



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 2 (2026) pp: 3592-3599

P-ISSN: 2963-9298, e-ISSN: 2963-914X

LetsGrow Health: Prediksi Risiko Stunting pada Anak Menggunakan Algoritma Random Forest Berbasis Data WHO

Riska Aini Putri, Muhammad Abdul Hadi, Fuad Maulana, Dzaky Akram, Nathasa Septianingrum, Gunawan

^{1,3,4,5,6}Politeknik Negeri Medan

²Binus University

¹riskaainiputri2206@gmail.com, ²muhammad.hadi006@binus.ac.id, ³fuadmau12@gmail.com, ⁴dzakyakram58@gmail.com,
⁵natashaseptia66@gmail.com, ⁶gunawan@polmed.ac.id *

Abstrak

Stunting merupakan salah satu permasalahan gizi kronis yang masih menjadi tantangan serius di berbagai negara berkembang, termasuk Indonesia, karena berdampak pada pertumbuhan fisik, perkembangan kognitif, produktivitas, serta kualitas sumber daya manusia di masa depan. Kondisi ini terjadi akibat kekurangan gizi dalam jangka panjang yang dipengaruhi oleh berbagai faktor, seperti asupan nutrisi yang tidak memadai, pola asuh, sanitasi, serta akses layanan kesehatan. Oleh karena itu, diperlukan metode deteksi dini yang akurat, cepat, dan efisien untuk membantu mengidentifikasi risiko stunting sejak awal sehingga penanganan dapat dilakukan secara lebih optimal. Penelitian ini bertujuan untuk mengembangkan model prediksi risiko stunting berbasis machine learning menggunakan algoritma Random Forest berdasarkan data standar World Health Organization (WHO), serta merancang integrasinya ke dalam aplikasi mobile LetsGrow Health sebagai sarana edukasi dan deteksi dini bagi masyarakat. Dataset penelitian mencakup variabel usia, jenis kelamin, tinggi badan, dan berat badan anak. Data diproses melalui tahap pra-pemrosesan, meliputi perhitungan Z-score menggunakan metode LMS, pengkodean data, serta pelabelan otomatis sesuai klasifikasi WHO. Model kemudian dilatih dan dievaluasi menggunakan confusion matrix dan classification report untuk mengukur performa klasifikasi. Hasil penelitian menunjukkan bahwa algoritma Random Forest memiliki performa yang sangat baik dengan tingkat akurasi sebesar 98%, presisi 90%, recall 98%, dan F1-score 94%. Temuan ini menunjukkan bahwa model mampu mendeteksi risiko stunting secara efektif dan berpotensi diterapkan pada aplikasi mobile guna mendukung upaya pencegahan stunting melalui deteksi dini dan peningkatan kesadaran masyarakat terhadap pentingnya pemenuhan gizi anak.

Kata kunci: Stunting, Random Forest, Machine Learning, Klasifikasi, Aplikasi Mobile

1. Latar Belakang

Stunting merupakan kondisi gagal tumbuh pada anak yang disebabkan oleh kekurangan gizi kronis dalam jangka waktu yang panjang, terutama pada periode 1000 hari pertama kehidupan. Kondisi ini ditandai dengan tinggi badan anak yang berada di bawah standar usianya berdasarkan indikator tinggi badan menurut umur. Stunting tidak hanya berdampak pada pertumbuhan fisik, tetapi juga berpengaruh terhadap perkembangan kognitif, kemampuan belajar, serta produktivitas di masa yang akan datang (WHO, 2014).

Di Indonesia stunting menjadi salah satu prioritas nasional karena berdampak langsung terhadap kualitas sumber daya manusia. Berdasarkan data Kementerian Kesehatan RI (2024) prevalensi stunting masih menunjukkan angka yang harus mendapatkan perhatian khusus. Kondisi ini dipengaruhi oleh berbagai faktor, antara lain kurangnya asupan gizi yang memadai, infeksi berulang, pola asuh yang kurang tepat, serta keterbatasan akses terhadap layanan kesehatan (Passarelli et al., 2020)

Seiring dengan perkembangan teknologi informasi, pemanfaatan teknologi digital dalam bidang kesehatan mengalami peningkatan yang signifikan. Salah satu bentuk penerapan teknologi tersebut adalah mobile health (m-Health), yaitu penggunaan perangkat mobile untuk mendukung layanan kesehatan. Teknologi ini memungkinkan masyarakat untuk memperoleh informasi serta melakukan pemantauan kondisi kesehatan secara mandiri, cepat, dan efisien (Leo et al., 2022). Namun demikian, sebagian besar aplikasi kesehatan yang tersedia saat ini masih bersifat informatif dan belum dilengkapi dengan kemampuan analisis prediktif berbasis data.

