



Implementasi X-StuntAI untuk Deteksi Dini dan Interpretasi Risiko Stunting pada Balita

Rayendra^{1*}, Andri Yunaldi²

¹Program Studi Manajemen Informatika, Politeknik Negeri Padang

²Program Studi Manajemen Informatika, Akademi Manajemen Informatika dan Komputer Kosgoro

rayendra@pnp.ac.id . andri.yunaldi261168@gmail.com

Abstract

Stunting in toddlers remains a major health problem in Indonesia because it affects physical growth, cognitive development and the future quality of human resources. This study aims to implement X-StuntAI, a framework based on Explainable Artificial Intelligence (XAI) with an Explainable Ensemble Learning approach for the early detection of stunting while also interpreting the risk factors influencing prediction results. The methods used include data preprocessing, splitting the data into training and testing sets, applying several machine learning algorithms and evaluating model performance using accuracy. The results show that the K-Nearest Neighbors (KNN) algorithm achieved the best performance with an accuracy of 99.53% followed by Support Vector Machine (SVM) at 99.48%, SVM with hyperparameter tuning using GridSearchCV at 99.40%, Logistic Regression at 74.81% and Gaussian Naive Bayes at 55.41%. These findings indicate that X-StuntAI can deliver highly accurate classification while also providing a more transparent interpretation of stunting risk factors. In the future, this framework has the potential to be developed into a more practical decision-support system to assist healthcare workers in the early detection and prevention of stunting in toddlers.

Keywords: *Stunting, Machine Learning, Explainable Artificial Intelligence (XAI), Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Explainable Ensemble Learning.*

Abstrak

Stunting pada balita masih menjadi persoalan kesehatan utama di Indonesia karena berdampak pada pertumbuhan fisik, perkembangan kognitif, dan kualitas sumber daya manusia di masa depan. Penelitian ini bertujuan mengimplementasikan X-StuntAI, yaitu framework berbasis Explainable Artificial Intelligence (XAI) dengan pendekatan Explainable Ensemble Learning, untuk mendeteksi dini stunting sekaligus menginterpretasikan faktor risiko yang memengaruhi hasil prediksi. Metode yang digunakan meliputi preprocessing data, pembagian data latih dan data uji, penerapan beberapa algoritma machine learning, serta evaluasi performa model menggunakan akurasi. Hasil penelitian menunjukkan bahwa algoritma K-Nearest Neighbors (KNN) memberikan performa terbaik dengan akurasi sebesar 99,53%, diikuti Support Vector Machine (SVM) sebesar 99,48%, SVM dengan hyperparameter tuning menggunakan GridSearchCV sebesar 99,40%, Logistic Regression sebesar 74,81%, dan Gaussian Naive Bayes sebesar 55,41%. Temuan ini menunjukkan bahwa X-StuntAI mampu memberikan klasifikasi yang sangat baik sekaligus membantu interpretasi faktor risiko stunting secara lebih transparan. Ke depan, framework ini berpotensi dikembangkan menjadi sistem pendukung keputusan yang lebih aplikatif untuk membantu tenaga kesehatan dalam deteksi dini dan pencegahan stunting pada balita.

Kata kunci: *Stunting, Explainable Artificial Intelligence (XAI), Support Vector Machine (SVM), K-Nearest Neighbors (KNN), Explainable Ensemble Learning.*



1. Pendahuluan

Stunting merupakan salah satu permasalahan gizi kronis yang masih menjadi tantangan besar dalam bidang kesehatan masyarakat di Indonesia. Kondisi *stunting* pada balita dapat menyebabkan gangguan pertumbuhan fisik, perkembangan kognitif, penurunan produktivitas, hingga meningkatkan risiko penyakit pada masa dewasa. Tingginya prevalensi *stunting* menunjukkan bahwa diperlukan upaya deteksi dini yang lebih efektif agar penanganan dapat dilakukan secara cepat dan tepat. Perkembangan teknologi digital dan pemanfaatan data kesehatan membuka peluang penerapan kecerdasan buatan untuk membantu proses identifikasi risiko *stunting* secara otomatis dan lebih akurat [1].

Stunting merupakan kondisi gagal tumbuh pada balita akibat kekurangan gizi kronis dalam jangka waktu panjang sehingga tinggi badan anak berada di bawah standar usianya. Kondisi ini tidak hanya berdampak pada pertumbuhan fisik, tetapi juga perkembangan kognitif, kemampuan belajar, dan produktivitas anak di masa depan. Penelitian terbaru menjelaskan bahwa *stunting* masih menjadi permasalahan kesehatan serius di berbagai negara berkembang, termasuk Indonesia, sehingga diperlukan upaya deteksi dini yang lebih efektif dan akurat [2]. Selain faktor gizi, berbagai faktor lain seperti sanitasi lingkungan, pendidikan orang tua, kondisi ekonomi keluarga, dan akses layanan kesehatan juga memengaruhi risiko terjadinya *stunting* pada balita. Penelitian tahun 2024 menunjukkan bahwa pendekatan berbasis data dan teknologi kesehatan digital dapat membantu proses identifikasi risiko *stunting* secara lebih cepat dan sistematis [3].

