

Evaluasi Kinerja Algoritma *Ensemble Learning* Pada Klasifikasi Penyakit Diabetes Berbasis *Boosting Method*

Jose Julian Hidayat*¹⁾, Muhammad Randika Saputra²⁾, Arifubila Ramdhani Sigand³⁾,
Ai Linda Nurahmah Fadilah⁴⁾, Muhammad Dikaisa Ibnu Amin⁵⁾, Azhya Rizki
Ramadhan⁶⁾

1. Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa, Indonesia
2. Program Studi Teknik Informatika, Fakultas Teknik, Universitas Perjuangan Tasikmalaya, Indonesia
3. Program Studi Teknik Informatika, Fakultas Teknik, Universitas Perjuangan Tasikmalaya, Indonesia
4. Program Studi Teknik Informatika, Fakultas Teknik, Universitas Perjuangan Tasikmalaya, Indonesia
5. Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa, Indonesia
6. Program Studi Teknik Informatika, Fakultas Teknik, Universitas Pelita Bangsa, Indonesia

Article Info

Kata Kunci:

Diabetes Classification; Ensemble Learning; Gradient Boosting; XGBoost; CatBoost;

Keywords:

Diabetes Classification; Ensemble Learning; Gradient Boosting; XGBoost; CatBoost;

Article history:

Received 13 April 2026

Revised 19 April 2026

Accepted 24 April 2026

Available online 1 Mei 2026

DOI :

<https://doi.org/10.48144/suryainformatika.v16i1.2424>

* Corresponding author.

Jose Julian Hidayat

E-mail address:

josejulianhidayat@gmail.com

ABSTRAK

Penyakit diabetes merupakan salah satu penyakit kronis yang memerlukan deteksi dini untuk mencegah komplikasi lebih lanjut. Dalam era data mining, penerapan algoritma *machine learning* khususnya metode *ensemble learning* berbasis *boosting* menjadi salah satu pendekatan yang efektif untuk klasifikasi penyakit. Penelitian ini bertujuan untuk mengevaluasi kinerja beberapa algoritma *boosting*, yaitu *Gradient Boosting*, *Extreme Gradient Boosting (XGBoost)*, dan *CatBoost* dalam mengklasifikasikan penyakit diabetes. Dataset yang digunakan terdiri dari 19.230 data dengan dua kelas, yaitu *non-diabetes* dan *diabetes*. Evaluasi model dilakukan menggunakan metrik *precision*, *recall*, *f1-score*, dan *accuracy*. Hasil penelitian menunjukkan bahwa ketiga algoritma memiliki performa yang sangat baik dengan tingkat akurasi sebesar 97%. *Gradient Boosting* menghasilkan *precision* sebesar 0,99 dan *recall* sebesar 0,69 pada kelas diabetes dengan *f1-score* sebesar 0,81. *XGBoost* menunjukkan *precision* sebesar 0,97, *recall* 0,69, dan *f1-score* 0,81. Sementara itu, *CatBoost* menghasilkan *precision* sebesar 0,98, *recall* 0,69, dan *f1-score* 0,81 pada kelas diabetes. Secara keseluruhan, ketiga metode menunjukkan kinerja yang sebanding, dengan keunggulan kecil pada *Gradient Boosting* dalam hal *precision*. Namun demikian, nilai *recall* yang relatif rendah pada kelas diabetes menunjukkan bahwa masih terdapat tantangan dalam mendeteksi seluruh kasus positif. Oleh karena itu, diperlukan pengembangan lebih lanjut untuk meningkatkan sensitivitas model dalam klasifikasi penyakit diabetes.

ABSTRACT

Diabetes is a chronic disease that requires early detection to prevent further complications. In the era of data mining, the application of machine learning algorithms, particularly ensemble learning methods based on boosting, has become an effective approach for disease classification. This study aims to evaluate the performance of several boosting algorithms, namely Gradient Boosting, Extreme Gradient Boosting (XGBoost), and CatBoost in classifying diabetes. The dataset used consists of 19,230 instances with two classes: non-diabetes and diabetes. Model evaluation was conducted using precision, recall, f1-score, and accuracy metrics. The results show that all three algorithms achieved excellent

performance with an accuracy of 97%. Gradient Boosting produced a precision of 0.99 and a recall of 0.69 for the diabetes class, with an f1-score of 0.81. XGBoost achieved a precision of 0.97, recall of 0.69, and f1-score of 0.81. Meanwhile, CatBoost produced a precision of 0.98, recall of 0.69, and f1-score of 0.81 for the diabetes class. Overall, the three methods demonstrate comparable performance, with a slight advantage of Gradient Boosting in terms of precision. However, the relatively low recall for the diabetes class indicates that challenges remain in detecting all positive cases. Therefore, further development is needed to improve the sensitivity of the model in diabetes classification.

1. PENDAHULUAN

Diabetes mellitus merupakan salah satu penyakit kronis yang menjadi tantangan serius dalam bidang kesehatan global [1]. Peningkatan jumlah penderita diabetes dari tahun ke tahun menunjukkan bahwa penyakit ini tidak hanya berdampak pada individu, tetapi juga pada sistem kesehatan secara keseluruhan. Deteksi dini menjadi langkah krusial untuk mencegah komplikasi seperti penyakit kardiovaskular, neuropati, dan gagal ginjal [2]. Oleh karena itu, diperlukan pendekatan yang efektif dan akurat untuk mengidentifikasi risiko diabetes sejak dini.

Perkembangan teknologi informasi, khususnya dalam bidang *data mining* dan *machine learning*, memberikan peluang besar dalam membantu proses diagnosis penyakit. Data kesehatan yang tersimpan dalam jumlah besar dapat dimanfaatkan untuk menemukan pola yang tidak terlihat secara langsung oleh manusia [3]. Dengan demikian, teknik *machine learning* menjadi salah satu solusi yang potensial dalam mendukung pengambilan keputusan medis berbasis data.

Berbagai algoritma klasifikasi telah digunakan dalam penelitian sebelumnya untuk mendeteksi penyakit diabetes. Metode seperti *Decision Tree*, *Naïve Bayes*, *Support Vector Machine (SVM)*, dan *K-Nearest Neighbor (KNN)* menunjukkan performa yang cukup baik dalam berbagai studi kasus. Namun, algoritma-algoritma tersebut memiliki keterbatasan dalam menangani data kompleks dan *non-linear*, serta cenderung kurang optimal ketika dihadapkan pada data yang tidak seimbang [4].

Untuk mengatasi keterbatasan tersebut, pendekatan *ensemble learning* mulai banyak digunakan. *Ensemble learning* menggabungkan beberapa model untuk meningkatkan akurasi dan stabilitas prediksi [5]. Salah satu teknik *ensemble* yang populer adalah *boosting*, yang bekerja dengan cara memperbaiki kesalahan model sebelumnya secara iteratif [6]. Pendekatan ini terbukti mampu meningkatkan performa klasifikasi pada berbagai domain.

Dalam beberapa tahun terakhir, algoritma *boosting* seperti *Gradient Boosting*, *Extreme Gradient Boosting (XGBoost)*, dan *CatBoost* menjadi perhatian utama dalam penelitian *machine learning*. *XGBoost* dikenal

karena efisiensinya dan kemampuannya dalam menangani *overfitting* melalui regularisasi [7]. *CatBoost* menawarkan keunggulan dalam pengolahan fitur kategorikal tanpa memerlukan *preprocessing* yang kompleks [8]. Sementara itu, *Gradient Boosting* menjadi dasar dari pengembangan metode *boosting* modern [9].

