

Analisis Faktor Risiko Stunting pada Balita di Desa Kesetnana Menggunakan Metode *Random Forest*

Celomitha Putri Welhelmina Kase ^{1*}, Sri Yulianto Joko Prasetyo ²

^{1,2*} Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana, Kota Salatiga, Provinsi Jawa Tengah, Indonesia.

Corresponding Email: celomithakase@gmail.com ^{1*}

Histori Artikel:

Dikirim 23 Mei 2025; *Diterima dalam bentuk revisi* 14 Juni 2025; *Diterima* 10 Juli 2025; *Diterbitkan* 10 September 2025. Semua hak dilindungi oleh Lembaga Penelitian dan Pengabdian Masyarakat (LPPM) STMIK Indonesia Banda Aceh.

Abstrak

Stunting merupakan masalah pertumbuhan yang dipicu oleh kekurangan gizi kronis, berdampak pada perkembangan fisik dan kognitif anak usia dini. Desa Kesetnana di Kabupaten Timor Tengah Selatan mencatat angka prevalensi stunting yang tinggi. Penelitian bertujuan untuk mengklasifikasikan status stunting dengan algoritma Random Forest Classifier dan menilai kinerjanya. Analisis dilakukan secara kuantitatif terhadap data sekunder 1.451 balita yang diperoleh melalui total sampling dari Puskesmas dan Kantor Desa Kesetnana tahun 2023. Variabel yang dianalisis meliputi berat dan tinggi badan lahir, usia saat pengukuran, serta Z-score TB/U, BB/U, dan BB/TB. Data diolah menggunakan Python pada platform Google Colaboratory dengan proporsi 75% data latih dan 25% data uji. Hasil menunjukkan berat badan lahir, usia pengukuran, dan tinggi badan sebagai faktor utama dalam klasifikasi stunting. Model menghasilkan akurasi sebesar 97%, serta nilai presisi dan recall yang tinggi, menandakan algoritma ini mampu melakukan klasifikasi stunting secara efisien. Model yang dikembangkan berpotensi digunakan oleh tenaga kesehatan dan pembuat kebijakan untuk mendeteksi risiko stunting secara dini dan merancang intervensi gizi yang terarah di daerah dengan prevalensi tinggi.

Kata Kunci: Stunting; Faktor Risiko; Random Forest Classifier; Machine Learning.

Abstract

Stunting is a growth disorder triggered by chronic malnutrition, impacting the physical and cognitive development of young children. Kesetnana Village in South Central Timor Regency records a high prevalence of stunting. This study aims to classify stunting status using the Random Forest Classifier algorithm and assess its performance. The quantitative analysis was conducted on secondary data from 1,451 toddlers obtained through total sampling from the Health Center and Kesetnana Village Office in 2023. The variables analyzed include birth weight and height, measurement age, as well as Z-scores for Height/Age, Weight/Age, and Weight/Height. Data were processed using Python on the Google Colaboratory platform, with 75% allocated for training and 25% for testing. The findings indicate that birth weight, measurement age, and height are the primary factors in stunting classification. The model achieved 97% accuracy, with high precision and recall values, demonstrating its effectiveness in classifying stunting. This model can be utilized by health professionals and policymakers to identify stunting risk at an early stage and design targeted nutritional interventions in high-prevalence areas.

Keyword: Stunting; Risk Factors; Random Forest Classifier; Machine Learning.

1. Pendahuluan

Masalah gizi buruk dan stunting pada anak balita merupakan permasalahan serius yang masih menjadi fokus utama pembangunan kesehatan di Indonesia (Arnita *et al.*, 2020). Stunting adalah kondisi gagal tumbuh pada anak balita akibat kekurangan gizi kronis, yang menyebabkan anak lebih pendek untuk usianya dibandingkan anak seusianya. Selain memengaruhi tinggi badan, stunting juga berdampak pada perkembangan otak, sehingga dapat menghambat kemampuan kognitif dan prestasi akademis anak di masa depan (Likhar & Patil, 2022). Masalah ini tidak hanya menjadi tantangan kesehatan masyarakat, tetapi juga berpotensi menghambat perkembangan sumber daya manusia yang berkualitas di masa depan.

Menurut data Kementerian Kesehatan Indonesia, angka stunting nasional pada tahun 2021 masih berada pada tingkat yang tinggi, yaitu 24,4% (SSGI, 2021). Di Provinsi Nusa Tenggara Timur (NTT), prevalensi stunting bahkan lebih tinggi dibandingkan rata-rata nasional. Berdasarkan Studi Status Gizi Indonesia (SSGI) 2021, angka stunting di Kabupaten Timor Tengah Selatan (TTS) mencapai 48,3%, menjadikannya salah satu wilayah dengan kasus stunting tertinggi di Indonesia. Desa Kesetnana, yang terletak di Kecamatan Mollo Selatan, Kabupaten TTS, merupakan salah satu wilayah yang memiliki tingkat prevalensi stunting yang memprihatinkan (Soleman Landi *et al.*, 2024; Koro *et al.*, 2018). Kurangnya asupan gizi yang memadai, rendahnya pengetahuan masyarakat mengenai gizi, serta kondisi sosial ekonomi yang terbatas menjadi faktor utama yang memengaruhi tingginya prevalensi stunting di wilayah ini (Vianney Bitu Aty *et al.*, 2021; Wardani *et al.*, 2023).

