



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 2 (2026) pp: 25363-25375

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Systematic Literature Review Perbandingan Algoritma Tree-Based dan Boosting dalam Klasifikasi Diabetes Mellitus

Alidin M, Soni

Fakultas Ilmu Komputer, Universitas Muhammadiyah Riau

220401249@student.umri.ac.id, soni@umri.ac.id

Abstrak

Diabetes Mellitus (DM) merupakan penyakit metabolik kronis dengan prevalensi global yang terus meningkat, sehingga deteksi dini menjadi penting untuk mencegah komplikasi. Penelitian ini menyajikan Systematic Literature Review (SLR) yang membandingkan kinerja algoritma Tree-Based dan Boosting dalam klasifikasi Diabetes Mellitus. Sebanyak 51 artikel yang diterbitkan pada rentang tahun 2020-2025 dipilih melalui proses pencarian basis data, kriteria inklusi-eksklusi, dan quality assessment. Algoritma Tree-Based yang ditinjau meliputi Decision Tree, Random Forest, dan Extra Trees, sedangkan algoritma Boosting meliputi XGBoost, LightGBM, Gradient Boosting, AdaBoost, dan CatBoost. Karena studi yang dianalisis menggunakan dataset, preprocessing, skema validasi, dan metrik yang berbeda, sintesis dilakukan secara deskriptif dan bukan sebagai meta-analisis. Hasil review menunjukkan bahwa Random Forest lebih sering melaporkan performa tinggi dan stabil, sedangkan XGBoost serta algoritma Boosting lainnya tetap kompetitif, terutama ketika dikombinasikan dengan preprocessing, resampling, dan hyperparameter tuning. Teknik resampling seperti SMOTE-ENN umumnya membantu meningkatkan performa pada dataset tidak seimbang. Penggunaan Explainable Artificial Intelligence (XAI), khususnya SHAP, mendukung interpretabilitas model dengan mengidentifikasi fitur klinis penting seperti glukosa, BMI, usia, dan tekanan darah. Review ini memberikan sintesis yang lebih hati-hati sebagai dasar pemilihan algoritma dan strategi preprocessing pada sistem prediksi diabetes.

Kata kunci: Diabetes Melitus, Pembelajaran Mesin, Berbasis Pohon, Boosting, Explainable AI

1. Latar Belakang

Diabetes Mellitus (DM) merupakan penyakit metabolik kronis yang ditandai dengan meningkatnya kadar glukosa darah akibat gangguan produksi insulin, resistensi insulin, atau kombinasi keduanya. Penyakit ini menjadi salah satu masalah kesehatan global karena prevalensinya terus meningkat dari tahun ke tahun. International Diabetes Federation (IDF) memperkirakan terdapat sekitar 415 juta orang dewasa berusia 20–79 tahun yang hidup dengan diabetes pada tahun 2015 dan jumlah tersebut diproyeksikan meningkat menjadi 642 juta orang pada tahun 2040. Selain itu, sekitar 75% penderita diabetes berada di negara berpendapatan rendah dan menengah, sehingga menimbulkan tantangan besar bagi sistem kesehatan di berbagai negara (Ogurtsova et al).

World Health Organization (WHO) menjelaskan bahwa diabetes dapat menyebabkan berbagai komplikasi serius, seperti penyakit kardiovaskular, stroke, gagal ginjal, kebutaan, serta amputasi ekstremitas bawah yang berdampak pada penurunan kualitas hidup dan peningkatan angka kematian. WHO juga melaporkan bahwa jumlah penderita diabetes secara global meningkat dari 180 juta orang pada tahun 1980 menjadi 422 juta orang pada tahun 2014. Kondisi tersebut menunjukkan bahwa deteksi dini dan penanganan yang tepat sangat penting untuk mengurangi risiko komplikasi serta mendukung upaya pencegahan dan pengendalian diabetes secara lebih efektif (Who_global_report_on_diabetes__a_summary.2 (1), n.d.).

Di tengah meningkatnya kebutuhan deteksi dini, metode konvensional yang mengandalkan pemeriksaan laboratorium seringkali bersifat invasif, membutuhkan biaya tinggi, dan memerlukan waktu relatif lama. Perkembangan teknologi *machine learning* (ML) dalam beberapa tahun terakhir menawarkan pendekatan alternatif yang lebih cepat, efisien, dan berpotensi meningkatkan akurasi prediksi diabetes (Ghosh et al., 2021).

Berbagai model ML telah dikembangkan untuk mempelajari pola kompleks dari data klinis dan demografis guna mengidentifikasi individu berisiko tinggi sebelum gejala klinis muncul (Ibrahim et al., 2025). Penerapan machine learning dalam bidang kesehatan juga digunakan pada kasus lain, seperti deteksi stunting balita, dengan membandingkan algoritma Random Forest, KNN, Decision Tree, dan XGBoost untuk melihat efektivitas model klasifikasi pada data kesehatan (Bimawan et al., 2024). Dua kelompok algoritma yang banyak digunakan dalam prediksi diabetes adalah algoritma Tree-Based dan Boosting. Algoritma Tree-Based seperti Decision Tree, Random Forest, dan Extra Trees dikenal sesuai untuk data tabular medis karena mampu menangani pola non-linear dan relatif mudah diinterpretasikan. Beberapa studi melaporkan Random Forest dapat mencapai performa tinggi pada dataset tertentu (Oktaviana et al., 2024). Di sisi lain, algoritma Boosting seperti XGBoost, LightGBM, Gradient Boosting, AdaBoost, dan CatBoost bekerja dengan memperbaiki kesalahan model secara bertahap. Beberapa studi menunjukkan bahwa Gradient Boosting menghasilkan akurasi 86,75%, sedangkan studi lain melaporkan XGBoost mencapai akurasi 96,33% dengan ROC-AUC 0,99 pada dataset Pima Indians. Meskipun berbagai penelitian telah mengevaluasi performa algoritma *machine learning* dalam prediksi diabetes, sebagian besar studi hanya berfokus pada satu algoritma atau membandingkan sebagian kecil model. Selain itu, isu teknis seperti ketidakseimbangan kelas (class imbalance) masih menjadi tantangan, karena jumlah sampel pasien non-diabetes umumnya jauh lebih besar (Astofa et al., 2025).

Berbagai pendekatan resampling seperti SMOTE dan SMOTE-ENN telah digunakan untuk mengatasi hal tersebut, dan terbukti mampu meningkatkan performa model. Namun, efektivitas teknik-teknik ini pada algoritma Tree-Based dan Boosting belum banyak ditinjau secara komprehensif. Di sisi lain, perkembangan *Explainable Artificial Intelligence* (XAI), terutama metode SHAP, semakin penting dalam meningkatkan interpretabilitas model prediksi diabetes, tetapi penggunaannya pada kedua kelompok algoritma tersebut juga belum banyak direview secara sistematis.

Berdasarkan kondisi tersebut, diperlukan literature review yang komprehensif untuk membandingkan performa algoritma Tree-Based dan Boosting dalam prediksi Diabetes Mellitus, mengidentifikasi faktor-faktor yang memengaruhi performa model, mengevaluasi efektivitas teknik resampling pada dataset tidak seimbang, serta meninjau peran XAI dalam meningkatkan transparansi model. Review ini tidak dimaksudkan untuk menyimpulkan satu algoritma terbaik secara mutlak, tetapi untuk memberikan gambaran kecenderungan performa berdasarkan studi yang ditinjau. Penelitian literatur review ini bertujuan untuk menjawab pertanyaan: (1) bagaimana performa algoritma Tree-Based dan Boosting dalam klasifikasi Diabetes Mellitus, (2) faktor-faktor apa saja yang memengaruhi performa model, (3) seberapa efektif teknik resampling seperti SMOTE, SMOTE-ENN, dan ADASYN dalam meningkatkan performa model pada dataset tidak seimbang, serta (4) bagaimana aplikasi XAI, khususnya SHAP, dalam meningkatkan interpretabilitas model prediksi Diabetes Mellitus.

2. Metode Penelitian

Metodologi penelitian ini menggunakan pendekatan Systematic Literature Review (SLR) untuk mengidentifikasi, menyeleksi, mengevaluasi, dan mensintesis artikel ilmiah yang relevan dengan klasifikasi Diabetes Mellitus menggunakan algoritma Tree-Based dan Boosting. Algoritma Tree-Based yang dikaji meliputi Decision Tree, Random Forest, dan Extra Trees, sedangkan kelompok Boosting mencakup XGBoost, LightGBM, Gradient Boosting, AdaBoost, dan CatBoost. Pendekatan SLR digunakan agar proses tinjauan dilakukan secara sistematis, transparan, dan dapat ditelusuri kembali.