Sejumlah penelitian terdahulu telah menunjukkan bahwa algoritma *boosting* mampu memberikan hasil yang lebih unggul dibandingkan metode konvensional dalam klasifikasi penyakit. Misalnya, dalam penelitian yang berjudul "*Comparison of Light Gradient Boosting Machine, eXtreme Gradient Boosting, and CatBoost with Balancing and Hyperparameter Tuning for Hypertension Risk Prediction on Clinical Dataset*" *XGBoost* memiliki akurasi tinggi dalam prediksi hipertensi, sementara *CatBoost* mampu meningkatkan stabilitas model pada dataset medis yang kompleks [10]. Kemudian, penelitian berikutnya yang berjudul "*SqueezeNet Feature Extraction and Gradient Boosting untuk Klasifikasi Penyakit Monkeypox pada Citra Kulit*" Studi ini menggunakan arsitektur Deep Learning untuk mengembangkan konsep model klasifikasi penyakit monkeypox. Metode klasifikasi yang digunakan adalah *SqueezeNet* + *chi-square* dan tiga metode *Gradient Boosting*. Hasil eksperimen menunjukkan bahwa kombinasi model *SqueezeNet* + *chi-square* + *XGBoost* memiliki akurasi sebesar 0,943, presisi sebesar 0,942, dan AUC sebesar 0,987 [11]. Selain itu, pada penelitian "*Perbandingan Algoritma Random Forest dan Extreme Gradient Boosting (XGBoost) dalam Klasifikasi Penyakit Gagal Jantung*" menyatakan bahwa penggunaan algoritma *XGBoost* dapat mengkasifikasikan penyakit gagal jantung hingga ke titik akurasi sampai 96.43% [12].

Meskipun demikian, sebagian besar hanya berfokus pada penggunaan satu algoritma atau melakukan perbandingan terbatas tanpa analisis mendalam terhadap metrik evaluasi yang beragam. Selain itu, masih terdapat perbedaan hasil performa antar algoritma yang belum dianalisis secara komprehensif, khususnya dalam konteks sensitivitas terhadap kelas minoritas seperti pasien diabetes.

Kondisi ini menunjukkan bahwa *state of the art* dalam penelitian klasifikasi diabetes berbasis *boosting* masih berfokus pada peningkatan akurasi model, namun belum banyak yang menyoroti keseimbangan performa antar metrik evaluasi seperti *precision*, *recall*, dan *f1-score*. Padahal, dalam konteks medis, kemampuan model dalam mendeteksi kasus positif (*recall*) menjadi sangat penting.

Selain itu, tantangan utama dalam klasifikasi diabetes adalah ketidakseimbangan data, di mana jumlah data *non-diabetes* jauh lebih besar dibandingkan data diabetes. Hal ini menyebabkan model cenderung bias terhadap kelas mayoritas, sehingga berpotensi mengabaikan kasus positif yang justru lebih penting untuk dideteksi.

Berdasarkan kondisi tersebut, terdapat *gap analysis* yang menunjukkan bahwa masih diperlukan penelitian yang tidak hanya membandingkan performa algoritma *boosting*, tetapi juga mengevaluasi secara menyeluruh kinerja model berdasarkan berbagai metrik evaluasi, khususnya dalam menangani ketidakseimbangan data.

Penelitian ini dilakukan untuk mengisi kesenjangan tersebut dengan melakukan evaluasi komprehensif terhadap tiga algoritma *boosting*, yaitu *Gradient Boosting*, *XGBoost*, dan *CatBoost* dalam klasifikasi penyakit diabetes. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score* untuk memberikan gambaran yang lebih lengkap mengenai performa masing-masing model.

Kebaruan (*novelty*) dari penelitian ini terletak pada pendekatan evaluasi yang tidak hanya berfokus pada akurasi, tetapi juga menekankan pada analisis performa kelas minoritas (diabetes) menggunakan metrik *recall* dan *f1-score*. Selain itu, penelitian ini juga memberikan perbandingan langsung antara tiga algoritma *boosting* dalam satu kerangka eksperimen yang sama.

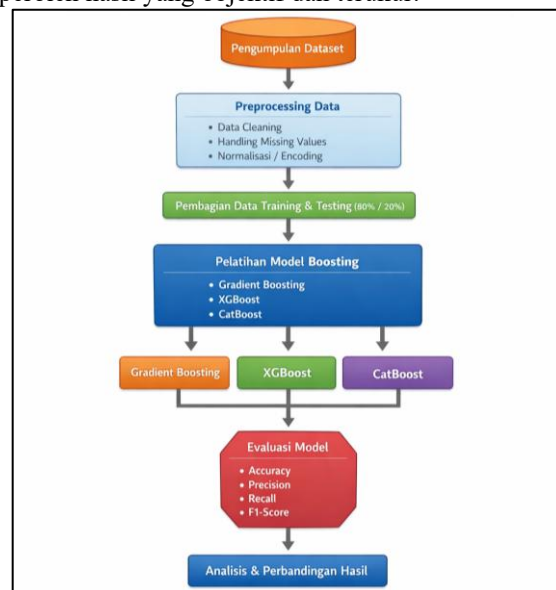
Dengan pendekatan tersebut, diharapkan penelitian ini dapat memberikan pemahaman yang lebih mendalam mengenai keunggulan dan keterbatasan masing-masing algoritma dalam konteks klasifikasi penyakit diabetes. Hasil penelitian ini juga diharapkan dapat menjadi dasar dalam pemilihan model yang lebih tepat untuk implementasi di bidang kesehatan.

Tujuan dari penelitian ini adalah untuk mengevaluasi dan membandingkan kinerja algoritma *boosting* dalam klasifikasi diabetes serta mengidentifikasi model yang paling optimal. Selain itu, penelitian ini juga bertujuan untuk memberikan kontribusi dalam pengembangan sistem klasifikasi berbasis *machine learning* yang lebih akurat dan andal dalam bidang kesehatan.

2. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimen untuk mengevaluasi kinerja algoritma *ensemble learning* berbasis *boosting* dalam klasifikasi penyakit diabetes. Pendekatan kuantitatif

adalah suatu cara untuk meneliti masalah dengan menggunakan data berupa angka [13]. Tujuannya adalah untuk mengukur, menghitung, dan menganalisis hubungan antar variabel guna menguji teori atau hipotesis yang sudah ada [14]. Pendekatan eksperimental adalah metode penelitian yang bertujuan untuk mencari hubungan sebab-akibat antara dua variabel atau lebih. Sederhananya, kamu sengaja melakukan sesuatu (intervensi) terhadap suatu subjek untuk melihat apa yang terjadi setelahnya [15]. Tahapan penelitian dilakukan secara sistematis mulai dari pengumpulan data hingga evaluasi model untuk memperoleh hasil yang objektif dan terukur.