Di sisi lain, perkembangan machine learning dalam bidang kesehatan menunjukkan potensi yang besar dalam mendukung proses pengambilan keputusan. Algoritma Random Forest merupakan salah satu metode klasifikasi yang memiliki tingkat akurasi tinggi serta mampu menangani data dengan kompleksitas yang beragam (Akbar et al., 2025). Pemanfaatan algoritma ini dalam prediksi risiko stunting diharapkan dapat menghasilkan analisis yang lebih akurat dan objektif.

Namun, penelitian sebelumnya memiliki keterbatasan, yaitu belum adanya integrasi antara sistem prediksi berbasis machine learning, rekomendasi makanan, dan fitur edukasi dalam satu platform yang dapat langsung digunakan oleh masyarakat. Sebagian besar penelitian hanya berfokus pada salah satu aspek tersebut secara terpisah.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan model prediksi risiko stunting menggunakan algoritma Random Forest yang selanjutnya dirancang untuk dapat diintegrasikan ke dalam aplikasi berbasis mobile, yaitu LetsGrow Health. Aplikasi ini menyediakan fitur prediksi risiko stunting, rekomendasi makanan dan fitur edukasi terintegrasi dalam bentuk artikel kesehatan dan menu makanan sehat.

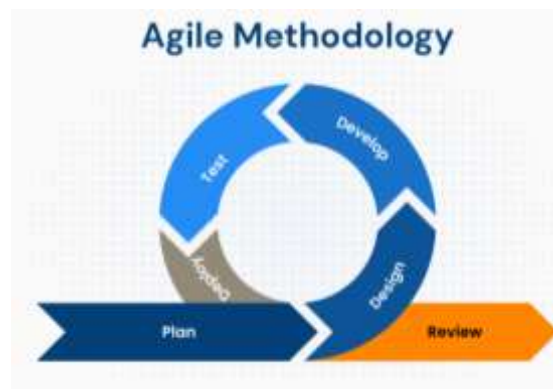
Namun, implementasi aplikasi dalam penelitian ini masih berada pada tahap pengembangan, sehingga fokus utama penelitian ini adalah pada pengembangan dan evaluasi model prediktif. Oleh karena itu, diperlukan suatu sistem yang tidak hanya mampu melakukan prediksi risiko stunting secara akurat, tetapi juga terintegrasi dengan fitur edukasi dan rekomendasi yang dapat langsung dimanfaatkan oleh pengguna.

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan menerapkan metode pengembangan sistem berbasis Agile untuk membangun aplikasi prediksi risiko stunting. Pendekatan Agile dipilih karena bersifat iteratif dan adaptif, sehingga memungkinkan pengembangan sistem secara bertahap dan dapat disesuaikan dengan kebutuhan pengguna.

a. Metode Pengembangan Sistem

Metode Agile merupakan pendekatan pengembangan perangkat lunak yang menekankan fleksibilitas dan adaptif terhadap perubahan kebutuhan selama proses pengembangan. Pendekatan ini menggunakan siklus iteratif, di mana sistem dikembangkan secara bertahap melalui serangkaian proses yang berulang dan saling terintegrasi. Alur penerapan metode Agile dalam penelitian ini disajikan pada Gambar 1.