Perumusan *research question* disusun berdasarkan kebutuhan penelitian dan mengacu pada lima elemen PICOC, yaitu:

1. *Population* (P): Individu atau kelompok yang diteliti, seperti pasien atau dataset Diabetes Mellitus.
2. *Intervention* (I): Perlakuan yang diberikan, yaitu penggunaan algoritma Machine Learning.
3. *Comparison* (C): Perbandingan antar algoritma yang diteliti.
4. *Outcomes* (O): Hasil intervensi yang dinilai melalui metrik akurasi, precision, recall, F1-score, dan AUC-ROC.
5. *Context* (C): Lingkup penelitian, yaitu klasifikasi medis khususnya prediksi Diabetes Mellitus.

Kelima elemen PICOC yang digunakan sebagai dasar dalam penyusunan *research question* pada penelitian ini disajikan pada Tabel 1.

Tabel 1. Struktur PICOC

Elemen	Deskripsi
Population (P)	Studi tentang klasifikasi Diabetes Mellitus menggunakan Machine Learning, terutama algoritma Tree-Based (Decision Tree, Random Forest, Extra Trees) dan Boosting (XGBoost, LightGBM, Gradient Boosting, AdaBoost, CatBoost).
Intervention (I)	Penerapan algoritma Tree-Based dan Boosting, termasuk teknik preprocessing, resampling (SMOTE, SMOTE-ENN), dan penggunaan Explainable AI (XAI).
Comparison (C)	Perbandingan antara algoritma Tree-Based dan Boosting, serta perbandingan efektivitas teknik resampling dan XAI pada kedua kelompok algoritma.
Outcomes (O)	Performansi model yang diukur melalui akurasi, precision, recall, F1-score, dan AUC-ROC.
Context (C)	Penerapan algoritma Tree-Based dan Boosting dalam klasifikasi dan prediksi Diabetes Mellitus pada data kesehatan dan medis.

Berdasarkan struktur PICOC pada Tabel 1, disusun research question yang menjadi pedoman dalam pelaksanaan Systematic Literature Review (SLR), sebagaimana ditunjukkan pada Tabel 2.

Tabel 2. Research Question

RQ	Research Question	Motivasi / Tujuan / Manfaat
RQ1	Bagaimana performa algoritma Tree-Based dan Boosting dalam klasifikasi Diabetes Mellitus, dan algoritma mana yang menunjukkan hasil terbaik berdasarkan metrik evaluasi?	Mengidentifikasi algoritma paling efektif untuk klasifikasi Diabetes Mellitus.
RQ2	Faktor-faktor apa yang mempengaruhi performa model klasifikasi Diabetes Mellitus pada kedua kelompok algoritma?	Menganalisis faktor-faktor penentu performa agar diperoleh pemahaman mengenai kondisi optimal penggunaan algoritma.
RQ3	Seberapa efektif teknik resampling seperti SMOTE, SMOTE-ENN, dan ADASYN dalam meningkatkan performa algoritma Tree-Based dan Boosting pada dataset tidak seimbang?	Mengevaluasi efektivitas teknik resampling dalam mengatasi <i>class imbalance</i> .
RQ4	Bagaimana penerapan XAI, khususnya SHAP, dalam meningkatkan interpretabilitas model prediksi Diabetes Mellitus pada algoritma Tree-Based dan Boosting?	Menilai kontribusi XAI terhadap interpretabilitas dan transparansi model.

Berdasarkan Tabel 2, research question (RQ) disusun sebagai pedoman utama dalam pelaksanaan Systematic Literature Review (SLR). Keempat pertanyaan penelitian tersebut menjadi dasar dalam proses pencarian, seleksi, ekstraksi, serta sintesis data dari setiap artikel yang ditinjau. Dengan demikian, seluruh tahapan penelitian dilakukan secara sistematis agar hasil analisis dapat menjawab tujuan penelitian sesuai dengan ruang lingkup yang telah ditetapkan.

Proses pencarian literatur dilakukan pada IEEE Xplore, ScienceDirect, SpringerLink, PubMed, dan Google Scholar. Pencarian difokuskan pada artikel tahun 2020-2025 dengan kombinasi kata kunci: "diabetes prediction", "diabetes classification", "machine learning", "tree-based", "decision tree", "random forest", "extra trees", "boosting", "XGBoost", "LightGBM", "CatBoost", "SMOTE", "SMOTE-ENN", "ADASYN", "class imbalance", "SHAP", dan "explainable AI". String pencarian umum yang digunakan adalah: ("diabetes prediction" OR

"diabetes classification") AND ("machine learning" OR "tree-based" OR "boosting" OR "random forest" OR "XGBoost" OR "LightGBM") AND ("SMOTE" OR "class imbalance" OR "SHAP" OR "explainable AI").

Kriteria inklusi meliputi: artikel diterbitkan pada tahun 2020-2025, membahas klasifikasi atau prediksi Diabetes Melitus, menggunakan dataset medis terkait diabetes, menerapkan minimal satu algoritma Tree-Based atau Boosting, melaporkan metrik evaluasi, dan tersedia dalam full text. Kriteria eksklusi meliputi: artikel duplikat, review atau editorial, artikel yang tidak membahas Diabetes Melitus, artikel tanpa hasil eksperimen, artikel tanpa metrik evaluasi yang jelas, serta artikel di luar rentang tahun penelitian.

1. QA1. Diterbitkan dalam rentang tahun 2020-2025.
2. QA2. Berasal dari sumber akademik yang dapat ditelusuri, seperti IEEE Xplore, ScienceDirect, SpringerLink, PubMed, atau Google Scholar.
3. QA3. Berfokus pada klasifikasi atau prediksi Diabetes Melitus menggunakan machine learning.
4. QA4. Memuat algoritma Tree-Based atau Boosting sebagai model utama atau pembanding.
5. QA5. Melaporkan metrik evaluasi seperti accuracy, precision, recall, F1-score, AUC-ROC, atau metrik sejenis.
6. QA6. Menjelaskan dataset medis terkait diabetes yang digunakan.
7. QA7. Dapat diakses dalam bentuk full text sehingga metode dan hasil dapat diverifikasi.
8. QA8. Merupakan artikel penelitian empiris, bukan review, editorial, atau artikel opini.

Setiap artikel dinilai menggunakan skor quality assessment: 1 untuk memenuhi kriteria, 0,5 untuk memenuhi sebagian, dan 0 untuk tidak memenuhi. Artikel dengan skor minimal 6 dari 8 dipertahankan sebagai studi utama. Data yang diekstraksi meliputi nama penulis, tahun, sumber publikasi, dataset, algoritma, teknik preprocessing, penanganan class imbalance, metode validasi, metrik evaluasi, serta penggunaan XAI.

Sintesis hasil dilakukan secara deskriptif karena studi yang dianalisis memiliki heterogenitas tinggi, terutama dari sisi dataset, ukuran sampel, skema validasi, preprocessing, dan metrik evaluasi. Nilai rata-rata akurasi pada tabel dihitung sebagai rata-rata sederhana dari nilai akurasi yang dilaporkan pada studi yang memenuhi kriteria, bukan rata-rata berbobot berdasarkan ukuran dataset. Oleh karena itu, angka tersebut digunakan sebagai gambaran kecenderungan, bukan sebagai hasil meta-analisis yang bersifat mutlak.

3. Hasil dan Diskusi

Hasil proses pencarian literatur berdasarkan kriteria inklusi, eksklusi, dan quality assessment. Berdasarkan proses seleksi bertahap, diperoleh 51 artikel yang memenuhi kriteria inklusi, eksklusi, dan quality assessment. Alur seleksi ditunjukkan pada Tabel 3 sebagai ringkasan PRISMA sederhana.

Tabel 3. Tahapan Pencarian Paper

No	Tahapan Proses	Jumlah Artikel
1	Pencarian awal berdasarkan database dan kata kunci	3.247 artikel
2	Penghapusan duplikat dan dokumen tidak lengkap	2.920 artikel
3	Penyaringan rentang tahun (2020-2025)	1.856 artikel
4	Screening judul dan abstrak berdasarkan relevansi topik	342 artikel
5	Pemeriksaan full text dan kriteria inklusi-eksklusi	68 artikel
6	Lolos quality assessment dan digunakan dalam sintesis	51 artikel

Tahap pencarian awal menghasilkan 3.247 artikel. Setelah penghapusan duplikat, penyaringan tahun, screening judul dan abstrak, pemeriksaan full text, serta quality assessment, 51 artikel digunakan sebagai sumber utama sintesis. Artikel yang tidak memenuhi kriteria dikeluarkan karena tidak relevan dengan Diabetes Melitus, tidak menggunakan algoritma yang dikaji, tidak melaporkan metrik evaluasi, atau bukan penelitian empiris.

