

COMPARISON OF RANDOM FOREST, K-NEAREST NEIGHBOR, DECISION TREE, AND XGBOOST ALGORITHMS FOR DETECTING STUNTING IN TODDLERS

Zaynuri Ilham Bimawan^{*1}, Tri Astuti², Primandani Arsi³

^{1,2,3}Informatics, Faculty of Computer Science, Universitas Amikom Purwokerto, Indonesia
Email: ¹zaynuribimawan@gmail.com, ²tri_astuti@amikompurwokerto.ac.id,
³ukhti.prima@amikompurwokerto.ac.id

(Article received: August 08, 2024; Revision: September 08, 2024; published: December 29, 2024)

Abstract

Stunting is a significant health issue in many developing countries, including Indonesia. Advances in health technology have opened new opportunities to improve the accuracy and efficiency of detecting stunting in young children, with one such advancement being Machine Learning technology. This study compares various Machine Learning algorithms for detecting stunting in children. The methodology includes data collection, data exploration, data preprocessing, feature extraction, model classification, and model evaluation. The results show that Random Forest demonstrates superior performance with the highest accuracy of 0.999132, recall of 0.999132, and a macro-averaged F1-score of 0.998906, making it the most consistent model for predicting child nutritional status. K-Nearest Neighbor also shows very good performance with an accuracy of 0.999050 and an F1-score of 0.998748. Decision Tree has an accuracy of 0.999091 and an F1-score of 0.998705, closely matching the performance of Random Forest and KNN. XGBoost, with an accuracy of 0.991033 and an F1-score of 0.987495, performs lower than the other three models. Therefore, Random Forest is the recommended choice for implementing stunting prediction in children.

Keywords: *Decision Tree, KNN, Random Forest, Stunting Detection, XGBoost.*

KOMPARASI ALGORITMA RANDOM FOREST, K-NEAREST NEIGHBOR, DECISION TREE, XGBOOST UNTUK MENDETEKSI PENYAKIT STUNTING BALITA

Abstrak

Stunting adalah masalah kesehatan yang signifikan di banyak negara berkembang, termasuk Indonesia. Perkembangan teknologi dalam bidang kesehatan telah membuka peluang baru untuk meningkatkan akurasi dan efisiensi dalam mendeteksi stunting pada balita salah satunya teknologi Machine Learning. Penelitian ini mengkomparasi berbagai algoritma Machine Learning dalam mendeteksi stunting pada balita. Metodologi yang digunakan dalam penelitian ini mencakup Pengumpulan Data, Eklporasi Data, Pra-Pemrosesan Data, Ekstraksi Fitur, Klasifikasi Model, Evaluasi Model. Hasil penelitian ini menunjukkan Random Forest menunjukkan kinerja unggul dengan akurasi tertinggi 0.999132, recall 0.999132, dan F1-score rata-rata makro 0.998906, menjadikannya model yang paling konsisten dalam memprediksi status gizi balita. K-Nearest Neighbor juga menunjukkan performa sangat baik dengan akurasi 0.999050 dan F1-score 0.998748. Decision Tree memiliki akurasi 0.999091 dan F1-score 0.998705, mendekati Random Forest dan KNN. XGBoost, dengan akurasi 0.991033 dan F1-score 0.987495, memiliki performa lebih rendah dibandingkan ketiga model tersebut. Oleh karena itu, Random Forest adalah pilihan utama untuk implementasi prediksi stunting pada balita.

Kata kunci: *Decision Tree, Deteksi Stunting, KNN, Random Forest.*

1. PENDAHULUAN

Stunting merupakan masalah kesehatan signifikan di banyak negara berkembang, termasuk Indonesia. Kondisi ini diakibatkan oleh kekurangan gizi kronis yang berkepanjangan, terutama selama 1.000 hari pertama kehidupan anak, yang meliputi masa kehamilan hingga usia dua tahun. Anak-anak

yang mengalami *stunting* memiliki tinggi badan yang lebih rendah dibandingkan dengan standar usianya dan menghadapi berbagai masalah perkembangan fisik dan kognitif. Dampak jangka panjang dari *stunting* mencakup penurunan produktivitas, penurunan kemampuan belajar, serta peningkatan risiko penyakit kronis di masa dewasa, yang pada

akhirnya dapat mempengaruhi pertumbuhan ekonomi suatu negara [1].

Berdasarkan data terbaru dari Kementerian Kesehatan Indonesia pada tahun 2023, *prevalensi stunting* pada balita mencapai 21,5 persen, angka yang masih cukup tinggi dan menjadi salah satu prioritas utama dalam agenda kesehatan nasional [2].

Upaya untuk menurunkan angka *stunting* memerlukan intervensi yang tepat dan terarah, termasuk deteksi dini kondisi ini agar tindakan pencegahan dan penanganan dapat segera dilakukan. Deteksi dini yang efektif memungkinkan intervensi gizi dan medis yang lebih cepat, meningkatkan peluang untuk memperbaiki status gizi dan kesehatan anak [3].

Perkembangan teknologi dalam bidang Kesehatan telah membuka peluang baru untuk meningkatkan akurasi dan efisiensi dalam mendeteksi *stunting* pada balita. Salah satu teknologi yang menjanjikan adalah penerapan algoritma *Machine Learning* [4]. Algoritma *Machine Learning* memiliki kemampuan untuk menganalisis data yang kompleks dan besar, serta membuat prediksi yang akurat berdasarkan pola-pola yang ditemukan dalam data [5].

Beberapa algoritma *Machine Learning* yang sering digunakan dalam deteksi kesehatan meliputi *K-Nearest Neighbors*, *Random Forest*, *Decision Tree*, dan *XGBoost*. Meskipun masing-masing algoritma memiliki kelebihan dan kekurangannya, belum ada penelitian komprehensif yang mengkomparasi efektivitas algoritma-algoritma ini secara spesifik untuk mendeteksi *stunting* pada balita [6].

