

Deteksi Dini Stunting Pada Anak Berdasarkan Indikator Antropometri dengan Menggunakan Algoritma *Machine Learning*

Ratnasari^{1*}, Ahmad Jurnaidi Wahidin², Tahta Herdian Andika³

¹Universitas Aisyah Pringsewu,

²Universitas Bina Sarana Informatika,

³Universitas Aisyah Pringsewu

*email: ratnasari@aisyahuniversity.ac.id

Info Artikel

Dikirim: 12 November 2024

Diterima: 8 Desember 2024

Diterbitkan: 30 Desember 2024

Kata kunci:

Stunting;

Deteksi Dini;

Antropometri;

Machine Learning.

ABSTRAK

Stunting sebagai dampak dari kekurangan gizi kronis, memiliki dampak yang signifikan terhadap kesehatan dan perkembangan anak di Indonesia. Penelitian ini mengembangkan model deteksi dini stunting pada anak dengan memanfaatkan indikator antropometri menggunakan pendekatan *Machine Learning*. Berbeda dengan metode tradisional yang bergantung pada penilaian manual atau pemeriksaan klinis yang memakan waktu, pendekatan ini menawarkan keunggulan berupa deteksi yang lebih cepat dan akurat. Data antropometri, seperti tinggi badan, berat badan, usia, dan jenis kelamin, digunakan dalam algoritma *Machine Learning*: *Random Forest*, *K-Nearest Neighbors* (KNN), *Naive Bayes*, dan *Support Vector Machine* (SVM). Setiap model dievaluasi berdasarkan akurasi, *confusion matrix*, dan *ROC Analysis* untuk menentukan performa terbaik. Hasil penelitian menunjukkan bahwa *Random Forest* memiliki akurasi tertinggi sebesar 92,70%, lebih unggul dibandingkan dengan KNN yang memiliki akurasi 91,40%. Algoritma *Random Forest* dipilih sebagai model terbaik untuk deteksi dini stunting karena kemampuannya yang tinggi dalam meminimalkan kesalahan prediksi. Penerapan model ini diharapkan dapat meningkatkan efektivitas skrining cepat stunting di lapangan, memungkinkan deteksi lebih awal bagi anak-anak berisiko tinggi, dan mendukung intervensi yang lebih tepat sasaran dalam program kesehatan masyarakat.

1. PENDAHULUAN

Stunting merupakan masalah gizi serius yang mempengaruhi perkembangan fisik dan kognitif anak, terutama di negara-negara berkembang, termasuk Indonesia. Stunting disebabkan oleh kekurangan gizi kronis pada 1.000 hari pertama kehidupan, yang dapat berdampak negatif pada kesehatan jangka panjang anak [1] [2]. Stunting juga memiliki konsekuensi sosial-ekonomi yang signifikan, mengurangi produktivitas sumber daya manusia di masa depan, yang pada akhirnya memengaruhi pertumbuhan ekonomi negara. Data terbaru menunjukkan bahwa prevalensi stunting di Indonesia pada tahun 2023 mencapai 21,5%, menurun dari angka 21,6% pada tahun 2022, Realisasi penurunan stunting dapat dikatakan masih jauh dari target sebesar 14 persen pada tahun 2024 [3].

Kabupaten Pringsewu yang terletak di Provinsi Lampung, menghadapi tantangan signifikan dalam penanganan stunting. Faktor-faktor yang berkontribusi terhadap tingginya prevalensi stunting di daerah ini meliputi akses terbatas terhadap layanan kesehatan, pendidikan gizi yang rendah, dan kondisi sosial-ekonomi yang kurang

mendukung pola makan yang sehat [4],[5]. Laporan terbaru dari Dinas Kesehatan Pringsewu mengindikasikan bahwa prevalensi stunting pada tahun 2023 adalah 15,8%, menunjukkan penurunan dari 16,2% tahun 2022 [6]. Namun, angka ini tetap lebih tinggi daripada rata-rata prevalensi stunting di Provinsi Lampung yang tercatat sebesar 15,2% [7].

Deteksi dini stunting sangat penting untuk menghindari dampak negatif jangka panjang bagi anak-anak. Indikator antropometrik, termasuk tinggi badan, berat badan, dan jenis kelamin, telah terbukti efektif dalam mengevaluasi status gizi anak [8],[9]. Meskipun demikian, analisis data antropometrik secara tradisional membutuhkan waktu dan sumber daya yang cukup besar, sehingga diperlukan pendekatan yang lebih efisien dan akurat [10]. Pendekatan tradisional yang mengandalkan pemeriksaan manual seringkali tidak dapat menangkap risiko stunting dengan cepat, terutama di daerah dengan keterbatasan sumber daya seperti Kabupaten Pringsewu.