RQ1. Performa Algoritma Tree-Based dan Boosting dalam Klasifikasi Diabetes Melitus

Untuk menjawab RQ1, dilakukan analisis terhadap 51 jurnal yang membahas klasifikasi Diabetes Melitus menggunakan algoritma Tree-Based dan Boosting. Algoritma Tree-Based yang dianalisis meliputi Decision Tree, Random Forest, dan Extra Trees, sedangkan algoritma Boosting mencakup XGBoost, LightGBM, Gradient Boosting, AdaBoost, dan CatBoost.

Tabel 4. Pengelompokan Algoritma Berdasarkan Kategori

No	Kategori Algoritma	Jumlah Artikel (fokus utama)	Rata-rata Akurasi Deskriptif
1	Tree-Based	18	91,2%
2	Boosting	15	88,5%
3	Kombinasi/Hybrid	8	90,1%
4	Algoritma lain	10	85,3%

Berdasarkan Tabel 4, kategori Tree-Based merupakan fokus utama terbanyak dengan 18 artikel, disusul oleh Boosting sebanyak 15 artikel. Kategori pada Tabel 4 bersifat eksklusif, yaitu setiap artikel dikelompokkan berdasarkan fokus utama penelitian. Pengelompokan ini dibuat untuk memudahkan pembacaan tren umum penggunaan algoritma dalam klasifikasi diabetes melitus (Marwati & Fauzi, 2024). Beberapa studi lain juga menggunakan Naive Bayes, KNN, dan SVM sebagai metode pembandingan untuk melihat perbedaan akurasi dan kemampuan klasifikasi pada dataset diabetes melitus (Rahayu et al., 2023), (Rahmansyah et al., 2024).

Rata-rata akurasi deskriptif menunjukkan bahwa kelompok Tree-Based memperoleh nilai 91,2%, sedangkan Boosting memperoleh 88,5%. Selisih tersebut menunjukkan bahwa kedua kelompok algoritma relatif kompetitif. Namun, perbandingan ini perlu dibaca secara hati-hati karena setiap studi menggunakan dataset, preprocessing, validasi, dan ukuran sampel yang berbeda. Selain algoritma Tree-Based dan Boosting, beberapa studi juga menggunakan algoritma pembandingan seperti K-Nearest Neighbor, Naive Bayes, dan Decision Tree. Salah satu penelitian membandingkan ketiga metode tersebut menggunakan RapidMiner untuk melihat perbedaan performa masing-masing algoritma dalam prediksi penyakit diabetes (Ardianto & Rushendra, 2025), (Wafa et al., 2022).

Selain SVM, variasi algoritma K-Nearest Neighbor juga digunakan dalam prediksi diabetes. Salah satu penelitian menerapkan Kernel K-Nearest Neighbor untuk memprediksi potensi pengidap penyakit diabetes berdasarkan faktor risiko pasien. Studi ini menunjukkan bahwa algoritma berbasis kedekatan data masih relevan digunakan sebagai pembandingan terhadap algoritma Tree-Based dan Boosting dalam klasifikasi Diabetes Melitus (Rafi et al., 2022).

Selain algoritma Tree-Based dan Boosting, beberapa penelitian juga membandingkan algoritma pembandingan seperti Random Forest, dan Gradient Boosting dalam prediksi Diabetes Melitus. Salah satu studi menunjukkan bahwa Random Forest memperoleh performa lebih baik dibandingkan Gradient Boosting berdasarkan metrik accuracy, precision, recall, dan F1-score. Temuan ini memperlihatkan bahwa Random Forest memiliki kemampuan yang baik dalam menangani variasi data klinis, sedangkan Gradient Boosting tetap dapat digunakan sebagai model pembandingan berbasis boosting pada prediksi diabetes (Setyawan & Nur, 2025) (Nainggolan & Sinaga, 2023).

Selain perbandingan beberapa metode klasifikasi, algoritma K-Nearest Neighbor (KNN) juga digunakan dalam beberapa studi sebagai model pembandingan untuk prediksi Diabetes Melitus. Salah satu penelitian menerapkan KNN menggunakan RapidMiner pada dataset Pima Indian dan menunjukkan bahwa metode ini dapat digunakan untuk mengklasifikasikan data diabetes berdasarkan kemiripan antar data pasien. Meskipun bukan termasuk algoritma Tree-Based maupun Boosting, KNN tetap relevan dicatat karena sering digunakan sebagai pembandingan dalam evaluasi performa model klasifikasi diabetes (Saputra et al., 2025).

Selain penggunaan KNN sebagai model pembandingan, beberapa penelitian juga menerapkan tahapan CRISP-DM dalam proses prediksi penyakit diabetes. Salah satu studi menggunakan metode K-Nearest Neighbor dan

Logistic Regression untuk membandingkan kemampuan klasifikasi pada data diabetes. Meskipun kedua algoritma tersebut bukan termasuk kelompok Tree-Based maupun Boosting, keduanya tetap relevan dicatat sebagai pembandingan dalam melihat perbedaan performa model klasifikasi Diabetes Melitus (Aprilia et al., 2024).

Selain penggunaan KNN dengan RapidMiner, penelitian lain juga menerapkan algoritma K-Nearest Neighbor dengan proses normalisasi data untuk prediksi penyakit diabetes. Normalisasi digunakan agar skala nilai antar fitur menjadi lebih seimbang sehingga proses perhitungan jarak pada KNN dapat berjalan lebih optimal. Temuan ini menunjukkan bahwa kualitas preprocessing, khususnya normalisasi, berperan penting dalam meningkatkan performa algoritma pembandingan pada klasifikasi Diabetes Melitus (Sholeh et al., 2022).

Selain itu, penelitian lain juga menunjukkan bahwa berbagai algoritma machine learning dapat digunakan untuk prediksi Diabetes Melitus. Studi tersebut memperlihatkan bahwa model machine learning dapat membantu proses klasifikasi berdasarkan data pasien, sehingga relevan dijadikan pembandingan terhadap algoritma Tree-Based dan Boosting yang menjadi fokus utama dalam penelitian ini (Safitri et al., 2024).

Tabel 5. Performa Algoritma Tree-Based

No	Algoritma	Jumlah Studi	Akurasi Tertinggi	Akurasi Terendah	Rata-rata Akurasi
1	Random Forest	12	99,3%	74%	87,4%
2	Decision Tree	8	97,19%	65,06%	85,2%
3	Extra Trees	2	89%	83,12%	86,06%

Tabel 5, menunjukkan bahwa Random Forest merupakan algoritma Tree-Based yang paling sering muncul, yaitu pada 12 kemunculan studi. Algoritma ini memiliki akurasi tertinggi yang dilaporkan sebesar 99,3%, dengan rata-rata akurasi deskriptif sebesar 87,4%. Nilai tertinggi tersebut berasal dari studi tertentu sehingga tidak dapat langsung digeneralisasi sebagai performa umum Random Forest pada semua dataset. Mekanisme ensemble pada Random Forest membantu mengurangi risiko overfitting dan meningkatkan generalisasi model (Anggreini et al., 2025), (Sriyanto & Supriyatna, 2021).

Selain itu, penelitian lain juga menunjukkan bahwa algoritma Random Forest dapat digunakan untuk memprediksi kemungkinan diabetes pada tahap awal. Hasil penelitian tersebut memperlihatkan bahwa Random Forest mampu mengolah data klinis pasien dan menghasilkan performa klasifikasi yang baik, sehingga algoritma ini relevan digunakan sebagai salah satu metode Tree-Based dalam sistem prediksi Diabetes Melitus (Aprilia et al., 2021).

Hasil serupa juga ditemukan pada penelitian lain yang menerapkan pendekatan ensemble untuk prediksi risiko diabetes tahap awal. Penelitian tersebut menunjukkan bahwa Random Forest memperoleh performa yang baik dan mampu menjadi model yang kompetitif dibandingkan beberapa algoritma ensemble lainnya. Temuan ini memperkuat bahwa pendekatan ensemble, khususnya Random Forest, relevan digunakan dalam klasifikasi Diabetes Melitus karena mampu meningkatkan stabilitas dan kemampuan generalisasi model (Laila et al., 2022).