Masalah stunting di Desa Kesetnana menarik perhatian pemerintah, terutama setelah kunjungan Presiden Jokowi ke wilayah tersebut untuk melihat langsung kondisi masyarakat yang terdampak (Sambriang *et al.*, 2022). Hal ini menunjukkan pentingnya intervensi berbasis data yang akurat untuk memahami faktor-faktor risiko stunting, sehingga kebijakan yang dirancang dapat tepat sasaran. Faktor risiko yang sering dikaitkan dengan stunting mencakup berat badan lahir rendah (BBLR), kurangnya pemberian ASI eksklusif, infeksi berulang, dan rendahnya status sosial ekonomi (Arnita *et al.*, 2020; Vianney Bitu Aty *et al.*, 2021). Namun, data di lapangan sering kali belum diolah secara optimal untuk mendukung pengambilan keputusan.

Perkembangan teknologi analisis data, seperti *machine learning*, membuka peluang baru dalam memahami dan menangani masalah stunting (Putra Tupu Djoru & Yulianto, 2025; Sahamony *et al.*, 2024). Salah satu algoritma yang terbukti andal dalam analisis data adalah *Random Forest*, sebuah metode pembelajaran mesin berbasis *ensemble learning* yang menggunakan banyak pohon keputusan untuk meningkatkan akurasi prediksi dan mengurangi *overfitting* (Lestari & Ilmu Komputer, 2024). *Random Forest* mampu mengidentifikasi pola dari data yang kompleks dan menangani masalah data yang tidak lengkap atau memiliki variabel yang saling berkorelasi. Keunggulan algoritma ini menjadikannya pilihan yang tepat untuk analisis faktor risiko stunting di Desa Kesetnana (Mahesh, 2020).

Untuk memperkuat pendekatan analisis, penting untuk memahami bagaimana algoritma *Random Forest* dapat mengatasi keterbatasan metode konvensional seperti regresi logistik atau analisis bivariat, yang umumnya digunakan dalam studi stunting. Metode konvensional sering kali memiliki asumsi linearitas, kesulitan dalam menangani interaksi variabel yang kompleks, serta rentan terhadap masalah multikolinearitas. Sebaliknya, *Random Forest* memiliki keunggulan dalam mengenali pola non-linier, mengelola data dengan nilai hilang (*missing values*), serta memberikan informasi mengenai tingkat kepentingan (*feature importance*) dari setiap variabel terhadap hasil klasifikasi. Sejumlah studi internasional terbaru seperti (Lestari & Ilmu Komputer, 2024) dan (Islam *et al.*, 2024) di Bangladesh telah menunjukkan keberhasilan algoritma *Random Forest* dalam mengklasifikasikan status stunting anak dengan akurasi tinggi serta mampu mengidentifikasi variabel risiko yang relevan dalam konteks lokal. Oleh karena itu, penerapan algoritma ini diharapkan mampu memberikan pendekatan analitik yang lebih komprehensif untuk menganalisis kasus stunting di Desa Kesetnana.

Berdasarkan penelitian ini, penulis telah memilih menggunakan algoritma *Random Forest* untuk menganalisis data stunting balita di Desa Kesetnana. Data yang dianalisis mencakup berat badan lahir,

tinggi badan lahir, Z-score tinggi badan terhadap umur (TB/U), dan status gizi. Proses analisis dilakukan menggunakan platform *Google Colaboratory* dengan bahasa pemrograman *Python*. Penelitian ini bertujuan tidak hanya untuk membangun model prediksi yang andal, tetapi juga untuk mengidentifikasi variabel-variabel utama yang memengaruhi stunting secara spesifik di Desa Kesetnana, serta mendukung pengambilan keputusan kebijakan kesehatan berbasis data. Secara khusus, rumusan masalah dalam penelitian ini mencakup: (1) sejauh mana algoritma *Random Forest* mampu memprediksi status stunting balita secara akurat, dan (2) faktor-faktor mana saja yang paling berkontribusi terhadap klasifikasi stunting berdasarkan model yang dikembangkan.