Dalam beberapa tahun terakhir, penerapan teknik *Machine Learning* dalam analisis data gizi menawarkan potensi untuk meningkatkan akurasi dan efisiensi dalam mendeteksi risiko stunting. Beberapa studi menunjukkan bahwa model *Machine Learning* dapat memprediksi status gizi anak dengan akurasi yang tinggi berdasarkan data antropometrik serta faktor sosial-ekonomi lainnya [11][12]. Penelitian ini berfokus pada penerapan *Machine Learning* untuk deteksi dini stunting, dengan kontribusi utama pada penerapan model yang lebih efisien dan terfokus pada konteks daerah yang memiliki tantangan khusus, seperti Kabupaten Pringsewu

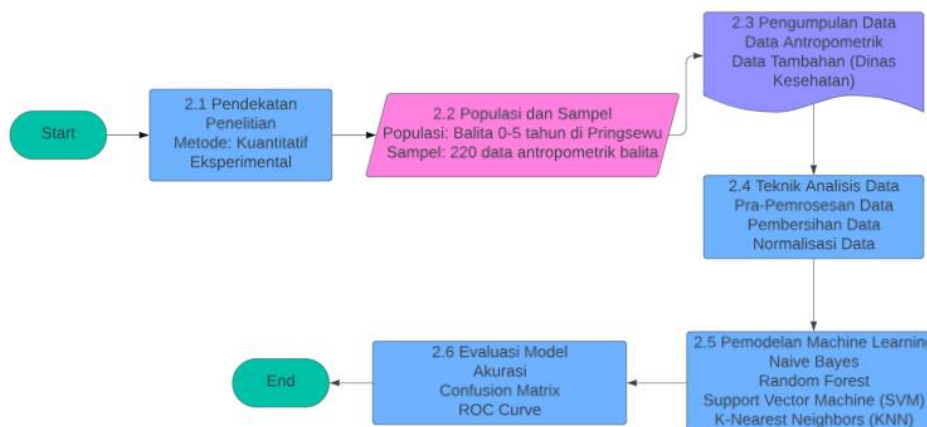
Penelitian yang dilakukan oleh Ridwan dan teman-temannya yang berjudul "The Comparison of Accuracy Between *Naïve Bayes* Classifier and C4.5 Algorithm in Classifying Toddler Nutrition Status Based on Anthropometry Index" mengevaluasi akurasi Algoritma *Naïve Bayes* Classifier dan C4.5 dalam mengklasifikasikan status gizi balita berdasarkan Indeks Massa Tubuh. Dengan parameter antropometri seperti tinggi badan, usia, dan berat badan, penelitian ini mengkategorikan status gizi balita ke dalam lima kelas: kurus, sangat kurus, normal, gemuk, dan sangat gemuk. Hasilnya menunjukkan Algoritma C4.5 memiliki akurasi 0,93% lebih tinggi dibandingkan *Naïve Bayes* Classifier, menunjukkan potensinya sebagai model yang efektif untuk mendukung keputusan terkait status gizi balita [13].

Obvious Nchimunya Chilyabanyama dan tim mengevaluasi algoritma *Machine Learning* seperti Logistic Regression, *Random Forest*, SVC, XGBoost, dan *Naïve Bayes* untuk memprediksi stunting pada anak di bawah lima tahun di Zambia menggunakan data ZDHS 2018. Hasil menunjukkan *Random Forest* memiliki akurasi tertinggi (79% pada data pengujian), sementara *Naïve Bayes* memiliki performa terendah. Penelitian ini menyoroti peran *Machine Learning* dalam mendukung diagnosis stunting dan pengembangan intervensi pencegahan yang lebih efektif [14]

Meskipun penelitian sebelumnya menunjukkan potensi penggunaan *Machine Learning* dalam deteksi stunting, masih ada gap dalam penerapan teknologi ini di daerah dengan tantangan akses dan sumber daya terbatas. Penelitian ini bertujuan untuk mengisi gap tersebut dengan menerapkan pendekatan *Machine Learning* yang lebih efisien dalam konteks Kabupaten Pringsewu, yang diharapkan dapat diintegrasikan dalam kebijakan kesehatan masyarakat untuk menurunkan prevalensi stunting. Melalui pemodelan yang tepat, intervensi yang lebih spesifik dapat dirancang untuk menargetkan kelompok berisiko tinggi, sehingga berpotensi mengurangi prevalensi stunting secara keseluruhan.

2. METODE PENELITIAN

Metode penelitian yang dilakukan sebagai berikut:



Gambar 1. Metode Penelitian

2.1 Pendekatan Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan metode eksperimental. Pendekatan ini dipilih untuk mengevaluasi keakuratan model *Machine Learning* dalam memprediksi risiko stunting berdasarkan data antropometrik pada balita di Kabupaten Pringsewu. Data yang diperoleh akan dianalisis secara statistik untuk mengevaluasi efektivitas model dalam mendeteksi risiko stunting.

2.2 Populasi dan Sampel

Populasi: Populasi dalam penelitian ini adalah balita usia 0–5 tahun yang terdaftar di layanan kesehatan Puskesmas Wates di Kabupaten Pringsewu pada tahun 2023. Sampel: Teknik purposive sampling digunakan untuk memilih sampel yang sesuai dengan kriteria penelitian, yaitu balita dengan catatan lengkap mengenai data antropometrik seperti tinggi badan, berat badan, jenis kelamin, dan usia. Jumlah sampel yang digunakan sebanyak 220 data balita.