Decision Tree, meskipun lebih sederhana dan mudah diinterpretasikan, menunjukkan variasi performa yang cukup besar, dengan akurasi terendah 65,06% dan tertinggi 97,19%. Hal ini menunjukkan bahwa Decision Tree sangat sensitif terhadap ukuran dataset dan noise data (Febrian et al., 2024).

Hasil penelitian *Implementation of Decision Tree Method for Diabetes Mellitus Type 2 Prediction* menunjukkan bahwa metode Decision Tree mampu menghasilkan akurasi sebesar 92%, dengan nilai precision sebesar 92%, recall sebesar 91,5%, dan F1-score sebesar 91,5%. Hasil tersebut menunjukkan bahwa Decision Tree memiliki kemampuan yang baik dalam memprediksi Diabetes Melitus Tipe 2 menggunakan data klinis pasien (Aditya et al., 2024).

Selain digunakan sebagai model tunggal, Decision Tree juga sering dibandingkan dengan algoritma klasifikasi sederhana lainnya. Salah satu penelitian membandingkan metode Decision Tree dan Naive Bayes untuk prediksi

penyakit diabetes. Perbandingan tersebut menunjukkan bahwa Decision Tree tetap relevan digunakan karena memiliki struktur keputusan yang mudah dipahami, sedangkan Naive Bayes dapat menjadi pembanding untuk melihat perbedaan performa model pada data diabetes (Permana & Patwari, 2021).

Extra Trees juga menunjukkan performa yang kompetitif dalam klasifikasi Diabetes Melitus. Salah satu penelitian yang memanfaatkan teknik up-sampling pada dataset PIMA dan BRFSS melaporkan akurasi sebesar 89% pada dataset PIMA. Hasil tersebut menunjukkan bahwa mekanisme randomisasi pada Extra Trees mampu meningkatkan kemampuan generalisasi model dalam mendeteksi diabetes.

Perlu ditegaskan bahwa jumlah studi pada Tabel 5 dan Tabel 6 merepresentasikan jumlah kemunculan penggunaan algoritma, bukan jumlah artikel yang berdiri sendiri. Dalam SLR ini, satu artikel dapat menerapkan lebih dari satu algoritma machine learning untuk tujuan perbandingan. Oleh karena itu, total kemunculan algoritma pada tabel performa tidak harus sama dengan 51 artikel utama yang dianalisis.

Tabel 6. Performa Algoritma Boosting

No	Algoritma	Jumlah Studi	Akurasi Tertinggi	Akurasi Terendah	Rata-rata Akurasi
1	XGBoost	8	97,12%	76%	88,1%
2	LightGBM	6	90,6%	79,28%	84,2%
3	Gradient Boosting	5	86,75%	75%	82,5%
4	AdaBoost	3	86,64%	81,87%	84,2%
5	CatBoost	2	81%	73,67%	77,34%

Berdasarkan Tabel 6, XGBoost merupakan algoritma Boosting yang paling banyak digunakan dengan delapan kemunculan studi. Algoritma ini memiliki rata-rata akurasi deskriptif sebesar 88,1% serta akurasi tertinggi yang dilaporkan mencapai 97,12%. Temuan tersebut menunjukkan bahwa XGBoost menjadi salah satu algoritma Boosting yang paling kompetitif dalam klasifikasi Diabetes Melitus. Keunggulan XGBoost berkaitan dengan regularisasi bawaan, efisiensi komputasi, dan kemampuannya memodelkan hubungan non-linear pada data tabular (Dinanthi et al., 2024).

Penelitian lain yang secara khusus menggunakan model XGBoost juga menunjukkan bahwa algoritma ini dapat diterapkan untuk prediksi Diabetes Melitus. XGBoost bekerja dengan membangun model secara bertahap untuk memperbaiki kesalahan prediksi sebelumnya, sehingga mampu menghasilkan performa yang kompetitif pada data klasifikasi medis. Temuan ini memperkuat bahwa XGBoost menjadi salah satu algoritma Boosting yang relevan digunakan dalam sistem prediksi diabetes (Xie & Xu, 2024).

Penelitian lain yang berfokus pada algoritma Gradient Boosting juga menunjukkan bahwa metode ini dapat digunakan untuk prediksi Diabetes Melitus dengan performa yang baik. Gradient Boosting bekerja dengan membangun model secara bertahap untuk memperbaiki kesalahan prediksi sebelumnya, sehingga mampu meningkatkan kemampuan klasifikasi pada data diabetes. Temuan ini menunjukkan bahwa Gradient Boosting tetap relevan digunakan sebagai salah satu algoritma boosting dalam prediksi Diabetes Melitus (Goswami & Saxena, 2021).

Selain itu, Gradient Boosting juga pernah dibandingkan dengan Naive Bayes dalam prediksi pasien diabetes. Hasil perbandingan tersebut menunjukkan bahwa Gradient Boosting dapat menjadi alternatif yang lebih kompetitif karena proses boosting mampu memperbaiki kesalahan model secara bertahap. Perbandingan ini juga memperlihatkan bahwa algoritma boosting dapat memberikan performa yang lebih baik dibandingkan algoritma probabilistik sederhana pada kondisi dataset tertentu (Sari & Linda Larasati, 2024).

AdaBoost juga menunjukkan performa yang cukup baik dalam klasifikasi Diabetes Melitus dengan rata-rata akurasi sebesar 84,2%. Beberapa penelitian menunjukkan bahwa kombinasi AdaBoost dengan teknik penanganan ketidakseimbangan data seperti SMOTE mampu meningkatkan kemampuan model dalam mengidentifikasi pasien diabetes. Selain itu, pendekatan ensemble berbasis AdaBoost juga sering digunakan bersama algoritma lain untuk meningkatkan akurasi dan kemampuan generalisasi model pada dataset medis (Syahri et al., 2024), (Sidiq et al., 2025).

Beberapa penelitian lain juga menunjukkan performa tinggi dari algoritma XGBoost dalam klasifikasi Diabetes Melitus. Salah satu studi memperoleh akurasi sebesar 97,12%, sedangkan penelitian lain melaporkan akurasi 96,07% dengan nilai AUC mencapai 99,29%. Hasil tersebut memperkuat temuan bahwa XGBoost mampu memberikan performa yang kompetitif dalam menangani data medis serta mendukung deteksi dini diabetes secara efektif. Selain penggunaan XGBoost sebagai model tunggal, pendekatan hybrid juga diterapkan untuk meningkatkan performa prediksi diabetes. Salah satu penelitian menggabungkan XGBoost dan Support Vector Machine (SVM) dalam sistem pendukung keputusan prediksi penyakit diabetes. Hasil penelitian menunjukkan bahwa model Hybrid XGBoost-SVM memperoleh akurasi sebesar 77%, lebih tinggi dibandingkan model XGBoost dan SVM tunggal yang masing-masing memperoleh akurasi 75%. Temuan ini menunjukkan bahwa kombinasi model dapat menjadi alternatif dalam meningkatkan performa klasifikasi diabetes (Surono et al., 2025).

LightGBM dan Gradient Boosting menunjukkan performa yang relatif stabil, namun rata-rata akurasinya lebih rendah dibandingkan XGBoost. Hal ini dapat disebabkan oleh perbedaan strategi pemrosesan fitur dan sensitivitas terhadap parameter learning rate dan jumlah estimators (Alfath et al., 2025).

Salah satu studi menunjukkan bahwa algoritma LightGBM mampu mencapai akurasi sebesar 90,6% dalam diagnosis Diabetes Melitus. Hasil tersebut menunjukkan bahwa LightGBM efektif dalam menangani data medis serta mampu memberikan performa yang baik pada proses klasifikasi diabetes. Temuan ini memperkuat bahwa LightGBM termasuk algoritma Boosting yang relevan digunakan dalam prediksi Diabetes Melitus (Rufo et al., 2021).

Studi lain menunjukkan bahwa LightGBM dapat digunakan untuk menangani permasalahan klasifikasi diabetes melalui optimasi hyperparameter dan penanganan ketidakseimbangan data menggunakan SMOTE. Penerapan GridSearchCV dan RandomSearchCV pada LightGBM menghasilkan peningkatan performa model dengan akurasi terbaik mencapai 84%, sehingga menunjukkan pentingnya proses tuning dalam meningkatkan kualitas klasifikasi diabetes (Ramadanti et al., 2024).

