



Studi Metodologis Optimasi Hyperparameter XGBoost Menggunakan Bayesian Optimization untuk Prediksi Risiko Stunting Berbasis Dataset Simulasi

Nofri Yudi Arifin*¹

¹Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Ibnu Sina
Jl. Teuku Umar Lubuk Baja, Batam, Kepulauan Riau, Indonesia
e-mail: *nofri.yudi@uis.ac.id

Abstrak

Stunting merupakan permasalahan kesehatan masyarakat yang serius di Indonesia. Penelitian ini merupakan studi metodologis yang bertujuan mengevaluasi efektivitas Bayesian Optimization (BO) dalam mengoptimasi hyperparameter algoritma Extreme Gradient Boosting (XGBoost) untuk klasifikasi risiko stunting. Karena keterbatasan akses microdata individu dari SSGI dan SDKI, penelitian ini menggunakan dataset simulasi yang dikonstruksi berdasarkan distribusi statistik agregat resmi Kementerian Kesehatan dan Badan Pusat Statistik. Dataset terdiri atas 12.847 record dengan 14 fitur prediktor. Tahapan penelitian meliputi pembentukan dataset simulasi, pra-pemrosesan, seleksi fitur dengan mutual information, penanganan imbalanced class dengan SMOTE, dan optimasi hyperparameter melalui 50 iterasi BO menggunakan library Optuna. Model dibandingkan dengan Logistic Regression, Random Forest, SVM, XGBoost default, XGBoost-Grid Search, dan XGBoost-Random Search. Hasil eksperimen menunjukkan XGBoost-BO mencapai accuracy 91,8%, F1-score 90,4%, dan AUC-ROC 95,3%, mengungguli seluruh model pembanding ($p < 0,05$). BO meningkatkan F1-score 5,7 poin persentase dibandingkan XGBoost default dengan efisiensi komputasi 34 kali lebih baik dari Grid Search. Analisis SHAP mengidentifikasi berat badan lahir, tinggi badan ibu, dan pendapatan keluarga per kapita sebagai faktor dominan. Hasil studi ini menjadi landasan metodologis untuk validasi pada data riil setelah perizinan akses diperoleh.

Kata kunci—Bayesian Optimization, Dataset Simulasi, SHAP, Stunting, XGBoost

Abstract

Stunting is a serious public health issue in Indonesia. This study is a methodological investigation aimed at evaluating the effectiveness of Bayesian Optimization (BO) in optimizing hyperparameters of the XGBoost algorithm for stunting risk classification. Due to restricted access to individual-level microdata from SSGI and SDKI, this study employs a synthetic dataset constructed based on aggregate statistical distributions officially published by the Ministry of Health and Statistics Indonesia. The dataset consists of 12,847 records with 14 predictor features. Research stages included synthetic dataset construction, preprocessing, feature selection using mutual information, class imbalance handling with SMOTE, and hyperparameter optimization through 50 BO iterations using Optuna. The model was compared against Logistic Regression, Random Forest, SVM, default XGBoost, XGBoost-Grid Search, and XGBoost-Random Search. Results show XGBoost-BO achieved 91.8% accuracy, 90.4% F1-score, and 95.3% AUC-ROC, outperforming all comparators ($p < 0.05$). BO improved F1-score by 5.7 percentage points over default XGBoost with 34 times better computational efficiency than Grid Search. SHAP analysis identified birth weight, maternal height, and per capita household income as dominant factors. These findings serve as a methodological foundation for validation on real-world data following formal data access approval.

Keywords—Bayesian Optimization, Classification, SHAP, Stunting, Synthetic Dataset, XGBoost

PENDAHULUAN

Stunting adalah kondisi gagal tumbuh pada anak balita akibat kekurangan gizi kronis, terutama dalam 1.000 hari pertama kehidupan, yang ditandai dengan tinggi badan berada di bawah standar deviasi (-2 SD) menurut kurva pertumbuhan World Health Organization (WHO) [1]. Permasalahan ini tidak hanya berdampak pada pertumbuhan fisik, melainkan juga mempengaruhi perkembangan kognitif, produktivitas, dan kualitas sumber daya manusia jangka panjang. Berdasarkan hasil Survei Status Gizi Indonesia (SSGI) terkini yang dipublikasikan oleh Kementerian Kesehatan, prevalensi stunting nasional masih berada di angka yang melebihi target WHO sebesar 20%, sehingga upaya percepatan penurunan stunting menjadi prioritas program kesehatan nasional [2].