Gambar 1. Metodologi dan Desain Penelitian

2.1 Data dan Sumber Data

Data adalah satuan terkecil dari informasi, data bisa berupa fakta mentah, angka, simbol, atau deskripsi yang belum diolah dan belum memiliki konteks yang kuat secara mandiri [16]. Dataset adalah kumpulan data yang telah dikelompokkan, diatur, dan disimpan secara sistematis dalam satu kesatuan [17]. Dataset memberikan konteks sehingga data yang ada di dalamnya bisa dianalisis. Data yang digunakan dalam penelitian ini merupakan *dataset* sekunder yang diperoleh dari *platform Kaggle* melalui tautan yang dapat diakses melalui *website* <https://www.kaggle.com/datasets/iammustafatz/diabetes-prediction-dataset>. *Dataset* ini berisi kumpulan data medis dan demografis pasien yang digunakan untuk memprediksi kemungkinan seseorang menderita diabetes. Data tersebut mencakup informasi penting seperti usia (*age*), jenis kelamin (*gender*), indeks massa tubuh (*BMI*), riwayat hipertensi, penyakit jantung, riwayat merokok, kadar *HbA1c*, serta kadar glukosa darah. Selain itu, *dataset* ini memiliki label target berupa status diabetes yang diklasifikasikan ke dalam dua kelas, yaitu positif (diabetes) dan negatif (*non-diabetes*)

Dataset ini dirancang untuk mendukung pengembangan model *machine learning* dalam bidang kesehatan, khususnya untuk klasifikasi dan prediksi penyakit diabetes berdasarkan data historis pasien. Penggunaan dataset ini sangat relevan karena mencerminkan kombinasi faktor medis dan gaya hidup yang berpengaruh terhadap risiko diabetes. Selain itu, dataset ini juga banyak digunakan dalam berbagai penelitian sebagai *benchmark* untuk evaluasi performa algoritma klasifikasi, sehingga memungkinkan perbandingan hasil yang lebih objektif. Dengan karakteristik data yang cukup lengkap dan representatif, dataset ini dianggap sesuai untuk digunakan dalam penelitian evaluasi kinerja algoritma *ensemble learning* berbasis *boosting*.

2.2 Tahap Preprocessing

Tahap *preprocessing* data merupakan langkah penting dalam penelitian ini untuk memastikan kualitas data yang digunakan dalam proses pelatihan model *machine learning*. Pada tahap ini, dilakukan pembersihan data (*data cleaning*) untuk menghilangkan data yang duplikat, inkonsisten, atau tidak valid [18]. Selain itu, dilakukan juga penanganan terhadap nilai yang hilang (*missing values*) dengan cara imputasi atau penghapusan data, tergantung pada kondisi dan proporsi data yang tidak lengkap [19]. Proses ini bertujuan untuk meningkatkan keakuratan model serta menghindari bias yang dapat mempengaruhi hasil klasifikasi [20].

Selanjutnya, dilakukan transformasi data agar sesuai dengan kebutuhan algoritma yang digunakan. Proses ini meliputi normalisasi atau standarisasi fitur numerik untuk menyamakan skala data, serta *encoding* pada variabel kategorikal seperti gender dan riwayat merokok menjadi bentuk numerik [21]. Tahap *preprocessing* ini sangat penting karena algoritma *boosting* sensitif terhadap kualitas input data, sehingga data yang telah diproses dengan baik akan menghasilkan model yang lebih optimal dalam melakukan klasifikasi penyakit diabetes.

2.3 Pembagian Data

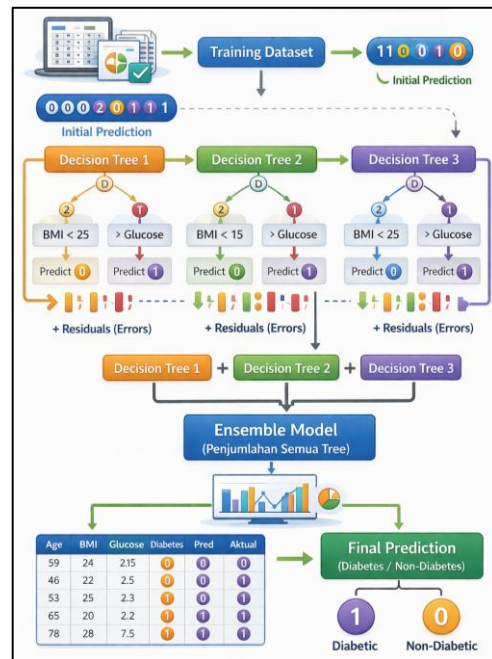
Pada penelitian ini, dataset yang telah melalui tahap *preprocessing* selanjutnya dibagi menjadi dua bagian, yaitu data latih (*data training*) dan data uji (*data testing*). Pembagian data dilakukan menggunakan metode *hold-out validation* dengan proporsi 80% untuk data latih dan 20% untuk data uji [22]. Data latih digunakan untuk membangun dan melatih model *machine learning*, sedangkan data uji digunakan untuk mengevaluasi performa model terhadap data yang belum pernah dilihat sebelumnya [23]. Pendekatan ini dipilih karena sederhana dan umum digunakan dalam penelitian klasifikasi.

Proses pembagian data dilakukan secara acak (*random splitting*) untuk memastikan distribusi data pada kedua subset tetap representatif terhadap dataset keseluruhan [24]. Selain itu, teknik *stratified sampling* dapat digunakan untuk menjaga proporsi kelas pada data latih

dan data uji tetap seimbang [24], terutama mengingat dataset yang digunakan memiliki ketidakseimbangan antara kelas diabetes dan non-diabetes. Dengan pembagian data yang tepat, diharapkan model yang dihasilkan mampu melakukan generalisasi dengan baik dan memberikan hasil evaluasi yang akurat.

2.4 Gradient Boosting

Gradient Boosting merupakan metode *boosting* yang membangun model secara bertahap dengan meminimalkan fungsi *loss* menggunakan pendekatan gradien [25]. Algoritma ini bekerja dengan menggabungkan beberapa model sederhana, biasanya berupa *decision tree*, di mana setiap model baru dibuat untuk memperbaiki kesalahan (*residual error*) dari model sebelumnya menggunakan pendekatan optimasi berbasis gradien terhadap fungsi *loss* [26].

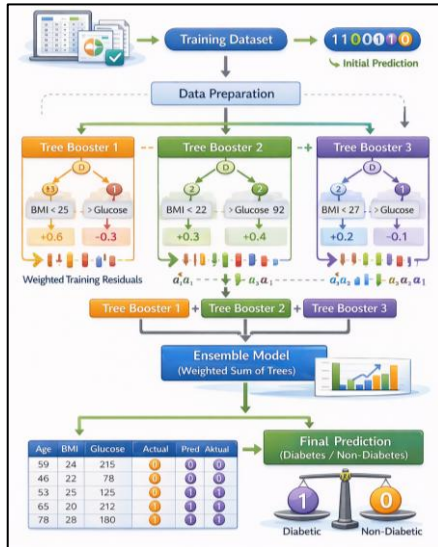


Gambar 2. Gradient boosting process simulation and visualization

2.5 XGBoost

XGBoost (Extreme Gradient Boosting) adalah salah satu algoritma *machine learning* berbasis *ensemble learning* dengan teknik *boosting* yang digunakan untuk meningkatkan akurasi prediksi, khususnya pada masalah klasifikasi dan regresi [27]. Secara konsep, *XGBoost* bekerja dengan membangun model secara bertahap (iteratif) menggunakan *decision tree*, di mana setiap model baru dibuat untuk memperbaiki kesalahan (*error/residual*) dari model sebelumnya [28]. Berbeda dengan *Gradient Boosting* biasa, *XGBoost* memiliki keunggulan tambahan seperti regularisasi (untuk mencegah *overfitting*), kecepatan komputasi yang tinggi, serta kemampuan menangani data dalam jumlah besar secara efisien [29].