Penggunaan LightGBM juga telah diterapkan pada kasus diabetes melitus gestasional. Hasil penelitian menunjukkan bahwa algoritma berbasis decision tree tersebut memiliki kemampuan klasifikasi yang baik dalam mendeteksi risiko diabetes selama masa kehamilan. Selain itu, penelitian ini juga menunjukkan bahwa penanganan class imbalance menggunakan ADASYN berkontribusi terhadap peningkatan performa model klasifikasi (M. R. Maulana & Wibisono, 2026).

Pendekatan hybrid dan kombinasi algoritma juga mulai banyak diterapkan pada model LightGBM. Salah satu penelitian menggabungkan K-Nearest Neighbors (KNN) dan LightGBM pada dataset Pima Indians Diabetes dan memperoleh akurasi sebesar 90,6%. Hasil tersebut menunjukkan bahwa kombinasi algoritma dapat meningkatkan kemampuan prediksi dibandingkan penggunaan model tunggal (M. N. Maulana et al., 2025), (Pramudyantoro et al., 2024a). CatBoost ditemukan pada dua studi yang memenuhi rentang tahun 2020-2025 dan menunjukkan akurasi sebesar 81% ketika dikombinasikan dengan teknik SMOTE. Temuan ini menunjukkan bahwa performa CatBoost masih dipengaruhi oleh karakteristik dataset, preprocessing, dan strategi penanganan ketidakseimbangan kelas (Syahri et al., 2024).

Tabel 7. Contoh Nilai Metrik Tertinggi yang Dilaporkan pada Studi Terpilih

No	Algoritma	Accuracy	Precision	Recall	F1-Score	AUC-ROC
1	Random Forest	99,3%	99,1%	99,5%	99,6%	1,00
2	XGBoost	97,12%	93,4%	97,16%	95,7%	0,99
3	Gradient Boosting	86,75%	83,73%	86,75%	83,60%	0,83

Tabel 7, menampilkan contoh nilai metrik tertinggi yang dilaporkan pada studi terpilih, bukan performa rata-rata seluruh studi. Nilai metrik Random Forest, XGBoost, dan Gradient Boosting pada tabel tersebut digunakan sebagai contoh perbandingan performa karena berasal dari studi yang mengevaluasi beberapa model berbasis Tree-Based dan Ensemble dalam prediksi diabetes melitus. Sementara itu, XGBoost menunjukkan keseimbangan yang

baik antara precision dan recall pada beberapa studi, sehingga relevan dalam konteks diagnosis medis yang membutuhkan pengurangan kesalahan klasifikasi. Gradient Boosting memiliki performa lebih rendah pada contoh studi yang ditampilkan, namun hasil tersebut tidak berarti algoritma tersebut selalu lebih buruk pada semua dataset. Dengan demikian, pemilihan algoritma tetap perlu mempertimbangkan karakteristik data dan desain eksperimen masing-masing penelitian.

RQ2. Faktor-Faktor yang Mempengaruhi Performa Model

Analisis terhadap RQ2 dilakukan dengan mengidentifikasi faktor-faktor yang memengaruhi performa algoritma Tree-Based dan Boosting.

Tabel 8. Faktor-Faktor yang Mempengaruhi Performa Model

No	Faktor	Jumlah Kemunculan	Kisaran Pengaruh yang Dilaporkan
1	Ukuran dataset	28	Meningkatkan akurasi 5–10%
2	Class imbalance	35	Menurunkan akurasi 10–15%
3	Preprocessing data	42	Meningkatkan akurasi 3–8%
4	Hyperparameter tuning	25	Meningkatkan akurasi 2–5%
5	Feature selection	18	Meningkatkan akurasi 2–4%
6	Teknik resampling	22	Meningkatkan akurasi 5–15%

Berdasarkan Tabel 8, faktor yang paling sering dibahas dalam literatur adalah preprocessing data (42 kemunculan) dan class imbalance (35 kemunculan). Class imbalance dilaporkan dapat menurunkan performa model, terutama ketika kelas non-diabetes dan diabetes tidak terdistribusi secara seimbang. Namun, kisaran pengaruh pada tabel merupakan ringkasan deskriptif dari studi yang ditinjau, bukan estimasi kausal yang berlaku umum pada semua dataset. Sebaliknya, penerapan preprocessing data yang tepat, seperti normalisasi, handling missing values, dan encoding fitur kategorikal, umumnya membantu meningkatkan kualitas input model. Hyperparameter tuning dan feature selection juga berkontribusi terhadap peningkatan performa, tetapi besar pengaruhnya bergantung pada algoritma, dataset, serta rancangan eksperimen yang digunakan (Jawza et al., 2025).

Pengaruh hyperparameter tuning juga terlihat pada algoritma Extra Trees. Salah satu penelitian membandingkan beberapa metode optimasi parameter, yaitu GridSearchCV, RandomSearchCV, Bayesian Optimization, dan Genetic Algorithm. Hasil penelitian menunjukkan bahwa kombinasi Extra Trees dan Genetic Algorithm menghasilkan akurasi terbaik sebesar 83,12%, yang menunjukkan bahwa pemilihan parameter yang tepat dapat meningkatkan performa model klasifikasi diabetes (Devarakonda et al., 2025). Faktor pemrosesan fitur juga memengaruhi performa model klasifikasi diabetes. Salah satu penelitian membandingkan kinerja XGBoost sebelum dan sesudah penerapan Principal Component Analysis (PCA). Hasil penelitian menunjukkan bahwa model tanpa PCA memperoleh akurasi 99,04%, sedangkan model dengan PCA memperoleh akurasi 98,08%. Meskipun akurasi dengan PCA sedikit lebih rendah, penerapan PCA tetap memberikan manfaat dalam efisiensi komputasi melalui reduksi dimensi fitur (Nusa & Indahsari, 2025).

Tabel 9. Pengaruh Ukuran Dataset

No	Ukuran Dataset	Jumlah Studi	Rata-rata Akurasi
1	Kecil (<1000)	15	82,3%
2	Sedang (1000–10000)	20	86,5%
3	Besar (>10000)	16	89,2%

Hasil pada Tabel 9 menunjukkan kecenderungan peningkatan akurasi seiring bertambahnya ukuran dataset. Dataset besar (>10.000 data) menghasilkan rata-rata akurasi deskriptif tertinggi (89,2%) karena berpotensi merepresentasikan variasi data klinis secara lebih luas. Meski demikian, ukuran dataset bukan satu-satunya faktor penentu karena kualitas data, distribusi kelas, dan skema validasi juga memengaruhi hasil.

Tabel 10. Pengaruh Class Imbalance

No	Penanganan	Jumlah Studi	Akurasi Sebelum	Akurasi Sesudah
1	Tidak ditangani	13	78,5%	–
2	SMOTE	15	79,2%	84,8%
3	SMOTE-ENN	8	70,8%	95,6%
4	ADASYN	3	80,0%	85,0%

Tabel 10 menunjukkan bahwa studi yang tidak menangani class imbalance cenderung memiliki akurasi lebih rendah. Penerapan SMOTE dan ADASYN dilaporkan mampu meningkatkan akurasi, sedangkan SMOTE-ENN menunjukkan peningkatan paling besar pada studi yang ditinjau. Namun, perbandingan ini perlu dibaca hati-hati karena nilai sebelum-sesudah berasal dari studi dan dataset yang tidak selalu sama. Penanganan class imbalance juga dapat dilakukan melalui kombinasi cost-sensitive learning dan teknik oversampling seperti SMOTE. Salah satu penelitian menunjukkan bahwa pendekatan tersebut dapat membantu model lebih memperhatikan kelas minoritas, sehingga proses klasifikasi diabetes menjadi lebih seimbang. Temuan ini memperkuat bahwa strategi penanganan data tidak seimbang perlu dipertimbangkan sebelum proses pelatihan model dilakukan (Pranto et al., 2020).

RQ3. Efektivitas Teknik Resampling

Analisis RQ3 difokuskan pada efektivitas teknik resampling dalam meningkatkan performa algoritma.