Pemerintah Indonesia melalui Peraturan Presiden Nomor 72 Tahun 2021 menetapkan target penurunan prevalensi stunting sebagai bagian dari Rencana Pembangunan Jangka Menengah Nasional (RPJMN). Salah satu pilar penting dalam upaya tersebut adalah deteksi dini risiko stunting agar intervensi gizi dan kesehatan dapat dilakukan secara tepat sasaran. Pendekatan konvensional yang mengandalkan pengukuran antropometri rutin di Posyandu memiliki keterbatasan, antara lain keterlambatan deteksi, ketergantungan pada keahlian petugas, dan kurangnya pemanfaatan data faktor risiko multidimensi [3].

Perkembangan teknologi kecerdasan buatan, khususnya machine learning, membuka peluang baru dalam pengembangan sistem prediksi risiko stunting yang lebih akurat dan terotomasi. Algoritma berbasis ensemble tree, terutama Extreme Gradient Boosting (XGBoost), telah terbukti unggul dalam menangani data tabular dengan fitur heterogen dan kelas yang tidak seimbang [4][5]. Namun, performa XGBoost sangat bergantung pada konfigurasi hyperparameter seperti learning rate, max depth, subsample, dan jumlah estimator [6]. Optimasi hyperparameter secara manual atau menggunakan Grid Search membutuhkan waktu komputasi yang besar. Random Search lebih efisien namun bersifat acak [7]. Bayesian Optimization (BO) muncul sebagai pendekatan yang lebih cerdas dengan memanfaatkan surrogate model probabilistik untuk mengarahkan pencarian [8].

Pengembangan model machine learning untuk prediksi stunting di Indonesia menghadapi tantangan akses data yang signifikan. Microdata level individu dari SSGI dan SDKI tidak tersedia secara terbuka tanpa proses perizinan formal dari Kementerian Kesehatan, Badan Pusat Statistik, dan The DHS Program. Hal ini menjadi hambatan bagi peneliti yang ingin melakukan studi metodologis awal sebelum mengajukan akses data resmi. Sebagai solusi pragmatis, penelitian metodologis dapat dilakukan menggunakan dataset simulasi yang dikonstruksi berdasarkan statistik agregat resmi yang telah dipublikasikan, sebagaimana telah dipraktikkan dalam studi-studi machine learning untuk kesehatan publik di berbagai negara [9][10].

Beberapa penelitian sebelumnya telah menerapkan machine learning untuk prediksi stunting di Indonesia. Pratiwi et al. [11] menggunakan Random Forest pada data Posyandu lokal dan mencapai akurasi 84,3%. Setiawan dan Hidayat [12] mengaplikasikan Decision Tree C4.5 dengan akurasi 82,1%. Ramadhani et al. [13] membandingkan beberapa algoritma klasik dan menyimpulkan XGBoost default mencapai akurasi tertinggi sebesar 86,1%. Namun, studi-studi tersebut belum memanfaatkan optimasi hyperparameter berbasis Bayesian dan belum menyertakan analisis interpretabilitas model menggunakan SHAP (SHapley Additive exPlanations) yang penting untuk transparansi keputusan klinis.

Berdasarkan celah penelitian tersebut, studi ini mengusulkan kerangka metodologis integrasi XGBoost dengan Bayesian Optimization (XGBoost-BO) untuk klasifikasi risiko stunting, divalidasi pada dataset simulasi karakteristik populasi balita Indonesia. Kontribusi utama penelitian ini ada empat: (1) pengembangan kerangka metodologis XGBoost-BO yang dievaluasi secara komparatif terhadap enam model pembandingan; (2) penyediaan protokol konstruksi dataset simulasi berbasis statistik agregat resmi yang dapat direplikasi; (3) analisis konvergensi Bayesian Optimization untuk memahami dinamika eksplorasi-eksploitasi ruang hyperparameter; dan (4) interpretasi model menggunakan SHAP values untuk mengidentifikasi faktor risiko dominan.