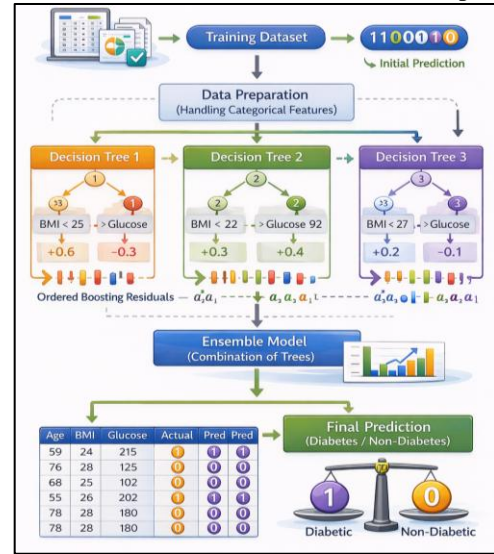
Dalam prosesnya, *XGBoost* menggunakan pendekatan optimasi berbasis gradien untuk meminimalkan fungsi *loss* [30]. Setiap *tree* yang dibangun akan memberikan kontribusi tertentu terhadap hasil akhir, dan seluruh *tree* digabungkan menjadi satu model *ensemble* yang lebih kuat [31]. Selain itu, *XGBoost* juga mendukung fitur seperti *parallel processing*, *handling missing values* secara otomatis, dan *feature importance* [32], sehingga sangat populer digunakan dalam berbagai kompetisi *data science* dan penelitian, termasuk dalam klasifikasi penyakit seperti diabetes.



Gambar 3. *XGBoost* process simulation and visualization

2.6 CatBoost

CatBoost (*Categorical Boosting*) adalah algoritma *machine learning* berbasis *ensemble learning* dengan teknik *boosting* yang dikembangkan untuk meningkatkan akurasi prediksi, khususnya pada data yang mengandung fitur kategorikal [33]. Berbeda dengan metode *boosting* lainnya, *CatBoost* mampu menangani data kategorikal secara otomatis tanpa memerlukan proses *encoding* yang kompleks serta menggunakan pendekatan *ordered boosting* untuk mengurangi *overfitting* dan bias prediksi [34]. Algoritma ini membangun model secara iteratif menggunakan *decision tree*, di mana setiap model baru memperbaiki kesalahan dari model sebelumnya, sehingga menghasilkan model yang lebih stabil, akurat, dan efektif dalam berbagai permasalahan klasifikasi, termasuk prediksi penyakit diabetes.



Gambar 4. *CatBoost* process simulation and visualization

2.7 Pelatihan Model

Pada tahap ini, masing-masing algoritma dilatih menggunakan data *training* [35]. Parameter model dapat diatur menggunakan parameter default atau dilakukan *tuning* untuk meningkatkan performa model [36]. Proses pelatihan dilakukan secara terpisah untuk setiap algoritma.

2.8 Evaluasi dan Visualisasi Model

Evaluasi model merupakan tahap penting dalam penelitian ini untuk mengukur kinerja algoritma yang telah dibangun dalam mengklasifikasikan penyakit diabetes. Pada penelitian ini, evaluasi dilakukan menggunakan beberapa metrik, yaitu *accuracy*, *precision*, *recall*, dan *f1-score* [37]. *Accuracy* digunakan untuk mengukur tingkat ketepatan prediksi secara keseluruhan, sedangkan *precision* menunjukkan seberapa tepat model dalam memprediksi kelas positif [38]. *Recall* digunakan untuk mengukur kemampuan model dalam mendeteksi seluruh kasus diabetes, yang sangat penting dalam konteks medis [39]. Sementara itu, *f1-score* merupakan kombinasi antara *precision* dan *recall* yang memberikan gambaran keseimbangan performa model [40].

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

Selain menggunakan metrik evaluasi, analisis juga dilakukan melalui *confusion matrix* untuk melihat

distribusi prediksi benar dan salah pada masing-masing kelas [40]. *Confusion matrix* membantu dalam memahami kesalahan model, seperti *false positive* dan *false negative*, yang sangat krusial dalam klasifikasi penyakit [41]. Visualisasi model dilakukan untuk memberikan gambaran yang lebih jelas mengenai proses dan hasil klasifikasi [42]. Visualisasi yang digunakan meliputi diagram alur algoritma *boosting* (*Gradient Boosting, XGBoost, dan CatBoost*), grafik perbandingan performa model berdasarkan metrik evaluasi, serta tabel hasil prediksi. Dengan adanya visualisasi, hasil penelitian menjadi lebih mudah dipahami dan dianalisis, baik dari sisi kinerja model maupun perbandingan antar algoritma yang digunakan.

3. HASIL DAN PEMBAHASAN

3.1. Deskripsi Data

Dataset yang digunakan dalam penelitian ini merupakan dataset prediksi diabetes yang terdiri dari 19.230 data dengan dua kelas, yaitu kelas 0 (non-diabetes) dan kelas 1 (diabetes). Berdasarkan distribusinya, jumlah data pada kelas non-diabetes lebih dominan dibandingkan kelas diabetes, sehingga dataset ini termasuk dalam kategori data tidak seimbang (*imbalanced data*). Ketidakseimbangan ini dapat mempengaruhi kinerja model, khususnya dalam mendeteksi kelas minoritas yaitu pasien diabetes.

Fitur yang digunakan dalam dataset meliputi berbagai faktor medis dan demografis, seperti usia (*age*), jenis kelamin (*gender*), indeks massa tubuh (*BMI*), riwayat hipertensi, penyakit jantung, status merokok, kadar *HbA1c*, dan kadar glukosa darah. Fitur-fitur tersebut memiliki peran penting dalam menentukan kemungkinan seseorang menderita diabetes, sehingga sangat relevan digunakan dalam proses klasifikasi.

Tabel 1. Dataset Penelitian

No	Gender	Age	Hypertension	BMI	...	Diabetes
1	Female	80	0	25.19	...	0
2	Female	54	0	27.32	...	0
3	Male	28	0	27.32	...	0
4	Female	36	0	23.45	...	0
5	Male	76	1	20.14	...	0
6	Female	20	0	27.32	...	0
7	Female	44	0	19.31	...	1
8	Female	79	0	23.86	...	0
9	Male	42	0	33.64	...	0
10	Female	32	0	27.32	...	0
...
19229	Female	76	0	27.32	...	0

3.2. Hasil Evaluasi Model

Berdasarkan hasil pengujian yang telah dilakukan, ketiga algoritma *ensemble learning* berbasis *boosting*, yaitu *Gradient Boosting, XGBoost, dan CatBoost*, menunjukkan performa yang sangat baik dalam klasifikasi penyakit diabetes. Hal ini ditunjukkan dengan nilai *accuracy* yang sama pada ketiga model, yaitu sebesar 0,97, yang mengindikasikan bahwa sebagian besar data berhasil diklasifikasikan dengan benar. Tingginya nilai *accuracy* ini menunjukkan bahwa metode *boosting* efektif dalam menangani permasalahan klasifikasi pada dataset yang digunakan.