2.3 Pengumpulan Data

Data dikumpulkan dari beberapa sumber berikut:

Data Antropometrik: Tinggi badan, berat badan, usia, dan jenis kelamin balita diperoleh dari catatan kesehatan Puskesmas Wates di Kabupaten Pringsewu.

Data Tambahan: Data mengenai prevalensi stunting di Kabupaten Pringsewu serta data dari Dinas Kesehatan setempat juga akan digunakan untuk analisis kontekstual.

2.4 Teknik Analisis Data

1) Pra-Pemrosesan Data

Data yang dikumpulkan akan melalui tahap pra-pemrosesan, meliputi:

- Pembersihan Data: Menghapus data yang tidak lengkap atau tidak konsisten. Dari total 224 record data, ditemukan bahwa ada 4 record yang memiliki atribut yang tidak lengkap. Record yang memiliki atribut yang tidak lengkap dihapus dari dataset. Sehingga, data yang siap digunakan dalam proses analisis dan pelatihan model *Machine Learning* berjumlah 220 record.
- Pemilihan Indikator Antropometri

Indikator utama yang digunakan dalam deteksi stunting adalah Z-score berdasarkan Height-for-Age (HFA) atau Tinggi Badan per Umur (TB/U)[15], yang diklasifikasikan sebagai berikut:

 - Normal: Z-score > -2 yaitu Anak memiliki pertumbuhan yang sesuai dengan usianya.
 - Pendek: Z-score antara -3 dan -2 (berisiko stunting ringan)
 - Sangat Pendek: Z-score < -3 (berisiko stunting berat)

Representasikan status gizi dengan nilai kategori:

- a) Normal = 0
- b) Pendek = 1
- c) Sangat Pendek = 2

Dalam penelitian ini, hanya anak-anak dengan status gizi Pendek (1) dan Sangat Pendek (2) yang dianggap mengalami stunting. Anak-anak dalam kategori Normal (0) dianggap tidak mengalami stunting.

c. Normalisasi Data

Pada tahapan ini normalisasi data sebagai berikut:

- a) Mengubah jenis kelamin menjadi nilai biner:
 Laki-laki = 1
 Perempuan = 0
- b) Mengkonversi umur kedalam satuan bulan
 Mengubah Tinggi Badan dalam cm
- c) Mengolah status gizi anak menjadi variabel target biner:
 Tidak Stunting (0): Anak dalam kategori Normal
 Stunting (1): Anak dalam kategori Pendek atau Sangat Pendek

Berikut Detail atribut yang digunakan:

Tabel 1. Detail atribut

Atribut	Keterangan
Jenis Kelamin	1 = Laki-laki 0 = Perempuan
Age	Umur dalam satuan bulan
Tinggi badan	Tinggi badan dalam satuan CM
Status Gizi	0 = Normal 1 = Stunting

Penganganan Outlier:

Selama tahap pra-pemrosesan, outlier yang ditemukan pada atribut tinggi badan dan berat badan akan diperiksa dan dikeluarkan jika dianggap tidak wajar atau lebih dari 3 standar deviasi dari nilai rata-rata.

Pembagian Data untuk Validasi:

Pembagian data dilakukan dengan menggunakan teknik *stratified k-fold cross-validation*. Data dibagi menjadi 5 bagian, dengan setiap bagian digunakan sebagai data uji bergantian selama 5 iterasi pelatihan. Hal ini bertujuan untuk memastikan model diuji pada seluruh dataset dan mencegah overfitting

2.5 Pemodelan Machine Learning

Beberapa algoritma *Machine Learning* akan digunakan untuk membangun model prediksi risiko stunting, antara lain:

- 1) *Naive Bayes*: Algoritma berbasis probabilitas yang menggunakan Teorema Bayes dengan asumsi independensi antar fitur. *Naive Bayes* dikenal cepat dan efisien, serta sering digunakan untuk kasus klasifikasi data sederhana. Model ini dipilih karena kesederhanaannya dan kemampuannya untuk menangani data dengan jumlah fitur yang relatif kecil.
- 2) *Random Forest*: Algoritma ini menggunakan banyak pohon keputusan (decision trees) untuk memberikan hasil yang lebih stabil dan akurat. *Random Forest* juga tangguh terhadap overfitting pada dataset besar dan dikenal efektif dalam menangani data yang kompleks. Model ini dipilih karena

kemampuannya dalam menangani interaksi non-linier antar fitur dan ketahanan terhadap overfitting, yang sangat penting dalam data dengan variabilitas tinggi seperti data antropometrik

- 3) *Support Vector Machine (SVM)*: Algoritma SVM bekerja dengan mencari hyperplane terbaik untuk memisahkan data dalam kelas-kelas berbeda, khususnya pada data dengan dimensi tinggi. SVM dipilih untuk menguji efektivitas dalam mengklasifikasikan balita berisiko dan tidak berisiko stunting, mengingat sifat data yang memiliki batasan yang cukup jelas namun kompleks dalam klasifikasi.
- 4) *K-Nearest Neighbors (KNN)*: Algoritma yang mengklasifikasikan data berdasarkan jarak atau kedekatan dengan data lain. KNN adalah algoritma sederhana namun sering efektif dalam beberapa kasus klasifikasi. Model ini digunakan untuk menguji kinerja pada data yang lebih terstruktur dan untuk membandingkan dengan algoritma lain yang lebih kompleks.