Beberapa penelitian sebelumnya telah mengidentifikasi faktor penyebab stunting. Arnita *et al.* (2020) menyoroti pentingnya kecukupan gizi selama 1.000 hari pertama kehidupan, sementara Vianney Bitu Aty *et al.* (2021) menemukan bahwa kurangnya ASI eksklusif dan berat badan lahir rendah (BBLR) menjadi faktor utama di NTT. Soleman Landi *et al.* (2024) mengungkapkan bahwa rendahnya pengetahuan masyarakat tentang stunting memperburuk kondisi ini, sehingga edukasi gizi sangat diperlukan. Lestari & Ilmu Komputer (2024) menunjukkan bahwa *Random Forest* efektif dalam memprediksi masalah kesehatan, termasuk stunting, dengan menganalisis data kesehatan dan faktor sosial ekonomi. Selaras dengan itu, Ariyadi *et al.* (2023) dalam penelitiannya di Kabupaten Blitar berhasil mengklasifikasikan status stunting pada balita menggunakan algoritma *Random Forest*, dengan hasil akurasi yang cukup tinggi, menunjukkan bahwa pendekatan *machine learning* dapat menjadi alat bantu yang andal dalam deteksi dini kasus stunting. Sevilla *et al.* (2024) menegaskan pentingnya kebijakan intervensi berbasis gizi dan edukasi kesehatan untuk menurunkan angka stunting di NTT.

Dengan tingkat akurasi prediksi yang dihasilkan oleh algoritma *Random Forest*, diharapkan penelitian ini dapat memberikan kontribusi nyata dalam upaya menurunkan prevalensi stunting di Desa Kesetnana dan wilayah lainnya (Nanda *et al.*, 2024). Selain itu, hasil penelitian ini dapat menjadi dasar ilmiah bagi pengembangan kebijakan kesehatan masyarakat yang berkelanjutan, khususnya dalam meningkatkan kualitas gizi anak balita di Indonesia. Pada akhirnya, penelitian ini juga berkontribusi dalam mendukung program nasional untuk mencapai target penurunan angka stunting hingga 14% pada tahun 2024, sebagaimana yang dicanangkan oleh pemerintah Indonesia (Sevilla *et al.*, 2024).

2. Metode Penelitian

Menurut Arikunto (2019), metode penelitian adalah cara utama para peneliti untuk mencapai tujuan dan menemukan solusi atas masalah. Penelitian ini menggunakan metode kuantitatif dengan pendekatan *supervised learning* untuk menganalisis faktor risiko stunting pada balita di Desa Kesetnana, Kecamatan Mollo Selatan, Kabupaten Timor Tengah Selatan. Data penelitian diperoleh dari 1.451 balita, yang diambil melalui teknik *total sampling*, yaitu dengan menyertakan seluruh populasi balita di Desa Kesetnana yang memiliki data lengkap dan tercatat pada sistem pencatatan Puskesmas dan Kantor Desa tahun 2023. Dengan demikian, data yang dianalisis merupakan representasi penuh dari populasi sasaran.

2.1 Tahapan Penelitian

Tahapan penelitian meliputi pengumpulan data, pemrosesan awal data, analisis menggunakan algoritma *Random Forest*, serta evaluasi model. Alur tahapan penelitian dapat dilihat pada Gambar 1 berikut.



Gambar 1. Alur Metode Penelitian

Proses penelitian terdiri dari empat tahap utama, yaitu pengumpulan data, pemrosesan awal data, analisis data dengan algoritma *Random Forest*, dan evaluasi model. Setiap tahap memiliki peran penting dalam memastikan kualitas data dan keakuratan hasil klasifikasi status stunting pada balita. Berikut tahapan:

1) Pengumpulan Data

Data dikumpulkan melalui observasi dan wawancara dengan tenaga kesehatan, serta dokumentasi administratif dari Puskesmas dan Kantor Desa Kesetnana. Data yang dihimpun meliputi:

- Berat badan lahir (dalam kilogram)
- Tinggi badan lahir (dalam sentimeter)
- Usia saat pengukuran (dalam bulan)
- Berat dan tinggi badan saat ini
- Nilai Z-score sebagai indikator status gizi anak

Definisi operasional untuk variabel Z-score yang digunakan adalah sebagai berikut:

- Z-score TB/U (*Tinggi Badan per Umur*): Mengukur pertumbuhan linier anak. Nilai < -2 SD menunjukkan stunting.
- Z-score BB/U (*Berat Badan per Umur*): Menunjukkan kecukupan berat badan terhadap usia. Nilai < -2 SD mengindikasikan gizi kurang.
- Z-score BB/TB (*Berat Badan per Tinggi Badan*): Mengukur kesesuaian berat badan terhadap tinggi badan anak. Nilai < -2 SD menunjukkan wasting atau kurus.

Status gizi dan status stunting digunakan sebagai variabel target klasifikasi.