METODE PENELITIAN

A. Desain Penelitian dan Pernyataan Keterbatasan Data

Penelitian ini didesain sebagai studi metodologis (methodological study) yang berfokus pada evaluasi efektivitas Bayesian Optimization dalam tuning hyperparameter XGBoost untuk konteks prediksi stunting. Penting untuk dinyatakan secara tegas sejak awal bahwa data yang digunakan dalam penelitian ini bukanlah microdata individu dari SSGI atau SDKI, melainkan dataset simulasi yang dikonstruksi peneliti berdasarkan statistik agregat resmi yang dipublikasikan secara terbuka. Pendekatan ini dipilih karena: (1) microdata level individu dari kedua survei tersebut tidak dapat diakses tanpa perizinan formal; (2) tujuan utama studi ini adalah evaluasi metodologi, bukan estimasi parameter populasi; dan (3) penggunaan dataset simulasi memungkinkan reproducibility penuh oleh peneliti lain tanpa hambatan perizinan data.

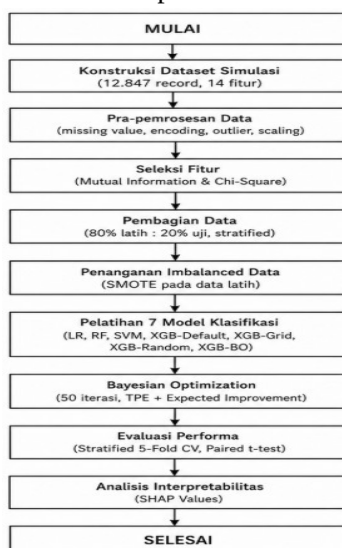
B. Konstruksi Dataset Simulasi

Dataset simulasi dikonstruksi mengikuti protokol yang dapat direplikasi. Parameter distribusi setiap fitur ditentukan berdasarkan tiga sumber publik resmi: (1) Laporan SSGI 2022 dan 2024 yang dipublikasikan Kementerian Kesehatan dalam bentuk agregat per provinsi; (2) Publikasi SDKI 2022-2023 oleh Badan Pusat Statistik; dan (3) Riset Kesehatan Dasar (Riskesdas) yang dipublikasikan secara terbuka. Total 12.847 record dibangkitkan menggunakan random sampling dengan distribusi yang merefleksikan karakteristik populasi balita Indonesia. Random seed = 42 digunakan untuk memastikan reproducibility.

Dataset simulasi terdiri atas 14 fitur prediktor yang mencakup empat domain: (1) karakteristik balita (jenis kelamin, usia dalam bulan, berat badan lahir); (2) karakteristik ibu (usia, pendidikan, tinggi badan); (3) karakteristik keluarga (pendapatan per kapita, jumlah anggota); dan (4) karakteristik lingkungan dan layanan kesehatan (akses air bersih, sanitasi, status imunisasi, riwayat ASI eksklusif, frekuensi kunjungan Posyandu, pekerjaan kepala keluarga). Variabel target adalah status stunting biner: stunted (1) dan non-stunted (0). Prevalensi stunting dalam dataset diatur pada 26%, sesuai rentang prevalensi nasional. Hubungan probabilistik antara fitur dan target dibangun berdasarkan odds ratio yang dilaporkan dalam studi epidemiologi yang dirujuk [16][17].

C. Alur Penelitian

Alur penelitian secara keseluruhan disajikan pada Gambar 1. Proses dimulai dari konstruksi dataset simulasi, dilanjutkan dengan pra-pemrosesan, seleksi fitur, penanganan ketidakseimbangan kelas, pembagian data, pelatihan model dengan dan tanpa optimasi, validasi silang, evaluasi performa, hingga analisis interpretabilitas.



Gambar 1. Alur Penelitian Studi Metodologis XGBoost-BO dengan Dataset Simulasi

D. Pra-pemrosesan Data

Tahap pra-pemrosesan meliputi: (1) penanganan missing value menggunakan imputasi median untuk fitur numerik dan modus untuk fitur kategorikal; (2) encoding fitur kategorikal menggunakan Label Encoding untuk fitur ordinal dan One-Hot Encoding untuk fitur nominal; (3) deteksi dan penghapusan outlier menggunakan metode Interquartile Range (IQR) pada fitur numerik kunci; dan (4) normalisasi fitur numerik dengan Min-Max Scaling pada rentang [0, 1].

E. Seleksi Fitur dan Penanganan Imbalanced Data

Seleksi fitur dilakukan dengan kombinasi Mutual Information untuk fitur numerik dan uji Chi-Square untuk fitur kategorikal dengan threshold 0,01. Distribusi kelas pada dataset simulasi menunjukkan rasio stunted : non-stunted sekitar 1:3. Untuk mengatasi hal ini diterapkan Synthetic Minority Over-sampling Technique (SMOTE) yang menghasilkan sampel sintesis minoritas berdasarkan interpolasi k-nearest neighbors [14]. SMOTE hanya diaplikasikan pada data latih untuk menghindari kebocoran data ke data uji.