Dalam beberapa tahun terakhir, penerapan *Artificial Intelligence (AI)* dan *Machine Learning (ML)* dalam bidang kesehatan mengalami peningkatan signifikan, termasuk pada sistem prediksi dan klasifikasi *stunting*. Pendekatan *machine learning* dinilai mampu mengolah data kesehatan dalam jumlah besar dan menemukan pola yang sulit dianalisis secara manual. Penelitian *Systematic Literature Review* tahun 2025 menjelaskan bahwa algoritma *machine learning* memiliki potensi besar dalam mendukung diagnosis dan intervensi dini *stunting* pada anak melalui analisis faktor risiko secara otomatis [16].

Machine Learning merupakan cabang dari kecerdasan buatan yang memungkinkan sistem komputer mempelajari pola dari data untuk menghasilkan prediksi atau klasifikasi secara otomatis. Dalam bidang kesehatan, *machine learning* banyak digunakan untuk mendukung diagnosis penyakit, prediksi risiko kesehatan, serta analisis data medis dalam jumlah besar. Penelitian terbaru menunjukkan bahwa *machine learning* mampu meningkatkan efektivitas sistem prediksi *stunting* karena dapat mengolah data kesehatan secara lebih cepat dan akurat dibandingkan metode konvensional [4][5]. Penerapan *machine learning* pada prediksi *stunting* telah menggunakan berbagai algoritma seperti *Support Vector Machine (SVM)*, *Random Forest*, *Naive Bayes*, *Logistic Regression*, hingga *Extreme Gradient Boosting (XGBoost)*. Salah satu penelitian di *Jurnal Pustaka AI* menunjukkan bahwa pendekatan *K-Nearest Neighbors* yang dioptimasi dengan metode metaheuristik dapat digunakan untuk pengelompokan faktor penyebab *stunting*, yang memperkuat relevansi pendekatan berbasis *machine learning* dalam analisis *stunting* [22]. Penelitian lain di *Jurnal Pustaka AI* juga menunjukkan bahwa sistem cerdas berbasis metode *Case-Based Reasoning* dan *SMART* dapat membantu edukasi pemenuhan gizi masyarakat, sehingga mendukung urgensi pemanfaatan teknologi dalam isu gizi dan pencegahan *stunting* [23]. Penelitian tahun 2025 juga menjelaskan bahwa penggunaan *machine learning* dapat membantu mendeteksi risiko *stunting* pada anak secara lebih dini sehingga proses intervensi kesehatan dapat dilakukan lebih cepat [5].

Support Vector Machine (SVM) merupakan algoritma *machine learning* yang digunakan untuk klasifikasi dengan mencari *hyperplane* optimal yang mampu memisahkan data antar kelas secara maksimal. SVM memiliki kemampuan generalisasi yang baik dan efektif digunakan pada data berdimensi tinggi. Penelitian tahun 2024 menunjukkan bahwa algoritma SVM mampu memberikan performa klasifikasi yang tinggi dalam prediksi *stunting* dibandingkan beberapa algoritma lainnya [6][7]. Pada penelitian lain tahun 2025, SVM digunakan dalam sistem prediksi *stunting* berbasis *machine learning* dan menghasilkan tingkat akurasi yang stabil pada data kesehatan balita. Penggunaan *kernel* pada SVM juga memungkinkan model menangani data nonlinier secara lebih efektif [8].

Multinomial Naive Bayes merupakan algoritma klasifikasi probabilistik yang bekerja berdasarkan Teorema Bayes dengan asumsi independensi antar fitur. Algoritma ini memiliki keunggulan dalam efisiensi komputasi dan sering digunakan pada klasifikasi data teks maupun data kategorikal. Penelitian tahun 2026 menjelaskan bahwa *Naive Bayes* cukup efektif digunakan pada sistem identifikasi status gizi balita berbasis *machine learning* karena

memiliki proses klasifikasi yang cepat dan sederhana [9]. Selain itu, penelitian tahun 2024 menunjukkan bahwa *Naive Bayes* dapat digunakan dalam analisis data kesehatan dengan performa klasifikasi yang cukup baik pada *dataset* tertentu [10].

Logistic Regression merupakan metode klasifikasi statistik yang digunakan untuk memprediksi probabilitas suatu kelas berdasarkan variabel input tertentu. Algoritma ini sering digunakan dalam bidang kesehatan karena mampu memberikan interpretasi hubungan antar variabel secara jelas. Penelitian tahun 2025 menunjukkan bahwa *Logistic Regression* cukup efektif digunakan untuk klasifikasi data stunting dan analisis faktor risiko kesehatan anak [11]. Sementara itu, *K-Nearest Neighbors (KNN)* merupakan algoritma klasifikasi berbasis jarak yang menentukan kelas berdasarkan tetangga terdekat dari suatu data. Penelitian tahun 2024 menjelaskan bahwa KNN memiliki implementasi sederhana dan cukup baik digunakan pada *dataset* kesehatan dengan ukuran kecil hingga menengah [14][15].