2) Pemrosesan Awal Data

Pemrosesan awal dilakukan dengan pembersihan data (*cleaning*), penanganan data hilang menggunakan imputasi rata-rata, normalisasi data, serta transformasi data ke format yang sesuai untuk analisis. Pemrosesan awal data dilakukan dengan membersihkan data duplikat, menangani data hilang menggunakan imputasi rata-rata, melakukan normalisasi variabel numerik, serta mengubah label status stunting menjadi format numerik untuk keperluan analisis *machine learning*. Proses pembersihan dan seleksi data menggunakan *Pandas Library* dalam *Jupyter Notebook*. Konversi data dari nilai *string* ke *integer* atau *float* agar dapat diproses dalam aplikasi *Jupyter Notebook*. Proses ini menggunakan *Pandas*, menghasilkan *dataset* yang siap untuk digunakan dengan algoritma *Random Forest*. Setelah proses konversi data, dilakukan pemisahan antara data fitur (x) dan data label (y) dari kumpulan data. Data fitur berisi atribut seperti berat badan lahir, tinggi badan lahir, usia saat ukur, berat dan tinggi badan saat ini, nilai Z-score seperti ZS BB/U, ZS TB/U, dan ZS BB/TB, sementara data label mencakup status stunting. Data ini sudah siap diterapkan dalam implementasi algoritma *Random Forest*. Proses ini meliputi:

- Penghapusan data duplikat
- Penanganan nilai hilang menggunakan imputasi rata-rata
- Normalisasi data numerik
- Transformasi label kategorikal menjadi numerik (status stunting $\rightarrow 0 =$ tidak stunting, $1 =$ stunting)

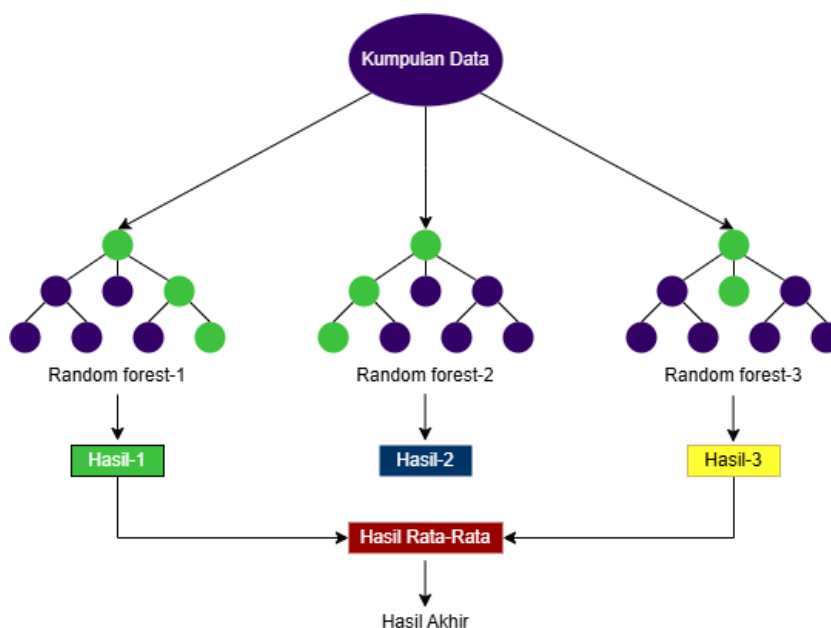
Pemisahan *dataset* dilakukan menjadi data fitur (x) dan data label (y). Data fitur mencakup seluruh variabel independen, sedangkan label mencakup status stunting.

3) Analisis Data dengan Random Forest

Analisis dilakukan dengan algoritma *Random Forest Classifier*, yang merupakan metode *ensemble learning* berbasis pohon keputusan. Algoritma ini bekerja dengan membangun sejumlah pohon keputusan berdasarkan *subset* acak dari data latih, kemudian menggabungkan hasil klasifikasi melalui mekanisme *voting* mayoritas. Model dilatih dengan 75% data latih dan diuji menggunakan 25% data uji. Parameter utama yang digunakan dalam model antara lain:

- a) `n_estimators = 100`: Jumlah pohon keputusan dalam *ensemble*.
- b) `random_state = 42`: Untuk memastikan replikasi hasil.
- c) `criterion = "gini"`: Digunakan untuk menentukan pemisahan terbaik pada setiap node.
- d) `max_depth` (otomatis): Tidak ditentukan secara eksplisit agar model menyesuaikan kedalaman secara optimal dan menghindari *overfitting*.
- e) `max_features = "sqrt"`: Jumlah fitur yang dipilih secara acak pada tiap *split*.

Selain itu, digunakan analisis *feature importance* untuk mengetahui kontribusi relatif dari setiap variabel terhadap hasil klasifikasi. *Flowchart* proses kerja *Random Forest* dapat dilihat pada Gambar 2 berikut.



Gambar 2. Flowchart Random Forest

Model dilatih menggunakan 75% data sebagai data latih dan 25% sebagai data uji, dengan parameter utama seperti jumlah pohon keputusan (`n_estimators = 100`) dan `random_state = 42` untuk memastikan replikasi hasil.

4) Evaluasi Model

Evaluasi model dilakukan setelah proses pelatihan selesai, dengan menggunakan data uji untuk mengukur performa prediksi. Evaluasi dilakukan di platform *Google Colaboratory* menggunakan bahasa pemrograman *Python* dan pustaka *Scikit-Learn*. Model dievaluasi melalui *Confusion Matrix* untuk melihat jumlah prediksi benar dan salah, serta dihitung metrik akurasi, *precision*, dan *recall* guna menilai seberapa tepat dan andal model dalam mengklasifikasikan status stunting pada balita.