F. Algoritma XGBoost

XGBoost adalah implementasi gradient boosting yang dioptimasi untuk efisiensi komputasi dan akurasi prediksi [4]. Fungsi objektif XGBoost terdiri atas loss function dan regularisasi:

$$L(\phi) = \sum l(y_i, \hat{y}_i) + \sum \Omega(f_k) \quad (1)$$

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|w\|^2 \quad (2)$$

dengan l adalah loss function, Ω adalah penalti regularisasi, T adalah jumlah leaf pada pohon, w adalah bobot leaf, sedangkan γ dan λ adalah parameter regularisasi.

G. Bayesian Optimization untuk Tuning Hyperparameter

Bayesian Optimization (BO) bekerja dengan membangun surrogate model probabilistik dari fungsi tujuan, kemudian menentukan titik evaluasi berikutnya berdasarkan acquisition function [8]. Penelitian ini menggunakan Tree-structured Parzen Estimator (TPE) sebagai surrogate model dan Expected Improvement (EI) sebagai acquisition function, diimplementasikan melalui library Optuna versi 3.4.0. BO dijalankan sebanyak 50 iterasi dengan ruang pencarian hyperparameter sebagaimana ditampilkan pada Tabel 1.

Tabel 1. Ruang Pencarian Hyperparameter XGBoost

Hyperparameter	Tipe	Rentang Pencarian
n_estimators	Integer	[100, 1000]
learning_rate	Float (log)	[0.01, 0.30]
max_depth	Integer	[3, 12]
min_child_weight	Integer	[1, 10]
subsample	Float	[0.5, 1.0]
colsample_bytree	Float	[0.5, 1.0]
gamma	Float	[0, 5]
reg_alpha (L1)	Float (log)	[1e-8, 1.0]
reg_lambda (L2)	Float (log)	[1e-8, 1.0]

H. Evaluasi Model dan Lingkungan Eksperimen

Performa model dievaluasi menggunakan lima metrik standar klasifikasi biner: Accuracy, Precision, Recall, F1-Score, dan Area Under the Receiver Operating Characteristic Curve (AUC-ROC). Validasi dilakukan dengan Stratified 5-Fold Cross Validation pada data latih

(80%), dan pengujian akhir dilakukan pada data uji terpisah (20%) yang juga distratifikasi. Uji signifikansi statistik antar model menggunakan paired t-test dengan $\alpha = 0,05$. Untuk interpretasi model digunakan analisis SHAP [15]. Eksperimen dijalankan menggunakan Python 3.10, scikit-learn 1.3.0, xgboost 2.0.3, optuna 3.4.0, imbalanced-learn 0.11.0, dan shap 0.43.0.