Beberapa penelitian sebelumnya telah menerapkan berbagai algoritma *machine learning* untuk prediksi stunting, seperti *Random Forest*, *Support Vector Machine (SVM)*, *Logistic Regression*, dan metode *hybrid machine learning*. Penelitian Indrisari dkk. tahun 2025 menyebutkan bahwa penggunaan *machine learning* dalam prediksi stunting mampu meningkatkan efektivitas sistem deteksi dini dan membantu pengambilan keputusan berbasis data kesehatan [16]. Selain itu, penelitian Hasdyna dkk. tahun 2024 menunjukkan bahwa pendekatan *hybrid machine learning* mampu menghasilkan performa klasifikasi yang baik dalam analisis prevalensi stunting di Indonesia [18]. Meskipun berbagai algoritma *machine learning* telah menunjukkan performa yang cukup baik, sebagian besar model masih memiliki kelemahan dalam aspek interpretabilitas. Model klasifikasi sering kali bekerja sebagai *black box* sehingga sulit dipahami oleh tenaga kesehatan maupun pengambil kebijakan. Padahal, interpretasi faktor risiko sangat penting untuk mendukung transparansi dan kepercayaan terhadap hasil prediksi.

Explainable Artificial Intelligence (XAI) merupakan pendekatan kecerdasan buatan yang bertujuan memberikan penjelasan terhadap hasil keputusan model *machine learning*. Konsep ini berkembang karena banyak model *machine learning* bekerja seperti *black box* sehingga sulit dipahami oleh pengguna, terutama dalam bidang kesehatan yang membutuhkan transparansi hasil prediksi. Penelitian terbaru tahun 2025 menjelaskan bahwa XAI dapat membantu tenaga kesehatan memahami faktor-faktor utama yang memengaruhi hasil klasifikasi pada sistem prediksi stunting [13][17]. Penggunaan XAI pada sistem kesehatan juga meningkatkan kepercayaan pengguna terhadap hasil prediksi *machine learning* karena proses pengambilan keputusan model menjadi lebih transparan dan mudah dipahami. Dengan demikian, pendekatan *explainable AI* sangat penting untuk mendukung sistem deteksi dini stunting yang akurat sekaligus *interpretable* [17].


Penelitian terbaru tahun 2026 mengenai penerapan *Explainable AI* pada prediksi stunting menunjukkan bahwa pendekatan *explainable machine learning* mampu membantu mengidentifikasi faktor-faktor utama yang memengaruhi risiko stunting, seperti berat badan, usia, dan kondisi kesehatan anak [18]. Selain meningkatkan akurasi klasifikasi, penggunaan XAI juga memberikan transparansi terhadap hasil prediksi sehingga lebih mudah dipahami dalam proses pengambilan keputusan di bidang kesehatan masyarakat [18]. Berdasarkan permasalahan tersebut, penelitian ini mengusulkan implementasi X-StuntAI untuk deteksi dini dan interpretasi faktor risiko stunting pada balita. *Framework* ini mengintegrasikan beberapa algoritma *machine learning*, yaitu *Support Vector Machine (SVM)*, *Multinomial Naive Bayes*, *Logistic Regression*, dan *K-Nearest Neighbors (KNN)*, untuk menghasilkan model klasifikasi yang optimal. Selain itu, pendekatan *explainable AI* digunakan untuk memberikan interpretasi terhadap faktor-faktor risiko yang memengaruhi hasil prediksi stunting. Diharapkan penelitian ini dapat membantu meningkatkan efektivitas deteksi dini stunting serta mendukung pengambilan keputusan yang lebih akurat dan transparan dalam bidang kesehatan anak.

Ensemble Learning merupakan metode *machine learning* yang menggabungkan beberapa model klasifikasi untuk meningkatkan performa prediksi. Teknik ini bekerja dengan mengombinasikan hasil dari beberapa algoritma sehingga menghasilkan akurasi yang lebih baik dibandingkan penggunaan model tunggal. Penelitian tahun 2025 menunjukkan bahwa pendekatan *ensemble learning* mampu meningkatkan stabilitas model dan mengurangi kesalahan klasifikasi pada prediksi stunting [19][20]. Selain meningkatkan akurasi, *ensemble learning* juga efektif dalam menangani data kesehatan yang kompleks dan tidak seimbang. Kombinasi beberapa model klasifikasi dapat membantu sistem mengenali pola data dengan lebih baik sehingga hasil prediksi menjadi lebih optimal [21].

2. Metode Penelitian

Penelitian ini menggunakan metode kuantitatif dengan pendekatan eksperimen komparatif *machine learning*. Penelitian ini bertujuan membangun sistem kecerdasan buatan untuk mendeteksi dini stunting pada balita serta menginterpretasikan faktor-faktor risiko yang memengaruhi hasil prediksi. Proses penelitian dilakukan melalui beberapa tahapan, yaitu pengumpulan data kesehatan balita, *preprocessing* data, seleksi fitur, pembagian *dataset* menjadi data latih (*training*) dan data uji (*testing*), implementasi beberapa algoritma klasifikasi, serta evaluasi

performa model. Data yang digunakan diklasifikasikan ke dalam kategori stunting dan non-stunting berdasarkan faktor risiko kesehatan balita. Evaluasi model dilakukan untuk membandingkan performa masing-masing algoritma dalam mendeteksi stunting secara akurat dan transparan. Diagram alir penelitian ditampilkan pada Gambar 1 sebagai gambaran umum tahapan penelitian.