Penelitian terdahulu telah mengeksplorasi penggunaan berbagai algoritma *Machine Learning* dalam konteks kesehatan, termasuk untuk mendeteksi penyakit kronis dan kondisi kesehatan lainnya. Misalnya, penelitian oleh Rakha Gusti Wardhana et al. (2023) menemukan bahwa *Random Forest* efektif dalam menganalisis data kesehatan yang kompleks, sementara Adam Razaki et al. (2024) menunjukkan bahwa algoritma *K-Nearest Neighbors* (KNN) dapat memberikan hasil yang akurat dalam deteksi penyakit kronis pada populasi tertentu [7], [8]. Namun, meskipun ada beberapa penelitian yang mengaplikasikan algoritma ini dalam berbagai konteks, studi komprehensif yang mengkomparasi efektivitas algoritma-algoritma ini secara spesifik untuk mendeteksi *stunting* pada balita masih terbatas [9].

Machine Learning memiliki berbagai metode yang memiliki karakteristik berbeda, yang mempengaruhi kinerja mereka dalam aplikasi tertentu seperti deteksi *stunting* [10]. Sebagai contoh, *Random Forest* adalah algoritma yang sangat efektif dalam menangani data dengan banyak fitur dan mencegah *overfitting*, karena menggunakan pendekatan *ensemble learning*. Metode ini sangat sesuai untuk *dataset* yang kompleks dengan banyak

variabel. *K-Nearest Neighbors* (KNN) merupakan algoritma yang sederhana dan mudah diimplementasikan namun, performanya sangat tergantung pada pemilihan parameter k dan jarak antar sampel. Ini membuat KNN cocok untuk *dataset* yang memiliki pola yang mudah dipetakan oleh *matriks* jarak tertentu. *Decision Tree* menawarkan interpretasi yang mudah dan jelas, tetapi tanpa teknik *pruning* yang tepat, algoritma ini rentan terhadap *overfitting*, sehingga lebih sesuai untuk *dataset* yang terstruktur dengan baik. Sementara itu, *XGBoost*, sebagai algoritma *boosting* yang canggih, sangat efektif dalam mengurangi kesalahan prediksi melalui peningkatan model yang berulang. Namun, karena *XGBoost* memerlukan penyesuaian parameter yang lebih kompleks, algoritma ini ideal untuk *dataset* yang memerlukan tingkat presisi yang tinggi dalam prediksi [11]. Oleh karena itu, membandingkan keunggulan dari masing-masing metode ini dalam konteks *dataset* yang digunakan sangat penting untuk menentukan algoritma mana yang paling efektif dalam mendeteksi *stunting* [12].

Penelitian ini bertujuan untuk mengisi kesenjangan tersebut dengan mengkomparasi berbagai algoritma *Machine Learning* dalam mendeteksi *stunting* pada balita. Dengan melakukan analisis komparatif ini, diharapkan dapat ditemukan algoritma yang paling efektif dan efisien untuk digunakan dalam program kesehatan masyarakat [13].

Hasil dari penelitian ini diharapkan dapat memberikan kontribusi nyata dalam upaya penurunan *prevalensi stunting* di Indonesia, serta memberikan wawasan lebih lanjut mengenai penerapan teknologi *Machine Learning* dalam bidang kesehatan. Selain itu, penelitian ini juga bertujuan untuk memberikan rekomendasi yang dapat diimplementasikan oleh pemerintah dan lembaga kesehatan dalam rangka meningkatkan deteksi dini dan penanganan *stunting* pada balita [14]. Melalui penelitian ini, diharapkan dapat dicapai tujuan utama yaitu memperbaiki status gizi dan kesehatan balita di Indonesia, yang pada akhirnya akan berdampak positif terhadap kualitas hidup dan masa depan generasi mendatang [15].

2. METODE PENELITIAN

Penelitian ini bertujuan untuk mengkomparasi berbagai algoritma *Machine Learning* dalam mendeteksi *stunting* pada balita.

Landasan Teori dari Setiap Algoritma

Berikut beberapa penjelasan metode-metode yang digunakan dalam komparasi keempat algoritma ini, berikut gambaran umum tentang bagaimana masing-masing algoritma bekerja dari segi formulasi matematis:

1. *Random Forest*

Decision Trees dalam algoritma *Random Forest* membangun banyak pohon keputusan (T_1, T_2, \dots, T_n) dari *subset* acak data dan *subset* acak fitur.

Ensemble Voting digunakan untuk memprediksi kelas, algoritma *Random Forest* menggabungkan prediksi dari setiap pohon keputusan dan memilih kelas mayoritas.

$$\hat{y} = \text{mode}\{T_1(x), T_2(x), \dots, T_n(x)\} \quad (1)$$

Dimana $T_i(x)$ adalah prediksi dari pohon keputusan ke- i .

Pada pohon keputusan (*Decision Trees*) bekerja secara paralel. Setiap pohon memproses bagian berbeda dari data, dan hasil akhir didapatkan dari *voting* mayoritas dari semua pohon [16].

2. K-Nearest Neighbor (KNN)

Distance Measurement: Untuk menentukan tetangga terdekat, KNN menghitung jarak (umumnya *Euclidean distance*) antara data uji dan data latih.

$$d(x, x_i) = \sqrt{\sum_{j=1}^n (x_i - x_{ij})^2} \quad (2)$$

Voting adalah kelas dari data uji diputuskan berdasarkan mayoritas kelas dari k tetangga terdekat.

$$\hat{y} = \text{mode}\{y_{i1}, y_{i2}, \dots, y_{ik}\} \quad (3)$$

Tidak ada fase pelatihan *eksplisit*. KNN menyimpan seluruh dataset latih dan untuk setiap data uji, menghitung jarak ke semua data latih, memilih k terdekat, dan memprediksi berdasarkan mayoritas dari mereka [17].