2.6 Evaluasi Model

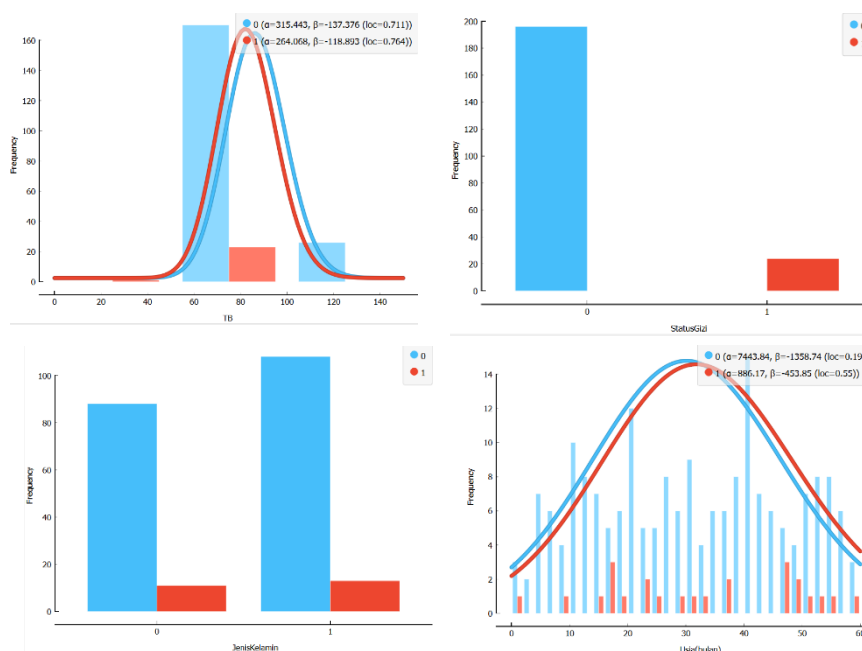
Model akan dievaluasi menggunakan metrik berikut untuk memberikan gambaran kinerja yang komprehensif:

- 1) *Akurasi*: Mengukur persentase prediksi yang benar dari keseluruhan prediksi yang dilakukan oleh model. Metrik ini kurang optimal jika data tidak seimbang, karena dapat didominasi oleh kelas mayoritas.
- 2) *Confusion matrix*: Matriks ini menampilkan jumlah prediksi benar dan salah, terbagi dalam kategori *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*, sehingga membantu mengidentifikasi pola kesalahan model.
- 3) *ROC (Receiver Operating Characteristic) Curve*: Grafik yang menunjukkan trade-off antara *true positive rate (TPR atau recall)* dan *false positive rate (FPR)* pada berbagai threshold, yang membantu dalam menentukan *threshold* optimal untuk hasil prediksi.

3. HASIL DAN PEMBAHASAN

3.1 Dataset

Dataset yang digunakan dalam penelitian ini sebanyak 220 data balita dipringsewu dengan variable jenis kelamin, usia anak dalam bulan, tinggi badan (TB), dan status gizi.

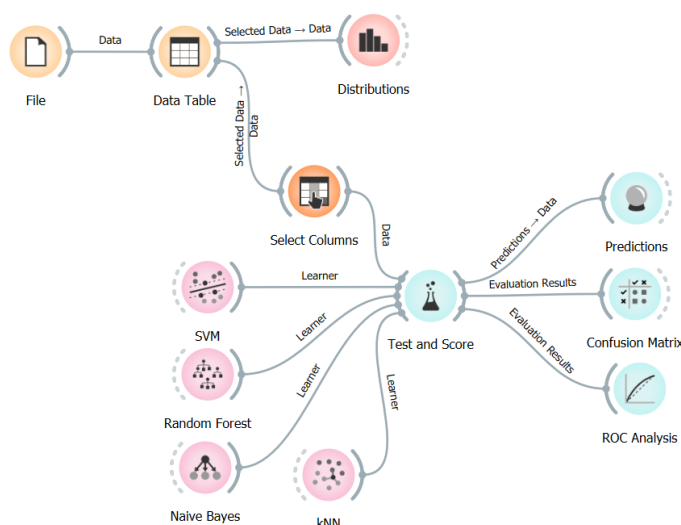


Gambar 2. Histogram variabel jenis kelamin, usia, tinggi badan dan status gizi

Histogram diatas memberikan gambaran tentang distribusi variabel jenis kelamin, usia, tinggi badan, dan status gizi anak dalam dataset. Warna biru pada histogram menunjukkan anak-anak dengan status gizi normal, sedangkan warna merah menunjukkan anak-anak yang terindikasi stunting. Grafik jenis kelamin menunjukkan prevalensi stunting di antara kelompok perempuan (0) dan laki-laki (1). Histogram usia memperlihatkan prevalensi stunting di berbagai rentang usia dalam satuan bulan. Histogram tinggi badan membantu mengidentifikasi perbedaan signifikan dalam pertumbuhan fisik antara anak-anak yang memiliki status gizi normal dan terindikasi stunting. Sementara histogram status gizi memperlihatkan perbandingan jumlah anak dengan status gizi normal dan yang terindikasi stunting.