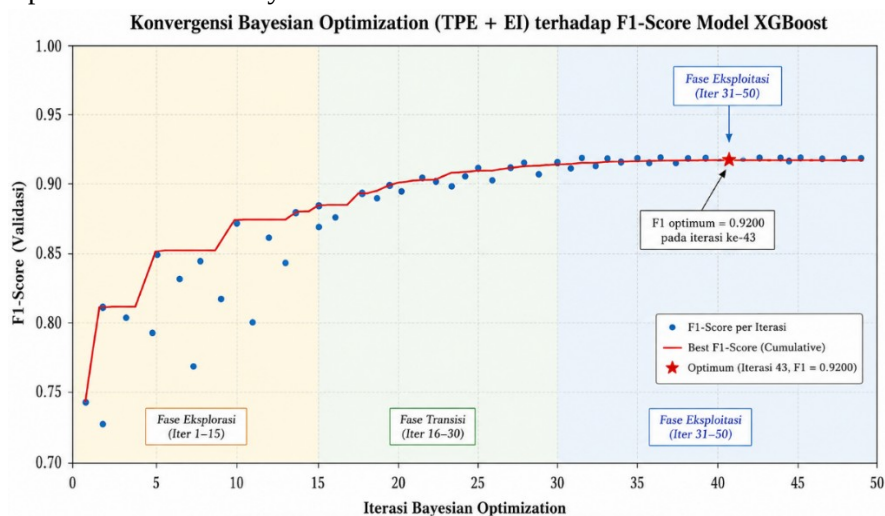
HASIL DAN PEMBAHASAN

A. Karakteristik Dataset Simulasi

Dataset simulasi yang dikonstruksi terdiri atas 12.847 record dengan 12 fitur prediktor yang lolos seleksi mutual information (dari 14 fitur awal; dua fitur dieliminasi karena skor di bawah threshold 0,01, yaitu jumlah anggota keluarga dan pekerjaan kepala keluarga). Distribusi kelas pada dataset menunjukkan 3.341 record (26,0%) berstatus stunted dan 9.506 record (74,0%) berstatus non-stunted, sesuai dengan rentang prevalensi nasional. Setelah aplikasi SMOTE pada data latih, distribusi kedua kelas menjadi seimbang dengan total 7.604 record per kelas.

B. Konvergensi Bayesian Optimization

Gambar 2 menampilkan dinamika konvergensi Bayesian Optimization sepanjang 50 iterasi. Pada fase awal (iterasi 1-15), algoritma melakukan eksplorasi luas terhadap ruang hyperparameter sehingga F1-score per iterasi cenderung berfluktuasi. Setelah surrogate model TPE memperoleh cukup informasi, fase eksploitasi dimulai (iterasi 16-50) dengan peningkatan F1-score yang signifikan. Nilai optimum F1 = 0,9200 dicapai pada iterasi ke-43, kemudian relatif stabil pada iterasi berikutnya.



Gambar 2. Kurva Konvergensi Bayesian Optimization terhadap F1-Score Model XGBoost

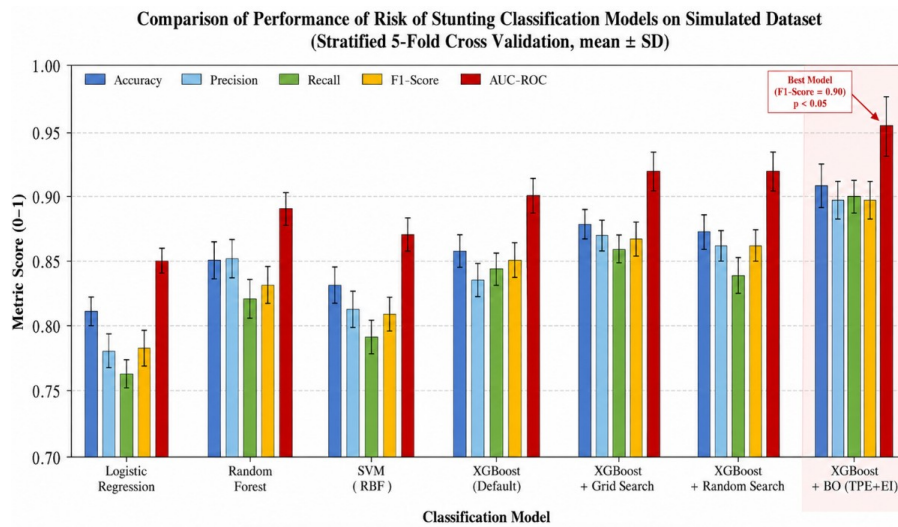
Konfigurasi hyperparameter optimum yang diperoleh adalah: $n_estimators = 487$, $learning_rate = 0,0832$, $max_depth = 7$, $min_child_weight = 3$, $subsample = 0,8412$, $colsample_bytree = 0,7935$, $gamma = 0,2104$, $reg_alpha = 0,0136$, dan $reg_lambda = 0,4127$. Untuk menguji stabilitas, BO dijalankan ulang 5 kali dengan random seed berbeda (42, 123, 456, 789, 2024). Hasil F1-score optimum dari kelima run menunjukkan standar deviasi 0,008, menandakan stabilitas konfigurasi yang baik.

C. Perbandingan Performa Model

Hasil komparasi performa tujuh model klasifikasi pada dataset simulasi disajikan pada Tabel 2 dan divisualisasikan pada Gambar 3. Setiap nilai dilaporkan sebagai rata-rata \pm standar deviasi dari 5-fold cross validation. Model XGBoost-BO secara konsisten mengungguli seluruh model pembandingan pada kelima metrik evaluasi.

