

CESS

(Journal of Computer Engineering, System and Science)

Available online: <https://jurnal.unimed.ac.id/2012/index.php/cess>

ISSN: 2502-714x (Print) | ISSN: 2502-7131 (Online)



Perbandingan *Random Forest* dan *XGBoost* untuk Klasifikasi Sanitasi Tidak Layak pada Rumah Tangga Indonesia

A Comparison of Random Forest and XGBoost for Classifying Inadequate Sanitation in Indonesian Households

Fatiya Hanifah^{1*}, Kinanti Rizky Pangestutik², Ain Fitri Basri³, Bagus Sartono⁴, Aulia Rizki Firdawanti⁵

^{1,2,3,4,5}Program Studi Statistika dan Sains Data, Sekolah Sains Data, Matematika, dan Informatika, IPB University, Indonesia

Jl. Meranti, Kampus IPB Dramaga, Bogor, Jawa Barat 16680, Indonesia

Email: ¹fatiyahanifah@apps.ipb.ac.id, ²kinantirizkypangestutik@apps.ipb.ac.id,

³ainfitribasri@apps.ipb.ac.id, ⁴bagusco@apps.ipb.ac.id, ⁵auliafirda@apps.ipb.ac.id

*Corresponding Author

ABSTRAK

Sanitasi layak merupakan indikator penting kesehatan lingkungan dan target Tujuan Pembangunan Berkelanjutan 6.2. Penelitian ini membandingkan *Random Forest* dan *XGBoost* untuk mengklasifikasikan status sanitasi rumah tangga Indonesia menggunakan data Susenas 2024. Variabel respon dibentuk dari kepemilikan fasilitas buang air besar (BAB), jenis kloset, dan tempat pembuangan akhir tinja, sedangkan 19 prediktor dinotasikan sebagai X1 hingga X19 yang mencakup wilayah, karakteristik kepala rumah tangga, kondisi rumah, akses layanan dasar, aset, bantuan sosial, dan kerawanan pangan. Data dibagi 80:20; ketidakseimbangan kelas ditangani menggunakan SMOTE pada *Random Forest* dan *class weight* pada *XGBoost*. Empat skenario dibandingkan menggunakan *accuracy*, *kappa*, *sensitivity*, *specificity*, *precision*, *F1-score*, dan AUC. Hasil menunjukkan *XGBoost* dengan *class weight* memiliki *sensitivity* tertinggi (0,6966) dan *F1-score* tertinggi (0,5807). Interpretasi SHAP mengidentifikasi perdesaan, kepemilikan aset, penggunaan kayu bakar, lantai keramik, dan dinding kayu/papan sebagai variabel paling berpengaruh. Model *XGBoost* dengan *class weight* dipilih karena paling relevan untuk mendeteksi sanitasi Tidak Layak.

Kata Kunci: Sanitasi Tidak Layak; *Random Forest*; *XGBoost*; SMOTE; SHAP

ABSTRACT

Improved sanitation is a key environmental health indicator and target of Sustainable Development Goal 6.2. This study compares *Random Forest* and *XGBoost* for classifying household sanitation status in Indonesia using the 2024 National Socio-Economic Survey



This open access article is distributed under a Creative Commons Attribution (CC-BY) 4.0 license

(Susenas). The response variable was constructed from toilet or defecation facility ownership, closet type, and final fecal disposal, while the 19 predictors were denoted as X1 to X19, representing region, household-head characteristics, housing conditions, basic service access, assets, social assistance, and food insecurity. The data were split 80:20; class imbalance was addressed using SMOTE for Random Forest and class weighting for XGBoost. Four model scenarios were evaluated using accuracy, kappa, sensitivity, specificity, precision, F1-score, and AUC. Results show that class-weighted XGBoost achieved the highest sensitivity (0.6966) and F1-score (0.5807). SHAP interpretation identified rural residence, asset ownership, firewood use, ceramic flooring, and wooden walls as the most influential variables. Class-weighted XGBoost was selected as the most relevant model for detecting inadequate sanitation.

Keywords: *Inadequate Sanitation; Random Forest ; XGBoost; SMOTE; SHAP*

1. PENDAHULUAN

Sanitasi merupakan salah satu aspek penting dalam peningkatan kualitas kesehatan masyarakat dan kesejahteraan rumah tangga. Akses terhadap sanitasi yang layak berperan dalam mencegah penyebaran penyakit berbasis lingkungan dan meningkatkan kualitas hidup. Hal ini juga mendukung pencapaian *Sustainable Development Goals* (SDGs), khususnya tujuan 6.2 mengenai akses sanitasi dan kebersihan yang layak bagi seluruh masyarakat [1]. Dalam konteks rumah tangga, sanitasi dapat dikatakan layak apabila memenuhi beberapa kriteria, seperti kepemilikan fasilitas buang air besar (BAB) sendiri atau bersama, penggunaan jenis kloset leher angsa, serta tempat pembuangan akhir tinja yang sesuai, misalnya tangki septik atau instalasi pengolahan air limbah (IPAL) [2]. Berdasarkan indikator tersebut, status sanitasi rumah tangga dalam penelitian ini diklasifikasikan menjadi dua kategori, yaitu sanitasi Layak dan sanitasi Tidak Layak.