3.2 Pemodelan Machine Learning

Setelah melalui tahap preprocessing, kami melakukan eksperimen menggunakan aplikasi Orange untuk menguji algoritma *Machine Learning* yang memberikan akurasi tertinggi dalam mendeteksi stunting pada anak berdasarkan indikator antropometri. Eksperimen ini menggunakan 10-fold cross-validation dengan pembagian data sebesar 90% untuk training dan 10% untuk testing, sebagaimana ditunjukkan pada gambar berikut :



Gambar 3. Pemodelan *Machine Learning*

Dari percobaan diatas penelitian kami mendapatkan hasil berikut:

Tabel 2. Tabel Hasil Pemodelan dan Evaluasi


Model	Akurasi (%)	Confusion Matrik																
SVM	86.60%	<table border="1"> <thead> <tr> <th></th> <th>0</th> <th>1</th> <th>Σ</th> </tr> </thead> <tbody> <tr> <th>0</th> <td>186.0</td> <td>14.0</td> <td>200</td> </tr> <tr> <th>1</th> <td>11.1</td> <td>8.9</td> <td>20</td> </tr> <tr> <th>Σ</th> <td>197</td> <td>23</td> <td>220</td> </tr> </tbody> </table>		0	1	Σ	0	186.0	14.0	200	1	11.1	8.9	20	Σ	197	23	220
	0	1	Σ															
0	186.0	14.0	200															
1	11.1	8.9	20															
Σ	197	23	220															
Random Forest	92.70%	<table border="1"> <thead> <tr> <th></th> <th>0</th> <th>1</th> <th>Σ</th> </tr> </thead> <tbody> <tr> <th>0</th> <td>186.7</td> <td>13.3</td> <td>200</td> </tr> <tr> <th>1</th> <td>13.0</td> <td>7.0</td> <td>20</td> </tr> <tr> <th>Σ</th> <td>200</td> <td>20</td> <td>220</td> </tr> </tbody> </table>		0	1	Σ	0	186.7	13.3	200	1	13.0	7.0	20	Σ	200	20	220
	0	1	Σ															
0	186.7	13.3	200															
1	13.0	7.0	20															
Σ	200	20	220															
Naive Bayes	86.60%	<table border="1"> <thead> <tr> <th></th> <th>0</th> <th>1</th> <th>Σ</th> </tr> </thead> <tbody> <tr> <th>0</th> <td>173.1</td> <td>26.9</td> <td>200</td> </tr> <tr> <th>1</th> <td>17.0</td> <td>3.0</td> <td>20</td> </tr> <tr> <th>Σ</th> <td>190</td> <td>30</td> <td>220</td> </tr> </tbody> </table>		0	1	Σ	0	173.1	26.9	200	1	17.0	3.0	20	Σ	190	30	220
	0	1	Σ															
0	173.1	26.9	200															
1	17.0	3.0	20															
Σ	190	30	220															
kNN	91.40%	<table border="1"> <thead> <tr> <th></th> <th>0</th> <th>1</th> <th>Σ</th> </tr> </thead> <tbody> <tr> <th>0</th> <td>189.6</td> <td>10.4</td> <td>200</td> </tr> <tr> <th>1</th> <td>15.0</td> <td>5.0</td> <td>20</td> </tr> <tr> <th>Σ</th> <td>205</td> <td>15</td> <td>220</td> </tr> </tbody> </table>		0	1	Σ	0	189.6	10.4	200	1	15.0	5.0	20	Σ	205	15	220
	0	1	Σ															
0	189.6	10.4	200															
1	15.0	5.0	20															
Σ	205	15	220															

Hasil menunjukkan bahwa model *Random Forest* mencapai akurasi tertinggi, yaitu 92,70%, menjadikannya model terbaik dalam mendeteksi stunting dengan tingkat kesalahan yang relatif rendah dibandingkan model lainnya. *K-Nearest Neighbors* (kNN) juga menunjukkan performa yang baik dengan akurasi 91,40%, sedikit di bawah *Random Forest*. Sementara itu, SVM dan *Naive Bayes* memperoleh akurasi yang sama, yakni 86,60%, namun *Naive Bayes* menunjukkan lebih banyak kesalahan dalam memprediksi kelas positif stunting.

Evaluasi *Confusion matrix* menunjukkan bahwa setiap model memiliki kemampuan yang berbeda dalam memprediksi kasus stunting (positif) dan non-stunting (negatif). *Random Forest* menunjukkan performa terbaik dengan akurasi 92,70%, serta kesalahan rendah pada prediksi positif (FN = 13.0) dan negatif (FP = 13.3). Keseimbangan yang baik antara prediksi benar dan salah menjadikan model ini yang paling direkomendasikan untuk deteksi dini stunting.