Tabel 11 Perbandingan Efektivitas Teknik Resampling

No	Teknik Resampling	Rata-rata Peningkatan Akurasi
1	SMOTE-ENN	+12,8%
2	SMOTE	+5,9%
3	ADASYN	+5,0%

Berdasarkan Tabel 11, SMOTE-ENN merupakan teknik resampling dengan rata-rata peningkatan akurasi terbesar pada studi yang melaporkan perbandingan sebelum-sesudah. Teknik ini tidak hanya menyeimbangkan distribusi kelas, tetapi juga mengurangi noise melalui proses pembersihan data. SMOTE dan ADASYN juga memberikan peningkatan performa, namun besarnya peningkatan tetap bergantung pada distribusi data dan algoritma yang digunakan (Amri et al., 2025). Selain digunakan pada algoritma Tree-Based dan Boosting, teknik SMOTE-ENN juga diterapkan pada model lain untuk menangani data diabetes yang tidak seimbang. Salah satu penelitian menggunakan SMOTE-ENN bersama fine-tuned LS-SVM untuk meningkatkan kualitas data sebelum proses klasifikasi dilakukan. Hasil tersebut menunjukkan bahwa SMOTE-ENN tidak hanya membantu menyeimbangkan kelas, tetapi juga mengurangi data noise sehingga performa klasifikasi diabetes dapat meningkat (Mohammed & Hama Saeed, 2025).

Selain teknik resampling, beberapa penelitian menerapkan pendekatan ensemble learning untuk meningkatkan performa klasifikasi diabetes. Salah satu studi mengombinasikan KNN, AdaBoost, dan LightGBM dalam sebuah model ensemble dan memperoleh akurasi sebesar 90,76%. Hasil tersebut menunjukkan bahwa kombinasi beberapa algoritma dapat meningkatkan kemampuan generalisasi model pada dataset tertentu (Sai et al., 2023). Penelitian lain menunjukkan bahwa kombinasi teknik resampling seperti SMOTE, ADASYN, dan SMOTE-ENN dapat meningkatkan kualitas data sebelum proses klasifikasi dilakukan. Pada penelitian tersebut, model GA-XGBoost yang dioptimasi menggunakan algoritma genetika dan dikombinasikan dengan metode stacking menghasilkan performa yang lebih baik dibandingkan model tunggal dalam prediksi diabetes (Li et al., 2024). Selain pendekatan GA-XGBoost dan stacking, penelitian lain juga menunjukkan bahwa stacking ensemble learning dapat digunakan untuk meningkatkan keberagaman data dan memperkuat kemampuan klasifikasi penyakit diabetes. Pendekatan ini mengombinasikan beberapa model agar hasil prediksi tidak hanya bergantung pada satu algoritma, sehingga dapat membantu meningkatkan stabilitas dan performa klasifikasi pada dataset diabetes (Majid et al., 2025).

RQ4. Penerapan XAI (SHAP)

Analisis RQ4 meninjau penerapan XAI, khususnya SHAP, dalam meningkatkan interpretabilitas model.

Tabel 12. Penggunaan SHAP pada Algoritma

Algoritma	Jumlah Studi	Jenis SHAP
Tree-Based & Boosting	Mayoritas	TreeSHAP

Tabel 12 menunjukkan bahwa sebagian besar studi yang menggunakan XAI pada algoritma Tree-Based dan Boosting menerapkan TreeSHAP karena kompatibel dengan model berbasis pohon. Penerapan SHAP memungkinkan identifikasi fitur-fitur penting seperti kadar glukosa, BMI, usia, insulin, dan tekanan darah sebagai faktor yang sering berkontribusi dalam prediksi Diabetes Melitus (Vakil et al., 2023).

Studi lain juga menerapkan pendekatan XAI menggunakan SHAP pada model XGBoost dan CatBoost untuk prediksi Type 2 Diabetes. Penelitian tersebut menunjukkan bahwa kombinasi SMOTE dengan algoritma boosting dapat membantu meningkatkan performa klasifikasi, sedangkan SHAP digunakan untuk menjelaskan kontribusi fitur terhadap hasil prediksi secara global maupun individual. Temuan ini menunjukkan bahwa XAI tidak hanya membantu meningkatkan transparansi model, tetapi juga mendukung interpretasi faktor risiko diabetes yang berpengaruh terhadap keputusan model (Rafie et al., 2025).

Tabel 13. Perbandingan Interpretabilitas Model

Aspek	Tanpa SHAP	Dengan SHAP
Transparansi	Rendah	Tinggi
Kepercayaan Klinisi	Rendah–Sedang	Tinggi
Validasi Klinis	Terbatas	Lebih baik

Berdasarkan Tabel 13, penggunaan SHAP dapat meningkatkan transparansi model dan membantu pengguna memahami alasan di balik hasil prediksi. Namun, klaim peningkatan kepercayaan klinisi perlu ditempatkan secara hati-hati karena sebagian besar studi masih bersifat eksperimental dan belum selalu melibatkan validasi langsung oleh tenaga klinis. Pentingnya interpretabilitas model juga terlihat pada pengembangan sistem pendukung keputusan klinis berbasis machine learning untuk prediksi ketergantungan insulin. Studi tersebut menunjukkan bahwa LightGBM mampu memberikan performa kompetitif dalam memanfaatkan data klinis pasien, sehingga berpotensi mendukung pengambilan keputusan medis yang lebih terarah (Pramudyantoro et al., 2024b).

Penelitian lain juga menunjukkan performa yang kuat dari algoritma Gradient Boosting pada prediksi Diabetes Melitus. Dengan menerapkan proses normalisasi data, up-sampling, feature selection, serta hyperparameter tuning, algoritma Gradient Boosting mampu mencapai akurasi sebesar 92,85%, lebih tinggi dibandingkan beberapa algoritma boosting lainnya pada dataset yang sama. Temuan ini menunjukkan bahwa kualitas preprocessing dan optimasi parameter memiliki kontribusi penting terhadap peningkatan performa model klasifikasi diabetes (Ganie et al., 2023). Selain meningkatkan transparansi, penerapan XAI melalui SHAP dan LIME juga membantu menjelaskan kontribusi setiap fitur terhadap hasil klasifikasi diabetes. Studi yang membandingkan Random Forest dan XGBoost menunjukkan bahwa XGBoost memperoleh akurasi 90,6% dan memberikan interpretasi yang lebih jelas terhadap faktor-faktor yang memengaruhi prediksi Diabetes Melitus (Nurul Puteri & Sumardin, 2024)..

4. Kesimpulan

Berdasarkan hasil Systematic Literature Review (SLR) terhadap 51 artikel ilmiah, dapat disimpulkan bahwa algoritma Tree-Based dan Boosting sama-sama banyak digunakan dan menunjukkan performa kompetitif dalam klasifikasi Diabetes Melitus. Berdasarkan studi yang ditinjau, Random Forest lebih sering melaporkan performa tinggi dan stabil pada data tabular medis, tetapi hasil tersebut tidak dapat dianggap sebagai keunggulan mutlak karena setiap studi menggunakan dataset, preprocessing, dan skema validasi yang berbeda. Algoritma Boosting, terutama XGBoost, menunjukkan performa yang kompetitif dan sering memberikan keseimbangan yang baik antara precision dan recall. Performa model dipengaruhi oleh beberapa faktor utama, yaitu ukuran dataset, ketidakseimbangan kelas, preprocessing data, feature selection, serta hyperparameter tuning. Teknik resampling seperti SMOTE-ENN dapat meningkatkan performa pada dataset tidak seimbang, tetapi efektivitasnya tetap bergantung pada karakteristik data. Selain aspek akurasi, penggunaan Explainable Artificial Intelligence (XAI) dengan metode SHAP dapat membantu meningkatkan transparansi dan interpretabilitas model dengan menunjukkan kontribusi fitur terhadap hasil prediksi. Penelitian selanjutnya disarankan untuk menggunakan protokol evaluasi yang lebih seragam, melaporkan skema validasi secara rinci, membandingkan algoritma pada dataset yang sama, serta mengintegrasikan resampling dan XAI secara lebih terkontrol.