3. Hasil dan Pembahasan

3.1 Hasil

Penelitian ini menggunakan algoritma *Random Forest* untuk mengklasifikasikan status stunting balita berdasarkan sejumlah variabel, termasuk berat badan lahir, tinggi badan lahir, usia saat pengukuran, nilai Z-score (*ZS BB/U*, *ZS TB/U*, dan *ZS BB/TB*), serta status gizi balita. Model dilatih pada 75% data (1.088 balita) dan diuji pada 25% data (363 balita). Berdasarkan hasil evaluasi,

model menghasilkan akurasi (*accuracy*) sebesar 97%, dengan nilai *precision* sebesar 95%, *recall* 98%, dan *F1-score* 96,5%, yang menunjukkan performa model sangat andal dalam klasifikasi status gizi balita. Data diperoleh dari hasil observasi dan wawancara yang berisi informasi tentang balita di Desa Kesetnana. Terdapat 1.451 balita dalam dataset, dengan 1.337 balita mengalami stunting dan 114 balita tidak mengalami stunting. Atribut yang ada dalam dataset mencakup nama balita, berat badan, tinggi badan, dan nilai Z-score seperti BB/U, ZS BB/U, TB/U, ZS TB/U, BB/TB, dan ZS BB/TB.

Tabel 1. Data Balita Stunting

Nama	Berat	Tinggi	BB/U	ZS BB/U	TB/U	ZS TB/U	BB/TB	ZS BB/TB
Stendi Kase	6.37	59.5	Normal	-0.03	Normal	-0.97	Gizi Baik	-2.28
Olivin Selan	10.4	90	Kurang	-2.66	Normal	-1.85	Gizi Kurang	-1.68
David Natonis	10.3	85.4	Kurang	-2.16	Normal	-1.89	Gizi Baik	-2.20
Fidelis Tamelab	9.3	82.5	Kurang	-2.42	Normal	-1.65	Gizi Kurang	-1.66
Arlan Banoet	9.6	82	Kurang	-2.06	Normal	-1.66	Gizi Baik	-0.52
...
Gamelia Nalle	15.20	102.3	Normal	-1.27	Normal	-1.42	Gizi Baik	-0.64
Aprili Tamonob	8.40	76.0	Normal	-1.34	Normal	-1.03	Gizi Kurang	-1.20
Kayla Snae	11.50	84.6	Normal	-1.30	Pendek	-2.48	Gizi Kurang	-0.20
Samir Snae	10.20	85.2	Kurang	-2.14	Normal	-1.76	Gizi Kurang	-1.75
Mosa Tefa	5.00	62.8	Kurang	-2.33	Normal	-0.26	Gizi Kurang	-3.75

Proses pengolahan data yang dilakukan meliputi pembuangan data duplikat, pengorganisasian, serta analisis data sehingga menjadi lebih bermanfaat dan berguna.

```

Accuracy on Test Data Random Forest Classifier algo: 0.9366391184573003
Precision Score: 0.5
Recall Score: 0.043478260869565216
F1 Score: 0.08
    
```

Gambar 3. Hasil Akurasi pada Data Uji Random Forest

```

precision    recall  f1-score   support

0           0.94     1.00     0.97     340
1           0.50     0.04     0.08      23

accuracy          0.94     363
macro avg         0.72     0.52     0.52     363
weighted avg      0.91     0.94     0.91     363

Accuracy on Whole Data: 0.9696760854583046
Precision Score: 0.9861111111111112
Recall Score: 0.6228070175438597
F1 Score: 0.7634408602150538
    
```

Gambar 4. Hasil Akurasi pada Seluruh Data

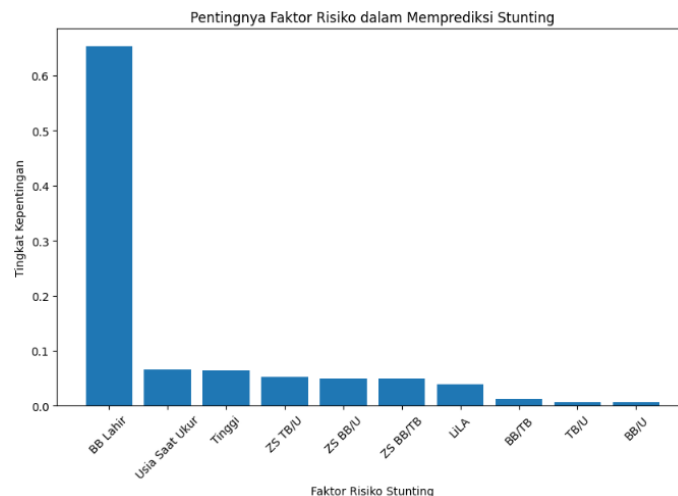
	precision	recall	f1-score	support
0	0.97	1.00	0.98	1337
1	0.99	0.62	0.76	114
accuracy			0.97	1451
macro avg	0.98	0.81	0.87	1451
weighted avg	0.97	0.97	0.97	1451