Gambar 1. Metodologi Penelitian

2.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini merupakan dataset kesehatan balita yang berjumlah 121000 data. Dataset tersebut berisi informasi terkait kondisi kesehatan dan faktor risiko stunting pada balita, seperti usia, tinggi badan, berat badan, status gizi, riwayat ASI eksklusif, pendidikan ibu, pendapatan keluarga, sanitasi lingkungan, dan riwayat penyakit infeksi. Data digunakan sebagai dasar dalam proses klasifikasi untuk mendeteksi risiko stunting pada balita menggunakan beberapa algoritma machine learning.

2.2. Pelabelan Data

Berdasarkan hasil pelabelan data, diperoleh distribusi status gizi balita yang terdiri dari kategori normal sebanyak sekitar 68.000 data, tinggi sekitar 19.000 data, severely stunted sekitar 20.000 data, dan stunted sekitar 14.000 data. Sebaran dataset tersebut secara visual disajikan pada Gambar 2.



Gambar 2. Distribusi Kelas Sentimen

2.3. Data Preprocessing

Tahap ini bertujuan untuk mereduksi *noise* pada teks melalui teknik *case folding*, pembersihan karakter non-alfabetik (*cleansing*), tokenisasi, *filtering*, dan pengubahan kata ke bentuk dasar (*stemming*).



Gambar 3. Wordcloud Setelah Preprocessing

3. Hasil dan Pembahasan

Setelah data melalui tahapan *preprocessing*, data dibagi menjadi data latih (*training*) dan data uji (*testing*) untuk proses pelatihan serta evaluasi model. Penelitian ini membandingkan empat algoritma klasifikasi, yaitu *Support Vector Machine (SVM)*, *Gaussian Naive Bayes*, *Logistic Regression*, dan *K-Nearest Neighbors (KNN)*, dalam mendeteksi risiko stunting pada balita. Hasil pengujian menunjukkan adanya perbedaan performa yang cukup signifikan di antara keempat model tersebut.

3.1. Analisis Karakteristik Data


Data yang digunakan dalam penelitian ini merupakan *dataset* kesehatan balita yang berjumlah 121.000 data. *Dataset* tersebut berisi informasi terkait kondisi kesehatan dan faktor risiko stunting pada balita, seperti usia, tinggi badan, berat badan, status gizi, riwayat ASI eksklusif, pendidikan ibu, pendapatan keluarga, sanitasi lingkungan, dan riwayat penyakit infeksi. Data ini digunakan sebagai dasar dalam proses klasifikasi untuk mendeteksi risiko stunting pada balita menggunakan beberapa algoritma *machine learning*.

A. Algoritma *Support Vector Machine (SVM)*

Proses klasifikasi data dengan cara mencari batas pemisah (*hyperplane*) terbaik antara dua atau lebih kelas data. SVM bekerja dengan memaksimalkan jarak antar kelas sehingga mampu menghasilkan klasifikasi yang lebih akurat. Dalam penelitian ini, algoritma SVM digunakan untuk mendeteksi risiko *stunting* pada balita berdasarkan data kesehatan dan faktor risiko yang dimiliki.

Classification Report (SVM):

	precision	recall	f1-score	support
normal	0.997	0.997	0.997	20327
severely stunted	0.994	0.995	0.995	5961
stunted	0.985	0.984	0.984	4144
tinggi	0.995	0.995	0.995	5868
accuracy			0.995	36300
macro avg	0.993	0.993	0.993	36300
weighted avg	0.995	0.995	0.995	36300