Permasalahan sanitasi Tidak Layak masih menjadi isu penting di Indonesia karena berkaitan erat dengan kondisi sosial ekonomi, karakteristik demografis, serta kualitas tempat tinggal rumah tangga [3]. Karakteristik rumah tangga, seperti kondisi hunian, akses air minum, sumber penerangan, bahan bakar memasak, dan tingkat pendidikan kepala rumah tangga, dapat memengaruhi kecenderungan status sanitasi [4]. Oleh karena itu, diperlukan analisis berbasis data untuk mengidentifikasi pola dan karakteristik rumah tangga yang berkaitan dengan sanitasi Tidak Layak. Data Survei Sosial Ekonomi Nasional atau Susenas 2024 dipilih karena memuat informasi sosial ekonomi dan kondisi perumahan rumah tangga secara luas di Indonesia.

Penelitian terdahulu yang menjadi landasan penelitian ini membahas pengaruh faktor sosial ekonomi terhadap akses sanitasi layak [2], variasi spasial akses sanitasi di Indonesia [3], serta keterkaitan kondisi perumahan dengan kesehatan rumah tangga [4]. Pendekatan tersebut telah memberikan informasi penting mengenai determinan sosial ekonomi, kondisi perumahan, dan pola kewilayahan. Namun, penelitian-penelitian yang dirujuk tersebut belum secara khusus diarahkan untuk membangun model klasifikasi pada tingkat rumah tangga yang mampu mendeteksi rumah tangga dengan sanitasi Tidak Layak. Penelitian-penelitian tersebut juga belum membandingkan metode *ensemble machine learning* dengan mempertimbangkan

ketidakseimbangan kelas dan interpretasi kontribusi setiap prediktor pada data sosial ekonomi rumah tangga berskala nasional. Kesenjangan tersebut menjadi dasar penggunaan pendekatan klasifikasi berbasis *machine learning* dalam penelitian ini.

Random Forest dan *XGBoost* dipilih karena keduanya merupakan metode *ensemble* berbasis pohon keputusan yang mampu menangani data berukuran besar serta hubungan nonlinier dan interaksi yang kompleks antarprediktor [5]. *Random Forest* menggunakan pendekatan *bagging* dengan membangun sejumlah pohon keputusan dan menggabungkan hasil prediksinya sehingga menghasilkan model yang relatif stabil [6]. Sementara itu, *XGBoost* menggunakan pendekatan *gradient boosting* dengan membangun pohon secara bertahap untuk memperbaiki kesalahan prediksi model sebelumnya [7]. Perbedaan mekanisme tersebut menjadi dasar perbandingan untuk mengetahui metode yang lebih sesuai dalam mengklasifikasikan status sanitasi rumah tangga pada data Susenas 2024.

Salah satu tantangan dalam klasifikasi status sanitasi adalah ketidakseimbangan kelas karena proporsi rumah tangga dengan sanitasi Layak lebih besar dibandingkan rumah tangga dengan sanitasi Tidak Layak. Kondisi tersebut dapat menyebabkan model lebih baik dalam mengenali kelas mayoritas dan kurang sensitif terhadap kelas Tidak Layak [8]. Oleh karena itu, penelitian ini menerapkan *Synthetic Minority Over-sampling Technique* (SMOTE) pada *Random Forest* dan *scale_pos_weight* sebagai bentuk *class weight* pada *XGBoost*. Penerapan kedua strategi tersebut bertujuan meningkatkan kemampuan model dalam mendeteksi rumah tangga dengan sanitasi Tidak Layak tanpa hanya menjadikan *accuracy* sebagai ukuran utama kinerja model.

Selain performa klasifikasi, interpretasi model juga diperlukan agar hasil prediksi dapat dipahami dalam konteks pengambilan keputusan berbasis kebijakan. Model *machine learning* sering dianggap sulit diinterpretasikan, terutama ketika hubungan antarprediktor dan hasil klasifikasi bersifat kompleks [9]. Oleh karena itu, penelitian ini menggunakan *SHapley Additive exPlanations* (SHAP) pada model terbaik untuk menjelaskan arah dan besarnya kontribusi setiap prediktor terhadap hasil klasifikasi. Pendekatan tersebut memungkinkan model tidak hanya dinilai berdasarkan performa prediksi, tetapi juga dipahami berdasarkan karakteristik rumah tangga yang mendorong prediksi ke arah sanitasi Layak atau Tidak Layak.