Gambar 1. Diagram Alur Metode Agile

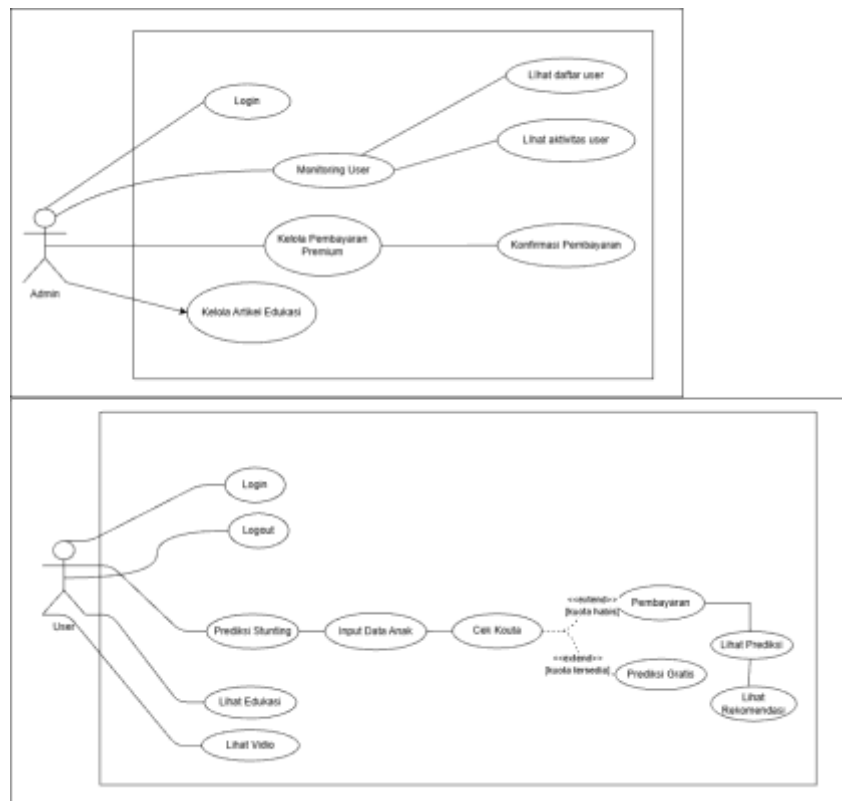
Berdasarkan Gambar 1, proses pengembangan dilakukan melalui beberapa tahapan yang saling berkesinambungan. Setiap tahapan dilakukan secara berulang sesuai kebutuhan hingga sistem yang dikembangkan mencapai hasil yang diharapkan dan sesuai dengan kebutuhan pengguna.

b. Use Case Diagram

Pada tahap perancangan sistem, use case diagram digunakan untuk menggambarkan fungsionalitas aplikasi serta alur interaksi antara pengguna dan sistem. Diagram ini disusun berdasarkan hasil analisis kebutuhan untuk

memastikan setiap fitur utama terdefinisi secara sistematis dan terstruktur. Selain itu, use case diagram juga bertujuan untuk memberikan gambaran yang jelas mengenai batasan sistem, peran aktor yang terlibat, serta hubungan antara para aktor dan fitur yang tersedia dalam aplikasi. Dengan demikian, proses pengembangan sistem dapat berjalan dengan lebih terstruktur dan sesuai dengan kebutuhan pengguna.

Berdasarkan analisis kebutuhan, aplikasi LetsGrow Health memiliki beberapa fitur utama, yaitu pencatatan data anak, prediksi risiko stunting, rekomendasi makanan, serta akses ke edukasi kesehatan dalam bentuk artikel dan rencana menu sehat. Berikut ini adalah use case diagram yang dibuat pada Gambar 2.



Gambar 2. Use Case Diagram Aplikasi LetsGrow Health

Use case diagram pada Gambar 2 menunjukkan bahwa sistem ini melibatkan satu aktor utama, yaitu pengguna (orang tua dan generasi muda). Pengguna memiliki beberapa hak akses, termasuk input data anak, melihat hasil prediksi risiko stunting, mendapatkan rekomendasi makanan, dan mengakses informasi edukasi kesehatan.

Setiap fitur yang tersedia dalam sistem direpresentasikan sebagai use case yang menggambarkan interaksi antara pengguna dan sistem. Dengan desain ini, diharapkan sistem yang dikembangkan dapat secara optimal memenuhi kebutuhan pengguna dan mendukung proses deteksi dini serta pencegahan stunting.

c. Activity Diagram

Activity Diagram digunakan untuk menggambarkan alur proses dalam suatu sistem, mulai dari masukan data hingga memberikan prediksi risiko stunting dan rekomendasi makanan. Diagram ini memberikan gambaran yang lebih rinci mengenai proses operasional sistem dibandingkan dengan use case diagram.

