

Prediksi Stunting pada Anak Balita Menggunakan Algoritma Extreme Gradient Boosting dan Bayesian Optimization

Rangga Yoga Pratama^{1*}, Anna Baita²

^{1,2}Informatika, Universitas Amikom Yogyakarta, Indonesia

e-mail: ranggaprtma@students.amikom.ac.id^{1*}, anna@amikom.ac.id²

Informasi Artikel

Article History:

Received : 26 Juli 2025
Revised : 16 September 2025
Accepted : 20 Oktober 2025
Published : 29 Oktober 2025

***Korespondensi:**

ranggaprtma@students.amikom.ac.id


Keywords:

Stunting, Prediction, XGBoost, Bayesian Optimization, Machine Learning

Hak Cipta ©2025 pada Penulis.
Dipublikasikan oleh Universitas
Dinamika



Artikel ini *open access* di bawah
lisensi [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/)

 10.37802/joti.v7i2.1174

**Journal of Technology and
Informatics (JoTI)**

P-ISSN 2721-4842

E-ISSN 2686-6102

[https://e-
journals.dinamika.ac.id/index.php/joti](https://e-journals.dinamika.ac.id/index.php/joti)

Abstract:

Stunting is a chronic malnutrition condition affecting children under five years that impairs cognitive development, physical growth, and future productivity. This study develops a stunting risk prediction model using the Extreme Gradient Boosting (XGBoost) algorithm with hyperparameter tuning and data balancing techniques. The dataset from Kaggle contains 120,998 records with variables including age, gender, height, and nutritional status. The methodology encompasses data preprocessing for outlier handling, categorical encoding, and feature extraction based on height thresholds. Feature selection utilized ANOVA F-test, while Exploratory Data Analysis identified height as the most influential attribute. To address class imbalance, Synthetic Minority Over-sampling Technique (SMOTE) was implemented, followed by Bayesian Optimization for hyperparameter tuning. Model evaluation was conducted using various data splits (80:20, 70:30, 60:40, 50:50) with metrics including accuracy, precision, recall, and F1-score. Results demonstrate that the optimized XGBoost model achieved exceptional performance with 0,982% accuracy, 0,973% precision, 0,979% recall, and 0,976% F1-score, consistently across all data configurations. The combination of XGBoost with Bayesian Optimization and SMOTE proves highly effective in handling imbalanced classification tasks. These findings highlight machine learning's potential in supporting public health initiatives through accurate early identification and targeted intervention for stunting prevention.

PENDAHULUAN

Stunting merupakan kondisi kegagalan pertumbuhan pada anak balita, yang ditandai dengan tinggi dan berat badan yang tidak sesuai dengan standar anak seusianya. Kondisi ini disebabkan oleh berbagai faktor, seperti terbatasnya akses terhadap makanan bergizi selama masa kehamilan dan awal kehidupan anak, rendahnya pengetahuan ibu mengenai pola makan dan kesehatan sebelum kehamilan, kurangnya asupan vitamin serta mineral, kehamilan pada usia remaja, serta jarak kehamilan yang terlalu dekat [1]. Risiko jangka pendek dari stunting meliputi menurunnya daya tahan tubuh, gangguan perkembangan kognitif, serta masalah kesehatan mental. Sedangkan risiko jangka panjangnya, balita yang mengalami stunting

cenderung memiliki kondisi fisik yang kurang optimal ketika dewasa dan meningkatkan risiko terserang berbagai penyakit kronis di kemudian hari [2].

Berdasarkan hasil Survei Status Gizi Indonesia (SSGI) 2024 yang dirilis oleh Kemenkes pada 26 Mei 2025, prevalensi stunting nasional turun dari 21,5% menjadi 19,8% melampaui target tahunan *RPJMN* sebesar 20,1%. Menteri Kesehatan menegaskan, pemerintah menetapkan target penurunan stunting menjadi 14,2% pada tahun 2029, dengan target tahunan berikutnya sebesar 18,8% pada 2025. Strategi ini mengedepankan intervensi pra-kelahiran seperti pengukuran lingkaran lengan dan kadar Hb pada ibu hamil, distribusi tablet tambah darah, serta peningkatan kapasitas Posyandu melalui distribusi 300.000 alat antropometri [3].

Beberapa penelitian terkini telah menunjukkan efektivitas algoritma Random Forest dalam klasifikasi stunting pada balita. Khusna [4] mendemonstrasikan potensi besar optimasi parameter melalui penerapan Random Forest, di mana akurasi model meningkat drastis dari 0,7730 menjadi 0,9578 setelah dilakukan hyperparameter tuning menggunakan Grid Search. Temuan ini diperkuat oleh penelitian Putri yang membandingkan performa tiga algoritma machine learning (Naive Bayes, KNN, dan Random Forest) dalam konteks klasifikasi stunting. Hasil evaluasi menunjukkan bahwa Random Forest mencapai akurasi tertinggi sebesar 87,75% dengan F1-score 0,922, menunjukkan keseimbangan optimal antara precision dan recall. Meskipun KNN unggul dalam aspek recall (0,967) yang menandakan sensitivitas tinggi dalam mendeteksi kasus stunting.

Masalah yang sering muncul pada algoritma klasifikasi dalam data mining adalah ketidakseimbangan data (*imbalanced data*), yang terjadi karena beberapa kelas memiliki jumlah sampel jauh lebih banyak dibandingkan kelas lainnya. Ketidakseimbangan data ini masih menjadi tantangan dalam penerapan model klasifikasi [5]. Salah satu strategi yang terbukti ampuh untuk menangani permasalahan tersebut adalah SMOTE (*Synthetic Minority Over-sampling Technique*), yaitu teknik untuk mengatasi data tidak seimbang dengan menambah sampel kelas minoritas hingga setara dengan kelas mayoritas. Meski proses prediksinya lambat, SMOTE efektif menangani ketidakseimbangan kelas [6]. Riset yang dilakukan Sulistiyono [7] membuktikan bahwa implementasi SMOTE berhasil meningkatkan tingkat akurasi dan skor G-mean secara substansial pada beragam algoritma pembelajaran mesin seperti Naive Bayes, SVM, K-NN, dan Decision Tree ketika diterapkan pada dataset yang mengalami ketidakseimbangan kelas.

XGBoost mengembangkan algoritma boosting dengan mengkompilasi beberapa model lemah menjadi model tunggal yang sangat kuat [8]. Algoritma ini kerap dipilih karena kemampuannya yang efisien dan dapat ditingkatkan skalanya untuk menyelesaikan berbagai permasalahan baik dalam klasifikasi maupun regresi [9]. Sejumlah penelitian mutakhir telah berhasil menerapkan algoritma Extreme Gradient Boosting (XGBoost) untuk mengidentifikasi status stunting pada anak balita dengan performa yang mengesankan. Penelitian oleh Muhamad Fikri [10] mengimplementasikan XGBoost pada data antropometri balita dan mencapai performa yang baik dengan akurasi 86%, presisi 89%, recall 95%, dan F1-score 92% membuktikan efektivitas model dalam mendeteksi stunting secara dini.