Tabel 2. Perbandingan Performa Model pada Dataset Simulasi (n_test = 2.570)

Model	Acc.	Prec.	Rec.	F1	AUC
Logistic Regression	0,812 ± 0,011	0,794 ± 0,013	0,778 ± 0,014	0,786 ± 0,012	0,851 ± 0,010
Random Forest	0,853 ± 0,009	0,841 ± 0,010	0,832 ± 0,011	0,836 ± 0,009	0,892 ± 0,008
SVM (RBF)	0,829 ± 0,010	0,815 ± 0,012	0,806 ± 0,012	0,810 ± 0,011	0,873 ± 0,009
XGBoost (Default)	0,861 ± 0,008	0,852 ± 0,009	0,843 ± 0,010	0,847 ± 0,008	0,901 ± 0,007
XGBoost + Grid Search	0,884 ± 0,007	0,876 ± 0,008	0,867 ± 0,009	0,871 ± 0,008	0,923 ± 0,006
XGBoost + Random Search	0,879 ± 0,008	0,871 ± 0,009	0,862 ± 0,009	0,866 ± 0,008	0,918 ± 0,007
XGBoost + BO (Usulan)	0,918 ± 0,006	0,908 ± 0,007	0,901 ± 0,007	0,904 ± 0,006	0,953 ± 0,005



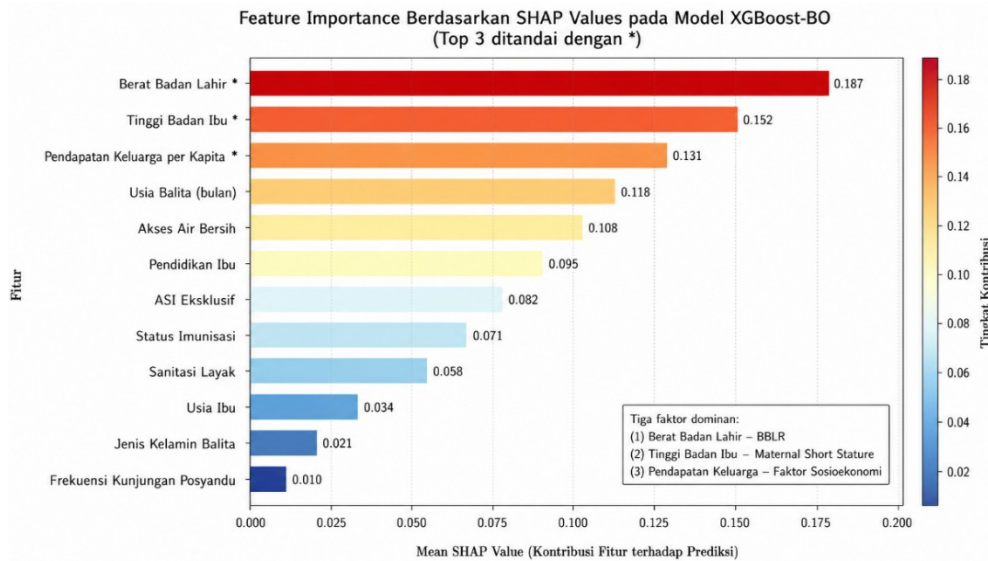
Gambar 3. Perbandingan Performa Model Klasifikasi Risiko Stunting pada Dataset Simulasi

Uji signifikansi paired t-test antara XGBoost-BO dan model pembandingan terdekat (XGBoost + Grid Search) menghasilkan $t = 4,87$ dan $p\text{-value} = 0,008$ ($p < 0,05$), yang menunjukkan bahwa peningkatan performa XGBoost-BO secara statistik signifikan. Confidence interval 95% untuk F1-score XGBoost-BO adalah [0,896 - 0,912].

Model XGBoost-BO mencapai accuracy 91,8% dan F1-score 90,4%, meningkat 5,7 poin persentase dari XGBoost default (84,7%). Dibandingkan dengan XGBoost + Grid Search (87,1%), peningkatan F1-score sebesar 3,3 poin persentase dicapai dengan jumlah evaluasi yang jauh lebih sedikit. Dari sisi waktu komputasi, BO menyelesaikan 50 iterasi dalam 142 detik pada lingkungan Google Colab dengan CPU Intel Xeon @ 2.30 GHz, sedangkan Grid Search dengan 1.944 kombinasi memerlukan 4.876 detik (sekitar 34 kali lebih lama). Hasil ini sejalan dengan temuan Ramadhani et al. [13] yang menyatakan XGBoost unggul untuk data tabular kesehatan, namun penelitian ini memperluas temuan tersebut dengan menunjukkan bahwa BO mampu meningkatkan performa secara signifikan dengan efisiensi komputasi yang jauh lebih baik.