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan membandingkan kinerja *Random Forest* dan *XGBoost* sebelum dan setelah penanganan ketidakseimbangan kelas, serta menginterpretasikan model terbaik menggunakan SHAP. SMOTE diterapkan pada *Random Forest*, sedangkan *class weight* diterapkan pada *XGBoost*. Berbeda dengan penelitian terdahulu yang lebih berfokus pada analisis faktor sosial ekonomi, kondisi perumahan, dan pola spasial, kontribusi penelitian ini terletak pada integrasi perbandingan metode *ensemble machine learning*, penanganan ketidakseimbangan kelas, dan pendekatan *explainable machine learning* pada data Susenas 2024 berskala nasional. Hasil penelitian ini diharapkan dapat mendukung penjarangan awal rumah tangga yang berpotensi memiliki sanitasi Tidak Layak serta memberikan informasi mengenai karakteristik yang berkontribusi terhadap hasil klasifikasi.

2. METODE PENELITIAN

2.1. Data dan Variabel Penelitian

Penelitian ini menggunakan data Susenas 2024 dengan unit analisis rumah tangga sebanyak 343.479 observasi. Data yang digunakan mencakup data rumah tangga dan data individu. Data individu digunakan untuk mengekstrak karakteristik kepala rumah tangga (KRT) dan membentuk variabel struktur rumah tangga. Variabel respon adalah status sanitasi rumah tangga yang dikodekan menjadi 0 untuk Layak dan 1 untuk Tidak Layak. Status sanitasi dibentuk berdasarkan tiga indikator, yaitu kepemilikan fasilitas BAB, jenis kloset, dan tempat pembuangan akhir tinja. Rumah tangga dikategorikan Layak apabila memiliki fasilitas BAB sendiri atau bersama yang memenuhi kriteria, menggunakan kloset leher angsa, serta membuang akhir tinja ke tangki septik atau IPAL. Jika salah satu kriteria tidak terpenuhi, rumah tangga dikategorikan Tidak Layak.

Variabel prediktor dalam penelitian ini berjumlah 19 variabel dan dinotasikan sebagai X1 sampai X19. Notasi tersebut digunakan untuk memudahkan penyajian hasil pemodelan, terutama pada output *dummy variable* dan interpretasi SHAP. Rincian notasi, nama variabel, dan kelompok variabel disajikan pada Tabel 1.

Tabel 1. Notasi, Deskripsi, dan Kelompok Variabel Prediktor

Notasi	Variabel	Kelompok Variabel
X1	Provinsi	Wilayah
X2	Klasifikasi desa/kota	Wilayah
X3	Umur KRT	Karakteristik KRT
X4	Jenis kelamin KRT	Karakteristik KRT
X5	Pendidikan KRT	Karakteristik KRT
X6	Status bekerja KRT	Karakteristik KRT
X7	Jumlah anggota rumah tangga	Struktur rumah tangga
X8	Rasio ketergantungan	Struktur rumah tangga
X9	Status kepemilikan rumah	Kondisi fisik rumah
X10	Luas lantai per kapita	Kondisi fisik rumah
X11	Jenis lantai	Kondisi fisik rumah
X12	Jenis dinding	Kondisi fisik rumah
X13	Jenis atap	Kondisi fisik rumah
X14	Sumber air minum	Akses layanan dasar
X15	Sumber penerangan	Akses layanan dasar
X16	Bahan bakar memasak	Akses layanan dasar
X17	Kepemilikan aset	Sosial ekonomi
X18	Bantuan sosial	Sosial ekonomi
X19	Kerawanan pangan	Sosial ekonomi

Variabel kategorik pada Tabel 1, yaitu seluruh variabel kecuali X3, X7, X8, X10, dan X17 yang bersifat numerik, dikodekan sebagai *dummy variable* pada tahap pemodelan; kode kategori yang relevan dengan hasil interpretasi dijelaskan pada Tabel 4 di Bagian 3.3. Adapun variabel X17, yaitu kepemilikan aset, dibentuk sebagai skor tertimbang berdasarkan nilai ekonomi relatif 13 jenis aset rumah tangga.