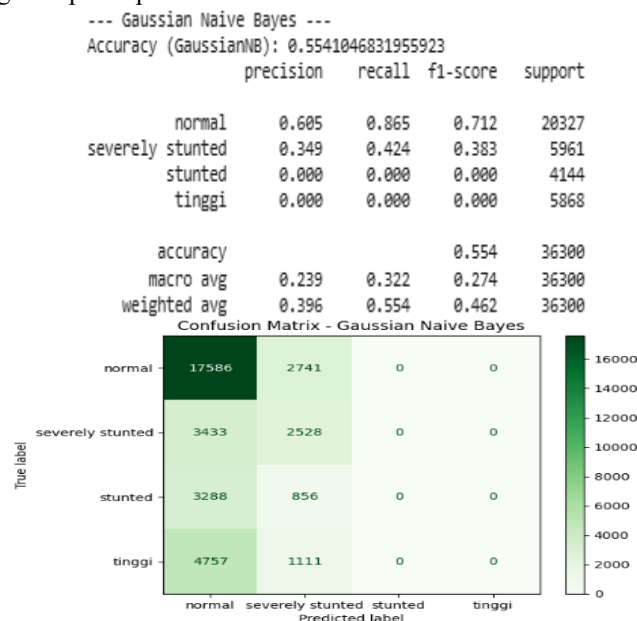


Gambar 4. Confusion Matrix SVM

Gambar 4 menunjukkan hasil evaluasi model *Support Vector Machine (SVM)* menggunakan *classification report* dan *confusion matrix* pada proses klasifikasi data stunting. Berdasarkan *classification report*, model SVM memperoleh tingkat akurasi sebesar 99,5%, yang menunjukkan bahwa model memiliki performa sangat baik dalam mengklasifikasikan data balita ke dalam kategori normal, *severely stunted*, *stunted*, dan tinggi. Nilai *precision*, *recall*, dan *f1-score* pada setiap kelas juga sangat tinggi, yaitu berada pada rentang 0,984 hingga 0,997. Hal ini menunjukkan bahwa model mampu melakukan prediksi dengan tingkat ketepatan dan konsistensi yang sangat baik. Pada kategori normal, model memperoleh *precision*, *recall*, dan *f1-score* sebesar 0,997 dengan jumlah data (*support*) sebanyak 20.327 data. Untuk kategori *severely stunted*, diperoleh nilai *precision* sebesar 0,994, *recall* 0,995, dan *f1-score* 0,995 dengan total 5.961 data. Selanjutnya, kategori *stunted* memperoleh *precision* sebesar 0,985, *recall* 0,984, dan *f1-score* 0,984 dengan jumlah 4.144 data. Pada kategori tinggi, model memperoleh *precision*, *recall*, dan *f1-score* sebesar 0,995 dengan total 5.868 data. Sementara itu, *confusion matrix* menunjukkan bahwa sebagian besar data berhasil diklasifikasikan dengan benar pada masing-masing kelas. Nilai diagonal pada matriks memiliki jumlah yang sangat besar, menandakan prediksi yang sesuai dengan label sebenarnya. Kesalahan klasifikasi hanya terjadi pada sebagian kecil data, sehingga model SVM dinilai sangat baik dalam mendeteksi risiko stunting.

B. Algoritma *Naïve Bayes*

Algoritma *Gaussian Naïve Bayes* digunakan untuk mengklasifikasikan risiko stunting pada balita berdasarkan data kesehatan dan faktor risiko yang tersedia. Metode ini cukup mampu melakukan klasifikasi, namun performanya masih berada di bawah SVM dan KNN karena karakteristik data kesehatan balita memiliki hubungan antarfitur yang cukup kompleks.

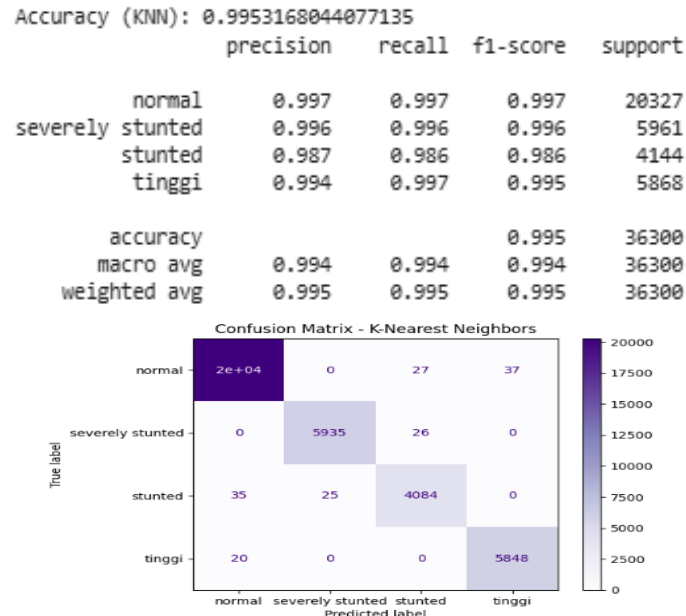
Gambar 5. Confusion Matrix SVM *Naïve Bayes*

Gambar 5 menunjukkan hasil evaluasi algoritma *Gaussian Naïve Bayes* menggunakan *classification report* dan *confusion matrix* pada klasifikasi data stunting. Berdasarkan hasil pengujian, algoritma *Gaussian Naïve Bayes* memperoleh tingkat akurasi sebesar 55,41%, sehingga performanya tergolong masih rendah dibandingkan algoritma lain yang digunakan dalam penelitian. Pada *classification report* terlihat bahwa kategori normal memiliki nilai *precision* sebesar 0,605, *recall* 0,865, dan *f1-score* 0,712 dengan jumlah data

sebanyak 20.327 data. Hal ini menunjukkan bahwa model cukup baik dalam mengenali data kategori normal. Selanjutnya, kategori *severely stunted* memperoleh *precision* sebesar 0,349, *recall* 0,424, dan *f1-score* 0,383 dengan total 5.961 data, yang menunjukkan performa klasifikasi masih kurang optimal. Sementara itu, pada kategori *stunted* dan tinggi, nilai *precision*, *recall*, dan *f1-score* bernilai 0,000. Hal ini menunjukkan bahwa model gagal mengenali kedua kategori tersebut dengan baik. Secara keseluruhan, hasil evaluasi menunjukkan bahwa *Gaussian Naive Bayes* kurang efektif digunakan pada *dataset* penelitian ini karena tingkat akurasi dan kemampuan klasifikasinya masih rendah, terutama dalam mengenali kategori *stunted* dan tinggi.