3. Decision Tree

Entropy & Information Gain contoh dari formasi dari algoritma *Decision Tree* memilih fitur yang memaksimalkan informasi yang diperoleh (*information gain*) untuk memisahkan data.

- *Entropy*

$$H(S) = - \sum_{i=1}^c p_i \log_2(p_i) \quad (4)$$

- *Information Gain*

$$IG(T, A) = H(T) - \sum_{v \in \text{Values}(A)} \frac{|T_v|}{|T|} H(T_v) \quad (5)$$

Dari segi arsitektur algoritma *Decision Tree* pohon dimulai dari *root*, di mana setiap node membuat keputusan berbasis satu fitur dan bercabang hingga mencapai daun yang menentukan kelas akhir [18].

4. XGBoost

Gradien Boosting dari algoritma *XGBoost* menggabungkan prediksi dari banyak model lemah (*weak learners*), seperti pohon keputusan, dengan meminimalkan fungsi kerugian menggunakan *gradien*.

$$\hat{y} = \sum_{n=1}^M \eta f_n(x) \quad (6)$$

di mana $f_m(x)$ adalah pohon keputusan pada iterasi ke- m , dan η adalah *learning rate*.

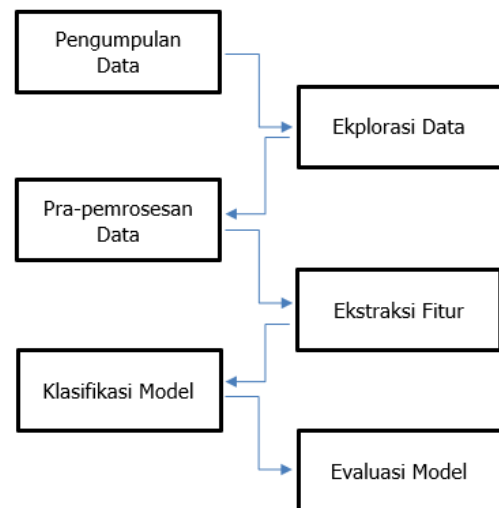
Objective Function: *XGBoost* meminimalkan fungsi objektif yang terdiri dari fungsi kerugian dan regulasi untuk menghindari *overfitting*:

$$Obj(\theta) = \sum_{i=1}^n l(y_i \hat{y}_i) + \sum_{n_1}^M \Omega(f_m) \quad (7)$$

di mana $\Omega(f)$ adalah fungsi regulasi untuk kompleksitas model.

XGBoost membangun pohon secara berurutan, di mana setiap pohon mencoba memperbaiki kesalahan dari pohon sebelumnya. Model menggunakan teknik regularisasi untuk mengontrol *overfitting*, dan pohon ditambahkan satu per satu [19].

Metodologi yang digunakan dalam penelitian ini mencakup beberapa tahapan, yaitu Pengumpulan Data, Ekplorasi Data, Pra-Pemrosesan Data, Ekstraksi Fitur, Klasifikasi Model, Evaluasi Model. Dibawah ini gambar 1, menunjukkan tahapan penelitian sebagai berikut:



Gambar 1. Tahapan Penelitian

Tahapan Penelitian Diantaranya :

1. Pengumpulan Data

Data dikumpulkan dari berbagai sumber seperti data klinis, rekam medis, dan survei terkait status kesehatan balita. Sumber data dapat mencakup database rumah sakit, pusat kesehatan. Data yang dikumpulkan mencakup atribut seperti umur, jenis kelamin, tinggi badan, status gizi, dan *Encoder*.

2. Ekplorasi Data

Ini adalah tahap di mana data yang telah dikumpulkan dieksplorasi untuk memahami karakteristiknya. Eksplorasi ini membantu peneliti memahami kualitas dan struktur data.

3. Pra-Pemrosesan Data

Tahap ini meliputi pembersihan data, seperti penanganan data yang hilang, penghapusan data duplikat, dan normalisasi data. Teknik lain yang digunakan termasuk *encoding* untuk variabel kategorikal dan *scaling* untuk memastikan semua fitur berada dalam skala yang sama. Data juga dibagi

menjadi data latih dan data uji untuk keperluan pelatihan model dan evaluasi.

4. Ekstraksi Fitur

Ekstraksi fitur merupakan proses dalam analisis data dan pembelajaran mesin yang bertujuan untuk mengidentifikasi dan memilih informasi penting dari data mentah, sehingga dapat digunakan untuk membangun model prediktif.

5. Klasifikasi Model

Beberapa algoritma klasifikasi diterapkan pada data yang telah diproses, termasuk *Random Forest*, *K-Nearest Neighbor*, *Decision Tree*, dan *XGBoost*. Setiap model dilatih menggunakan data latih untuk memprediksi status *stunting* pada anak balita. Hasil klasifikasi kemudian dibandingkan untuk menentukan algoritma yang paling efektif.

6. Evaluasi Model

Model dievaluasi menggunakan data uji untuk mengukur performa. Metode evaluasi mencakup akurasi, presisi, *recall* dan *F1-score*. Perbandingan hasil evaluasi dari setiap model memberikan wawasan tentang keefektifan dan efisiensi masing-masing algoritma dalam mendeteksi *stunting* pada balita.