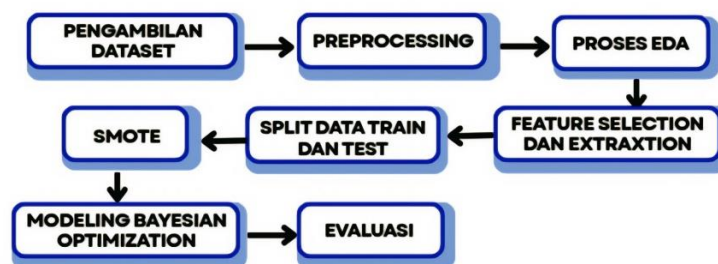
Optimasi Bayesian (BO) merupakan teknik optimasi hiperparameter yang populer dalam bidang machine learning. Keunggulan metode ini terletak pada kemampuannya untuk menangani fungsi tujuan yang tidak dapat diturunkan secara matematika, sehingga banyak digunakan pada berbagai algoritma pembelajaran mesin. Studi yang dilakukan Dwi Utami [11] membuktikan keefektifan pendekatan ini, di mana penerapan Bayesian Optimization pada Support Vector Machine (SVM) berhasil meningkatkan tingkat akurasi dari 94% menjadi 95%,

menunjukkan kontribusi positif metode optimasi ini terhadap peningkatan performa model klasifikasi. Selain itu, studi Pramudhyta [12] mengoptimalkan parameter XGBoost melalui teknik Grid Search yang dirancang khusus untuk klasifikasi stunting, yang terbukti meningkatkan konsistensi kinerja model dalam aplikasi praktis tanpa memerlukan perbandingan dengan algoritma alternatif lainnya.

Penelitian ini menerapkan metode Extreme Gradient Boosting (XGBoost) untuk menentukan klasifikasi status stunting pada anak balita. Tahap pertama melibatkan pembangunan model dengan menggunakan parameter standar untuk mengukur kinerja awal sistem. Kemudian, penelitian dilanjutkan dengan penyesuaian parameter optimal melalui pendekatan Bayesian Optimization dan mengatasi masalah data yang tidak seimbang menggunakan teknik *Synthetic Minority Oversampling Technique* (SMOTE) guna meningkatkan tingkat akurasi dan kestabilan model. Tujuan utama dari penelitian ini adalah untuk mengevaluasi seberapa efektif algoritma XGBoost, baik dalam pengaturan default maupun setelah proses optimasi, dalam mengidentifikasi kondisi stunting pada anak usia balita.

METODE

Penelitian ini dilakukan melalui beberapa fase kunci yang dimulai dengan pengumpulan dan pra-pemrosesan data sekunder terkait kondisi gizi balita. Kemudian, dilakukan pengembangan dan pelatihan model klasifikasi dengan algoritma XGBoost untuk memprediksi status gizi berdasarkan variabel usia, jenis kelamin, dan tinggi badan. Setelah model terbentuk, dilakukan proses evaluasi performa model dengan menggunakan parameter penilaian seperti akurasi, precision, recall, dan F1-score.



Gambar 1. Diagram Alur

Pengumpulan dan Pra Pemrosesan data

Fase ini meliputi proses pengumpulan data sekunder mengenai kondisi gizi balita yang menjadi fondasi penelitian, beserta rangkaian tahapan pra-pemrosesan data yang krusial untuk memastikan kualitas input model. Kualitas dan struktur data memiliki dampak signifikan terhadap performa model klasifikasi yang menggunakan XGBoost. Dengan demikian, dilakukan preparasi data secara komprehensif untuk menjamin bahwa data yang dipakai telah bersih, konsisten, dan terorganisir sesuai dengan spesifikasi model. Penjelasan mengenai sumber data, atribut yang digunakan, serta proses pra-pemrosesan data diuraikan sebagai berikut.

Pengumpulan Data

Penelitian ini menggunakan pendekatan kuantitatif berbasis data sekunder yang diperoleh dari situs Kaggle [13]. Dataset yang digunakan berjudul "Stunting Balita Detection"

dengan jumlah sebanyak 120.998 data anak balita, yang mencakup empat atribut utama yaitu umur (*age*), jenis kelamin (*gender*), tinggi badan (*height*), dan status gizi (*nutritional status*) rincian structure data dapat di lihat di tabel 1.

Tabel 1. Nama dan Kategorikal

Nama Kolom	Kategorikal	Value
Age	Usia balita dalam bulan	0-60
Gender	Laki-laki dan Perempuan	Laki-laki dan Perempuan
Height	Tinggi dalam cm	40.01 – 128.0
Nutritional Status	Severely stunted, stunted, normal, tinggi	Severely stunted, stunted, normal, tinggi

Pra Pemrosesan

Dalam studi ini, data mengalami beberapa tahapan pra-pemrosesan yang bertujuan untuk mengadaptasi format data sesuai dengan kebutuhan model serta memperkaya atribut yang ada. Proses ini sangat penting untuk meningkatkan kualitas input dan mendukung performa model XGBoost secara maksimal. Adapun tahapan-tahapan pra-pemrosesan yang dilakukan adalah sebagai berikut:

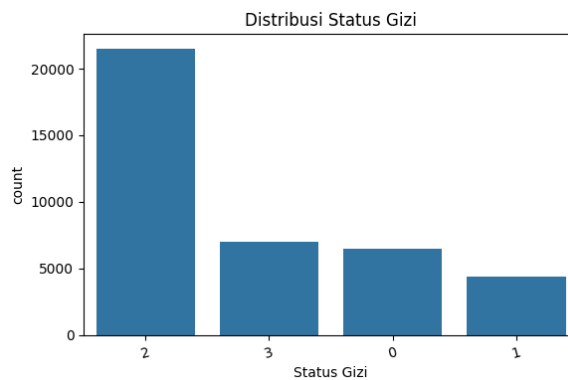
1. Penanganan missing value tidak diperlukan dalam penelitian ini karena seluruh data yang digunakan tidak memiliki nilai yang hilang, sehingga dataset sudah lengkap dan siap untuk proses pemodelan.
2. Melihat data unqi hasil dari fungsi *data.unique()* menunjukkan bahwa setiap atribut dalam dataset memiliki nilai unik yang cukup bervariasi. Umur memiliki 61 nilai unik, Jenis Kelamin 2, Tinggi Badan 6800, dan Status Gizi 4. Hal ini menandakan bahwa data lengkap dan tidak terdapat missing value pada setiap atribut.
3. Menangani Outlier pertama mendeteksi outlier pada kolom numerik menggunakan metode IQR. Diketahui kolom Umur (bulan) tidak memiliki outlier, sementara kolom Tinggi Badan (cm) terdapat 38 outlier. Untuk mengatasi outlier tersebut, digunakan metode clipping yang membatasi nilai pada batas bawah dan atas IQR agar nilai ekstrim digantikan dengan batas terdekat. Dengan cara ini, outlier dihaluskan tanpa menghapus data, sehingga data lebih stabil untuk analisis selanjutnya.
4. Dalam penelitian ini, diterapkan proses encoding pada dua kolom kategorikal, yaitu 'Jenis Kelamin' dan 'Status Gizi'. Kategori dalam kolom '*Jenis Kelamin*' dikonversi menjadi nilai numerik dengan 0 untuk '*laki-laki*' dan 1 untuk '*perempuan*'. Sedangkan kategori dalam kolom '*Status Gizi*' ditransformasi menjadi angka 0 sampai 3, yang berturut-turut merepresentasikan '*severely stunted*', '*stunted*', '*normal*', dan '*tinggi*'. Transformasi ini diperlukan untuk memastikan bahwa data berbentuk numerik dan dapat diproses oleh algoritma machine learning seperti XGBoost, yang memerlukan input dalam format bilangan.
5. Penanganan data duplikat mencari dan menampilkan data duplikat berdasarkan semua kolom, lalu menghapus duplikat tersebut untuk menghasilkan dataset bersih tanpa data yang berulang, data bersih setelah di hapus 39.425 dari yang awalnya 120.999.

Exploratory Data Analysis

1. Melihat tendensi sentral dan sebaran data Analisis deskriptif terhadap 120.999 data balita menunjukkan bahwa umur memiliki rentang 0-60 bulan dengan rata-rata 30,17 bulan (standard deviation=17,57), dimana distribusi kuartilnya menunjukkan 25% balita berusia di

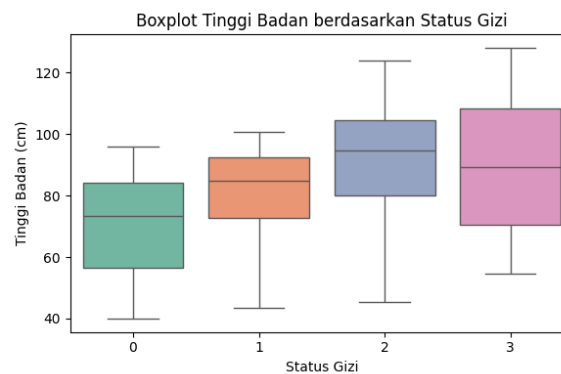
bawah 15 bulan, median 30 bulan, dan 75% di bawah 45 bulan, yang mencerminkan distribusi usia balita yang cukup merata termasuk balita baru lahir (0 bulan). Sementara itu, tinggi badan berkisar antara 40,01-128 cm dengan rata-rata 88,66 cm (standard deviation=17,30), dengan distribusi kuartil menunjukkan 25% balita memiliki tinggi di bawah 77 cm, median 89,8 cm, dan 75% di bawah 101,2 cm, yang secara keseluruhan mencerminkan variasi pertumbuhan fisik balita yang normal dalam dataset ini.

2. Hasil visualisasi distribusi status gizi balita pada Gambar 2 menggambarkan dominasi kategori status gizi normal (label 2) dalam dataset, dengan jumlah kasus status gizi tinggi (label 3) dan stunted (label 0) yang cenderung berimbang, sedangkan kategori severely stunted (label 1) menunjukkan frekuensi terendah. Ketimpangan distribusi antar kategori ini menciptakan kondisi imbalanced classification yang berpotensi menurunkan akurasi model machine learning, sehingga diperlukan implementasi teknik penyeimbangan data seperti SMOTE (Synthetic Minority Over-sampling Technique) pada fase pemodelan untuk mengoptimalkan performa prediksi model dapat dilihat pada gambar 2.



Gambar 2. Distribusi Status Gizi

3. Analisis sebaran tinggi badan berdasarkan klasifikasi status gizi melalui visualisasi boxplot pada Gambar di bawah memperlihatkan pola distribusi yang konsisten dengan kategori pengkodean: 0 (*severely stunted*), 1 (*stunted*), 2 (*normal*), dan 3 (*tinggi*). Visualisasi tersebut mengungkapkan adanya hubungan proporsional antara kategori status gizi dengan nilai median tinggi badan, dimana kategori 0 menunjukkan distribusi tinggi badan terendah, sementara kategori 3 memperlihatkan nilai median dan variabilitas tinggi badan yang paling superior. Temuan ini mengkonfirmasi eksistensi korelasi linier yang signifikan antara status gizi dan pertumbuhan tinggi badan pada populasi balita dalam dataset dapat dilihat pada gambar 3.



Gambar 3. Tinggi badan berdasarkan status gizi

Feature Extraction dan Selection

Dalam pengembangan model data, fase ekstraksi dan pemilihan fitur menjadi tahapan krusial untuk mengoptimalkan performa model dan memahami seberapa besar pengaruh setiap fitur terhadap variabel yang hendak diprediksi. Pada studi ini, ditambahkan fitur baru yaitu "tinggi di atas rata-rata" yang dihitung berdasarkan nilai mean dari kolom tinggi badan keseluruhan balita dalam dataset. Kemudian, untuk menentukan fitur yang paling berpengaruh terhadap status gizi balita, diterapkan teknik ANOVA F-test yang dapat mengevaluasi seberapa signifikan dampak setiap fitur terhadap variabel target. Selain itu, dilakukan pula analisis korelasi antar fitur melalui heatmap guna mengidentifikasi hubungan linear antara variabel dan mencegah terjadinya redundansi dalam data. Gambar heatmap korelasi antar fitur dan tabel ANOVA F-test di tampilkan pada gambar di bawah sebagai dari eksplorasi awal terhadap data.