2.2. Pra-pemrosesan dan Eksplorasi Data

Pra-pemrosesan dimulai dengan penggabungan data rumah tangga dan data individu untuk mengambil karakteristik KRT dan struktur rumah tangga. Pemeriksaan *missing value* menunjukkan bahwa terdapat tiga variabel yang memiliki nilai hilang, yaitu pendidikan KRT (X5) sebanyak 14.867 observasi atau sekitar 4,33%, status bekerja KRT (X6) sebanyak 7.398 observasi atau sekitar 2,15%, dan rasio ketergantungan (X8) sebanyak 19.899 observasi atau sekitar 5,79% dari total 343.479 observasi.

Missing value pada variabel kategorik, yaitu X5 dan X6, ditangani menggunakan imputasi modus karena modus merepresentasikan kategori yang paling sering muncul. Sementara itu, *missing value* pada variabel numerik, yaitu X8, ditangani menggunakan imputasi median karena median lebih tahan terhadap nilai ekstrem dibandingkan rata-rata. Setelah proses imputasi, tidak terdapat *missing value* pada data yang digunakan untuk pemodelan.

Data dibagi menjadi data latih dan data uji dengan proporsi 80:20 secara *stratified* agar proporsi kelas Layak dan Tidak Layak tetap terjaga pada kedua subset. Data latih terdiri dari 274.784 observasi dan data uji 68.695 observasi, dengan proporsi Tidak Layak masing-masing 27,43%. Eksplorasi data dilakukan untuk melihat distribusi target, pola variabel kategorik terhadap respon, serta distribusi variabel numerik berdasarkan status sanitasi.

2.3. Model dan Penanganan Ketidakseimbangan Kelas

Empat skenario model dibandingkan: (1) *Random Forest* tanpa penanganan *imbalance*, (2) *XGBoost* tanpa penanganan *imbalance*, (3) *Random Forest* dengan SMOTE, dan (4) *XGBoost* dengan *class weight*. *Random Forest* diimplementasikan menggunakan 5-fold cross validation, jumlah pohon 150, serta tuning pada parameter *mtry* $\in \{3, 5\}$ dan *min.node.size* $\in \{5, 10\}$. Model optimal menggunakan *mtry* = 5 dan *min.node.size* = 10 (tanpa penanganan *imbalance*) serta *mtry* = 5 dan *min.node.size* = 5 (dengan SMOTE).

Pada skenario SMOTE, data latih diseimbangkan melalui interpolasi antarobservasi kelas minoritas menggunakan *package themis* dalam R [10]. Proporsi kelas Tidak Layak meningkat dari 27,43% menjadi 50% setelah SMOTE, sehingga jumlah data latih bertambah dari 274.784 menjadi 398.816 observasi.

XGBoost diimplementasikan dengan *objective binary:logistic*, *eta* = 0,05, *max_depth* = 5, *min_child_weight* = 5, *subsample* = 0,8, *colsample_bytree* = 0,8, dan 300 iterasi *boosting*. Pada skenario *class weight*, parameter *scale_pos_weight* ditetapkan sebesar 2,646 (rasio kelas mayoritas terhadap minoritas), sehingga kesalahan prediksi pada kelas Tidak Layak diberi bobot lebih selama pelatihan [11].

2.4. Evaluasi Model dan Interpretasi SHAP

Evaluasi model dilakukan pada data uji menggunakan tujuh metrik: *accuracy*, *kappa*, *sensitivity*, *specificity*, *precision*, *F1-score*, dan AUC. Kelas positif ditetapkan sebagai Tidak Layak sehingga *sensitivity* menunjukkan kemampuan model mendeteksi rumah tangga yang benar-benar berstatus sanitasi Tidak Layak. Pemilihan model terbaik mengutamakan *sensitivity*, kemudian *F1-score* dan AUC sebagai metrik pendukung. Kurva ROC dan AUC dihitung menggunakan *package pROC* [12].

Interpretasi model terbaik menggunakan SHAP, yang dihitung pada sampel 1.000 observasi data uji untuk efisiensi komputasi. Nilai SHAP positif menunjukkan kontribusi

variabel ke arah prediksi Tidak Layak, sedangkan nilai SHAP negatif menunjukkan kontribusi ke arah Layak. Visualisasi mencakup *feature importance* dan *beeswarm plot* [13], [14].

3. HASIL DAN PEMBAHASAN

3.1. Eksplorasi Data dan Distribusi Target

Hasil eksplorasi menunjukkan bahwa data mengalami ketidakseimbangan kelas dengan proporsi rumah tangga Layak sekitar 72,57% (249.259 observasi) dan Tidak Layak sekitar 27,43% (94.220 observasi). Proporsi ini terjaga secara *stratified* pada data latih (274.784 observasi) dan data uji (68.695 observasi).