3. HASIL DAN PEMBAHASAN

Berdasar pada penelitian ini berfokus pada komparasi empat algoritma *Machine Learning* (*Random Forest*, *KNN*, *Decision Tree*, *XGBoost*) upaya deteksi *stunting* pada anak balita. Metode yang diterapkan dalam studi ini melibatkan beberapa langkah, sebagai berikut:

3.1. Metode Pengumpulan Data

Proses Pengumpulan Data diperoleh dari platform *Kaggle*, yang merupakan sumber data terbuka dan populer untuk berbagai kebutuhan analisis, dilakukan dengan mengunduh *dataset* yang tersedia dalam format CSV, Kemudian *dataset* tersebut di masukan ke dalam lingkungan analisis menggunakan Bahasa pemrograman *Python* di platform *Google Colaboratory*. Jumlah data yang terkumpul berjumlah 12.0999 data, berikut dibawah ini:

	Umur (bulan)	Jenis Kelamin	Tinggi Badan (cm)	Status Gizi	Jenis Kelamin Encoder
0	0	laki-laki	44.591973	stunted	0
1	0	laki-laki	56.705203	tinggi	0
2	0	laki-laki	46.863358	normal	0
3	0	laki-laki	47.508026	normal	0
4	0	laki-laki	42.743494	severely stunted	0
...
120994	60	perempuan	100.600000	normal	1
120995	60	perempuan	98.300000	stunted	1
120996	60	perempuan	121.300000	normal	1
120997	60	perempuan	112.200000	normal	1
120998	60	perempuan	109.800000	normal	1

Gambar 2. Dataset

Gambar 2, menunjukkan jumlah keseluruhan *dataset* yang akan dianalisis menggunakan *Google Colaboratory*.

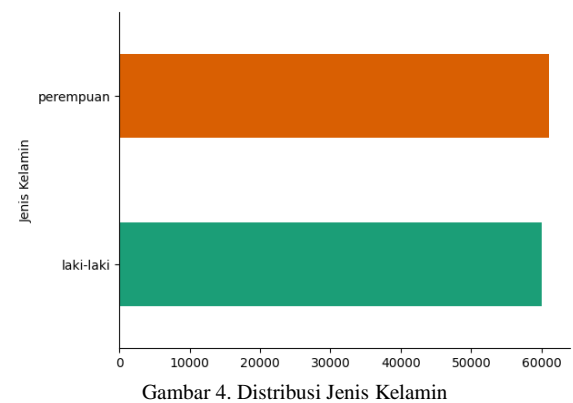
3.2. Ekplorasi Data

Dari Dari hasil data yang berhasil di kumpulkan berjumlah 120999 data. Sebelum data di analisis lebih lanjut data kami cek terlebih dahulu apakah ada data yang tidak sesuai atau *Missing Value*. *Missing Value* atau nilai yang hilang merujuk pada data yang tidak tersedia atau tidak tercatat dalam *dataset*, berikut gambar 3, menunjukkan empat data atribut itu sesuai, tidak ada *Missing Value*.

```
[5] df.isnull().sum()
0
Umur (bulan) 0
Jenis Kelamin 0
Tinggi Badan (cm) 0
Status Gizi 0
dtype: int64
```


Gambar 3. Data *Missing Value*

Visualisasi Data adalah proses mengubah data mentah menjadi bentuk visual yang informatif dan mudah dipahami, seperti grafik, diagram, dan peta. Ini membantu dalam mengekstrak pola, tren, dan informasi penting dari data yang mungkin sulit dilihat hanya dengan melihat angka atau tabel. Pada tahapan ini ditunjukkan pada gambar 4 dan 5, dibawah ini :



Gambar 4. Distribusi Jenis Kelamin

Dari gambar 4, data diatas diketahui bahwa balita perempuan sebanyak 61002 dan balita laki laki sebanyak 59997.



Gambar 5. Distribusi Status Gizi

3.3. Pra Pemrosesan Data

Proses pra pemrosesan data yg pertama adalah proses label *encoding*. Label *encoding* adalah proses konversi data kategori (seperti nama, label, atau klasifikasi) menjadi format numerik yang dapat diproses oleh algoritma pembelajaran mesin. Label *encoding* adalah metode untuk mengubah setiap kategori menjadi angka unik. Misalnya, kategori "laki laki", "perempuan" dapat diubah menjadi 0 dan 1, berikut ditunjukkan pada tabel 1, dibawah ini :

Tabel 1. Label *Encoding*

Jenis Kelamin	Label <i>Encoding</i>
Laki-laki	0
Perempuan	1

3.4. Ekstraksi Fitur

Ekstraksi Fitur adalah proses dalam analisis data dan pembelajaran mesin yang bertujuan untuk mengidentifikasi dan mengekstrak informasi penting dari data mentah yang dapat digunakan untuk membangun model prediktif. Proses ini mengubah data asli menjadi representasi yang lebih berguna dan efisien.

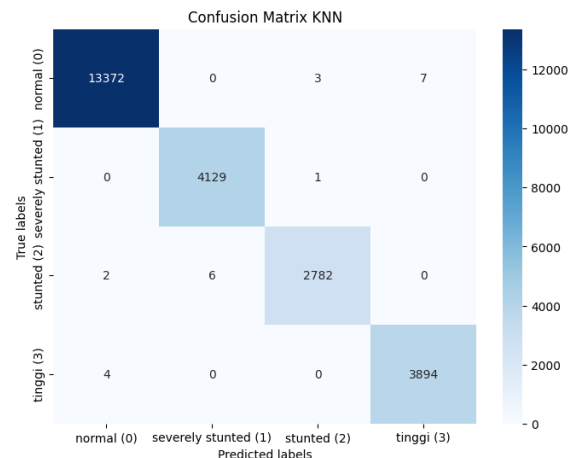
```
[5]: from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, Y, test_size=0.2, random_state=42)
```

Gambar 6. Data *Training* dan Data Tes

Split Data 80% Training & 20% Testing adalah metode yang umum digunakan dalam pembelajaran mesin untuk membagi *dataset* menjadi dua bagian: satu untuk melatih model (*training set*) dan satu lagi untuk menguji kinerja model (*testing set*).