Referensi

- Aditya, M. F., Pramuntadi, A., Wijaya, D. P., & Wicaksono, Y. (2024). Implementasi Metode Decision Tree pada Prediksi Penyakit Diabetes Melitus Tipe 2. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(3), 1104–1110. <https://doi.org/10.57152/malcom.v4i3.1284>
- Alfath, A. S., Wardhana, A. K., & Rumini. (2025). Hypertension Risk Prediction Using Stacking Ensemble of CatBoost, XGBoost, and LightGBM: A Machine Learning Approach. *Journal of Applied Informatics and Computing (JAIC)*, 9(6), 3146. <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Amri, Z., Muhammad Rodi, M. Nurul Wathani, Amir Bagja, & Zulkipli. (2025). Prediksi Diabetes Menggunakan Algoritma K-Nearest (KNN) Teknik SMOTE-ENN. *Infotek: Jurnal Informatika Dan Teknologi*, 8(1), 193–204. <https://doi.org/10.29408/jit.v8i1.27975>
- Anggreini, N. L., Yuliana, A., Ramdan, D. S., & Al-Dayyeni, W. (2025). Improving Diabetes Prediction Performance Using Random Forest Classifier with Hyperparameter Tuning. *Jurnal Teknik Informatika (Jutif)*, 6(4), 1847–1860. <https://doi.org/10.52436/1.jutif.2025.6.4.4755>
- Aprilia, A., Lo, P., Jennifer, V., & Tjioe, E. (2024). Penerapan Model CRISP-DM untuk Prediksi Penyakit Diabetes Menggunakan Metode K-Nearest Neighbor dan Logistic regression. *JURNAL SISTEM INFORMASI BISNIS*, 4, 48–57.
- Aprilia, W., Kurniawan, I., Baydhowi, M., & Haryati, T. (2021). SISTEMASI: Jurnal Sistem Informasi Prediksi Kemungkinan Diabetes pada Tahap Awal Menggunakan Algoritma Klasifikasi Random Forest. *Jurnal Sistem Informasi*, 10(1), 2540–9719. <http://sistemasi.ftik.unisi.ac.id>
- Ardianto, M. R., & Rushendra, R. (2025). PREDIKSI PENYAKIT DIABETES BERDASARKAN PERBANDINGAN KLASIFIKASI METODE K-NEAREST NEIGHBOR, NAÏVE BAYES, DAN DECISION TREE MENGGUNAKAN RAPID MINER. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 10(2), 973–985. <https://doi.org/10.29100/jupi.v10i2.6079>
- Astofa, A., Rosyani, P., & Apandi, S. (2025). BULLETIN OF COMPUTER SCIENCE RESEARCH Evaluasi Komparatif Algoritma Machine Learning untuk Prediksi Dini Diabetes. *BULLETIN OF COMPUTER SCIENCE RESEARCH*, 6(1), 558–565. <https://doi.org/10.47065/bulletincsr.v6i1.859>
- Bimawan, Z. I., Astuti, T., & Arsi, P. (2024). COMPARISON OF RANDOM FOREST, K-NEAREST NEIGHBOR, DECISION TREE, AND XGBOOST ALGORITHMS FOR DETECTING STUNTING IN TODDLERS. *Jurnal Teknik Informatika (Jutif)*, 5(6), 1599–1607. <https://doi.org/10.52436/1.jutif.2024.5.6.2629>
- Devarakonda, M., Bavisetti, N., S Veeresh, D. S., Kate, C., & Hyils Sharon Magdalene, A. (2025). A Comparative Study of Hyperparameter Tuning Methods for Diabetes Prediction using Extra Trees Classifier. *Grenze International Journal of Engineering and Technology*, 11(6), 6930–6939.
- Dinanthi, D. A., Ramadanti, E., Sri, C., Aditya, K., & Chandranegara, D. R. (2024). Diabetes Detection Using Extreme Gradient Boosting (XGBoost) with Hyperparameter Tuning. *Indonesian Journal of Electronics, Electromedical Engineering, and Medical Informatics*, 6(2), 78–84. <https://doi.org/10.35882/ijeeemi.v6i2.351>
- Febrian, M. G., Ferdiansyah, R., Nugraha, E. A., Satriatama, D., & Kusumastuti, R. (2024). PREDIKSI RISIKO DIABETES MENGGUNAKAN ALGORITMA DECISION TREE DENGAN APLIKASI RAPID MINER. *Amikom Surakarta*, 23(8), 14–24.
- Ganie, S. M., Pramanik, P. K. D., Bashir Malik, M., Mallik, S., & Qin, H. (2023). An ensemble learning approach for diabetes prediction using boosting techniques. *Frontiers in Genetics*, 14(10), 1–15. <https://doi.org/10.3389/fgene.2023.1252159>
- Ghosh, P., Azam, S., Karim, A., Hassan, M., Roy, K., & Jonkman, M. (2021). A comparative study of different machine learning tools in detecting diabetes. *Procedia Computer Science*, 192(1), 467–477. <https://doi.org/10.1016/j.procs.2021.08.048>
- Goswami, G., & Saxena, M. (2021). Analysis and High Accuracy Prediction of Diabetes using Gradient Boosting Algorithm. *Print International Journal of Research and Technology*, 9(4), 2321–7510. www.ijrt.org
- Ibrahim, M. C., Fachrudin, & Nurhadi. (2025). MALCOM: Indonesian Journal of Machine Learning and Computer Science Comparison of Diabetes Prediction Data Using Machine Learning Perbandingan Data Prediksi Diabetes Menggunakan Machine Learning. *MALCOM*, 5(4), 1423–1436. <https://doi.org/10.57152/malcom.v5i4.2301>
- Jawza, D. N., Mazdadi, M. I., Farmadi, A., Saragih, T. H., Kartini, D., & Abdullayev, V. (2025). Enhancing Diabetes Prediction Accuracy Using Random Forest and XGBoost with PSO and GA-Based Feature Selection. *Journal of Electronics, Electromedical Engineering, and Medical Informatics*, 7(2), 295–306. <https://doi.org/10.35882/ijeeemi.v7i2.626>
- Laila, U. e., Mahboob, K., Khan, A. W., Khan, F., & Taekeun, W. (2022). An Ensemble Approach to Predict Early-Stage Diabetes Risk Using Machine Learning: An Empirical Study. *Sensors*, 22(14), 2–15. <https://doi.org/10.3390/s22145247>
- Li, W., Peng, Y., & Peng, K. (2024). Diabetes prediction model based on GA-XGBoost and stacking ensemble algorithm. *PLoS ONE*, 19(9 September), 1–29. <https://doi.org/10.1371/journal.pone.0311222>
- Majid, N. K., Supriyanto, C., & Marjuni, A. (2025). Peningkatan Keberagaman Data untuk Klasifikasi Penyakit Diabetes Berbasis Stacking Ensemble Learning. *Jurnal Informatika: Jurnal Pengembangan IT*, 10(1), 1–10. <https://doi.org/10.30591/jpit.v10i1.7375>
- Marwati, F., & Fauzi, R. (2024). Prediksi Penyakit Diabetes Melitus Menggunakan Jaringan Syaraf Tiruan dengan Metode Backpropagation. *Jurnal Informatika Utama*, 2(1), 26–34. <https://doi.org/10.55903/jitu.v2i1.163>
- Maulana, M. N., Muljono, M., & Meindiawan, E. P. A. (2025). Comparative Analysis of Homogeneous and Heterogeneous Ensembles for Diabetes Classification Optimization. *Sinkron*, 9(1), 512–521. <https://doi.org/10.33395/sinkron.v9i1.14439>
- Maulana, M. R., & Wibisono, S. (2026). STUDI KOMPARATIF ALGORITMA RANDOM FOREST, GRADIENT BOOSTING, DAN LIGHTGBM PADA KLASIFIKASI RISIKO DIABETES MELITUS. *Jurnal Mahasiswa Teknik Informatika*, 10(2), 2116–2122.
- Mohammed, N., & Hama Saeed, M. (2025). An Efficient Categorization of Diabetes Imbalanced Data Using SMOTE-ENN With Fine-Tuned LS-SVM Algorithm. *Iraqi Journal for Computers and Informatics*, 51(1), 119–129. <https://doi.org/10.25195/ijci.v51i1.579>
- Nainggolan, S. P., & Sinaga, A. (2023). COMPARATIVE ANALYSIS OF ACCURACY OF RANDOM FOREST AND GRADIENT BOOSTING CLASSIFIER ALGORITHM FOR DIABETES CLASSIFICATION. *Sebatik*, 27(1), 97–102. <https://doi.org/10.46984/sebatik.v27i1.2157>
- Nurul Puteri, A., & Sumardin, A. (2024). Comparison of Random Forest and XGBoost for Diabetes Classification with SHAP and LIME Interpretation. *Jurnal Teknologi Rekayasa*, 9(2), 121–130. <https://doi.org/10.31544/jtera.v9.i1.2024.121-130>
- Nusa, R. B., & Indahsari, R. D. (2025). Komparasi Kinerja Algoritma XGBoost dengan Reduksi Dimensi PCA pada Klasifikasi Diabetes. *JUSIFOR : Jurnal Sistem Informasi Dan Informatika*, 4(2), 320–329. <https://doi.org/10.70609/jusifor.v4i2.8563>
- Ogurtsova, K., da Rocha Fernandes, J. D., Huang, Y., Linnenkamp, U., Guariguata, L., Cho, N. H., Cavan, D., Shaw, J. E., & Makaroff, L. E. (2017). IDF Diabetes Atlas: Global estimates for the prevalence of diabetes for 2015 and 2040. *Diabetes Research and Clinical Practice*, 128, 40–50. <https://doi.org/10.1016/j.diabres.2017.03.024>