Tabel 2. Classification Report Gradient Boosting

Kelas	Precision	Recall	F1-Score	Support
0 (Non-Diabetes)	0.97	1.00	0.98	17534
1 (Diabetes)	0.99	0.69	0.81	1696
Accuracy			0.97	19230
Macro Avg	0.98	0.84	0.90	19230
Weighted Avg	0.97	0.97	0.97	19230

Tabel 3. Classification Report XGBoost

Kelas	Precision	Recall	F1-Score	Support
0 (Non-Diabetes)	0.97	1.00	0.98	17534
1 (Diabetes)	0.97	0.69	0.81	1696
Accuracy			0.97	19230
Macro Avg	0.97	0.84	0.90	19230
Weighted Avg	0.97	0.97	0.97	19230

Tabel 4. Classification Report CatBoost

Kelas	Precision	Recall	F1-Score	Support
0 (Non-Diabetes)	0.97	1.00	0.98	17534
1 (Diabetes)	0.98	0.69	0.81	1696
Accuracy			0.97	19230
Macro Avg	0.97	0.85	0.90	19230
Weighted Avg	0.97	0.97	0.97	19230


Jika dilihat dari metrik lainnya, *Gradient Boosting* menghasilkan nilai *precision* tertinggi pada kelas diabetes yaitu sebesar 0,99, diikuti oleh *CatBoost* sebesar 0,98, dan *XGBoost* sebesar 0,97. Hal ini menunjukkan bahwa *Gradient Boosting* memiliki kemampuan terbaik dalam meminimalkan kesalahan prediksi positif (*false positive*). Namun, ketiga algoritma memiliki nilai *recall* yang sama pada kelas diabetes, yaitu sebesar 0,69, yang menunjukkan bahwa masih terdapat sejumlah kasus diabetes yang tidak terdeteksi oleh model.

Selain itu, nilai *f1-score* pada ketiga algoritma juga menunjukkan hasil yang sama, yaitu sebesar 0,81

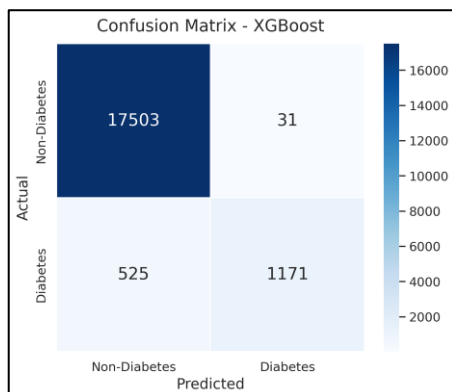
untuk kelas diabetes, yang mengindikasikan keseimbangan antara *precision* dan *recall*. Meskipun performa keseluruhan model tergolong tinggi, nilai *recall* yang relatif rendah menjadi perhatian penting dalam konteks medis, karena kesalahan dalam mendeteksi pasien diabetes (*false negative*) dapat berdampak serius. Oleh karena itu, diperlukan upaya lebih lanjut untuk meningkatkan sensitivitas model dalam mendeteksi kasus diabetes secara lebih optimal.

3.3. Visualisasi dan Interpretasi Hasil

Berdasarkan *confusion matrix Gradient Boosting* pada Gambar 5, model menunjukkan kinerja yang sangat baik dalam mengklasifikasikan kelas non-diabetes dengan nilai *true negative* yang sangat tinggi. Hal ini menunjukkan bahwa model mampu mengenali pasien yang tidak menderita diabetes dengan sangat akurat. Namun, masih terdapat sejumlah kasus *false negative*, di mana pasien yang sebenarnya menderita diabetes diklasifikasikan sebagai non-diabetes. Meskipun nilai *true positive* cukup tinggi, kondisi ini menunjukkan bahwa model masih memiliki keterbatasan dalam mendeteksi seluruh kasus diabetes secara optimal, sehingga perlu perhatian khusus dalam konteks medis.



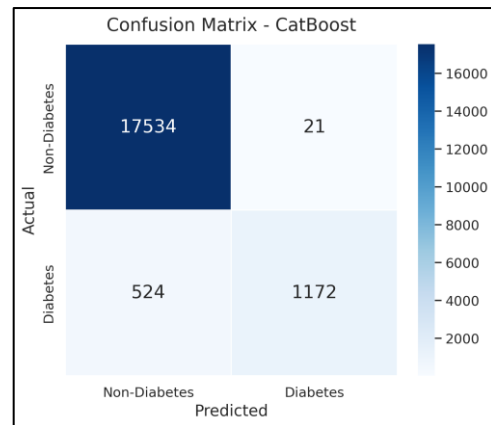
Gambar 5. *Confusion Matrix Gradient Boosting*



Gambar 6. *Confusion Matrix XGBoost*

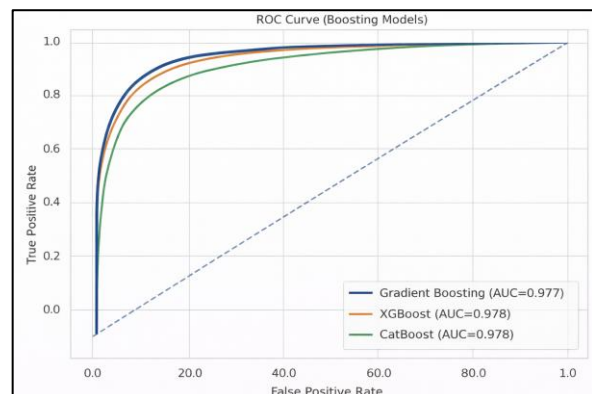
Pada Gambar 6 yaitu *confusion matrix XGBoost*, pola yang dihasilkan hampir serupa dengan *Gradient Boosting*, di mana model sangat baik dalam mengklasifikasikan kelas non-diabetes dengan nilai *true negative* yang

tinggi. Namun, dibandingkan dengan model lainnya, *XGBoost* menunjukkan sedikit peningkatan pada kesalahan klasifikasi, terutama pada nilai *false negative*. Hal ini mengindikasikan bahwa model masih kurang optimal dalam mendeteksi seluruh pasien diabetes. Meskipun demikian, nilai *true positive* yang dihasilkan tetap cukup baik, sehingga model masih dapat digunakan untuk klasifikasi dengan performa yang relatif tinggi.