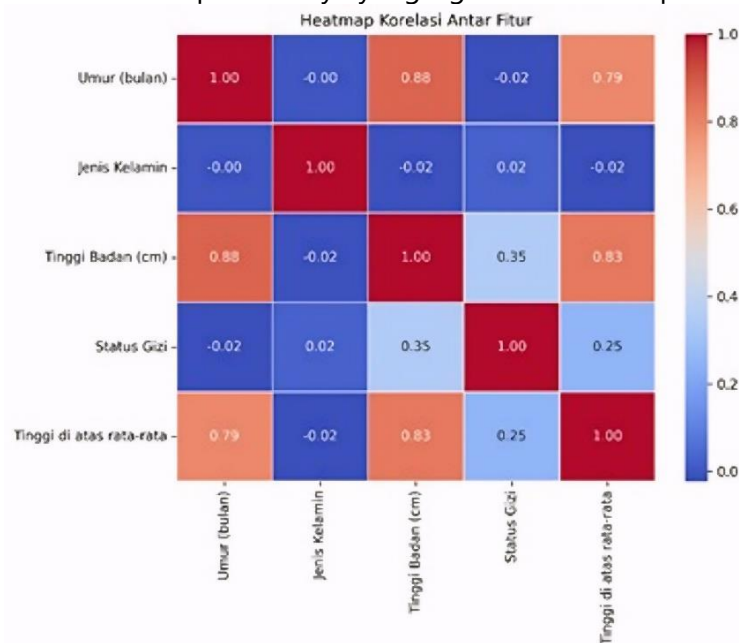
Skor Seleksi Fitur:

	Fitur	Skor ANOVA F-test
2	Tinggi Badan (cm)	2314.768315
3	Tinggi di atas rata-rata	1656.860023
0	Umur (bulan)	779.296715
1	Jenis Kelamin	7.482395

Gambar 4. Skor Anova

Melalui teknik seleksi fitur ANOVA F-test, teridentifikasi bahwa variabel Tinggi Badan (cm) meraih skor tertinggi senilai 2314.77, membuktikan signifikansinya yang paling besar dalam menentukan klasifikasi Status Gizi. Selanjutnya ditempati oleh Tinggi di atas rata-rata dengan skor 1656.86, dan Umur (bulan) dengan skor 779.30. Sebaliknya, Jenis Kelamin memperlihatkan skor paling minim yaitu 7.48, mencerminkan pengaruhnya yang terbatas terhadap proses klasifikasi status gizi apabila diperbandingkan dengan fitur-fitur yang lain.

Hasil ini didukung oleh analisis korelasi melalui heatmap Gambar 5 di bawah yang menunjukkan fitur dengan skor ANOVA tinggi memiliki korelasi lebih kuat terhadap variabel target. Dengan demikian, fitur Tinggi Badan dan Tinggi di atas rata-rata relevan dipertahankan dalam pemodelan karena kontribusi prediktifnya yang signifikan terhadap status gizi balita.



Gambar 5. Heatmap

Berdasarkan hasil analisis korelasi, tinggi badan menunjukkan hubungan paling kuat dengan status gizi balita dengan koefisien korelasi 0.35, mengindikasikan bahwa balita dengan tinggi badan optimal cenderung memiliki status gizi yang lebih baik. Sebaliknya, jenis kelamin dan umur memperlihatkan korelasi yang sangat lemah dengan nilai masing-masing 0.02 dan -0.02, menunjukkan bahwa kedua variabel tersebut tidak memiliki pengaruh linier yang signifikan terhadap status gizi balita dalam penelitian ini. Koefisien korelasi tersebut diperoleh melalui heatmap korelasi yang dibuat ,yakni sebelum dataset dibagi menjadi data latih dan data uji (train-test split) serta sebelum penerapan metode penyeimbangan data seperti SMOTE.

Pemodelan dan Pelatihan Model

Setelah menyelesaikan tahap preprocessing data dan pemilihan atribut yang signifikan, tahap selanjutnya adalah penerapan model untuk memprediksi kondisi nutrisi pada balita. Penelitian ini mengadopsi algoritma Extreme Gradient Boosting (XGBoost) karena kemampuan unggulnya dalam menyelesaikan masalah klasifikasi dataset kompleks serta keahliannya dalam mengatasi ketidakseimbangan fitur dan hubungan nonlinear. Sebelum memulai pelatihan model, dataset dipartisi menjadi dua bagian, yakni dataset training dan dataset testing, dengan maksud memisahkan fase pembelajaran dan validasi model.

Pada fase pertama, pelatihan model dijalankan dengan menggunakan konfigurasi parameter default XGBoost untuk mendapatkan performa dasar algoritma pada dataset yang tersedia. Kemudian, guna meningkatkan kinerja model, diterapkan proses optimasi hyperparameter dengan memanfaatkan metode Bayesian Optimization (BO) yang dioperasikan melalui library Optuna. Pendekatan ini memfasilitasi pencarian kombinasi parameter optimal secara efektif dengan mempertimbangkan keseimbangan antara eksplorasi dan eksploitasi dalam ruang parameter, sehingga diproyeksikan dapat meningkatkan tingkat akurasi dan kemampuan generalisasi model.

Splitting Data

Dalam studi ini, diimplementasikan tiga percobaan primer untuk menganalisis kinerja algoritma Extreme Gradient Boosting (XGBoost) dalam mengklasifikasikan kondisi gizi balita, dengan penekanan pada dampak optimasi hyperparameter dan pengelolaan ketidakseimbangan data.

1. Percobaan awal memanfaatkan model XGBoost dengan konfigurasi parameter standar tanpa melakukan proses tuning dan tanpa menerapkan teknik penanganan data imbalance, yang berperan sebagai model acuan.
2. Percobaan kedua mengimplementasikan optimasi hyperparameter melalui Optuna untuk memperoleh parameter terbaik berdasarkan pendekatan Bayesian Optimization. Pada tahapan ini, data tetap dipertahankan dalam kondisi original tanpa menggunakan metode balancing.
3. Percobaan ketiga merupakan penyempurnaan dari percobaan sebelumnya, dengan mengintegrasikan teknik SMOTE (*Synthetic Minority Over-sampling Technique*) sebelum fase pelatihan untuk mengatasi distribusi kelas yang timpang.

Pada setiap percobaan, diterapkan empat skema pembagian data latih dan uji, yaitu 80:20, 70:30, 60:40, dan 50:50, dengan tujuan mengamati responsivitas model terhadap variasi volume data pelatihan. Meskipun proporsi data yang digunakan beragam, keseluruhan proses partisi data menggunakan random state yang identik, sehingga memfasilitasi komparasi hasil yang objektif dan konsisten di antara percobaan.

Setiap kombinasi percobaan dan rasio data dievaluasi melalui empat pengujian independen menggunakan pembagian data yang berbeda berdasarkan seed yang konsisten. Hasil dari keempat pengujian tersebut dirata-ratakan untuk mendapatkan performa final yang representatif dan meminimalkan pengaruh variasi data akibat proses pembagian.

Structure Model

1. Extreme Gradient Boosting

Model yang diterapkan dalam penelitian ini adalah Extreme Gradient Boosting (XGBoost), merupakan algoritma ensemble yang mengkombinasikan beberapa decision tree secara iteratif melalui teknik *gradient boosting*. Arsitektur model ini menggunakan pendekatan aditif, dimana setiap tree dikonstruksi untuk memperbaiki error yang dihasilkan oleh tree sebelumnya.

