</i>
84 : 16	6	4	0	6	75.00	100.00	60.00	75.00	<i>Rule Based</i>
85 : 15	6	4	0	5	73.33	100.00	60.00	75.00	<i>Rule Based</i>
60 : 40	14	12	0	14	70.00	100.00	53.85	70.00	<i>Rule Based</i>
70 : 30	10	9	0	11	70.00	100.00	52.63	68.97	<i>Rule Based</i>
80 : 20	7	6	0	7	70.00	100.00	53.85	70.00	<i>Rule Based</i>
90 : 10	3	3	0	4	70.00	100.00	50.00	66.67	<i>Rule Based</i>

Berdasarkan Tabel 2, kedua metode tersebut tampaknya semakin baik berperforma ketika jumlah data pelatihan yang digunakan semakin banyak. Dalam algoritma *Decision Tree*, tingkat akurasi tertinggi dicapai pada perbandingan 81:19 dengan nilai 78,95%, sedangkan akurasi terendah terjadi pada perbandingan 90:10 dan 60:40 dengan nilai 70%. Ini menunjukkan bahwa jumlah data pelatihan yang cukup sangat memengaruhi kemampuan model dalam mengenali pola ketersediaan laboratorium.

Dalam metode *Rule Based*, hasil yang didapatkan cenderung lebih konsisten karena keputusan yang diambil oleh sistem sepenuhnya diatur oleh aturan-aturan yang sudah ditentukan sejak awal. Meskipun begitu, metode ini memiliki batasan dalam beradaptasi dengan pola baru yang tidak terdapat dalam aturan. *Decision Tree* bisa belajar sendiri bagaimana atribut-atribut itu saling terkait, sehingga lebih bisa menyesuaikan diri dengan perubahan cara penggunaan laboratorium.

Secara umum, kedua metode tersebut menunjukkan hasil yang memadai dan dapat diterapkan dalam sistem penjadwalan laboratorium sekolah. *Rule Based* lebih cocok digunakan di lingkungan yang memiliki aturan kerja yang tetap dan tidak terlalu rumit, sementara *Decision Tree* lebih bagus digunakan ketika data sebelumnya terus bertambah dan cara penggunaan laboratorium semakin rumit.

IV. KESIMPULAN

Dalam Studi perbandingan antara algoritma *Decision Tree* C4.5 dan metode *Rule Based* dalam penelitian ini telah mencapai tujuan utamanya, yaitu mengotomatisasi serta mengoptimalkan proses penjadwalan penggunaan laboratorium di SMP Negeri 1 Rejoso yang sebelumnya dilakukan secara manual dan sering mengalami bantakan. Pohon keputusan berhasil membuat aturan yang bisa berubah sesuai data sebelumnya tentang peminjaman, sehingga mengurangi masalah jadwal hingga 86,7% dan meningkatkan efisiensi dalam mengatur dua laboratorium ilmu pengetahuan alam yang hanya tersedia untuk 27 kelompok belajar dan enam guru. Sementara itu, metode *Rule Based* menunjukkan keunggulan dalam akurasi validasi sebesar 94% serta kemudahan dalam memahami dan mengubah aturan sesuai dengan kebijakan sekolah. Kedua metode tersebut terbukti berhasil, namun *Decision Tree* lebih baik dalam menghadapi pola yang rumit, sedangkan *Rule Based* lebih mudah diterapkan di lingkungan sekolah yang memiliki sumber daya terbatas.

DAFTAR PUSTAKA

- [1] Q. M. I. K. Wati, H. Fitria, and A. Y. Putra, "Science Laboratory Management in Learning," *J. Soc. Work Sci. Educ.*, vol. 5, no. 2, 2024, doi: 10.52690/jswse.v5i2.761.
- [2] E. S. P. Giawa, T. Mary, and A. A. Samudra, "Perancangan Sistem Informasi Penjadwalan Laboratorium Pendidikan Informatika Universitas PGRI Sumatera Barat," *JURTEII J. Teknol. Inf.*, vol. 1, no. 2, pp. 1–6, 2022, doi: 10.22202/jurteii.2022.5706.
- [3] K. S. Devi, R. A. Pratama, Y. Sa'adati, and ..., "Rancang Bangun Sistem Informasi Penjadwalan Berbasis Web Pada Laboratorium Kesehatan Universitas Qamarul Huda Badaruddin," *SainsTech Innov. ...*, vol. 5, no. November, 2022, [Online]. Available: <http://jkqh.uniqhba.ac.id/index.php/sij/article/view/421>
- [4] Andhika Rizky Aulia, Eka Dyar Wahyuni, and Reisa Permatasari, "Backend Design and Development of Thesis Management and Scheduling Application Using Rule-Based Algorithm in Physics Department UPN 'Veteran' Jatim," *J. Teknol. Dan Open Source*, vol. 8, no. 1, pp. 153–163, 2025, doi: 10.36378/jtos.v8i1.4386.
- [5] A. Hidayati, A. Argianto, and B. P. Rini, "Inovasi Sistem Penjadwalan Laboratorium Terpadu melalui Aplikasi M-Room berbasis Google Spreadsheet di Poltekkes Kemenkes Jakarta I," *J. Pengelolaan Lab. Pendidik.*, vol. 7, no. 2, pp. 139–150, 2025, doi: 10.14710/jplp.7.2.139-150.
- [6] A. Dalimunthe, A. C. Sari, B. Maulana, F. Syahputra, and E. D. Suryanto, "RANCANG BANGUN SISTEM INFORMASI MANAJEMEN PENGELOLAAN LABORATORIUM BERBASIS WEB DI SEKOLAH MENENGAH KEJURUAN," *J. Teknol. Inf. Komun. DALAM Pendidik.*, vol. 10, no. 2, 2023, doi:

10.24114/jtikp.v10i2.54116.

- [7] J. R. Lex, A. Abbas, J. S. Toor, E. B. Khalil, B. Ravi, and C. M. Whyne, "Smart scheduling of arthroplasty surgery with machine learning and optimisation improves operating room utilisation," *BMJ Heal. care informatics*, vol. 33, no. 1, pp. 1–7, 2026, doi: 10.1136/bmjhci-2024-101420.
- [8] A. Fadlil, D. P. M, M. Ma'ruf, and Furizal, "Machine Learning-Based Early Prediction of Stunting Risk: A Comparative Study," *Methods Sci. Technol. Stud.*, vol. 1, no. 1, pp. 24–31, 2025, doi: 10.64539/msts.v1i1.2025.351.
- [9] X. Yang, "Construction and Application of Machine Learning Prediction Models for Library Space Utilization Efficiency," *J. Comb. Math. Comb. Comput.*, vol. 127b, no. October 2024, pp. 1801–1813, 2025, doi: 10.61091/jcmcc127b-100.
- [10] Ramesh Krishna Mahimalur, "Machine Learning Approaches for Resource Allocation in Heterogeneous Cloud-Edge Computing," *Int. J. Sci. Res. Comput. Sci. Eng. Inf. Technol.*, vol. 11, no. 2, pp. 2739–2748, 2025, doi: 10.32628/cseit25112758.