Eksplorasi variabel kategorik menunjukkan adanya perbedaan proporsi status sanitasi yang paling mencolok terlihat pada klasifikasi desa/kota. Rumah tangga perdesaan memiliki proporsi Tidak Layak sebesar 36,30%, sedangkan rumah tangga perkotaan hanya 15,25%. Beberapa variabel lain juga menunjukkan pola serupa, meliputi jenis lantai, pendidikan KRT, sumber air minum, status kepemilikan rumah, dan kerawanan pangan. Temuan ini mengindikasikan bahwa status sanitasi tidak hanya berkaitan dengan fasilitas sanitasi secara langsung, tetapi juga dengan karakteristik wilayah, kondisi tempat tinggal, dan faktor sosial ekonomi rumah tangga.

Pada variabel numerik, perbedaan distribusi antara kelas Layak dan Tidak Layak tidak setajam variabel kategorik, namun tetap informatif. Rata-rata skor kepemilikan aset rumah tangga Tidak Layak (20,76) lebih rendah dibandingkan rumah tangga Layak (26,32). Rata-rata luas lantai per kapita rumah tangga Tidak Layak (23,84 m²) juga lebih kecil dibandingkan Layak (29,47 m²). Hal ini mengindikasikan bahwa kondisi ekonomi dan kualitas hunian berkorelasi dengan status sanitasi.

3.2. Perbandingan Kinerja Model

Tabel 2 menyajikan perbandingan kinerja keempat skenario model pada data uji. Model tanpa penanganan *imbalance* menunjukkan *specificity* tinggi namun *sensitivity* rendah. *Random Forest* tanpa *imbalance* menghasilkan *specificity* 0,9678 tetapi *sensitivity* hanya 0,2939, menunjukkan bahwa model sangat baik mengenali rumah tangga Layak namun lemah mendeteksi Tidak Layak. *XGBoost* tanpa *imbalance* sedikit lebih baik dengan *sensitivity* 0,3450, namun masih menunjukkan bias serupa terhadap kelas mayoritas.

Pada *Random Forest*, penerapan SMOTE meningkatkan *sensitivity* dari 0,2939 menjadi 0,3742 dan *F1-score* dari 0,4262 menjadi 0,4883 dengan penurunan *specificity* dari 0,9678 menjadi 0,9401. Hal ini menunjukkan adanya *trade-off*, model lebih peka terhadap kelas Tidak Layak, tetapi sedikit berkurang dalam mengenali kelas Layak. Pola ini konsisten dengan karakteristik SMOTE yang menyeimbangkan kelas melalui pembentukan observasi sintesis pada kelas minoritas.

XGBoost dengan *class weight* memberikan hasil terbaik berdasarkan fokus penelitian. Model ini menghasilkan *sensitivity* tertinggi (0,6966), *F1-score* tertinggi (0,5807), dan *kappa* tertinggi (0,3835). Meskipun *accuracy* lebih rendah (0,7241), hal ini disebabkan model lebih sering memprediksi kelas Tidak Layak—sebuah *trade-off* yang relevan karena tujuan utama penelitian adalah mendeteksi rumah tangga dengan sanitasi Tidak Layak. Nilai AUC keempat

model relatif serupa ($\approx 0,794$), sehingga *sensitivity* dan *F1-score* menjadi pembeda utama. Berdasarkan pertimbangan ini, *XGBoost* dengan *class weight* dipilih sebagai model terbaik.

Tabel 2. Perbandingan Kinerja Model Tanpa dan Dengan Penanganan *Imbalance*

Skenario	Model	Accuracy	Kappa	Sensitivity	Specificity	Precision	F1	AUC
Tanpa Penanganan	<i>Random Forest</i>	0,7829	0,3243	0,2939	0,9678	0,7751	0,4262	0,7944
Tanpa Penanganan	<i>XGBoost</i>	0,7854	0,3552	0,3450	0,9519	0,7305	0,4687	0,7941
Dengan Penanganan	RF + SMOTE	0,7849	0,3678	0,3742	0,9401	0,7026	0,4883	0,7947
Dengan Penanganan	<i>XGBoost</i> + <i>class weight</i>	0,7241	0,3835	0,6966	0,7345	0,4979	0,5807	0,7940

Meskipun *XGBoost* dengan *class weight* memiliki *sensitivity* tertinggi, nilai *precision* model ini sebesar 0,4979. Artinya, dari seluruh rumah tangga yang diprediksi sebagai Tidak Layak, sekitar 49,79% benar-benar Tidak Layak, sedangkan sisanya merupakan prediksi positif yang keliru. Kondisi ini menunjukkan adanya *trade-off* antara peningkatan *sensitivity* dan penurunan *precision*. Model menjadi lebih agresif dalam mendeteksi rumah tangga Tidak Layak, tetapi konsekuensinya jumlah *false positive* juga meningkat.