Pembangunan model dilakukan dengan mengoptimalkan fungsi objektif yang mencakup fungsi loss dan elemen regularisasi. Proses optimasi memanfaatkan turunan tingkat pertama (*gradient*) dan turunan tingkat kedua (*hessian*), yang membuat proses training lebih efisien dan stabil. Dalam penelitian ini, model dilatih menggunakan konfigurasi parameter standar tanpa melakukan penyesuaian (*hyperparameter tuning*), sehingga jumlah dan kedalaman tree mengacu pada pengaturan default dari library XGBoost. Adapun konfigurasi parameter yang digunakan dalam implementasi model adalah sebagai berikut pada tabel 2.

Tabel 2. *Extreme Gradient Boosting Default*

Parameter	Nilai	Deskripsi
max_depth	6	Kedalaman maksimum pohon
n_estimators	100	Jumlah pohon dalam ensemble
learning_rate	0.3	Kecepatan pembelajaran
subsample	1.0	Proporsi data yang digunakan dalam setiap iterasi pelatihan
Colsample_bytree	1.0	Proporsi fitur yang digunakan dalam setiap pohon
Random_state	42	Untuk menjaga reproduktibilitas
Use_label_encoder	False	Menonaktifkan label encoder bawaan (untuk kompatibilitas) Metrik evaluasi selama training
Eval_metric	mlogloss	

Parameter tersebut digunakan untuk membangun model XGBoost secara seragam pada setiap skenario pembagian data (train-test split).

2. Tuning Hyperparameter Bayesian Optimization

Permasalahan ini diselesaikan melalui implementasi teknik oversampling, khususnya *Synthetic Minority Oversampling Technique* (SMOTE). Teknik ini berfungsi untuk menambahkan data dengan menciptakan data poin tiruan berdasarkan karakteristik dari data poin aslinya[14]. Strategi ini bertujuan memperoleh konfigurasi parameter optimal yang dapat meningkatkan akurasi klasifikasi, khususnya pada dataset dengan distribusi kelas yang timpang.

Optimasi dilaksanakan dengan memanfaatkan algoritma Bayesian Optimization yang dioperasikan melalui library Optuna, yang secara efisien menjelajahi ruang parameter berdasarkan hasil evaluasi terdahulu. Proses optimasi dijalankan selama 30 iterasi ($n_trials = 30$), dengan sasaran memaksimalkan nilai weighted F1-score sebagai metrik penilaian primer. Sebelum memulai proses optimasi, data pelatihan terlebih dahulu disetimbangkan menggunakan SMOTE. Teknik ini beroperasi dengan menghasilkan sampel sintesis baru dari kelas minoritas berdasarkan kemiripan atribut, sehingga menciptakan distribusi kelas yang lebih proporsional. Setelah tahap resampling, pipeline model dikonstruksi dengan

mengintegrasikan StandardScaler untuk normalisasi fitur, diikuti oleh model XGBoostClassifier dengan parameter yang direkomendasikan oleh Optuna pada setiap iterasi. Adapun rentang eksplorasi parameter yang ditentukan dalam proses optimasi mencakup berbagai hyperparameter XGBoost sebagaimana ditunjukkan pada Tabel 3.

Tabel 3. XGBoost dengan *Tuning* dan SMOTE

Parameter	Rentang Nilai	Deskripsi
max_depth	3 – 15	Kedalaman maksimum pohon
n_estimators	100 – 1000	Jumlah pohon dalam ensemble
learning_rate	0.01 – 0.3	Kecepatan pembelajaran
subsample	0.5 – 0.1	Proporsi data yang digunakan dalam setiap iterasi pelatihan
Colsample_bytree	0.5 – 1.0	Proporsi fitur yang digunakan dalam setiap pohon
Random_state	42	Untuk menjaga reproduktibilitas
Use_label_encoder	False	Menonaktifkan label encoder bawaan (untuk kompatibilitas)
Eval_metric	logloss	Metrik evaluasi selama training
Gama	0.0 – 0.5	Minimum loss reduction yang diperlukan untuk membagi node (pruning)
Reg_lambda	0.0 – 1.0	Koefisien regularisasi L2 (Ridge)
Reg_alpha	0.0 – 1.0	Koefisien regularisasi L1 (Lasso)
Min_child_weight	1 – 10	Jumlah minimum bobot sum anak (leaf), mencegah overfitting

Penilaian dilakukan menggunakan Stratified K-Fold Cross Validation ($n_splits = 5$) untuk menjamin bahwa distribusi kelas tetap konsisten pada setiap fold. Parameter terbaik yang diperoleh dari proses ini selanjutnya digunakan untuk membangun model final yang akan dibandingkan kinerjanya dengan model baseline dan model tuning tanpa SMOTE.

HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil analisis data penelitian yang bertujuan memprediksi status stunting pada balita menggunakan algoritma Extreme Gradient Boosting (XGBoost). Analisis dilaksanakan melalui tahapan sistematis mulai dari preprocessing data, konstruksi model, hingga evaluasi kinerja dan interpretasi hasil. Kontribusi utama penelitian ini adalah implementasi optimasi hyperparameter menggunakan Bayesian Optimization (BO) melalui library Optuna untuk memaksimalkan performa XGBoost dalam klasifikasi status gizi balita.

Penelitian ini melibatkan tiga eksperimen primer pertama, model baseline (XGBoost default) menggunakan parameter standar tanpa tuning dan penanganan ketidakseimbangan data sebagai acuan kinerja awal kedua, model XGBoost + Hyperparameter Tuning (Optuna) yang telah dioptimasi melalui pencarian kombinasi hyperparameter terbaik menggunakan Bayesian Optimization namun belum menerapkan penyeimbangan data dan ketiga, model XGBoost + Hyperparameter Tuning + SMOTE yang mengkombinasikan optimasi hyperparameter dengan SMOTE (*Synthetic Minority Oversampling Technique*) untuk menghasilkan model yang optimal secara parameter sekaligus adil terhadap distribusi kelas minoritas.

Baseline Model

Guna memastikan stabilitas dan konsistensi kinerja model, proses pelatihan dan pengujian

dilakukan sebanyak tiga kali menggunakan parameter yang identik. Setiap pengujian menghasilkan metrik evaluasi berupa akurasi, precision, recall, dan F1-score yang selanjutnya dibandingkan untuk mengamati variasi kinerja model. Hasil dari ketiga pengujian tersebut menunjukkan bahwa model XGBoost mampu memberikan hasil yang stabil dan dapat diandalkan dalam memprediksi stunting berdasarkan dataset yang digunakan.