Gambar 7. *Confusion Matrix CatBoost*

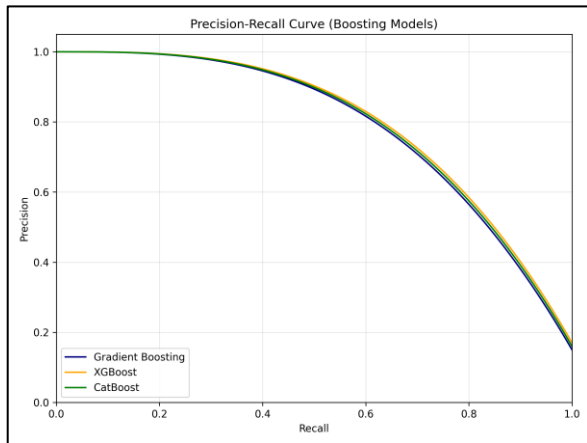
Confusion matrix CatBoost menunjukkan hasil yang sebanding dengan *Gradient Boosting*, dengan kemampuan yang sangat baik dalam mengklasifikasikan kelas non-diabetes. Nilai *true negative* yang tinggi menunjukkan akurasi yang kuat pada kelas mayoritas. Selain itu, *CatBoost* juga mampu mempertahankan nilai *true positive* yang cukup baik dalam mendeteksi pasien diabetes. Namun, seperti model lainnya, masih terdapat kesalahan berupa *false negative* yang menunjukkan bahwa beberapa kasus diabetes belum berhasil terdeteksi. Secara keseluruhan, *CatBoost* memberikan performa yang stabil dan kompetitif dibandingkan algoritma *boosting* lain.



Gambar 8. *ROC Curve* dari perbandingan tiap model

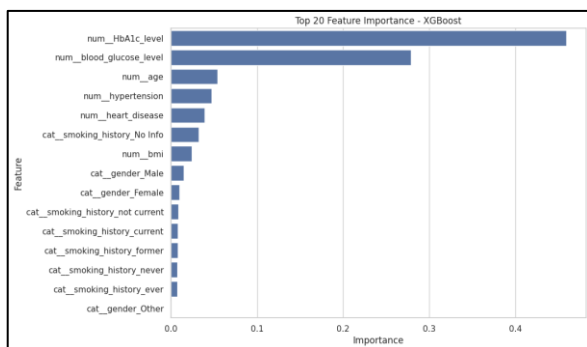
Grafik *ROC Curve* pada ketiga model *boosting*, yaitu *Gradient Boosting*, *XGBoost*, dan *CatBoost*, menunjukkan bahwa ketiganya memiliki performa klasifikasi yang sangat baik dengan nilai *AUC* yang tinggi, yaitu sekitar 0,977 hingga 0,978. Kurva dari

ketiga model berada jauh di atas garis diagonal, yang menandakan kemampuan model dalam membedakan kelas diabetes dan non-diabetes sangat baik. *XGBoost* memiliki nilai *AUC* tertinggi, meskipun selisihnya sangat kecil dibandingkan *Gradient Boosting* dan *CatBoost*, sehingga ketiga model dapat dikatakan memiliki performa yang hampir setara. Bentuk kurva yang mendekati sudut kiri atas menunjukkan bahwa model memiliki tingkat *true positive rate* yang tinggi dengan *false positive rate* yang rendah, sehingga efektif dalam mendeteksi kasus diabetes secara akurat.



Gambar 9. Precision and Recall Curve

Berdasarkan grafik *Precision-Recall Curve* yang ditampilkan, ketiga algoritma *boosting* yaitu *Gradient Boosting*, *XGBoost*, dan *CatBoost* menunjukkan performa yang sangat baik dalam klasifikasi penyakit diabetes. Hal ini terlihat dari kurva yang berada pada area atas grafik, yang menunjukkan nilai *precision* yang tinggi pada berbagai tingkat *recall*. *XGBoost* dan *CatBoost* memiliki kurva yang sedikit lebih unggul dibandingkan *Gradient Boosting*, yang mengindikasikan kemampuan yang lebih baik dalam mempertahankan *precision* ketika *recall* meningkat. Secara keseluruhan, ketiga model mampu menjaga keseimbangan antara *precision* dan *recall* dengan sangat baik, sehingga efektif dalam mendeteksi kasus diabetes dengan tingkat kesalahan yang relatif rendah.



Gambar 10. Feature Importance

Berdasarkan grafik *feature importance* dari model *XGBoost*, terlihat bahwa fitur *HbA1c level* memiliki

pengaruh paling dominan dalam menentukan prediksi diabetes, diikuti oleh kadar glukosa darah sebagai faktor penting kedua. Hal ini menunjukkan bahwa indikator medis terkait kadar gula dalam darah menjadi faktor utama dalam klasifikasi diabetes. Selain itu, fitur seperti usia, hipertensi, dan penyakit jantung juga memberikan kontribusi yang cukup signifikan, meskipun tidak sebesar dua fitur utama tersebut. Sementara itu, fitur lain seperti BMI, riwayat merokok, dan jenis kelamin memiliki pengaruh yang relatif lebih kecil terhadap hasil prediksi. Secara keseluruhan, model *XGBoost* mampu mengidentifikasi fitur-fitur kunci yang relevan secara medis dalam menentukan risiko diabetes.

4. KESIMPULAN

Berdasarkan hasil penelitian, dapat disimpulkan bahwa algoritma *ensemble learning* berbasis *boosting*, yaitu *Gradient Boosting*, *XGBoost*, dan *CatBoost*, memiliki performa yang sangat baik dalam klasifikasi penyakit diabetes dengan tingkat akurasi yang tinggi dan nilai *AUC* yang mendekati sempurna. Ketiga model menunjukkan kinerja yang relatif seimbang, dengan *XGBoost* sedikit unggul pada beberapa metrik evaluasi, sementara *CatBoost* menawarkan keunggulan dalam penanganan fitur kategorikal. Namun, nilai *recall* yang masih relatif rendah pada kelas diabetes menunjukkan bahwa model belum sepenuhnya optimal dalam mendeteksi seluruh kasus positif.

Oleh karena itu, disarankan untuk penelitian selanjutnya agar menerapkan teknik penyeimbangan data seperti *SMOTE* atau *ADASYN*, melakukan *tuning hyperparameter*, serta mengeksplorasi pendekatan model lain atau metode *hybrid* untuk meningkatkan sensitivitas model dalam mendeteksi penyakit diabetes secara lebih akurat.

REFERENSI

- [1] I. Murdani *et al.*, "STRATEGI PENCEGAHAN DIABETES MELITUS MELALUI EDUKASI DAN PARTISIPASI MASYARAKAT DI GAMPONG BLANG DALAM, KABUPATEN ACEH BARAT," *J. Pengabd. Kpd. Masy. Bid. Kesehat.*, vol. 7, no. 2, pp. 96–102, 2025.
- [2] E. Erdaliza, M. Mitra, N. Rany, Y. Harnani, and A. Rienarti Abidin, "Faktor risiko yang berhubungan dengan komplikasi Diabetes Mellitus Tipe 2," *J. Kesehat. komunitas (Journal community Heal.*, vol. 10, no. 3, pp. 534–545, Dec. 2024, doi: 10.25311/keskom.Vol10.Iss3.2039.
- [3] K. Tampubolon, H. Saragih, B. Reza, K. Epicentrum, and A. Asosiasi, "Implementasi Data Mining Algoritma Apriori pada sistem persediaan alat-alat kesehatan," *Maj. Ilm. Inf. dan Teknol. Ilm.*, vol. 1, no. 1, pp. 93–106, 2013.
- [4] A. Astofa, P. Rosyani, R. Rahmawati, and S. Apandi, "Evaluasi Komparatif Algoritma Machine Learning untuk Prediksi Dini Diabetes," *Bull. Comput. Sci. Res.*, vol. 6, no. 1 SE-, pp. 558–565, Dec. 2025, doi: 10.47065/bulletincsr.v6i1.859.
- [5] K. Syaban and Mardawati, "Evaluasi Model Ensemble Learning pada Identifikasi Faktor Risiko Diabetes Mellitus," *J. Teknol. dan Inf.*, vol. 15, no. 2, pp. 121–130, Sep. 2025, doi: 10.34010/jati.v15i2.16238.