3.5. Klasifikasi Model

Klasifikasi adalah proses di mana algoritma pembelajaran mesin digunakan untuk mengkategorikan data ke dalam kelas-kelas atau kategori-kategori tertentu. Di penelitian ini kami menggunakan empat algoritma klasifikasi utama: *K-Nearest Neighbors*, *Decision Tree*, *Random Forest*, dan *XGBoost*. Setiap algoritma memiliki pendekatan dan karakteristik unik dalam menangani masalah klasifikasi. *K-Nearest Neighbors* adalah algoritma pembelajaran mesin yang digunakan untuk klasifikasi dan regresi. Dalam klasifikasi dan mengklasifikasikan data baru berdasarkan mayoritas kelas dari k-tetangga terdekatnya dalam ruang fitur.



Gambar 7. Hasil *Confusion Matrix KNN*

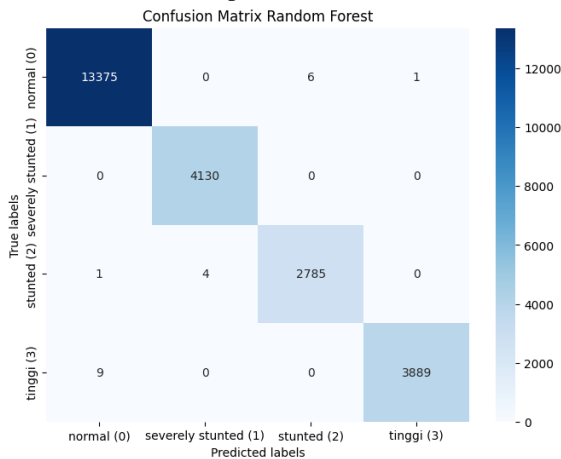
Pada gambar 7 terlihat *Confusion Matrix* yang ditampilkan menunjukkan performa model *K-Nearest Neighbors* dalam mengklasifikasikan status gizi anak-anak berdasarkan data yang tersedia. *Matriks* ini membandingkan label sebenarnya (*true labels*) dengan label yang diprediksi (*predicted labels*), yang masing-masing dikategorikan sebagai normal, *Severely Stunted*, *Stunted*, dan tinggi. Dari hasil tersebut, terlihat bahwa model *K-Nearest Neighbor* memiliki tingkat akurasi yang sangat tinggi dalam mengklasifikasikan anak-anak dengan status gizi normal dan tinggi, ditunjukkan oleh jumlah besar pada diagonal utama (13,372 untuk normal dan 3,894 untuk tinggi). Kategori *Severely Stunted* dan *Stunted* juga diklasifikasikan dengan baik, meskipun terdapat beberapa kesalahan klasifikasi kecil, seperti 1 kasus *Severely Stunted* yang diprediksi sebagai *Stunted* dan 6 kasus *Stunted* yang diprediksi sebagai *Severely Stunted*. Secara keseluruhan, model ini efektif karena sebagian besar prediksi berada pada diagonal utama, menunjukkan prediksi yang benar sesuai dengan label sebenarnya. Dengan sedikit kesalahan klasifikasi di luar diagonal utama, performa model *K-Nearest Neighbor* ini dapat dikatakan sangat baik dalam mengklasifikasikan status gizi anak-anak.



Gambar 8. Hasil *Confusion Matrix Decision Tree*

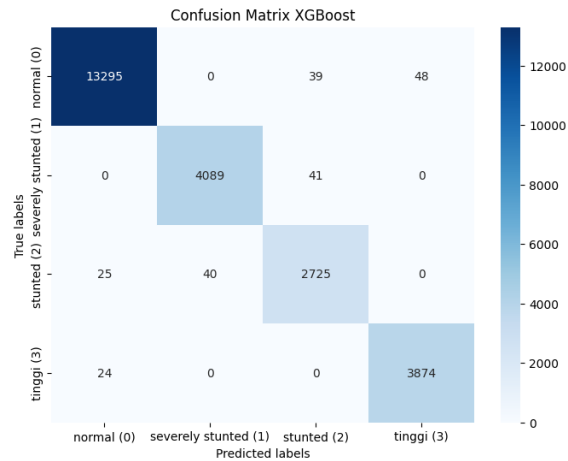
Hasil pengujian pada gambar 8, dari analisis *Confusion Matrix* menunjukkan bahwa model

Decision Tree menunjukkan performa yang sangat baik dalam mengklasifikasikan status gizi balita. Model ini mampu mengidentifikasi kategori balita dengan akurasi yang tinggi, dengan kesalahan klasifikasi yang minimal. Untuk kelas Normal (0), hanya terdapat 6 kesalahan dari 13.382 prediksi, menunjukkan akurasi yang sangat tinggi. Kelas *Severely Stunted* (1) juga menunjukkan kinerja yang baik dengan hanya 4 kesalahan dari 4.130 prediksi. Kelas *Stunted* (2) memiliki beberapa kesalahan klasifikasi, yakni 8 dari 2.790 prediksi, tetapi tetap menunjukkan hasil yang memuaskan. Kelas Tinggi (3) hampir sepenuhnya benar, dengan hanya 4 kesalahan dari 3.898 prediksi.