K-Nearest Neighbors (kNN) juga memberikan hasil yang baik dengan akurasi 91,40% dan tingkat kesalahan rendah pada FN (5.0) dan FP (10.4), sedikit di bawah *Random Forest* namun masih lebih unggul daripada SVM dan *Naive Bayes*.

Sebaliknya, *Support Vector Machine* (SVM) dan *Naive Bayes* menunjukkan kesalahan lebih tinggi dalam memprediksi kasus positif stunting. Meskipun akurasi keduanya sama (86,60%), tingginya jumlah FN dan FP membuat kedua model ini kurang ideal untuk deteksi dini stunting.



Gambar 4. ROC Analysis

Kurva ROC menunjukkan performa *Random Forest* dan *K-Nearest Neighbors* (kNN) dalam mendeteksi stunting pada anak. Kedua model ini memiliki kurva yang mendekati sudut kiri atas grafik, menunjukkan kemampuan yang baik dalam membedakan antara kasus stunting (positif) dan non-stunting (negatif). *Random Forest* menunjukkan performa yang lebih konsisten dengan kurva yang lebih stabil, menandakan keseimbangan yang baik antara sensitivitas (True Positive Rate) dan spesifisitas (False Positive Rate). Meskipun kNN juga memiliki performa yang kuat, *Random Forest* tampak sedikit lebih unggul.

Secara keseluruhan, kedua model layak digunakan untuk deteksi dini stunting, namun *Random Forest* lebih direkomendasikan karena performanya yang sedikit lebih baik dalam membedakan kasus positif dan negatif.

3.3 Analisis Mendalam Performa Model

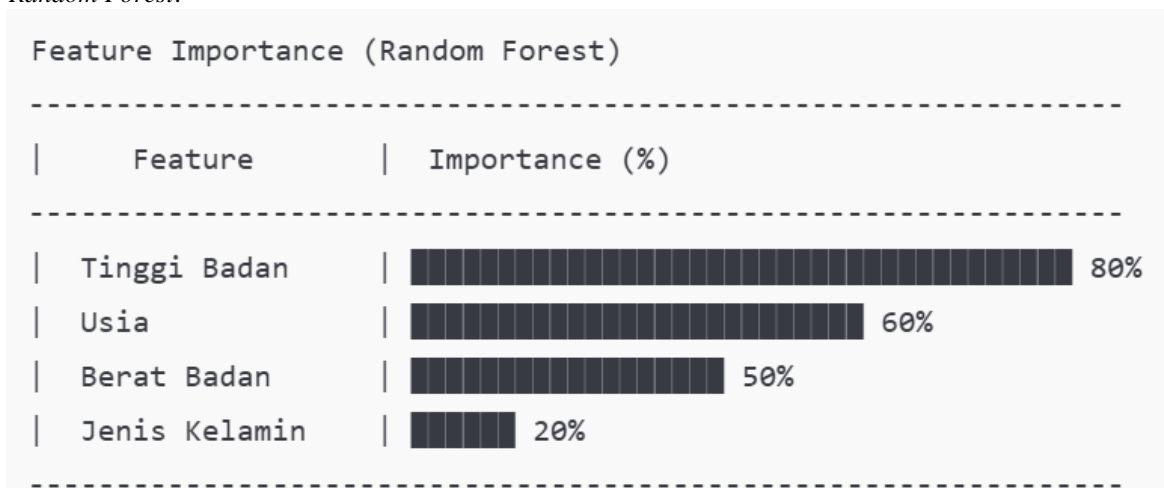
Perbedaan performa antara algoritma dapat dijelaskan berdasarkan karakteristik data dan fitur yang digunakan. *Random Forest*, yang mengandalkan banyak pohon keputusan (decision trees), mampu menangani interaksi

non-linier antar fitur dengan lebih baik dibandingkan algoritma lain. Dalam dataset ini, fitur-fitur seperti tinggi badan, usia, dan berat badan saling berinteraksi secara kompleks, dan *Random Forest* lebih mampu menangkap hubungan-hubungan ini tanpa perlu pemrosesan tambahan pada fitur. Sebaliknya, *Naive Bayes* mengasumsikan independensi antar fitur, yang tidak selalu sesuai dengan sifat data antropometrik yang saling berkorelasi. Hal ini menyebabkan *Naive Bayes* menunjukkan performa yang lebih buruk.

Selain itu, *Random Forest* memiliki kemampuan untuk menangani data yang lebih besar dan lebih bervariasi dengan lebih baik dibandingkan SVM dan *Naive Bayes*, terutama pada dataset dengan banyak variasi antar individu, seperti yang ditemukan dalam data antropometrik ini. SVM, meskipun efektif dalam klasifikasi data dengan dimensi tinggi, cenderung memerlukan lebih banyak pemrosesan dan parameter tuning yang lebih rumit.