DOI: <https://doi.org/10.31004/riggs.v5i2.12934>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

29. Oktaviana, A., Wijaya, D. P., Pramuntadi, A., & Heksaputra, D. (2024). Prediksi Penyakit Diabetes Melitus Tipe 2 Menggunakan Algoritma K-Nearest Neighbor (K-NN). *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(3), 812–818. <https://doi.org/10.57152/malcom.v4i3.1268>
30. Permana, B. A. C., & Patwari, I. K. D. (2021). Komparasi Metode Klasifikasi Data Mining Decision Tree dan Naïve Bayes Untuk Prediksi Penyakit Diabetes. *Infotek: Jurnal Informatika Dan Teknologi*, 4(1), 63–69. <https://doi.org/10.29408/jit.v4i1.2994>
31. Pramudyantoro, A., Utami, E., & Ariatmanto, D. (2024a). PENGGABUNGAN K-NEAREST NEIGHBORS DAN LIGHTGBM UNTUK PREDIKSI DIABETES PADA DATASET PIMA INDIANS: MENGGUNAKAN PENDEKATAN EXPLORATORY DATA ANALYSIS. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 9(3), 1133–1144. <https://doi.org/10.29100/jupi.v9i3.4966>
32. Pramudyantoro, A., Utami, E., & Ariatmanto, D. (2024b). PENGGABUNGAN K-NEAREST NEIGHBORS DAN LIGHTGBM UNTUK PREDIKSI DIABETES PADA DATASET PIMA INDIANS: MENGGUNAKAN PENDEKATAN EXPLORATORY DATA ANALYSIS. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 9(3), 1133–1144. <https://doi.org/10.29100/jupi.v9i3.4966>
33. Pranto, B., Mehnaz, M., Momen Sifat, & Syed Maruful Huq. (2020). *Prediction of diabetes using cost sensitive learning and oversampling techniques on Bangladeshi and Indian female patients*. 8(10).
34. Rafi, R. R., Athallah, Cholissodin, I., & Adikara, P. P. (2022). Prediksi Potensi Pengidap Penyakit Diabetes berdasarkan Faktor Risiko Menggunakan Algoritme Kernel K-Nearest Neighbor. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 6(8), 3777–3785. <http://j-ptiik.ub.ac.id>
35. Rafie, Z., Talab, M. S., Koor, B. E. Z., Garavand, A., Salehnasab, C., & Ghaderzadeh, M. (2025). Leveraging XGBoost and explainable AI for accurate prediction of type 2 diabetes. *BMC Public Health*, 25(1), 2–17. <https://doi.org/10.1186/s12889-025-24953-w>
36. Rahayu, C. A., Hartono, R., & Sudiarjo, A. (2023). PREDIKSI PENDERITA DIABETES MENGGUNAKAN METODE NAIVE BAYES. *Jurnal Informatika Dan Teknik Elektro Terapan*, 11(3), 261–266. <https://doi.org/10.23960/jitet.v11i3.3055>
37. Rahmansyah, N., Armonitha Lusinia, S., Raya Lubuk Begalung, J., & Barat, S. (2024). Analisa Prediksi Penyakit Diabetes Menggunakan Metode Naive Bayes dan K-NN Teknik informatika, Universitas Putra Indonesia YPTK. *Journal Of Social Science Research*, 5(1), 5311–5323.
38. Ramadanti, E., Dinathi, D. A., Sri, C., Aditya, K., & Chandranegara, R. (2024). Diabetes Disease Detection Classification Using Light Gradient Boosting (LightGBM) With Hyperparameter Tuning. *Jurnal Dan Penelitian Teknik Informatika*, 8(2), 956–963. <https://doi.org/10.33395/v8i2.13530>
39. Rufo, D. D., Debelee, T. G., Ibenthal, A., & Negera, W. G. (2021). Diagnosis of Diabetes Mellitus Using Gradient Boosting Machine (LightGBM). *Diagnostics*, 11(9), 2–14. <https://doi.org/10.3390/diagnostics11091714>
40. Safitri, E., Rofianto, D., Purwati, N., Kurniawan, H., & Karnila, S. (2024). Prediksi Penyakit Diabetes Melitus Menggunakan Algoritma Machine Learning. *Jurnal Sistem Dan Teknologi Informasi*, 12(4), 760–766. <https://doi.org/10.26418/justin.v12i4.84620>
41. Sai, M. J., Chettri, P., Panigrahi, R., Garg, A., Bhoi, A. K., & Barsocchi, P. (2023). An Ensemble of Light Gradient Boosting Machine and Adaptive Boosting for Prediction of Type-2 Diabetes. *International Journal of Computational Intelligence Systems*, 16(1), 14–20. <https://doi.org/10.1007/s44196-023-00184-y>
42. Saputra, D. C., Gabriel Carol Aldosion, Nurhidayat, S. S., Sukrinah, & Herdyawan, T. T. (2025). Implementasi Algoritma K-Nearest Neighbor (Knn) Menggunakan Rapid Miner Untuk Prediksi Penyakit Diabetes Berdasarkan Dataset Pima Indian. *Journal of Information Technology and Informatics Engineering*, (1), 36–40.
43. Sari, N. C., & Linda Larasati, T. (2024). Komparasi Algoritma Naïve Bayes dan Gradient Boosting untuk Prediksi Pasien Diabetes. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 10(2), 118–125. <https://doi.org/10.25077/teknosi.v10i2.2024.118-125>
44. Setyawan, N. H., & Nur, W. (2025). ANALISIS PERBANDINGAN METODE LOGISTIC REGRESSION, RANDOM FOREST, GRADIENT BOOSTING UNTUK PREDIKSI DIABETES. *JUPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 10(1), 150–162. <https://doi.org/10.29100/jupi.v10i1.5743>
45. Sholeh, M., Andayati, D., & Yuliana Rachmawati, R. (2022). DATA MINING MODEL KLASIFIKASI MENGGUNAKAN ALGORITMA K-NEAREST NEIGHBOR DENGAN NORMALISASI UNTUK PREDIKSI PENYAKIT DIABETES. *Jurnal TelKa*, 12(2), 77–87.
46. Sidiq, S., Alfian, & Mabrur, N. S. (2025). Pengembangan Model Prediksi Risiko Diabetes Menggunakan Pendekatan AdaBoost dan Teknik Oversampling SMOTE. *Jurnal Ilmiah Informatika Dan Ilmu Komputer (Jima-Ilkom)*, 4(1), 13–23. <https://doi.org/10.58602/jima-ilkom.v4i1.41>
47. Sriyanto, & Supriyatna, A. R. (2021). *Teknika 17 (1): 163-172* Prediksi Penyakit Diabetes Menggunakan Algoritma Random Forest. *IJCCS*, 1(17), 163–172.
48. Suro, M., Fadli, M., Purwanti, D. S., & Susanto, E. R. (2025). Hybrid XGBoost-SVM Model untuk Sistem Pendukung Keputusan dalam Prediksi Penyakit Diabetes. *INSOLOGI: Jurnal Sains Dan Teknologi*, 4(3), 443–454. <https://doi.org/10.55123/insologi.v4i3.5410>
49. Syahri, A., Fariha, U., Afandi, R., & Nurliyana, I. (2024). Comparison of Logistic Regression, Random Forest and Adaboost Algorithms for Diabetes Mellitus Classification. *IJATIS: Indonesian Journal of Applied Technology and Innovation Science*, 1(1), 41–46. <https://doi.org/10.57152/ijatiss.v1i1.1116>
50. Vakil, V., Pachchigar, S., Chavda, C., & Soni, S. (2023). *Explainable predictions of different machine learning algorithms used to predict Early Stage diabetes*. 7(3), 435–445.
51. Wafa, H. S., Hadiana, A. I., & Umbara, F. R. (2022). Prediksi Penyakit Diabetes Menggunakan Algoritma Support Vector Machine (SVM). *INFORMATICS AND DIGITAL EXPERT (INDEX)*, 4(1), 40–45. <https://e-journal.unper.ac.id/index.php/informatics>
52. *who_global_report_on_diabetes_a_summary.2 (1)*. (n.d.).
53. Xie, P., & Xu, J. (2024). Prediction of diabetes mellitus using XGBoost model. *Applied and Computational Engineering*, 67(1), 131–141. <https://doi.org/10.54254/2755-2721/67/20240646>