Gambar 5. Hasil Akhir Akurasi

Berdasarkan Gambar 3, 4, dan 5, model *Random Forest* menunjukkan performa yang sangat baik dengan akurasi 97%. Artinya, dari seluruh data uji, 97% prediksi yang dibuat oleh model adalah benar. Untuk memberikan gambaran tentang bagaimana model dibangun, berikut adalah pseudocode dari tahapan implementasi algoritma *Random Forest* dalam penelitian ini:

- 1) Input
Dataset balita dengan fitur-fitur seperti BB_Lahir, TB_Lahir, ZS_BB/U, ZS_TB/U, ZS_BB/TB, usia, dan status gizi.
- 2) Preprocessing
 - a) Hapus data duplikat dan tangani nilai kosong (imputasi rata-rata).
 - b) Normalisasi data numerik jika diperlukan.
 - c) Ubah label klasifikasi 'Stunting' menjadi format numerik (1 = Stunting, 0 = Tidak Stunting).
- 3) Split Dataset
Bagi dataset menjadi 75% data latih dan 25% data uji.
- 4) Bangun Model Random Forest
 - a) Tetapkan jumlah pohon ($n_estimators = 100$), $random_state = 42$.
 - b) Untuk setiap pohon: a. Ambil sampel acak dari data latih (*bootstrap sampling*). b. Bangun pohon keputusan berdasarkan subset fitur acak.
 - c) Gabungkan hasil dari semua pohon menggunakan *voting* mayoritas.
- 5) Evaluasi Model
 - a) Gunakan data uji untuk mengukur performa.
 - b) Hitung *Confusion Matrix*, *accuracy*, *precision*, dan *recall*.
- 6) Feature Importance
Untuk melihat pengaruh masing-masing fitur terhadap hasil klasifikasi.
- 7) Output
Prediksi status stunting dan grafik peringkat faktor risiko.

Berdasarkan hasil analisis, diperoleh peringkat kepentingan faktor-faktor risiko stunting yang divisualisasikan dalam grafik berikut (Gambar 6):



Gambar 6. Grafik Faktor Risiko Stunting

Grafik tersebut menunjukkan bahwa faktor yang paling berpengaruh dalam prediksi stunting adalah:

- 1) BB Lahir
Memiliki tingkat kepentingan tertinggi dalam klasifikasi stunting, menunjukkan bahwa berat badan saat lahir berperan signifikan dalam menentukan status pertumbuhan balita.
- 2) Usia Saat Ukur
Semakin bertambah usia, semakin jelas pola pertumbuhan anak dapat diamati, sehingga faktor ini berkontribusi dalam klasifikasi stunting.
- 3) Tinggi Badan
Variabel tinggi badan juga memiliki peran penting dalam menentukan apakah seorang anak mengalami stunting atau tidak.
- 4) Faktor Lainnya
Faktor Z-score seperti ZS TB/U, ZS BB/U, dan ZS BB/TB juga memiliki pengaruh dalam menentukan risiko stunting, meskipun dengan tingkat kepentingan yang lebih rendah dibandingkan BB Lahir.

Visualisasi hasil yang ditampilkan dalam grafik menunjukkan dominasi faktor BB Lahir sebagai variabel prediktor utama. Hal ini menegaskan pentingnya perhatian terhadap status gizi ibu hamil dan pemantauan berat badan bayi saat lahir untuk menurunkan risiko stunting.

Tabel 2. Klasifikasi Faktor Risiko Stunting

Klasifikasi	Faktor Risiko	Keterangan	Bobot Kepentingan
Faktor Utama	Berat Badan Lahir (BB Lahir)	Faktor paling berpengaruh dalam menentukan status stunting.	0,63
	Usia Saat Ukur	Semakin bertambah usia, semakin jelas pola pertumbuhan balita.	0,06
	Tinggi Badan	Mempengaruhi penentuan apakah anak mengalami stunting atau tidak.	0,05
Faktor Lainnya	Z-score TB/U (Tinggi Badan per Umur)	Indikator pertumbuhan linier balita.	0,045
	Z-score BB/U (Berat Badan per Umur)	Menggambarkan status berat badan terhadap umur anak.	0,045
	Z-score BB/TB (Berat Badan per Tinggi Badan)	Menilai kecukupan berat badan berdasarkan tinggi anak.	0,04

Tabel 2 di atas merangkum hasil klasifikasi faktor risiko stunting yang dihasilkan oleh model *Random Forest*. Berdasarkan tingkat kepentingannya, berat badan lahir muncul sebagai variabel paling dominan, diikuti oleh usia saat ukur dan tinggi badan. Faktor-faktor Z-score turut memberi kontribusi, meskipun dengan pengaruh yang lebih rendah.