3.4 Visualisasi Data - Feature Importance

Untuk memperjelas pengaruh atribut terhadap keputusan model, visualisasi *feature importance* digunakan untuk menunjukkan atribut antropometrik yang paling berpengaruh dalam prediksi stunting. Berikut adalah grafik *feature importance* yang menunjukkan kontribusi masing-masing fitur terhadap keputusan model *Random Forest*:



Gambar 5. Feature Importance Random Forest

Grafik di atas menunjukkan bahwa tinggi badan dan usia memiliki kontribusi terbesar dalam prediksi status stunting, diikuti oleh berat badan dan jenis kelamin. Ini menunjukkan bahwa tinggi badan dan usia adalah dua faktor yang paling menentukan dalam mengidentifikasi anak-anak yang berisiko stunting.

3.5 Evaluasi Kontekstual - Tantangan Implementasi di Lapangan

Meskipun *Random Forest* menunjukkan performa yang sangat baik dalam penelitian ini, ada beberapa tantangan yang perlu dipertimbangkan dalam implementasi model ini di lapangan, terutama dalam layanan kesehatan masyarakat:

- 1) **Ketersediaan Data:** Salah satu tantangan utama adalah ketersediaan data yang akurat dan lengkap. Di lapangan, tidak semua Puskesmas atau fasilitas kesehatan memiliki catatan yang lengkap atau akurat mengenai data antropometrik balita. Oleh karena itu, implementasi model ini memerlukan perbaikan dalam pengumpulan data dan peningkatan kualitas pencatatan data kesehatan.
- 2) **Keterbatasan Sumber Daya:** Penerapan model *Machine Learning* seperti *Random Forest* membutuhkan sumber daya komputasi yang lebih besar, yang mungkin tidak tersedia di banyak daerah dengan infrastruktur kesehatan yang terbatas. Oleh karena itu, implementasi di lapangan perlu mempertimbangkan solusi yang lebih efisien, seperti penggunaan perangkat mobile dengan aplikasi berbasis *cloud* untuk analisis data secara real-time.
- 3) **Penerimaan dan Pelatihan:** Model ini akan membutuhkan pelatihan untuk tenaga medis dan petugas kesehatan agar dapat memahami dan menginterpretasi hasil prediksi model dengan baik. Selain itu,

intervensi berbasis model ini perlu dikombinasikan dengan pendekatan berbasis edukasi untuk meningkatkan kesadaran orang tua dan keluarga dalam menangani masalah stunting.

3.6 Implikasi Praktis

Penerapan model ini di lapangan dapat membantu dalam deteksi dini stunting dan memberikan intervensi yang lebih tepat sasaran. Dengan menggunakan *Random Forest* sebagai model prediksi, Puskesmas dan fasilitas kesehatan lainnya dapat mengidentifikasi anak-anak yang berisiko stunting dengan lebih cepat dan akurat, sehingga memungkinkan mereka untuk memberikan perawatan yang lebih efektif. Namun, agar model ini dapat diterapkan secara luas, dibutuhkan kolaborasi antara instansi kesehatan, pengembang teknologi, dan masyarakat untuk memastikan bahwa data yang digunakan akurat dan mudah diakses.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa pendekatan *Machine Learning* berbasis indikator antropometri efektif untuk deteksi dini stunting pada anak. Dari berbagai algoritma yang diuji, *Random Forest* terbukti menjadi model terbaik dengan akurasi tertinggi sebesar 92,70%, diikuti oleh *K-Nearest Neighbors* (KNN) dengan akurasi 91,40%. Algoritma *Random Forest* memiliki keunggulan dalam meminimalkan kesalahan prediksi, yang menjadikannya pilihan yang andal untuk mendeteksi risiko stunting. Dengan demikian, penerapan model ini dalam skrining kesehatan masyarakat dapat mendukung intervensi yang lebih tepat sasaran dan efektif bagi anak-anak berisiko tinggi stunting.

Implikasi praktis penerapan model *Random Forest* dalam deteksi dini stunting berpotensi besar untuk diintegrasikan ke dalam sistem kesehatan masyarakat. Untuk itu, disarankan agar model ini diterapkan dalam sistem rekam medis elektronik (RME) yang ada di Puskesmas atau fasilitas kesehatan lainnya. Integrasi ini akan memungkinkan petugas medis untuk melakukan analisis cepat terhadap data antropometrik, seperti tinggi badan, berat badan, dan usia, serta memberikan prediksi risiko stunting secara real-time. Hal ini dapat mempermudah identifikasi anak-anak yang berisiko dan memberikan intervensi yang lebih cepat dan tepat sasaran.

Rekomendasi penelitian lanjutan untuk penelitian lanjutan, selain mengeksplorasi algoritma *Machine Learning* lainnya, disarankan untuk menggunakan data longitudinal yang mencakup pengukuran status gizi anak secara berkelanjutan. Ini akan memungkinkan analisis yang lebih mendalam tentang perubahan status gizi anak dalam jangka panjang dan memberikan gambaran yang lebih akurat mengenai faktor-faktor yang mempengaruhi stunting. Selain itu, penting untuk memperhatikan faktor sosial-ekonomi dalam model ini. Penelitian lanjutan bisa fokus pada pengumpulan dan analisis data terkait kondisi sosial-ekonomi keluarga (misalnya, pendapatan, pendidikan orang tua, dan akses ke layanan kesehatan) yang dapat berkontribusi pada risiko stunting. Dengan mengintegrasikan variabel-variabel ini, model prediksi stunting dapat menjadi lebih komprehensif dan relevan dengan kondisi masyarakat setempat.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada semua pihak yang telah berkontribusi dalam terlaksananya penelitian ini. Ucapan terima kasih kami sampaikan kepada Universitas Aisyah Pringsewu dan Universitas Bina Sarana Informatika atas dukungan fasilitas dan lingkungan akademik yang kondusif. Tanpa dukungan dan kerjasama dari semua pihak, penelitian ini tidak akan terselesaikan dengan baik.