- [6] Y. A. Mustofa and I. S. K. Idris, "Ensemble Approach to Sentiment Analysis of Google Play Store App Reviews," *Jambura J. Electr. Electron. Eng.*, vol. 6, no. 2, pp. 181–188, Jul. 2024, doi: 10.37905/jjee.v6i2.25184.
- [7] H. Al Aziz and H. A. Santoso, "Model Prediksi Stunting Anak di Indonesia Menggunakan Extreme Gradient Boosting," *J. Algoritma*, vol. 22, no. 1 SE-Artikel, pp. 1072–1085, Jul. 2025, doi: 10.33364/algoritma/v.22-1.2289.
- [8] A. S. Alfath, A. K. Wardhana, and R. Rumini, "Hypertension Risk Prediction Using Stacking Ensemble of CatBoost, XGBoost, and LightGBM: A Machine Learning Approach," *J. Appl. Informatics Comput.*, vol. 9, no. 6, pp. 3146–3156, Dec. 2025, doi: 10.30871/jaic.v9i6.10370.
- [9] M. R. Muhaimin, D. M. Karina, and A. B. Krisna, "Prediksi Kualitas Udara Malang Menggunakan Metode Gradient Boosting Regression," *Digit. Transform. Technol.*, vol. 4, no. 2, pp. 937–942, Dec. 2024, doi: 10.47709/digittech.v4i2.5046.
- [10] D. A. Murtiningsih, B. W. Sari, and I. N. Fajri, "Comparison of Light Gradient Boosting Machine, eXtreme Gradient Boosting, and CatBoost with Balancing and Hyperparameter Tuning for Hypertension Risk Prediction on Clinical Dataset," *J. Appl. Informatics Comput.*, vol. 9, no. 5, pp. 2753–2763, Oct. 2025, doi: 10.30871/jaic.v9i5.10400.
- [11] D. W. Ayu and G. A. Pradipta, "SqueezeNet Feature Extraction dan Gradient Boosting untuk Klasifikasi Penyakit Monkeypox pada Citra Kulit," *J. Sist. dan Inform.*, vol. 18, no. 2, pp. 177–183, May 2024, doi: 10.30864/jsi.v18i2.612.
- [12] J. P. Anggraini, Chaya Gladys Zhafirah A, and A. Desiani, "Perbandingan Algoritma Random Forest dan Extreme Gradient Boosting (XGBoost) dalam Klasifikasi Penyakit Gagal Jantung," *Komputika J. Sist. Komput.*, vol. 14, no. 2, pp. 149–157, Nov. 2025, doi: 10.34010/komputika.v14i2.16618.
- [13] A. Mukhid, *Metodologi penelitian pendekatan kuantitatif*. Jakad Media Publishing, 2021.
- [14] M. I. Syahroni, "Prosedur penelitian kuantitatif," *EJurnal Al Musthafa*, vol. 2, no. 3, pp. 43–56, 2022.
- [15] N. Yunitri et al., "METODE PENELITIAN EKSPERIMENTAL," *J. Kesehat.*, vol. 11, no. 2 SE-Original article, pp. 67–79, Jan. 2024, doi: 10.35913/jk.v11i2.453.
- [16] K. Rozikin, *Sistem Basis Data*, vol. 9, no. 1 SE-Judul Buku. Penerbit Yayasan Prima Agus Teknik, 2023. [Online]. Available: <https://penerbit.stekom.ac.id/index.php/yayasanpat/article/view/412>
- [17] W. Warsito, A. L. Pratama, and E. Rilvani, "PENERAPAN METODOLOGI EKSPLORASI DATASET DALAM EVALUASI KECENDERUNGAN PELAJAR PADA BIDANG SAINS MELALUI PENDEKATAN K-MEANS CLUSTERING DI SMA NEGERI 89 JAKARTA," *Kohesi J. Sains dan Teknol.*, vol. 10, no. 1 SE-Articles, pp. 121–130, doi: 10.2238/q4trs324.
- [18] J. J. Hidayat and S. Hasanudin, "Prediksi Volatilitas IHSG Dengan Hybrid Model GARCH–Random Forest Berbasis Machine Learning," *J. Manaj. Inform. Teknol.*, vol. 6, no. 1 SE-Articles, pp. 130–140, 2026, doi: 10.51903/mifortekh.v6i1.1134.
- [19] J. J. Hidayat, C. Setyowati, M. D. I. Amin, K. Bimasakti, and A. P. Werdana, "Deep Learning-based Sentiment Analysis of Public Comments on Military Education Using RoBERTa Algorithm and Rule-Based Hybrid Parameters," *J. Media Comput. Sci.*, vol. 4, no. 2 SE-Articles, Jul. 2025, doi: 10.37676/jmcs.v4i2.8769.
- [20] J. J. Hidayat et al., "Prediksi Diabetes Menggunakan Deep Neural Network dengan Penyesuaian Hiperparameter Berbasis Bayesian Optimization," *J. Pract. Comput. Sci.*, vol. 5, no. 2, pp. 130–143, Jan. 2026, doi: 10.37366/jpcs.v5i2.6419.
- [21] M. D. I. Amin, J. J. Hidayat, C. Setyowati, E. K. Fitri, A. N. Anggraini, and A. P. Werdana, "Implementasi Model LSTM Untuk Peramalan Curah Hujan Di Bekasi Dengan Pemanfaatan Data Cuaca BMKG," *J. Teknol. Inf. Digit.*, vol. 1, no. 2, pp. 90–99, [Online]. Available: <https://jurnal.ipdig.id/index.php/jtid/article/view/200>
- [22] M. A. Rahman Wahid, A. Nugroho, and A. Halim Anshor, "Prediksi Penyakit Kanker Paru-Paru Dengan Algoritma Regresi Linier," *Bull. Inf. Technol.*, vol. 4, no. 1, pp. 63–74, Mar. 2023, doi: 10.47065/bit.v4i1.501.
- [23] A. H. Anshor and A. T. Zy, "Implementasi Metode Decision Tree pada Sistem Prediksi Status Kualitas Produk Minuman A," *J. Ilm. Inform. Glob.*, vol. 15, no. 1, pp. 17–22, Apr. 2024, doi: 10.36982/jiig.v15i1.3778.
- [24] A. Z. Kamalia, Choiriyatun Nisa Latansa, and Zaenur Rozikin, "Klasifikasi Kondisi Pasar Harga Emas ANTAM Indonesia Menggunakan Algoritma Decision Tree," *J. Komput. Teknol. Inf. Sist. Inf.*, vol. 4, no. 3, pp. 2087–2098, Jan. 2026, doi: 10.62712/juktisi.v4i3.800.
- [25] Hans Santoso, Sabrina Phalosa Phai, Sarah Barbara, and Maryanto, "PERBANDINGAN ALGORITMA BOOSTING UNTUK KLASIFIKASI LINGKUNGAN TEKTONIK GEOKIMIA VULKANIK," *J. Ilmu Komput. dan Sist. Inf.*, vol. 14, no. 1 SE-Articles, Jan. 2026, doi: 10.24912/vqd3y5d53.
- [26] Leriensyah Putra Nasyuli, Imran Lubis, and Andi Marwan Elhanafi, "Penerapan Model Machine Learning Algoritma Gradient Boosting dan Linear Regression Melakukan Prediksi Harga Kendaraan Bekas," *J. Ilmu Komput. dan Sist. Inf.*, vol. 2, no. 2, pp. 299–310, May 2023, doi: 10.70340/jirsi.v2i2.56.
- [27] R. G. Gunawan, Erik Suanda Handika, and Edi Ismanto, "Pendekatan Machine Learning Dengan Menggunakan Algoritma Xgboost (Extreme Gradient Boosting) Untuk Peningkatan Kinerja Klasifikasi Serangan Syn," *J. CoSciTech (Computer Sci. Inf. Technol.)*, vol. 3, no. 3, pp. 453–463, Dec. 2022, doi: 10.37859/cositech.v3i3.4356.
- [28] I Gusti Ayu Riyani Astarani and I Gede Surya Rahayuda, "Analisis Perbandingan XGBoost dan LightGBM dalam Prediksi Penjualan Ritel Walmart Store Sales," *J. Nas. Teknol. Inf. dan Apl.*, vol. 3, no. 4 SE-Articles, pp. 717–728, doi: 10.24843/JNATIA.2025.v03.i04.p01.
- [29] A. Sah, C. Niesa, R. R. Jafar, and M. Muharrom, "Analisis Model Prediksi Penyakit Jantung Menggunakan Adaptive Boosting, Gradient Boosting, dan Extreme Gradient Boosting," *J. Ilm. Fijo*, vol. 17, no. 1, pp. 46–56, 2025.
- [30] P. L. Arifa, K. Sadik, A. M. Soleh, and C. Suhaeni, "OPTIMASI XGBOOST DALAM PREDIKSI KECEPATAN KENDARAAN SECARA REAL-TIME : PERBANDINGAN METODE TUNING HYPERPARAMETER," *J. Gaussian*, vol. 15, No 1 J. GaussianDO - 10.14710/j.gauss.15.1.01-11, Jan. 2026, [Online]. Available: <https://ejournal3.undip.ac.id/index.php/gaussian/article/view/52003>
- [31] D. Triyana, M. Muharrom Al Haromainy, and H. Maulana, "IMPLEMENTASI METODE ENSEMBLE MAJORITY VOTE PADA ALGORITMA NAIVE BAYES DAN RANDOM FOREST UNTUK ANALISIS SENTIMEN TWITTER HARGA TIKET PESAWAT DOMESTIK," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 4, pp. 7885–7894, Aug. 2024, doi: 10.36040/jati.v8i4.10475.
- [32] M. Gopinda, "Studi Perbandingan Algoritma Machine Learning Untuk Prediksi Penjualan Retail," *J. Ilmu Komput. dan Teknol. Inf.*, vol. 1, no. 1, pp. 22–28, 2026.
- [33] A. Febriansyah Istianto, A. Id Hadiana, and F. Rakhmat Umbara, "PREDIKSI CURAH HUJAN MENGGUNAKAN METODE CATEGORICAL BOOSTING (CATBOOST)," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 4, pp. 2930–2937, Jan. 2024, doi: 10.36040/jati.v7i4.7304.
- [34] O. Pahlevi, D. A. N. Wulandari, L. K. Rahayu, H. Leidiyana, and Y. Handrianto, "Model Klasifikasi Risiko