Gambar 9. Hasil *Confusion Matrix Random Forest*

Hasil prediksi dari gambar 9, model *Random Forest* menunjukkan kinerja yang sangat baik dalam mengklasifikasikan status gizi balita. Model ini dengan akurat mengidentifikasi 13.375 balita sebagai Normal (0), dengan hanya 6 kesalahan klasifikasi ke kelas *Stunted* (2) dan 1 kesalahan ke kelas Tinggi (3), menandakan tingkat akurasi yang sangat tinggi. Untuk kelas *Severely Stunted* (1), model mencapai akurasi penuh dengan 4.130 balita teridentifikasi dengan benar tanpa kesalahan klasifikasi ke kelas lain. Dalam hal kelas *Stunted* (2), model mengidentifikasi 2.785 balita dengan benar, meskipun ada 1 kesalahan klasifikasi ke kelas Normal (0) dan 4 kesalahan ke kelas *Severely Stunted* (1). Kelas Tinggi (3) juga menunjukkan hasil yang sangat baik, dengan 3.889 prediksi yang benar dan hanya 9 kesalahan klasifikasi ke kelas Normal (0). Secara keseluruhan, model *Random Forest* menunjukkan performa yang sangat baik, dengan sebagian besar kesalahan klasifikasi berupa pergeseran *minor* antar kategori, menjadikannya alat yang sangat efektif untuk mendukung intervensi dalam menangani masalah *stunting*.



Gambar 10. Hasil *Confusion Matrix XGBoost*

Hasil prediksi dari model *XGBoost* dapat dilihat pada gambar 10, menunjukkan kinerja yang sangat baik dalam mengklasifikasikan status gizi balita. Untuk kelas Normal (0), model berhasil mengidentifikasi 13.295 balita dengan benar, dengan hanya 39 kesalahan klasifikasi ke kelas *Stunted* (2) dan 48 kesalahan klasifikasi ke kelas Tinggi (3). Kelas *Severely Stunted* (1) menunjukkan hasil yang baik dengan 4.089 prediksi yang benar dan hanya 41 kesalahan klasifikasi ke kelas *Stunted* (2). Model ini juga menunjukkan performa yang solid dalam mengidentifikasi kelas *Stunted* (2), dengan 2.725 balita diklasifikasikan dengan benar, meskipun ada 25 kesalahan klasifikasi ke kelas Normal (0) dan 40 ke kelas *Severely Stunted* (1). Kelas Tinggi (3) hampir sepenuhnya benar, dengan 3.874 prediksi yang akurat dan hanya 24 kesalahan klasifikasi ke kelas Normal (0). Secara keseluruhan, model *XGBoost* sangat efektif dalam memprediksi status gizi balita, dengan sebagian besar kesalahan terjadi pada pengklasifikasian yang relatif *minor* antar kategori.

3.6. Evaluasi Model

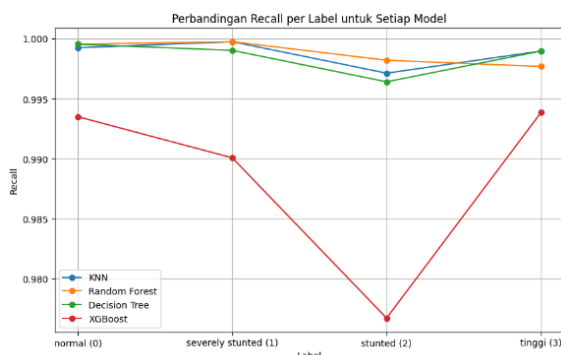
Hasil evaluasi empat model klasifikasi, yaitu *K-Nearest Neighbors*, *Random Forest*, *Decision Tree*, dan *XGBoost*, menunjukkan performa yang sangat baik dalam hal *recall* untuk mengklasifikasikan status gizi anak-anak.

	Model	precision	recall	f1-score
normal (0)	KNN	0.99552	0.99253	0.99402
severely stunted (1)	KNN	0.998549	0.999758	0.999153
stunted (2)	KNN	0.998564	0.997133	0.997848
tinggi (3)	KNN	0.998206	0.998974	0.998590
accuracy	KNN	0.999050	0.999050	0.999050
macro avg	KNN	0.998718	0.998779	0.998748
weighted avg	KNN	0.999050	0.999050	0.999050
normal (0)	Random Forest	0.999253	0.999477	0.999365
severely stunted (1)	Random Forest	0.999032	1.000000	0.999516
stunted (2)	Random Forest	0.997850	0.998208	0.998029
tinggi (3)	Random Forest	0.999743	0.997691	0.998716
accuracy	Random Forest	0.999132	0.999132	0.999132
macro avg	Random Forest	0.998970	0.998844	0.998906
weighted avg	Random Forest	0.999132	0.999132	0.999132
normal (0)	Decision Tree	0.999402	0.999552	0.999477
severely stunted (1)	Decision Tree	0.999031	0.999031	0.999031
stunted (2)	Decision Tree	0.996775	0.997133	0.996954
tinggi (3)	Decision Tree	0.999743	0.998974	0.999358
accuracy	Decision Tree	0.999091	0.999091	0.999091
macro avg	Decision Tree	0.998738	0.998672	0.998705
weighted avg	Decision Tree	0.999091	0.999091	0.999091
normal (0)	XGBoost	0.996328	0.993499	0.994911
severely stunted (1)	XGBoost	0.990312	0.990073	0.990193
stunted (2)	XGBoost	0.971480	0.976703	0.974084