C. Algoritma *K-Nearest Neighbors*

Algoritma *K-Nearest Neighbors* (KNN) digunakan untuk mengklasifikasikan risiko stunting pada balita berdasarkan kedekatan data terhadap tetangga terdekatnya. Hasil pengujian menunjukkan bahwa KNN menghasilkan performa terbaik dibandingkan algoritma lainnya, sehingga model ini paling efektif digunakan pada *dataset* penelitian ini.



Gambar 6. Confusion Matrix K-Nearest Neighbors


Gambar 6 menunjukkan hasil evaluasi algoritma *K-Nearest Neighbors* (KNN) menggunakan *classification report* dan *confusion matrix* pada klasifikasi data stunting. Berdasarkan hasil pengujian, algoritma KNN memperoleh tingkat akurasi sebesar 99,53%, sehingga menunjukkan performa yang sangat baik dalam mengklasifikasikan data balita ke dalam kategori normal, *severely stunted*, *stunted*, dan tinggi. Pada *classification report* terlihat bahwa setiap kategori memiliki nilai *precision*, *recall*, dan *f1-score* yang sangat tinggi.

D. Algoritma *LogisticRegression*

Algoritma *Logistic Regression* digunakan untuk mengklasifikasikan risiko stunting pada balita berdasarkan data kesehatan dan faktor risiko yang tersedia. Algoritma ini memiliki keunggulan dalam memberikan interpretasi hubungan antarvariabel secara lebih jelas. Dalam penelitian ini, *Logistic Regression* digunakan sebagai salah satu model pembandingan untuk menilai performa klasifikasi stunting.

Accuracy (LogisticRegression): 0.7481267217630854

	precision	recall	f1-score	support
normal	0.729	0.950	0.825	20327
severely stunted	0.729	0.751	0.740	5961
stunted	0.000	0.000	0.000	4144
tinggi	0.916	0.573	0.705	5868
accuracy			0.748	36300
macro avg	0.594	0.569	0.568	36300
weighted avg	0.676	0.748	0.698	36300



Gambar 7. Confusion Matrix Logistic Regression

Gambar 7 menunjukkan hasil evaluasi algoritma *K-Nearest Neighbors* (KNN) menggunakan *classification report* dan *confusion matrix* pada klasifikasi data *stunting*. Berdasarkan hasil pengujian, algoritma KNN memperoleh tingkat akurasi sebesar 99,53%, sehingga menunjukkan performa yang sangat baik dalam mengklasifikasikan data balita ke dalam kategori normal, *severely stunted*, *stunted*, dan tinggi. Pada *classification report* terlihat bahwa setiap kategori memiliki nilai *precision*, *recall*, dan *f1-score* yang sangat tinggi. Kategori normal memperoleh nilai *precision*, *recall*, dan *f1-score* sebesar 0,997 dengan jumlah data sebanyak 20.327 data. Selanjutnya, kategori *severely stunted* memperoleh *precision* sebesar 0,996, *recall* 0,996, dan *f1-score* 0,996 dengan total 5.961 data. Untuk kategori *stunted*, diperoleh *precision* sebesar 0,987, *recall* 0,986, dan *f1-score* 0,986 dengan jumlah 4.144 data. Sementara itu, kategori tinggi memperoleh *precision* sebesar 0,994, *recall* 0,997, dan *f1-score* 0,995 dengan total 5.868 data. Berdasarkan *confusion matrix*, sebagian besar data berhasil diprediksi dengan benar pada masing-masing kelas. Nilai diagonal pada matriks memiliki jumlah yang sangat besar, yang menunjukkan bahwa prediksi model sesuai dengan label sebenarnya. Misalnya, lebih dari 20 ribu data kategori normal berhasil diklasifikasikan dengan benar. Kesalahan klasifikasi hanya terjadi pada sebagian kecil data, seperti beberapa data *stunted* yang diprediksi sebagai normal atau *severely stunted*. Namun, jumlah kesalahan tersebut sangat sedikit dibandingkan jumlah prediksi yang benar.

3.2. Hasil Klasifikasi Model

Berdasarkan hasil pengujian terhadap empat algoritma klasifikasi, yaitu *Support Vector Machine* (SVM), *Multinomial Naive Bayes* (MNB), *Logistic Regression* (LR), dan *K-Nearest Neighbour* (KNN) terlihat adanya perbedaan kinerja yang cukup signifikan sebagaimana ditunjukkan Tabel 1. Evaluasi menggunakan metrik akurasi, presisi, *recall*, dan *F1-score* untuk menilai performa model secara komprehensif.