Tabel 4. Tabel Baseline

Spllitting	Accuracy	Precision	Recall	F1-Score
80/20	0.984	0.978	0.979	0.978
70/30	0.981	0.973	0.974	0.973
60/40	0.981	0.972	0.975	0.973
50/50	0.980	0.972	0.972	0.972

Berdasarkan eksperimen pada Tabel 4, model XGBoost menunjukkan performa yang sangat konsisten dan stabil. Meskipun dijalankan dengan pengaturan standar (default) dan tanpa optimisasi hyperparameter, model ini berhasil mempertahankan akurasi yang tinggi secara konsisten di angka 0.98. Performa ini tidak berubah meskipun terjadi variasi proporsi data latih dan uji (80/20, 70/30, 60/40, dan 50/50). Pencapaian ini membuktikan bahwa XGBoost memiliki kemampuan generalisasi yang sangat baik dan tahan banting (robust) karena struktur internalnya yang menggabungkan gradient boosting dengan regularisasi L1 dan L2. Mekanisme ini secara efektif mengontrol kompleksitas model dan mencegah overfitting, sehingga model mampu menangkap pola data yang sebenarnya tanpa harus disesuaikan secara manual. Oleh karena itu, XGBoost sangat cocok dijadikan sebagai baseline model yang andal sebelum dilakukan proses optimisasi lanjutan.

Tuned Model

Penelitian ini melakukan penyetelan hyperparameter pada model XGBoost menggunakan metode Bayesian Optimization (BO) selama 30 iterasi. Berbeda dengan Grid Search atau Random Search yang mencari secara menyeluruh atau acak, BO bekerja secara adaptif dan terarah. Metode ini memanfaatkan hasil dari percobaan sebelumnya untuk memandu pencarian selanjutnya, sehingga proses optimasi menjadi lebih efisien dan akurat dalam menemukan kombinasi parameter optimal yang dapat meningkatkan performa klasifikasi model. Ruang pencarian (search space) yang dioptimasi meliputi parameter utama seperti jumlah pohon ($n_estimators$) (100–1000 dengan langkah 100), kedalaman maksimum (max_depth) (3–15), dan laju pembelajaran ($learning_rate$) (0.01–0.3 pada skala logaritmik). Parameter lain yang juga disetel adalah $subsample$ dan $colsample_bytree$ (0.5–1.0), $gamma$ (0.0–0.5), reg_alpha dan reg_lambda (0.0–1.0), serta min_child_weight (1–10). Seluruh proses tuning menggunakan metrik evaluasi logloss dan diatur dengan $random_state=42$ untuk menjaga reproducibility hasil. Berdasarkan hasil yang disajikan pada Tabel 5, konfigurasi setingan hyperparameter terbaik ditemukan adalah sebagai berikut:

Tabel 5. Best Parameter

Parameter	Value
max_depth	15
$n_estimators$	1000
$learning_rate$	0.2940
$subsample$	0.8254

Parameter	Value
Colsample_bytree	0.9965
Random_state	42
Use_label_encoder	False
Eval_metric	logloss
Gamma	0.0009
Reg_lambda	0.0092
Reg_alpha	0.5394
Min_child_weight	1

Tabel 5 menyajikan setingan tuning hyperparameter terbaik untuk algoritma XGBoost yang diperoleh melalui pendekatan Bayesian Optimization yang hasilnya pada tabel 6 with smote 60/40. Tujuan dari proses ini adalah untuk menemukan kombinasi parameter yang menghasilkan performa klasifikasi terbaik, khususnya dalam memprediksi status gizi balita berdasarkan data yang tersedia.

Tabel 6. Tabel Evaluasi Xgboost

	Splitting	Accuracy	Precision	Recall	F1-Score
Without Smote	80/20	0.985	0.978	0.981	0.980
	70/30	0.983	0.975	0.978	0.977
	60/40	0.981	0.973	0.975	0.974
	50/50	0.979	0.970	0.971	0.971
With Smote	80/20	0.981	0.970	0.981	0.975
	70/30	0.979	0.966	0.978	0.971
	60/40	0.982	0.973	0.979	0.976
	50/50	0.977	0.962	0.976	0.969

Tabel 6 menampilkan hasil evaluasi kinerja model Extreme Gradient Boosting (XGBoost) untuk klasifikasi status gizi balita dilakukan pada empat rasio pembagian data (80/20, 70/30, 60/40, dan 50/50), baik dengan atau tanpa menggunakan teknik oversampling SMOTE. Pengujian ini dimaksudkan untuk menilai dampak SMOTE pada performa model, terutama saat menghadapi ketidakseimbangan kelas.

Model XGBoost tanpa SMOTE mencapai kinerja puncaknya pada pembagian data 80/20, menghasilkan metrik terbaik akurasi 0.985, precision 0.978, recall 0.981, dan F1-score 0.980. Nilai F1-score yang unggul ini mengindikasikan keseimbangan yang sangat baik antara kemampuan model untuk mengidentifikasi kasus positif (presisi) dan kemampuannya untuk menemukan semua kasus positif (recall).

Sebaliknya, pada model dengan SMOTE, performa terbaik tercatat pada rasio pembagian data 60/40, dengan akurasi 0.982, precision 0.973, recall 0.979, dan F1-score 0.976. Meskipun metrik ini sedikit di bawah hasil terbaik dari model tanpa SMOTE, peningkatan pada nilai recall menunjukkan bahwa SMOTE berhasil meningkatkan sensitivitas model terhadap kelas minoritas, menghasilkan deteksi yang lebih seimbang di seluruh kategori status gizi.

Secara umum, temuan ini menyimpulkan bahwa meskipun model XGBoost tanpa SMOTE dengan rasio 80/20 menunjukkan performa keseluruhan yang paling optimal pada dataset ini, penerapan SMOTE tetap memberikan dampak positif dalam meningkatkan kinerja model, khususnya dalam menangani isu ketidakseimbangan kelas.

Tabel 7. Tabel Perbandingan *Baseline* dan Tuned Model

	Spilting	Accuracy	Precision	Recall	F1-Score
Baseline Model	80/20	0.984	0.978	0.979	0.978
	70/30	0.981	0.973	0.974	0.973
	60/40	0.981	0.972	0.975	0.973
	50/50	0.980	0.972	0.972	0.972
Tuned Model	80/20	0.981	0.970	0.981	0.975
	70/30	0.979	0.966	0.978	0.971
	60/40	0.982	0.973	0.979	0.976
	50/50	0.977	0.962	0.976	0.969

Berdasarkan Tabel 7 (Perbandingan Baseline dan Tuned Model), terlihat bahwa hyperparameter tuning memberikan dampak yang bervariasi pada kinerja model di berbagai skenario pembagian data latih/uji, namun secara keseluruhan, baik model baseline maupun tuned menunjukkan performa yang sangat tinggi (semua metrik di atas 0.97). Model Baseline mencapai performa puncak pada pembagian data 80/20, dengan akurasi tertinggi (0.984), precision (0.978), recall (0.979), dan F1-score (0.978). Ini menegaskan bahwa model awalnya sudah sangat efektif.