Berdasarkan *confusion matrix* model *XGBoost* dengan *class weight*, terdapat 13.126 rumah tangga Tidak Layak yang berhasil terdeteksi dengan benar sebagai Tidak Layak, sedangkan 5.718 rumah tangga Tidak Layak masih gagal terdeteksi dan diprediksi sebagai Layak. Jumlah *false negative* ini penting diperhatikan karena dalam konteks sanitasi, rumah tangga Tidak Layak yang gagal terdeteksi berpotensi luput dari program intervensi. Di sisi lain, terdapat 13.235 rumah tangga Layak yang diprediksi sebagai Tidak Layak. *False positive* ini dapat berdampak pada efisiensi program apabila model digunakan untuk penentuan prioritas sasaran, karena sebagian rumah tangga yang sebenarnya sudah Layak dapat diprioritaskan secara keliru.

Tabel 3. *Confusion Matrix* Model *XGBoost* dengan *Class Weight*

Aktual/Prediksi	Prediksi Tidak Layak	Prediksi Layak
Aktual Tidak Layak	13.126	5.718
Aktual Layak	13.235	36.616

Dengan demikian, pemilihan *XGBoost* dengan *class weight* tetap relevan karena tujuan utama penelitian adalah meningkatkan deteksi rumah tangga dengan sanitasi Tidak Layak. Namun, hasil ini perlu diinterpretasikan sebagai model yang lebih berorientasi pada penjarangan kasus berisiko, bukan sebagai model yang sepenuhnya optimal dari sisi ketepatan sasaran. Jika model digunakan untuk mendukung kebijakan, maka hasil prediksi sebaiknya tetap dipadukan dengan verifikasi lapangan atau penyesuaian *threshold* untuk mengendalikan keseimbangan antara *false negative* dan *false positive*.

3.3. Interpretasi SHAP pada Model XGBoost

Interpretasi SHAP dilakukan pada model *XGBoost* dengan *class weight* menggunakan sampel 1.000 observasi data uji. Tabel 4 menyajikan 10 variabel dengan nilai *mean absolute* SHAP tertinggi, sedangkan Gambar 1 menyajikan visualisasi hasil interpretasi SHAP yang terdiri atas (a) *SHAP Feature Importance* dan (b) *SHAP Beeswarm Plot*.


Pada output SHAP, beberapa variabel kategorik muncul dalam bentuk *dummy variable* karena proses pengkodean variabel kategorik sebelum pemodelan. Untuk meningkatkan keterbacaan hasil, Tabel 4 menyajikan nama teknis variabel sekaligus label substantif dari setiap kategori. Misalnya, X2_Desa_Kota.2 menunjukkan kategori perdesaan pada variabel klasifikasi desa/kota; X16_Bahan_Bakar_Memasak.10 menunjukkan kategori kayu bakar pada variabel bahan bakar memasak; X11_Jenis_Lantai.2 menunjukkan kategori keramik pada variabel jenis lantai; dan X12_Jenis_Dinding.3 menunjukkan kategori kayu/papan pada variabel jenis dinding.

Variabel dengan kontribusi terbesar adalah kategori perdesaan pada variabel klasifikasi desa/kota dengan nilai *mean absolute* SHAP sebesar 0,3116. Nilai ini jauh lebih besar dibandingkan variabel lainnya, sehingga menunjukkan bahwa klasifikasi wilayah merupakan faktor dominan dalam membedakan status sanitasi [3]. Variabel penting berikutnya adalah kepemilikan aset, penggunaan kayu bakar sebagai bahan bakar memasak, lantai keramik, dan dinding kayu/papan. Secara substantif, hasil ini menunjukkan bahwa prediksi sanitasi Tidak Layak tidak hanya berkaitan dengan karakteristik fasilitas sanitasi, tetapi juga dengan wilayah tempat tinggal, kondisi ekonomi, kualitas fisik rumah, dan akses layanan dasar.

Tabel 4. Top 10 Variabel Berdasarkan *Mean Absolute* SHAP

Peringkat	Label Substantif	Nama Teknis Variabel	Mean SHAP
1	Perdesaan	X2_Desa_Kota.2	0,31159
2	Kepemilikan aset	X17_Kepemilikan_Aset	0,18015
3	Bahan bakar memasak: kayu bakar	X16_Bahan_Bakar_Memasak.10	0,14901
4	Jenis lantai: keramik	X11_Jenis_Lantai.2	0,13248
5	Jenis dinding: kayu/papan	X12_Jenis_Dinding.3	0,13191
6	Provinsi: Jawa Barat	X1_Provinsi.32	0,09406
7	Sumber air minum: air isi ulang	X14_Sumber_Air_Minum.2	0,09267
8	Luas lantai per kapita	X10_Luas_Lantai_per_Kapita	0,08634
9	Jenis lantai: kayu/papan	X11_Jenis_Lantai.5	0,06699
10	Pendidikan KRT: SD	X5_Pendidikan_KRT.3	0,05934

Visualisasi nilai *mean absolute* SHAP ditunjukkan pada Gambar 1(a), sedangkan distribusi arah dan besar kontribusi setiap variabel terhadap prediksi model ditampilkan pada Gambar 1(b).