Tabel 1. Perbandingan Performa Model

Algoritma	Akurasi
<i>Support Vector Machine</i> (SVM)	99,48%
<i>Gaussian Naive Bayes</i>	55,41%
<i>Logistic Regression</i>	74,81%
<i>K-Nearest Neighbors</i> (KNN)	99,53%

Berdasarkan tabel hasil akurasi algoritma, dapat diketahui bahwa algoritma *K-Nearest Neighbors* (KNN) memperoleh performa terbaik dengan tingkat akurasi sebesar 99,53%. Hasil tersebut menunjukkan bahwa KNN memiliki kemampuan yang sangat baik dalam mengklasifikasikan data balita *stunting* dan *non-stunting* dibandingkan metode lainnya. Selain itu, algoritma *Support Vector Machine* (SVM) juga menunjukkan performa yang sangat tinggi dengan akurasi sebesar 99,48%, sehingga metode ini dinilai sangat efektif dalam mengenali pola data *stunting*. Kemudian, *Logistic Regression* memperoleh akurasi sebesar 74,81%, yang menandakan bahwa metode ini cukup baik digunakan dalam klasifikasi data *stunting* meskipun performanya masih di bawah metode SVM dan KNN. Sementara itu, algoritma *Gaussian Naive Bayes* memperoleh akurasi sebesar 55,41%.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, implementasi *framework* X-StuntAI berbasis *Explainable Ensemble Learning* mampu digunakan untuk mendeteksi dini risiko *stunting* pada balita dengan performa klasifikasi yang sangat baik. Penelitian ini menerapkan beberapa algoritma *machine learning*, yaitu *Support Vector Machine* (SVM), *Gaussian Naive Bayes*, *Logistic Regression*, dan *K-Nearest Neighbors* (KNN). Hasil evaluasi menunjukkan bahwa algoritma *K-Nearest Neighbors* (KNN) merupakan metode dengan performa terbaik dibandingkan algoritma lainnya, dengan tingkat akurasi sebesar 99,53%. Metode ini dinilai paling optimal karena mampu menghasilkan klasifikasi yang sangat akurat dalam membedakan data balita *stunting* dan *non-stunting* berdasarkan kedekatan karakteristik data. Selain itu, algoritma SVM juga menunjukkan performa yang sangat baik dengan akurasi sebesar 99,48%, diikuti *Logistic Regression* sebesar 74,81%, dan *Gaussian Naive Bayes* sebesar

55,41%. Tingginya performa KNN menunjukkan bahwa metode tersebut sangat sesuai digunakan pada dataset penelitian ini karena mampu mengenali pola data dengan baik melalui pendekatan jarak antar data. Selain menghasilkan klasifikasi yang akurat, *framework* X-StuntAI juga mampu memberikan interpretasi terhadap faktor-faktor risiko *stunting* melalui pendekatan *Explainable AI* (XAI), sehingga hasil prediksi menjadi lebih transparan dan mudah dipahami. Dengan demikian, penelitian ini diharapkan dapat membantu tenaga kesehatan dan pihak terkait dalam mendukung pengambilan keputusan, identifikasi faktor risiko, serta upaya pencegahan *stunting* pada balita secara lebih efektif.