REFERENSI

- [1] M. L. W. Kinshella, S. E. Moore, and R. Elango, "The missing focus on women's health in the First 1,000 days approach to nutrition," Apr. 01, 2021, *Cambridge University Press*. doi: 10.1017/S1368980020003894.

- [2] A. J. Prendergast and J. H. Humphrey, "The stunting syndrome in developing countries," *Paediatr Int Child Health*, vol. 34, no. 4, pp. 250–265, Nov. 2014, doi: 10.1179/2046905514Y.0000000158.
- [3] Kepala Biro Komunikasi dan Pelayanan Publik, "Membentengi Anak Dari Stunting." [Online]. Available: <https://link.kemkes.go.id/mediakom>
- [4] M. A. B. Ndetu, P. Weraman, and P. Romeo, "Factors Associated with Stunting in Children Under Five: A Cross-Sectional Study from Ritaebang Health Center, West Solor, East Flores, Indonesia," *Journal of Health Promotion and Behavior*, vol. 8, no. 1, pp. 1–7, 2023, doi: 10.26911/thejhp.2023.08.01.01.
- [5] A. Khomsan *et al.*, "Supplemental feeding and nutrition education to reduce stunting in Indonesian toddlers - The DASHAT programme," *Progress in Nutrition*, vol. 26, no. 1, Mar. 2024, doi: 10.23751/pn.v26i1.15270.
- [6] Diskominfo Pringsewu, "6 Pemkab Pringsewu Bentuk Jejaring Skrining Layak Hamil^J ANC^J dan Stunting," p. 1, Aug. 2024, Accessed: Nov. 15, 2024. [Online]. Available: <https://pringsewukab.go.id/portal/berita/read/pemkab-pringsewu-bentuk-jejaring-skrining-layak-hamil-anc-dan-stunting>
- [7] "7 Laporan Penyelenggaraan Percepatan Penurunan Stunting Propinsi Lampung," Jul. 2023, Accessed: Nov. 15, 2024. [Online]. Available: https://aksi.bangda.kemendagri.go.id/emonev/assets/uploads/laporan_pro/laporan_pro_18_periode_5_1691987988.pdf
- [8] G. María Pita-Rodríguez *et al.*, "Anthropometric indicators of nutritional status in children up to 2 years according to Urban or Rural Area, Cuba Anthropometric indicators of nutritional status in children up to 2 years according to Urban or Rural Area, Cuba Background and Objective." [Online]. Available: <https://www.researchgate.net/publication/265728181>
- [9] "Peraturan Menteri Kesehatan Republik Indonesia," 2020. Accessed: Nov. 15, 2024. [Online]. Available: http://hukor.kemkes.go.id/uploads/produk_hukum/PMK_No__2_Th_2020_ttg_Standar_Antropometri_Anak.pdf
- [10] S. Khare, S. Kavyashree, D. Gupta, and A. Jyotishi, "Investigation of Nutritional Status of Children based on *Machine Learning* Techniques using Indian Demographic and Health Survey Data," in *Procedia Computer Science*, Elsevier B.V., 2017, pp. 338–349. doi: 10.1016/j.procs.2017.09.087.
- [11] T. E. Putri, R. T. Subagio, Kusnadi, and P. Sobiki, "Classification System of Toddler Nutrition Status using *Naïve Bayes* Classifier Based on Z- Score Value and Anthropometry Index," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Nov. 2020. doi: 10.1088/1742-6596/1641/1/012005.
- [12] I. P. Putri, T. Terttiaavini, and N. Arminarahmah, "Analisis Perbandingan Algoritma *Machine Learning* untuk Prediksi Stunting pada Anak," *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 1, pp. 257–265, Jan. 2024, doi: 10.57152/malcom.v4i1.1078.
- [13] A. Ridwan and T. N. Sari, "The comparison of accuracy between *Naïve Bayes* classifier and c4.5 algorithm in classifying toddler nutrition status based on anthropometry index," in *Journal of Physics: Conference Series*, IOP Publishing Ltd, Feb. 2021. doi: 10.1088/1742-6596/1764/1/012047.
- [14] O. N. Chilyabanyama *et al.*, "Performance of *Machine Learning* Classifiers in Classifying Stunting among Under-Five Children in Zambia," *Children*, vol. 9, no. 7, Jul. 2022, doi: 10.3390/children9071082.
- [15] WHO (World Health Organization), "Length/height-for-age, weight-for-age, weight-for-length, weight-for-height and body mass index-for-age Methods and development." Accessed: Nov. 16, 2024. [Online]. Available: <https://www.who.int/publications/i/item/924154693X>