Setelah tuning, performa model sedikit meningkat dan lebih konsisten di beberapa metrik. Hasil terbaik dari model yang dioptimasi (tuned model) dicapai pada pembagian data 60/40, dengan akurasi 0.982, precision 0.973, recall 0.979, dan F1-score 0.976. Secara ringkas, meskipun performa sangat tinggi sudah tercapai pada model baseline, proses hyperparameter tuning berhasil menjaga stabilitas performa dan memberikan peningkatan kecil namun penting pada metrik evaluasi utama, yang menunjukkan bahwa tuning memperbaiki keseimbangan model antara kemampuan generalisasi dan akurasi prediksi.

Tabel 8. Perbandingan Akurasi Model

Algoritma	Accuracy	Precision	Recall	F1-Score
Proposed Model	0.981	0.970	0.982	0.976
Random Forest Grid Search [4]	0.9578	0.9480	0.9451	0.9469
Naïve Bayes [5]	83.2	0.892	0.897	0.895
KNN [5]	84.4	0.869	0.967	0.916
Random Forest [5]	87.75	0.891	0.956	0.922
XGBoost [8]	0.86	0.89	0.95	0.92
XGBoost Grid Search [10]	89.09	94.55	85.12	89.58
SVM Bayesian Optimization [11]	95	98	87	92

Tabel 8 menampilkan komparasi kinerja berbagai algoritma klasifikasi dari sejumlah studi, termasuk model yang dikembangkan dalam riset ini. Hasil evaluasi menunjukkan bahwa XGBoost dengan penyesuaian hyperparameter melalui Bayesian Optimization memperoleh performa tertinggi dengan tingkat akurasi 98%, precision 98%, recall 99%, dan F1-score 98%. Hal ini sejalan dengan penelitian [11] hasil ini membuktikan bahwa penggabungan algoritma XGBoost dengan teknik optimasi Bayesian dapat meningkatkan kemampuan model secara substansial dalam memproses data klasifikasi, terutama pada kasus identifikasi stunting yang umumnya menghadapi tantangan ketidakseimbangan distribusi kelas.

Sebagai tambahan, confusion matrix diimplementasikan untuk menyajikan gambaran visual yang lebih komprehensif terkait distribusi prediksi yang akurat dan tidak akurat di setiap

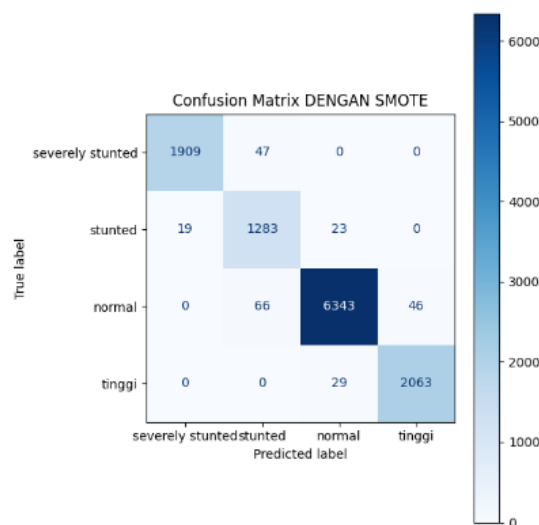
kategori kelas. Confusion matrix ini dihasilkan dari model XGBoost yang telah dioptimasi menggunakan parameter terbaik hasil tuning, dengan rasio pembagian dataset training dan testing 60:40.

Analisis confusion matrix memperlihatkan bahwa model berhasil mengklasifikasikan sebagian besar sampel dengan akurat, khususnya untuk kategori normal dan tinggi, yang masing-masing berhasil diklasifikasikan dengan benar pada 6.343 dan 2.063 kasus. Walaupun masih ditemukan beberapa misklasifikasi pada kategori severely stunted dan stunted, proporsi kesalahan tersebut masih dalam batas yang dapat diterima jika dibandingkan dengan volume keseluruhan dataset.

Hasil confusion matrix menunjukkan bahwa model memiliki kinerja kuat dalam mengklasifikasikan kelas mayoritas, dengan keberhasilan klasifikasi yang sangat tinggi pada kelas normal (6.343 kasus) dan tinggi (2.063 kasus). Namun, model masih menghadapi tantangan pada kelas stunted/severely stunted, ditandai dengan adanya misklasifikasi. Pola ini konsisten dengan literatur nasional, seperti ditunjukkan oleh penelitian Halim menggunakan Extreme Gradient Boosting yang juga mencapai metrik presisi, recall, dan F1-score tinggi pada kelas dominan [15].

Tantangan pada kelas minoritas ini juga terbukti dalam studi yang menggunakan teknik oversampling seperti SMOTE pada Random Forest, yang meskipun berhasil meningkatkan akurasi, tetap kesulitan menangani kelas minoritas [16]. Selain itu, penelitian lain menegaskan bahwa kesalahan klasifikasi antar kelas sangat dipengaruhi oleh penggunaan teknik balancing data dan pemilihan fitur [17]. Oleh karena itu, confusion matrix ini menegaskan perlunya evaluasi kinerja model secara spesifik per kelas, bukan hanya akurasi global, serta perlunya langkah mitigasi yang efektif terhadap misklasifikasi pada kelas minoritas, sesuai dengan temuan studi-studi di Indonesia.

Model klasifikasi menunjukkan bahwa kelas 'normal' adalah yang paling dominan dalam himpunan data pengujian, menjadikannya kelas yang paling berpengaruh terhadap matriks secara keseluruhan. Secara spesifik, kelas 'normal' menyumbang total 6.455 observasi True label (0 + 66 + 6343 + 46), yang merupakan jumlah sampel terbanyak. Dari total tersebut, model berhasil mengklasifikasikan 6.343 sampel sebagai True Positives yaitu prediksi 'normal' yang benar menunjukkan kemampuan model yang sangat baik dalam mengenali kelas mayoritas ini. Kenyataan bahwa kelas 'normal' memiliki jumlah observasi tertinggi (6.455) menegaskan posisinya sebagai kelas mayoritas dalam data pengujian, yang juga menjelaskan mengapa jumlah True Positive-nya (6.343) paling tinggi dibandingkan kelas lainnya.



Gambar 6. Confusion Matrix

KESIMPULAN DAN SARAN

Penelitian ini berhasil mengimplementasikan algoritma *Extreme Gradient Boosting* (XGBoost) untuk klasifikasi status stunting pada balita dengan hasil yang sangat memuaskan. Melalui penerapan tuning hyperparameter menggunakan Bayesian Optimization (BO) dan teknik penyeimbangan data SMOTE, model mencapai performa optimal dengan akurasi 0,982%, precision 0.973%, recall 0.979%, dan F1-score 0.976%. Evaluasi pada berbagai skenario pembagian data (80:20, 70:30, 60:40, dan 50:50) menunjukkan konsistensi model dengan akurasi berkisar 97-98%. Hasil ini membuktikan bahwa kombinasi XGBoost, Bayesian Optimization, dan SMOTE efektif mengatasi tantangan klasifikasi pada data tidak seimbang, menjadikan model ini dapat diandalkan untuk deteksi stunting pada anak balita.