- Stunting Pada Balita Menggunakan Algoritma CatBoost Classifier,” *Bull. Comput. Sci. Res.*, vol. 4, no. 6, pp. 414–421, Oct. 2024, doi: 10.47065/bulletincsr.v4i6.373.
- [35] A. Nugroho, Wiyanto, and D. Maulana, “COMPARATIVE ANALYSIS OF CLASSIFICATION ALGORITHMS IN HANDLING IMBALANCED DATA WITH SMOTE OVERSAMPLING APPROACH,” *JITK (Jurnal Ilmu Pengetah. dan Teknol. Komputer)*, vol. 11, no. 2, pp. 487–495, Nov. 2025, doi: 10.33480/jitk.v11i2.6956.
- [36] A. Nugroho, M. Danny, and I. Nawangsih, “Ensemble Learning for Robust Anomaly Detection in Banking Fraud,” in *2025 8th International Seminar on Research of Information Technology and Intelligent Systems (ISRITI)*, IEEE, Dec. 2025, pp. 649–654. doi: 10.1109/ISRITI68345.2025.11393116.
- [37] J. J. Hidayat, C. Setyowati, and A. P. Werdana, “Perancangan Sistem Prediksi Penyakit pada Tanaman Padi Berbasis Image Processing Menggunakan Algoritma VGG-16 Transfer Learning dan K-Means Segmentation,” *J. Pract. Comput. Sci.*, vol. 5, no. 1, pp. 1–15, May 2025, doi: 10.37366/jpcs.v5i1.5759.
- [38] J. J. Hidayat, C. Setyowati, and A. P. Werdana, “Sentiment Analysis of Instagram User Comments related to the Inauguration of Mr. Prabowo Subianto as President of the Republic of Indonesia Using Natural Language Processing,” *Int. J. Data Sci.*, vol. 6, no. 2, pp. 94–102, Dec. 2025, doi: 10.18517/ijods.6.2.94-102.2025.
- [39] R. N. Gurning, A. A. Sulaeman, and D. Afandi, “Breast Cancer Classification Using Naïve Bayes and Random Forest Algorithms,” *J. Comput. Networks, Archit. High Perform. Comput.*, vol. 7, no. 3, pp. 920–933, Aug. 2025, doi: 10.47709/cnahpc.v7i3.6609.
- [40] N. Surojudin, S. Butsianto, and A. Firmansyah, “Perbandingan Kinerja Naïve Bayes dengan dan Tanpa SMOTE untuk Klasifikasi Gangguan Kecemasan Mahasiswa pada Data Tidak Seimbang,” *Bull. Comput. Sci. Res.*, vol. 6, no. 2 SE-, pp. 804–812, Feb. 2026, doi: 10.47065/bulletincsr.v6i2.1021.
- [41] F. Reynaldi Valerian, M. Syarief, and D. Abdul Fatah, “KLASIFIKASI TINGKAT OBESITAS MENGGUNAKAN METODE GBM DAN CONFUSION MATRIX,” *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 9, no. 2, pp. 2242–2249, Mar. 2025, doi: 10.36040/jati.v9i2.13062.
- [42] J. J. Hidayat, M. D. I. Amin, E. K. Fitri, A. N. Anggraini, A. P. Werdana, and C. Setyowati, “Implementasi Model EfficientNetB0 Pada Pembuatan Aplikasi Desktop Untuk Identifikasi Hama Tanaman Sawi Berbasis Deep Learning,” *J. Teknol. Inf. Digit.*, vol. 1, no. 2, pp. 82–89, [Online]. Available: <https://jurnal.ipdig.id/index.php/jtid/article/view/195>