Gambar 1. Visualisasi SHAP pada Model *XGBoost* dengan *class weight*. (a) *SHAP Feature Importance*; (b) *SHAP Beeswarm Plot*

Berdasarkan Gambar 1(b), variabel perdesaan ($X2_Desa_Kota.2 = 1$) secara konsisten menghasilkan nilai SHAP positif, yang berarti rumah tangga di daerah perdesaan cenderung diprediksi memiliki sanitasi Tidak Layak. Hal ini berkaitan dengan disparitas akses infrastruktur sanitasi antara perkotaan dan perdesaan. Analisis spasial sebelumnya juga menemukan bahwa faktor geografis menjadi determinan utama akses sanitasi layak di Indonesia [3].

Kepemilikan aset ($X17$) menunjukkan hubungan monoton yang jelas: skor aset rendah menghasilkan SHAP positif (mendorong prediksi Tidak Layak), sedangkan skor aset tinggi menghasilkan SHAP negatif (mendorong prediksi Layak). Hasil ini konsisten dengan temuan bahwa kondisi ekonomi rumah tangga berkaitan dengan kemampuan mengakses fasilitas sanitasi yang memadai [2]. Penggunaan kayu bakar ($X16_Bahan_Bakar_Memasak.10$) juga memiliki kontribusi besar ke arah Tidak Layak, mencerminkan keterbatasan akses energi modern yang umumnya berkorelasi dengan kondisi sosial ekonomi yang lebih rendah.

Lantai keramik ($X11_Jenis_Lantai.2$) cenderung menghasilkan SHAP negatif, mencerminkan kualitas hunian yang lebih baik dan berkorelasi positif dengan sanitasi Layak. Sebaliknya, dinding kayu/papan ($X12_Jenis_Dinding.3$) menghasilkan SHAP positif, menggambarkan kualitas bangunan yang lebih sederhana dan berkaitan dengan sanitasi Tidak Layak. Secara keseluruhan, hasil SHAP menunjukkan bahwa sanitasi Tidak Layak merupakan fenomena multidimensional yang berkaitan erat dengan kombinasi faktor wilayah, kondisi ekonomi, kualitas fisik rumah, dan akses layanan dasar[8], [15].

4. KESIMPULAN

Penelitian ini membandingkan *Random Forest* dan *XGBoost* untuk mengklasifikasikan rumah tangga dengan sanitasi Tidak Layak di Indonesia menggunakan data Susenas 2024. Status sanitasi dibentuk berdasarkan fasilitas BAB, jenis kloset, dan tempat pembuangan akhir tinja, sedangkan 19 prediktor mencakup karakteristik wilayah, karakteristik KRT, struktur rumah tangga, kondisi fisik rumah, akses layanan dasar, aset, bantuan sosial, dan kerawanan pangan.

Hasil evaluasi menunjukkan bahwa penanganan ketidakseimbangan kelas diperlukan karena model tanpa penanganan cenderung memiliki *sensitivity* rendah terhadap kelas Tidak

Layak. *Random Forest* dengan SMOTE meningkatkan *sensitivity* dibandingkan *Random Forest* tanpa *imbalance*, tetapi peningkatannya terbatas. *XGBoost* dengan *class weight* memberikan hasil terbaik dengan *sensitivity* 0,6966 dan *F1-score* 0,5807, sehingga dipilih sebagai model utama untuk deteksi sanitasi Tidak Layak. Namun, model ini juga menghasilkan *precision* sebesar 0,4979, sehingga terdapat konsekuensi *false positive* yang perlu diperhatikan apabila model digunakan untuk penentuan prioritas sasaran program.

Interpretasi SHAP menunjukkan bahwa perdesaan, kepemilikan aset rendah, penggunaan kayu bakar, serta dinding kayu/papan cenderung mendorong prediksi model ke arah sanitasi Tidak Layak, sedangkan lantai keramik cenderung mendorong prediksi ke arah sanitasi Layak. Temuan ini memberikan informasi penting bagi perumusan kebijakan sanitasi yang berbasis wilayah dan kondisi sosial ekonomi rumah tangga.