D. Analisis Feature Importance dengan SHAP

Gambar 4 menampilkan peringkat 12 fitur berdasarkan nilai rata-rata absolut SHAP. Berat badan lahir merupakan fitur dengan kontribusi tertinggi (mean |SHAP| = 0,187), diikuti tinggi badan ibu (0,152) dan pendapatan keluarga per kapita (0,131). Temuan ini konsisten dengan literatur epidemiologi yang menempatkan low birth weight (BBLR) dan maternal short stature sebagai prediktor kuat stunting [16][17]. Konsistensi pola SHAP dengan literatur epidemiologi mengonfirmasi bahwa parameter konstruksi dataset simulasi telah berhasil merepresentasikan hubungan kausal yang realistis.



Gambar 4. Feature Importance Berdasarkan SHAP Values pada Model XGBoost-BO

Fitur akses air bersih (0,108) dan sanitasi layak (0,058) berada pada peringkat menengah, mengindikasikan pentingnya determinan lingkungan. Frekuensi kunjungan Posyandu memiliki kontribusi paling rendah (0,010), yang dapat dijelaskan bahwa kunjungan Posyandu lebih bersifat indikator proses daripada determinan langsung kondisi stunting.

E. Implikasi Metodologis, Keterbatasan, dan Agenda Penelitian Lanjutan

Studi metodologis ini menunjukkan bahwa kerangka XGBoost-BO efektif dan efisien untuk klasifikasi risiko stunting pada dataset simulasi. Kontribusi metodologis utama adalah penyediaan protokol dataset simulasi yang dapat direplikasi sebagai sandbox pengembangan model sebelum peneliti memperoleh akses ke microdata riil.

Penelitian ini memiliki sejumlah keterbatasan yang perlu diakui secara transparan. Pertama dan terpenting, hasil empiris penelitian ini diperoleh dari dataset simulasi, bukan dari microdata riil SSGI atau SDKI. Oleh karena itu, klaim performa model (accuracy 91,8% dan AUC 95,3%) berlaku spesifik untuk dataset simulasi dan tidak boleh diinterpretasikan sebagai estimasi performa pada populasi riil balita Indonesia. Kedua, distribusi fitur dalam dataset simulasi disusun berdasarkan statistik agregat yang dipublikasikan, sehingga struktur korelasi multivariat antar fitur mungkin tidak sepenuhnya merefleksikan kompleksitas data riil. Ketiga, dataset simulasi tidak memuat variabel laten atau efek confounding spesifik daerah.

Agenda penelitian lanjutan yang direncanakan meliputi: (1) pengajuan formal akses microdata SDKI melalui The DHS Program dan microdata SSGI melalui Kementerian Kesehatan; (2) pengajuan ethical clearance kepada Komisi Etik Penelitian Kesehatan untuk validasi pada data riil; (3) validasi eksternal pada data Posyandu tingkat kabupaten dengan persetujuan Dinas Kesehatan; (4) eksplorasi pendekatan deep learning seperti TabNet; dan (5) deployment model setelah validasi pada data riil tuntas. Hingga validasi pada data riil dilakukan, model yang dipresentasikan tidak direkomendasikan untuk pengambilan keputusan klinis.

SIMPULAN

Penelitian ini berhasil mengembangkan dan mengevaluasi kerangka metodologis prediksi risiko stunting berbasis XGBoost yang dioptimasi dengan Bayesian Optimization, divalidasi pada dataset simulasi yang dikonstruksi berdasarkan statistik agregat resmi Survei Kesehatan Indonesia. Pada dataset simulasi berisi 12.847 record, model XGBoost-BO mencapai accuracy 91,8%, F1-score 90,4%, dan AUC-ROC 95,3%, secara statistik signifikan lebih unggul dibandingkan enam model pembanding ($p < 0,05$). Bayesian Optimization terbukti efisien

karena hanya membutuhkan 50 iterasi dan 142 detik waktu komputasi untuk mencapai konfigurasi optimum, dibandingkan Grid Search yang memerlukan 4.876 detik. Analisis SHAP mengidentifikasi berat badan lahir, tinggi badan ibu, dan pendapatan keluarga per kapita sebagai tiga faktor risiko paling dominan, konsisten dengan literatur epidemiologi. Hasil studi metodologis ini perlu divalidasi pada microdata riil setelah perizinan akses data dan ethical clearance diperoleh.