Daftar Rujukan

- [1] N. Purwati and T. Widiatoro, “AI and Machine Learning untuk Diagnosis dan Intervensi Dini pada Stunting Balita: A Systematic Literature Review,” *Infomatek*, vol. 27, no. 1, pp. 71–86, 2025, doi: 10.23969/infomatek.v27i1.24136.
- [2] J. P. Adhani, A. Lahdji, and C. Faizin, “Analisis Faktor Risiko Kejadian Stunting Pada Balita Di Wilayah Kerja Puskesmas Karanganyar I Kabupaten Demak,” *J. Ilmu Kedokt. dan Kesehat.*, vol. 11, no. 2, pp. 430–439, 2024, doi: 10.33024/jikk.v11i2.10600.
- [3] P. Pamungkas and A. P. Hidayathillah, “Pengembangan Model Kasiting Berbasis Artificial Intelligence Terhadap Deteksi Dini Stunting Bayi Pada Kader Kesehatan,” *Prepotif J. Kesehat. Masy.*, vol. 8, no. 3, pp. 5829–5835, 2024, doi: 10.31004/prepotif.v8i3.34697.
- [4] D. Wahyuni and R. Fithriyana, “Pengaruh Sosial Ekonomi Dengan Kejadian Stunting Pada Balita Di Desa Kualu Tambang Kampar,” *PREPOTIF J. Kesehat. Masy.*, vol. 4, no. 1, pp. 20–26, 2020, doi: 10.31004/prepotif.v4i1.539.
- [5] M. Mirafuddin and S. Supriyatna, “Penerapan Machine Learning pada Aplikasi Kesehatan HEALTIME,” *J. Nas. Komputasi dan Teknol. Inf.*, vol. 7, no. 6, pp. 1601–1606, 2024, doi: 10.32672/jnkti.v7i6.8233.
- [6] E. Prasetyo and K. Nugroho, “Optimasi Klasifikasi Data Stunting Melalui Ensemble Learning pada Label Multiclass dengan Imbalance Data,” *Techno.Com*, vol. 23, no. 1, pp. 1–10, 2024, doi: 10.62411/tc.v23i1.9779.
- [7] F. Lawalata, “Analisis Performa Support Vector Machine (SVM) dengan Hyperparameter Tuning untuk Klasifikasi Data Stress Monitoring Siswa,” *JOINTER J. Informatics Eng.*, vol. 6, no. 02, pp. 9–15, 2025, doi: 10.53682/jointer.v6i02.413.
- [8] Taqwanur and Mega Bilqis Suryawantiningtyas, “G-Tech : Jurnal Teknologi Terapan,” *G-Tech J. Teknol. Terap.*, vol. 6, no. 2, pp. 295–305, 2022.
- [9] Dicky Satria Mahendra, Basuki Rahmat, and Retno Mumpuni, “Implementasi Metode Multinomial Naive Bayes dalam Klasifikasi Judul Berita Clickbait,” *Neptunus J. Ilmu Komput. Dan Teknol. Inf.*, vol. 2, no. 3, pp. 303–316, 2024, doi: 10.61132/neptunus.v2i3.249.
- [10] I. Engineering, J. V. Wie, M. Siddik, P. T. Informatika, and F. I. Komputer, “Penerapan Metode Naïve Bayes Dalam,” vol. 6, no. 2, pp. 69–77, 2022.
- [11] D. Fabiyanto and Z. Pratama Putra, “Validasi Efektivitas Logistic Regression untuk Diagnosa Penyakit Jantung melalui Pendekatan Machine Learning,” *J. Ilm. FIFO*, vol. 16, no. 2, p. 158, 2024, doi: 10.22441/fifo.2024.v16i2.006.
- [12] U. Nijunniyah, S. S. Hilabi, F. Nurapriani, and E. Novalia, “Implementasi Algoritma K-Nearest Neighbor untuk Prediksi Penjualan Alat Kesehatan pada Media Alkes: Implementation of the K-Nearest Neighbor Algorithm to Predict Sales of Medical Devices in Medical Devices,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 2, pp. 695–701, 2024.
- [13] I. P. Putri, T. Terttiavini, and N. Arminarahmah, “Analisis Perbandingan Algoritma Machine Learning untuk Prediksi Stunting pada Anak,” *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 1, pp. 257–265, 2024, doi: 10.57152/malcom.v4i1.1078.
- [14] A. Heriyanto, “Penerapan Metode K-Nearest Neighbor (KNN) Untuk Klasifikasi Stunting Pada Balita,” *Publ. Ilm. Univ. Muhammadiyah Jember*, 2021.
- [15] R. Alfiatul Karima and Z. Fatah, “Jurnal Ilmiah Multidisiplin Ilmu Implementasi Metode K-Nearest Neighbor Untuk Klasifikasi Penyakit Paru-Paru Pada Anak,” *J. Ilm. Multidisiplin Ilmu*, vol. 1, no. 6, pp. 13–14, 2024.
- [16] E. Indrisari, H. Febiansyah, and B. Adiwino, “A Systematic Literature Review on the Application of

- Machine Learning for Predicting Stunting Prevalence in Indonesia (2020–2024),” *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 14, no. 3, pp. 277–283, Jul. 2025, doi: 10.32736/sisfokom.v14i3.2366.
- [17] M. Emhandyksa and I. Nur, “Metode Explainable Artificial Intelligence (XAI) Berbasis Feature Importance Untuk Deteksi Dini Penyakit Jantung,” vol. 1, no. 1, pp. 68–79, 2026.
- [18] A. M. Majid *et al.*, “Penerapan Explainable AI dan Model Stacking Untuk Mengidentifikasi Faktor Risiko Stunting Balita,” pp. 239–253, 2024.
- [19] L. N. Hapsari, I. Fannani, Y. Rahmawati, and A. Muhariya, “Explainable Machine Learning untuk Prediksi Risiko Penyakit Jantung Menggunakan Random Forest dan Analisis SHAP,” *REMIK Ris. dan E-Jurnal Manaj. Inform. Komput.*, vol. 10, no. 1, pp. 190–199, 2026.
- [20] M. E. Ramadhan and J. Zeniarja, “Implementasi Deep Transfer Learning dan Explainable AI dalam Klasifikasi Kanker Kulit Implementation of Deep Transfer Learning and Explainable AI in Skin Cancer Classification,” *Sist. J. Sist. Inf.*, vol. 14, no. 5, pp. 2266–2279, 2025.
- [21] K. Syaban, “Evaluasi Model Ensemble Learning pada Identifikasi Faktor Risiko Diabetes Mellitus Evaluation of Ensemble Learning Models in Identifying Risk Factors for Diabetes Mellitus,” *Eval. Model Ensemble Learn. Model. Identifying Risk Factors Diabetes Mellit.*, vol. 15, no. 2, pp. 121–130, 2025, doi: 10.34010/jati.v15i2.16238.
- [22] Aritonang, M. A. S., Siregar, M. A., Arnomo, S. A., & Farasalsabila, F. (2025). *Penerapan Algoritma Metaheuristik untuk Optimasi Nilai K pada K-NN dalam Pengelompokan Faktor Penyebab Stunting. Jurnal Pustaka AI*, 5(3), 611–618.
- [23] Hamidani, S., & Yanto, R. (2025). *Sistem Cerdas Pemilihan Makanan Sehat Berbasis Case Based Reasoning dan SMART untuk Edukasi Pemenuhan Gizi Masyarakat. Jurnal Pustaka AI*, 5(2), 355–363.