3.2 Pembahasan

Faktor berat badan lahir muncul sebagai variabel dengan pengaruh terbesar dalam menentukan status stunting. Hal ini selaras dengan teori seribu hari pertama kehidupan (1000 HPK), yang menyatakan bahwa masa sejak konsepsi hingga usia dua tahun merupakan periode krusial dalam pertumbuhan anak. Berat badan lahir rendah sering kali menjadi indikator adanya gangguan gizi atau kesehatan selama kehamilan (Likhari & Patil, 2022), dan temuan ini memperkuat hasil penelitian dari Arnita *et al.* (2020) serta Vianney Bitu Aty *et al.* (2021) yang menyatakan bahwa BBLR merupakan prediktor kuat stunting di wilayah NTT. Interaksi antar variabel juga perlu diperhatikan. Misalnya, anak dengan berat badan lahir rendah yang pada usia pengukuran juga memiliki tinggi badan di bawah standar (Z-score TB/U rendah), sangat rentan mengalami stunting. Dalam konteks ini, usia saat pengukuran menjadi penting karena semakin bertambah usia, semakin tampak manifestasi gangguan pertumbuhan. Kombinasi antara faktor bawaan (seperti BB Lahir) dan faktor perkembangan (usia, TB) menjelaskan kompleksitas kondisi stunting.

Meskipun hasil klasifikasi disajikan dengan baik, diskusi tentang implikasi praktis dari temuan ini perlu diperluas. Misalnya, program intervensi dapat difokuskan pada pemantauan berat badan ibu hamil dan edukasi gizi sejak masa kehamilan, serta penanganan dini pada bayi dengan berat lahir rendah. Model ini dapat diimplementasikan oleh puskesmas setempat untuk deteksi awal risiko stunting, sehingga intervensi dapat dilakukan secara lebih tepat sasaran. Penelitian ini juga sejalan dengan temuan Ariyadi *et al.* (2023) di Kabupaten Blitar yang menggunakan *Random Forest* untuk klasifikasi stunting dengan hasil akurasi tinggi (Ramadani Akbar Ariyadi *et al.*, 2023). Hal ini menunjukkan bahwa pendekatan *machine learning*, khususnya *Random Forest*, cukup kuat dalam analisis kesehatan masyarakat berbasis data.

Namun demikian, perlu disadari adanya keterbatasan dalam penelitian ini. Pertama, data yang digunakan berasal dari satu desa saja, sehingga dapat membatasi generalisasi model. Kedua, algoritma *Random Forest* tidak secara eksplisit menjelaskan hubungan kausal, sehingga interpretasi hubungan antar variabel perlu dilakukan dengan hati-hati. Ketiga, tidak semua faktor risiko stunting, seperti kondisi sanitasi, pendidikan ibu, atau pemberian ASI eksklusif, tersedia dalam dataset. Di sisi lain, kelebihan *Random Forest* adalah kemampuannya menangani data yang kompleks dan multivariat serta menghasilkan model prediktif yang stabil. Namun, interpretasi hasil bisa menjadi tantangan, terutama dalam hal *black box model*. Oleh karena itu, kombinasi dengan metode interpretatif seperti SHAP (*SHapley Additive exPlanations*) dapat digunakan di masa depan untuk memperjelas kontribusi masing-masing fitur terhadap prediksi individu.

4. Kesimpulan dan Rekomendasi

Penelitian ini berhasil mengidentifikasi dan mengklasifikasikan faktor risiko utama yang berkontribusi terhadap stunting pada balita di Desa Kesetnana dengan menerapkan algoritma *Random Forest Classifier*. Model yang dikembangkan menunjukkan performa tinggi dengan tingkat *accuracy* sebesar 97%, serta nilai *precision* sebesar 95%, *recall* 98%, dan *F1-score* 96,5%, yang menunjukkan keandalan dalam klasifikasi status gizi balita. Secara spesifik, faktor yang paling berpengaruh adalah berat badan lahir, diikuti oleh usia saat pengukuran dan tinggi badan, serta indikator pertumbuhan lainnya seperti Z-score TB/U, BB/U, dan BB/TB. Temuan ini menegaskan pentingnya perhatian sejak masa kehamilan hingga usia dua tahun pertama anak dalam upaya pencegahan stunting.

Implikasi praktis dari temuan ini sangat relevan bagi tenaga kesehatan dan pembuat kebijakan. Model klasifikasi yang dibangun dapat digunakan untuk mendeteksi balita yang berisiko tinggi

mengalami stunting secara lebih dini, sehingga intervensi gizi dan pemantauan tumbuh kembang dapat dilakukan secara lebih terarah dan efektif. Program intervensi berbasis data seperti ini memungkinkan efisiensi alokasi sumber daya dalam upaya menurunkan prevalensi stunting di daerah dengan risiko tinggi. Untuk penelitian selanjutnya, disarankan dilakukan validasi model menggunakan dataset dari wilayah lain agar hasilnya dapat digeneralisasi secara nasional. Selain itu, perlu dilakukan perbandingan antara algoritma *Random Forest* dan metode *machine learning* lainnya seperti XGBoost, SVM, atau *Neural Network* untuk mengevaluasi pendekatan terbaik. Penelitian lanjutan juga sebaiknya mengintegrasikan variabel tambahan seperti riwayat pemberian ASI, status pendidikan ibu, dan sanitasi lingkungan untuk memperkaya analisis dan meningkatkan akurasi prediksi.