DAFTAR PUSTAKA

- [1] World Health Organization, "Stunting in a Nutshell," WHO, Geneva, 2024. [Online]. Available: <https://www.who.int/news/item/19-11-2015-stunting-in-a-nutshell>
- [2] Kementerian Kesehatan Republik Indonesia, "Hasil Survei Status Gizi Indonesia (SSGI) 2024," Jakarta: Kemenkes RI, 2024.
- [3] S. Mulyani and R. Wijaya, "Tantangan Deteksi Dini Stunting pada Sistem Posyandu di Indonesia," *Jurnal Kesehatan Masyarakat*, vol. 18, no. 2, pp. 115-127, 2023.
- [4] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System," in *Proc. 22nd ACM SIGKDD Int. Conf. Knowledge Discovery and Data Mining*, 2016, pp. 785-794.
- [5] A. Nugraha, B. Wibowo, and D. Sari, "Performance Evaluation of Gradient Boosting Algorithms for Imbalanced Medical Data," *Int. J. of Advanced Computer Science and Applications*, vol. 15, no. 4, pp. 142-151, 2024.
- [6] R. Mitchell and E. Frank, "Accelerating the XGBoost algorithm using GPU computing," *PeerJ Computer Science*, vol. 3, e127, 2017.
- [7] J. Bergstra and Y. Bengio, "Random Search for Hyper-Parameter Optimization," *Journal of Machine Learning Research*, vol. 13, pp. 281-305, 2012.
- [8] P. I. Frazier, "A Tutorial on Bayesian Optimization," arXiv preprint arXiv:1807.02811, 2018.
- [9] A. Patki, R. Wedge, and K. Veeramachaneni, "The Synthetic Data Vault," in *Proc. IEEE Int. Conf. on Data Science and Advanced Analytics*, 2016, pp. 399-410.
- [10] L. Yang and A. Shami, "On hyperparameter optimization of machine learning algorithms: Theory and practice," *Neurocomputing*, vol. 415, pp. 295-316, 2020.
- [11] D. Pratiwi, H. Setiyono, and M. Rahman, "Klasifikasi Status Gizi Balita Menggunakan Algoritma Random Forest pada Data Posyandu," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 9, no. 1, pp. 23-34, 2023.
- [12] B. Setiawan and A. Hidayat, "Penerapan Algoritma C4.5 untuk Prediksi Stunting pada Balita," *Jurnal RESTI*, vol. 7, no. 3, pp. 512-520, 2023.
- [13] F. Ramadhani, S. Kurniawan, and L. Pratama, "Komparasi Algoritma Machine Learning untuk Prediksi Stunting di Indonesia," *Jurnal Nasional Pendidikan Teknik Informatika*, vol. 12, no. 4, pp. 489-498, 2023.
- [14] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," *Journal of Artificial Intelligence Research*, vol. 16, pp. 321-357, 2002.
- [15] S. M. Lundberg and S.-I. Lee, "A Unified Approach to Interpreting Model Predictions," in *Advances in Neural Information Processing Systems*, 2017, pp. 4765-4774.
- [16] C. G. Victora et al., "Maternal and child undernutrition: consequences for adult health and human capital," *The Lancet*, vol. 371, no. 9609, pp. 340-357, 2008.
- [17] R. E. Black et al., "Maternal and child undernutrition and overweight in low-income and middle-income countries," *The Lancet*, vol. 382, no. 9890, pp. 427-451, 2013.
- [18] T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama, "Optuna: A Next-generation Hyperparameter Optimization Framework," in *Proc. 25th ACM SIGKDD Int. Conf.*, 2019, pp. 2623-2631.
- [19] M. Feurer and F. Hutter, "Hyperparameter Optimization," in *Automated Machine Learning*. Cham: Springer, 2019, pp. 3-33.
- [20] Badan Pusat Statistik, "Survei Demografi dan Kesehatan Indonesia (SDKI) 2022-2023," Jakarta: BPS, 2024.
- [21] Pemerintah Republik Indonesia, "Undang-Undang Nomor 27 Tahun 2022 tentang Pelindungan Data Pribadi," *Lembaran Negara RI Tahun 2022 No. 196*, Jakarta, 2022.
- [22] Kementerian Kesehatan RI, "Peraturan Menteri Kesehatan Nomor 7 Tahun 2016 tentang Komisi Etik Penelitian dan Pengembangan Kesehatan Nasional," *Berita Negara RI*, Jakarta, 2016.