Penelitian selanjutnya dapat mempertimbangkan: (1) penyetelan *threshold* prediksi yang optimal; (2) perbandingan metode penanganan *imbalance* lain seperti ADASYN; (3) validasi model pada data Susenas tahun berbeda untuk menguji stabilitas temporal; serta (4) perluasan interpretasi variabel hingga tingkat provinsi agar hasil lebih operasional untuk perencanaan kebijakan sanitasi berbasis wilayah.

DAFTAR PUSTAKA

- [1] S. Cheng, D. P. Saroj, K. Xu, N. Rana, and E. M. Huba-Mang, Eds., *Sustainable sanitation - how can we improve sanitation systems in the global south?* in *Frontiers Research Topics*. Frontiers Media SA, 2023. doi: 10.3389/978-2-8325-2364-3.
- [2] D. Widyastuti, H. N. Jamaluddin, R. Arisanti, and F. Kartiasih, "Analisis Pengaruh Faktor Sosial Ekonomi Terhadap Akses Sanitasi Layak di Indonesia Tahun 2021," *Seminar Nasional Official Statistics*, vol. 2023, no. 1, pp. 105–116, Oct. 2023, doi: 10.34123/semnasoffstat.v2023i1.1853.
- [3] M. R. Aprilia, A. P. Andryani, and A. F. Indrayani, "Analisis spasial faktor-faktor yang mempengaruhi akses sanitasi layak di Indonesia tahun 2023 menggunakan Geographically Weighted Regression," *Sanitasi: Jurnal Kesehatan Lingkungan*, vol. 17, no. 1, pp. 14–23, Feb. 2024, doi: 10.29238/sanitasi.v17i1.3008.
- [4] Y. Nurislami, M. Mahmudah, and N. N. Rosyada, "Determinan Kondisi Perumahan Terhadap Keluhan Kesehatan Rumah Tangga di Jawa Timur: Survei Sosial Ekonomi Nasional 2024," *Jurnal Sosial dan Teknologi*, vol. 6, no. 3, pp. 928–939, Mar. 2026, doi: 10.59188/jurnalsostech.v6i3.32678.
- [5] B. A. Hamed, O. A. S. Ibrahim, and T. Abd El-Hafeez, "Optimizing classification efficiency with machine learning techniques for pattern matching," *J. Big Data*, vol. 10, no. 1, p. 124, Jul. 2023, doi: 10.1186/s40537-023-00804-6.
- [6] L. Breiman, "Random Forest s," *Mach. Learn.*, vol. 45, no. 1, pp. 5–32, Oct. 2001, doi: 10.1023/A:1010933404324.
- [7] A. Momparler, P. Carmona, and F. Climent, "Catalyzing Sustainable Investment: Revealing ESG Power in Predicting Fund Performance with Machine Learning," *Comput. Econ.*, vol. 65, no. 3, pp. 1617–1642, Mar. 2025, doi: 10.1007/s10614-024-10618-0.

- [8] B. Bakirarar and A. H. Elhan, "Class Weighting Technique to Deal with Imbalanced Class Problem in Machine Learning: Methodological Research," *Turkiye Klinikleri Journal of Biostatistics*, vol. 15, no. 1, pp. 19–29, 2023, doi: 10.5336/biostatic.2022-93961.
- [9] D. V. Carvalho, E. M. Pereira, and J. S. Cardoso, "Machine Learning Interpretability: A Survey on Methods and Metrics," *Electronics (Basel)*, vol. 8, no. 8, p. 832, Jul. 2019, doi: 10.3390/electronics8080832.
- [10] 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, Jun. 2002, doi: 10.1613/jair.953.
- [11] T. Chen and C. Guestrin, "XGBoost," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, New York, NY, USA: ACM, Aug. 2016, pp. 785–794. doi: 10.1145/2939672.2939785.
- [12] X. Robin *et al.*, "pROC: an open-source package for R and S+ to analyze and compare ROC curves," *BMC Bioinformatics*, vol. 12, no. 1, p. 77, Dec. 2011, doi: 10.1186/1471-2105-12-77.
- [13] S. M. Lundberg and S.-I. Lee, "A Unified Approach to Interpreting Model Predictions," *Adv. Neural Inf. Process. Syst.*, vol. 30, pp. 4765–4774, 2017, [Online]. Available: <https://github.com/slundberg/shap>
- [14] S. M. Lundberg *et al.*, "From local explanations to global understanding with explainable AI for trees," *Nat. Mach. Intell.*, vol. 2, no. 1, pp. 56–67, Jan. 2020, doi: 10.1038/s42256-019-0138-9.
- [15] T. Hastie, R. Tibshirani, and J. Friedman, *The Elements of Statistical Learning*. New York, NY: Springer New York, 2009. doi: 10.1007/978-0-387-84858-7.