Gambar 11. Hasil Evaluasi Model

Berdasarkan gambar 11, Seluruh *matriks* Evaluasi Model, *Random Forest* menunjukkan kinerja yang paling unggul dengan akurasi tertinggi sebesar 0.999132, *recall* tertinggi sebesar 0.999132, dan *F1-score* rata-rata makro tertinggi sebesar 0.998906. Hal ini menunjukkan bahwa *Random Forest* memiliki kinerja yang paling konsisten dan unggul dibandingkan model-model lainnya dalam memprediksi status gizi balita. *KNN*, meskipun sedikit di bawah *Random Forest*, tetap menunjukkan kinerja yang sangat baik dengan akurasi sebesar 0.999050, *recall* sebesar 0.999050, dan *F1-score* sebesar 0.998748. Model ini masih sangat andal dalam tugas prediksi ini. *Decision Tree* juga menunjukkan kinerja yang tinggi dengan akurasi sebesar 0.999091, *recall* sebesar 0.999091, dan *F1-score* sebesar 0.998705, yang mendekati kinerja *Random Forest* dan *KNN*. Di sisi lain, *XGBoost*, meskipun memiliki akurasi (0.991033), *recall* (0.991033), dan *F1-score* (0.987495) yang lebih rendah dibandingkan model-model lainnya, masih merupakan model yang sangat baik. Namun, dalam konteks prediksi status gizi balita ini, *XGBoost* kurang unggul dibandingkan *Random Forest*, *KNN*, dan *Decision Tree*. Oleh karena itu, *Random Forest* seharusnya dipertimbangkan sebagai pilihan utama untuk implementasi prediksi *stunting* pada balita.

Pada gambar 12, Grafik Perbandingan yang diberikan menunjukkan perbandingan nilai *recall* untuk setiap label pada empat model pembelajaran mesin: *K-Nearest Neighbors*, *Random Forest*, *Decision Tree*, dan *XGBoost*. Label-label yang digunakan adalah normal (0), sangat pendek (1), pendek (2), dan tinggi (3). Berdasarkan nilai *recall*, *Random Forest* dan *XGBoost* adalah model dengan performa terbaik, karena keduanya mempertahankan nilai *recall* yang tinggi di seluruh label. *KNN* juga merupakan model yang kuat tetapi sedikit kurang konsisten dibandingkan *Random Forest* dan *XGBoost*. *Decision Tree* menunjukkan performa yang baik untuk sebagian besar label, tetapi memiliki kelemahan yang mencolok dalam mengklasifikasikan label "pendek".



Gambar 12. Grafik Perbandingan *Recal* Setiap Model

4. DISKUSI

Secara keseluruhan, hasil ini menunjukkan bahwa *Random Forest* adalah model yang paling

konsisten dan unggul dalam mendeteksi status gizi balita. Model ini disarankan untuk dipertimbangkan sebagai pilihan utama untuk implementasi prediksi *stunting* pada balita, karena memberikan keseimbangan yang optimal antara akurasi, *recall*, dan *F1-score*. *K-Nearest Neighbor* dan *Decision Tree* juga bisa menjadi alternatif yang layak, tergantung pada kebutuhan spesifik dari aplikasi yang diinginkan. Sementara itu, *XGBoost*, meskipun kuat dalam banyak kasus, mungkin kurang cocok untuk tugas prediksi ini [19].

Berbagai penelitian sebelumnya telah menitikberatkan pada pengklasifikasian *stunting* menggunakan beragam metode dan pendekatan yang berbeda. Penelitian yang dilakukan oleh Widya Cholid Wahyudin dengan penerapan algoritma *Naive Bayes* [20]. Hasil Pengujian algoritma ini menunjukkan akurasi sebesar 85,33% ketika diterapkan pada *dataset* yang terdiri dari 300 sampel data [13]. Penelitian yang dilaksanakan oleh Clara Dewanti menunjukkan hasil yang kurang optimal ketika menggunakan *Regresi Probit Biner*, dengan tingkat akurasi sebesar 67,81% [13].

Dengan menganalisis secara mendalam faktor-faktor yang berkontribusi terhadap *Stunting*, penyedia layanan kesehatan dan pihak-pihak terkait dapat mengembangkan pendekatan yang lebih efisien untuk meningkatkan kesadaran publik, sehingga berpotensi menurunkan prevalensi *Stunting*.

5. KESIMPULAN

Semua model menunjukkan performa yang sangat baik dalam hal *recall*, *Precision* dan *f1-score*, *Random Forest* menjadi Model yang terbaik secara keseluruhan terutama karena *recall* sempurna untuk kategori *Severely Stunted* (1). *K-Nearest Neighbor* dan *Decision Tree* juga menunjukkan performa yang sangat baik dan konsisten untuk semua kategori. *XGBoost*, meskipun sedikit lebih rendah, masih memberikan performa yang sangat baik dengan *recall* di atas 0.976 untuk semua kategori. Model-model ini sangat efektif dalam mengklasifikasikan status gizi anak-anak berdasarkan data yang tersedia.

UCAPAN TERIMA KASIH

Kami ucapan terima kasih kepada teman teman dan dosen pembimbing yang sudah mensupport dalam penelitian ini baik waktu, tenaga dan pikiran. Semoga penelitian ini bisa menambah wawasan dan ilmu untuk kita semua Aamiin.

DAFTAR PUSTAKA

- [1] M. R. Akbar Ariyadi, S. Lestanti, and S. Kirom, "KLASIFIKASI BALITA STUNTING MENGGUNAKAN RANDOM FOREST CLASSIFIER DI KABUPATEN BLITAR," *JATI (Jurnal Mhs. Tek. Inform., vol. 7, no. 6, pp. 3846–3851, Jan. 2024, doi: 10.36040/jati.v7i6.7822.*