5. Daftar Pustaka

- Ariyadi, M. R. A., Lestanti, S., & Kirom, S. (2023). Klasifikasi Balita Stunting Menggunakan Random Forest Classifier Di Kabupaten Blitar. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(6), 3846-3851.
- Arnita, S., Rahmadhani, D. Y., & Sari, M. T. (2020). Hubungan pengetahuan dan sikap ibu dengan upaya pencegahan stunting pada balita di wilayah kerja Puskesmas Simpang Kawat Kota Jambi. *Jurnal Akademika Baiturrahim Jambi*, 9(1), 7. <https://doi.org/10.36565/jab.v9i1.149>
- Islam, M. M., Shoukot Jahan Kibria, N. M., Kumar, S., Roy, D. C., & Karim, M. R. (2024). Prediction of undernutrition and identification of its influencing predictors among under-five children in Bangladesh using explainable machine learning algorithms. *PLoS ONE*, 19(12), e0315393. <https://doi.org/10.1371/journal.pone.0315393>
- Iswahyudi, S. N. S., & Putra, R. E. (2025). Sistem Deteksi Stunting pada Balita Berbasis Web Menggunakan Metode Random Forest. *Journal of Informatics and Computer Science (JINACS)*, 6(03), 755-764. <https://doi.org/10.26740/jinacs.v6n03.p755-764>.
- Koro, S., Hadju, V., As'ad, S., & Bahar, B. (2018). Determinants of 6-24 Months Child Stunting in South Central Timor District, East Nusa Tenggara Province. *Health Information : Jurnal Penelitian*, 10(1), 1–10. <https://doi.org/10.36990/hijp.v10i1.1>
- Landi, S., Timo, B., & Liufeto, M. (2024). Hubungan Pola Asuh Ibu Dan Riwayat Penyakit Infeksi Dengan Kejadian Stunting Pada Balita di Wilayah Kerja Puskesmas Nulle Kabupaten Timor Tengah Selatan Tahun 2024. *Jurnal Pangan Gizi Dan Kesehatan*, 13(2), 89-105. <https://doi.org/10.51556/ejpazih.v13i2.367>
- Lestari, S. (2024). Prediction of Stunting in Toddlers Using Bagging and Random Forest Algorithms. *Sinkron: jurnal dan penelitian teknik informatika*, 8(2), 947-955. <https://doi.org/10.33395/sinkron.v8i2.13448>
- Likhar, A., & Patil, M. S. (2022). Importance of maternal nutrition in the first 1,000 days of life and its effects on child development: a narrative review. *Cureus*, 14(10), e30083. <https://doi.org/10.7759/cureus.30083>
- Mahesh, B. (2020). Machine learning algorithms: A review. *International Journal of Science and Research (IJSR)*, 9(1), 381–386. <https://doi.org/10.21275/art20203995>

- Putra Tupu Djoru, A., & Yulianto, S. (2025). Pendekatan machine learning untuk deteksi stunting pada balita menggunakan K-Nearest Neighbors (Skripsi, Universitas Kristen Satya Wacana). Perpustakaan Universitas Kristen Satya Wacana. <https://repository.uksw.edu/handle/123456789/36443>
- Sahamony, N. F., Terttiaavini, T., & Rianto, H. (2024). Analisis perbandingan kinerja model machine learning untuk memprediksi risiko stunting pada pertumbuhan anak. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(2), 413–422. <https://doi.org/10.57152/malcom.v4i2.1210>
- Sambriong, M., Herwanti, E., & Aty, Y. M. V. B. (2022). Edukasi gizi cegah stunting bagi orang tua di Desa Kesetnana, Kabupaten Timor Tengah Selatan. *Poltekita: Jurnal Pengabdian Masyarakat*, 3(4), 898–906. <https://doi.org/10.33860/pjpm.v3i4.1284>
- Sevilla, J., Nugroho, A., & Turymshayeva, A. (2024). The effectiveness of accelerating stunting reduction policy. *Journal of Sustainable Development and Regulatory Issues (JSDERI)*, 2(2), 132–147. <https://doi.org/10.53955/jsderi.v2i2.31>
- SSGI. (2021). Survei Status Gizi Indonesia 2021. [Dataset].
- Vianney Bitu Aty, Y. M., Herwanti, E., & Mochsen, R. (2021). Simultaneous factors affecting toddler nutritional status. *Jurnal Ilmu Kesehatan*, 19(1), 64–72. <https://doi.org/10.31965/infokes.Vol19i1.64>
- Wardani, L. K., Aulia, V., Hadhikul, M., & Kardila, M. (2023). Risks of stunting and interventions to prevent stunting. *Journal of Community Engagement in Health*, 6(2), 79–83. <https://doi.org/10.30994/jceh.v6i2.528>