Untuk penelitian selanjutnya, disarankan untuk memperluas cakupan variabel input dengan menambahkan faktor-faktor eksternal seperti kondisi sosial-ekonomi keluarga, lingkungan tempat tinggal, dan riwayat kesehatan maternal guna menghasilkan prediksi yang lebih holistik. Selain itu, perlu dilakukan eksplorasi algoritma ensemble lainnya atau hibridisasi dengan deep learning untuk membandingkan performa. Implementasi model dalam sistem real-time juga dapat dikembangkan untuk mendukung program deteksi dini stunting di fasilitas kesehatan. Terakhir, validasi model pada dataset yang lebih besar dan beragam dari berbagai wilayah geografis akan meningkatkan generalisasi dan aplikabilitas model dalam skala yang lebih luas.

DAFTAR PUSTAKA

- [1] O. Pahlevi, A. Amrin, and Y. Handrianto, "Optimasi Algoritma Naïve Bayes Berbasis Particle Swarm Optimization Untuk Klasifikasi Status Stunting," *Comput. Sci.*, vol. 4, no. 1, pp. 37–43, 2024, doi: 10.31294/coscience.v4i1.2963.
- [2] G. N. Masacgi and M. S. Rohman, "Optimasi Model Algoritma Klasifikasi menggunakan Metode Bagging pada Stunting Balita," *Edumatic J. Pendidik. Inform.*, vol. 7, no. 2, pp. 455–464, 2023, doi: 10.29408/edumatic.v7i2.23812.
- [3] SSGI, "Prevalensi Stunting Nasional Turun Menjadi 19,8%," kemenkes. Accessed: Jul. 16, 2025. [Online]. Available: <https://kemkes.go.id/id/ssgi-2024-prevalensi-stunting-nasional-turun-menjadi-198>
- [4] N. F. Khusna, A. Rahmah, R. K. Nur, N. Izzah, K. C. Chumairoh, and F. Fauzi, "Implementasi Random Forest dalam Klasifikasi Kasus Stunting pada Balita dengan Hyperparameter Tuning Grid Search," *Pros. Semin. Nas. Sains Data*, vol. 4, no. 1, pp. 791–801, 2024, doi: 10.33005/senada.v4i1.334.
- [5] H. H. Sinaga and S. Agustian, "Pebandingan Metode Decision Tree dan XGBoost untuk Klasifikasi Sentimen Vaksin Covid-19 di Twitter," *J. Nas. Teknol. dan Sist. Inf.*, vol. 8, no. 3, pp. 107–114, 2022, doi: 10.25077/teknosi.v8i3.2022.107-114.
- [6] R. Ubaidillah, M. Muliadi, D. T. Nugrahadi, M. R. Faisal, and R. Herteno, "Implementasi XGBoost Pada Keseimbangan Liver Patient Dataset dengan SMOTE dan Hyperparameter Tuning Bayesian Search," *J. Media Inform. Budidarma*, vol. 6, no. 3, p. 1723, 2022, doi: 10.30865/mib.v6i3.4146.
- [7] M. Sulistiyono, Y. Pristyanto, S. Adi, and G. Gumelar, "Implementasi Algoritma Synthetic Minority Over-Sampling Technique untuk Menangani Ketidakseimbangan Kelas pada Dataset Klasifikasi," *Sistemasi*, vol. 10, no. 2, p. 445, 2021, doi: 10.32520/stmsi.v10i2.1303.
- [8] D. Asmawati, L. Arif Sanjani, C. Dimas Renggana, C. Fatichah, and T. Mustaqim, "Arrhythmia Classification with ECG Signal using Extreme Gradient Boosting (XGBoost) Algorithm," *J. Technol. Informatics*, vol. 6, no. 1, pp. 36–42, 2024, doi:

- 10.37802/joti.v6i1.792.
- [9] S. LUTFIANI, T. H. Saragih, F. Abadi, M. R. Faisal, and D. Kartini, "Perbandingan Metode Extreme Gradient Boosting Dan Metode Decision Tree Untuk Klasifikasi Genre Musik," *J. Inform. Polinema*, vol. 9, no. 4, pp. 373–382, 2023, doi: 10.33795/jip.v9i4.1319.
- [10] Muhamad Fikri, "Klasifikasi Status Stunting Pada Anak Bawah Lima Tahun Menggunakan Extreme Gradient Boosting," *Merkurius J. Ris. Sist. Inf. dan Tek. Inform.*, vol. 2, no. 4, pp. 173–184, Jun. 2024, doi: 10.61132/mercurius.v2i4.159.
- [11] Dwi Utami, Fathoni Dwiatmoko, and Nuari Anisa Sivi, "Analisis Pengaruh Bayesian Optimization Terhadap Kinerja SVM Dalam Prediksi Penyakit Diabetes," *Infotek J. Inform. dan Teknol.*, vol. 8, no. 1, pp. 140–150, 2025, doi: 10.29408/jit.v8i1.28468.
- [12] N. A. Pramudhyta and M. S. Rohman, "Perbandingan Optimasi Metode Grid Search dan Random Search dalam Algoritma XGBoost untuk Klasifikasi Stunting," *J. Media Inform. Budidarma*, vol. 8, no. 1, p. 19, 2024, doi: 10.30865/mib.v8i1.6965.
- [13] R. P. Pradana, "Stunting Toddler (Balita) Detection (121K rows)," Kaggle. Accessed: Jul. 10, 2025. [Online]. Available: <https://www.kaggle.com/datasets/rendiputra/stunting-balita-detection-121k-rows/code>
- [14] M. Guhdar, A. Ismail Melhum, and A. Luqman Ibrahim, "Optimizing Accuracy of Stroke Prediction Using Logistic Regression," *J. Technol. Informatics*, vol. 4, no. 2, pp. 41–47, 2023, doi: 10.37802/joti.v4i2.278.
- [15] H. Al Aziz and H. A. Santoso, "Model Prediksi Stunting Anak di Indonesia Menggunakan Extreme Gradient Boosting," pp. 1072–1085, 2025, doi: 10.33364/algoritma/v.22-1.2289.
- [16] A. A. Dhani, T. A. Y. Siswa, and W. J. Pranoto, "Perbaikan Akurasi Random Forest Dengan ANOVA Dan SMOTE Pada Klasifikasi Data Stunting," *Teknika*, vol. 13, no. 2, pp. 264–272, 2024, doi: 10.34148/teknika.v13i2.875.
- [17] F. M. T. Pane and D. Hindarto, "Comparative Analysis of Machine Learning Models for Stunting Prediction in Jakarta," *J. JTIK (Jurnal Teknol. Inf. dan Komunikasi)*, vol. 9, no. 4, pp. 1365–1375, 2025, doi: 10.35870/jtik.v9i4.3853.