- [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, Dec. 2023, doi: 10.29408/edumatic.v7i2.23812.
- [3] A. A. R. Reza and Muhammad Syaifur Rohman, "Prediction Stunting Analysis Using Random Forest Algorithm and Random Search Optimization," *J. INFORMATICS Telecommun. Eng.*, vol. 7, no. 2, pp. 534–544, Jan. 2024, doi: 10.31289/jite.v7i2.10628.
- [4] B. Satria, T. Azhima, Y. Siswa, and W. J. Pranoto, "Optimasi Random Forest dengan Genetic Algorithm dan Recursive Feature Elimination pada High Dimensional Data Stunting Samarinda," vol. 8, pp. 1778–1789, 2024, doi: 10.30865/mib.v8i3.7883.
- [5] R. N. Ramadhon, A. Ogi, A. P. Agung, R. Putra, S. S. Febrihartina, and U. Firdaus, "Implementasi Algoritma Decision Tree untuk Klasifikasi Pelanggan Aktif atau Tidak Aktif pada Data Bank," *Karimah Tauhid*, vol. 3, no. 2, pp. 1860–1874, Feb. 2024, doi: 10.30997/karimahtauhid.v3i2.11952.
- [6] N. Windy Mardiyah, N. Rahaningsih, and I. Ali, "PENERAPAN DATA MINING MENGGUNAKAN ALGORITMA K-NEAREST NEIGHBOR PADA PREDIKSI PEMBERIAN KREDIT DI SEKTOR FINANSIAL," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 2, pp. 1491–1499, Apr. 2024, doi: 10.36040/jati.v8i2.9010.
- [7] R. G. Wardhana, G. Wang, and F. Sibuea, "PENERAPAN MACHINE LEARNING DALAM PREDIKSI TINGKAT KASUS PENYAKIT DI INDONESIA," *J. Inf. Syst. Manag.*, vol. 5, no. 1, pp. 40–45, Jul. 2023, doi: 10.24076/joism.2023v5i1.1136.
- [8] M. E. Setiyawati, L. P. Ardhiyanti, E. N. Hamid, N. A. T. Muliarta, and Y. J. Raihanah, "Studi Literatur: Keadaan Dan Penanganan Stunting Di Indonesia," *IKRA-ITH Hum. J. Sos. dan Hum.*, vol. 8, no. 2, pp. 179–186, Jul. 2024, doi: 10.37817/ikraith-humaniora.v8i2.3113.
- [9] I. P. Putri, T. Terttiaavini, 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, Jan. 2024, doi: 10.57152/malcom.v4i1.1078.
- [10] S. Lonang, A. Yudhana, and M. K. Biddinika, "Analisis Komparatif Kinerja Algoritma Machine Learning untuk Deteksi Stunting," *J. MEDIA Inform. BUDIDARMA*, vol. 7, no. 4, p. 2109, Oct. 2023, doi: 10.30865/mib.v7i4.6553.
- [11] D. D. S. Fatimah, Y. Septiana, and G. Ramadhan, "Rancang Bangun Aplikasi Sistem Pakar Diagnosa Penyakit Stunting Berbasis Web Menggunakan Metode Certainty Factor," *J. Algoritm.*, vol. 19, no. 2, pp. 547–557, Nov. 2022, doi: 10.33364/algoritma/v.19-2.1144.
- [12] S. E. Herni Yulianti, Oni Soesanto, and Yuana Sukmawaty, "Penerapan Metode Extreme Gradient Boosting (XGBOOST) pada Klasifikasi Nasabah Kartu Kredit," *J. Math. Theory Appl.*, vol. 4, no. 1, pp. 21–26, Aug. 2022, doi: 10.31605/jomta.v4i1.1792.
- [13] 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, Jan. 2024, doi: 10.30865/mib.v8i1.6965.
- [14] K. H. Hanif and N. R. Muntiar, "Penerapan Algoritma Decision Tree, Svm, Naïve Bayes Dalam Deteksi Stunting Pada Balita," *METHOMIKA J. Manaj. Inform. Komputerisasi Akunt.*, vol. 8, no. 1, pp. 105–109, 2024, doi: 10.46880/jmika.
- [15] A. Husaini, I. Hoeronis, H. H. Lumana, and L. D. Puspareni, "Early Detection of Stunting in Toddlers Based on Ensemble Machine Learning in Purbaratu Tasikmalaya," *J. Sist. dan Teknol. Inf.*, vol. 11, no. 3, p. 487, Jul. 2023, doi: 10.26418/justin.v11i3.66465.
- [16] D. Gunawan and V. N. Andika, "Implementasi Teorema Bayes Pada Sistem Informasi Posyandu Dalam Mendeteksi Stunting Pada Balita," *J. Sist. Komput. dan Inform.*, vol. 4, no. 4, p. 692, Jun. 2023, doi: 10.30865/json.v4i4.6146.
- [17] I. C. R. Drajana and A. Bode, "Prediksi Status Penderita Stunting Pada Balita Provinsi Gorontalo Menggunakan K-Nearest Neighbor Berbasis Seleksi Fitur Chi Square," *J. Nas. Komputasi dan Teknol. Inf.*, vol. 5, no. 2, pp. 309–316, Apr. 2022, doi: 10.32672/jnkti.v5i2.4205.
- [18] U. R. Gurning, S. F. Octavia, D. R. Andriyani, N. Nurainun, and I. Permana, "Prediksi Risiko Stunting pada Keluarga Menggunakan Naïve Bayes Classifier dan Chi-Square," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 1, pp. 172–180, Jan. 2024, doi: 10.57152/malcom.v4i1.1074.
- [19] R. Maulana, Z. Panjaitan, and A. Alhafiz, "Penerapan Metode Naive Bayes Untuk Mendiagnosa Penyakit Stunting Pada Balita,"

- J. Sist. Inf. Triguna Dharma (JURSI TGD)*, vol. 1, no. 4, p. 425, Jul. 2022, doi: 10.53513/jursi.v1i4.5446.
- [20] M. Ula, A. F. Ulva, M. Mauliza, M. A. Ali, and Y. R. Said, "Application of Machine Learning in Determining the Classification of Children'S Nutrition With Decision Tree," *J. Tek. Inform.*, vol. 3, no. 5, pp. 1457–1465, 2022, doi: 10.20884/1.jutif.2022.3.5.599.