Activity diagram dalam penelitian ini berfokus pada proses prediksi stunting, termasuk mekanisme pembatasan akses bebas dan integrasi fitur rekomendasi. Activity diagram tersebut ditampilkan pada Gambar 3.



Gambar 3. Activity Diagram Aplikasi LetsGrow Health

Seperti yang ditunjukkan pada Gambar 3, proses ini dimulai dengan pengguna yang masuk ke sistem, kemudian memasukkan data anak yang akan digunakan dalam untuk proses prediksi. Selanjutnya, sistem memeriksa status pengguna terkait fitur prediksi tersebut.

Jika pengguna belum pernah melakukan prediksi sebelumnya, sistem memberikan akses gratis untuk melakukan prediksi stunting. Sebaliknya, jika pengguna telah menggunakan akses gratis tersebut, sistem akan mengarahkan pengguna untuk menyelesaikan proses pembayaran sebelum melanjutkan ke tahap prediksi.

Setelah proses prediksi selesai, sistem menampilkan hasil prediksi kepada pengguna. Selanjutnya, sistem secara otomatis memberikan rekomendasi makanan yang dapat diakses tanpa biaya tambahan. Proses berakhir setelah pengguna menerima hasil prediksi dan rekomendasi yang disediakan oleh sistem.

d. Data Set Penelitian

Kumpulan data yang digunakan dalam penelitian ini merupakan data kesehatan anak yang mengacu pada standar pertumbuhan yang ditetapkan oleh World Health Organization (WHO). Variabel yang digunakan meliputi usia, jenis kelamin, berat badan, dan tinggi badan sebagai indikator utama dalam penilaian status pertumbuhan anak.

Pengukuran status stunting dalam penelitian ini didasarkan pada indikator Height-for-Age Z-score (HAZ), yang merupakan standar WHO dalam mengevaluasi pertumbuhan linier anak. Seorang anak dikategorikan mengalami

stunting jika memiliki nilai Z-score kurang dari -2 standar deviasi (< -2 SD), sedangkan anak dengan nilai Z-score lebih dari atau sama dengan -2 standar deviasi (≥ -2 SD) dikategorikan sebagai tidak stunting (World Health Organization, 2020).

Selanjutnya, data diklasifikasikan ke dalam dua kategori utama, yaitu stunting dan tidak stunting. Klasifikasi ini digunakan sebagai label dalam proses pelatihan model machine learning untuk membangun sistem prediksi risiko stunting.

e. Pra-Pemrosesan Data

Pra-pemrosesan data dilakukan untuk meningkatkan kualitas data sebelum digunakan dalam proses pelatihan model *machine learning*. Proses ini bertujuan untuk memastikan bahwa data yang digunakan bersih, terstruktur, dan siap untuk diproses.

Dalam penelitian ini kumpulan data yang diperoleh dari WHO kemudian diolah melalui proses penggabungan data berdasarkan jenis kelamin dan rentang usia. Selain itu, dilakukan simulasi data tinggi dan berat badan anak-anak untuk melengkapi data yang digunakan dalam penelitian ini. Perhitungan Z-score dilakukan menggunakan metode LMS (Lambda, Median, Sigma) sesuai dengan standar WHO. Selanjutnya, dilakukan proses pelabelan otomatis untuk mengklasifikasikan status stunting berdasarkan Z-score yang dihasilkan.

Data yang digunakan terdiri dari empat kategori utama, yang kemudian digabungkan menjadi dataset yang terintegrasi. Adapun langkah-langkah yang dilakukan adalah sebagai berikut:

1. Variabel jenis kelamin ditambahkan sebagai salah satu fitur dalam model. Data kemudian diubah menjadi format yang sesuai untuk pemrosesan komputasi.
2. Perhitungan Z-score dilakukan berdasarkan standar WHO untuk menentukan status pertumbuhan anak-anak. Z-score dihitung dengan membandingkan data tinggi badan anak terhadap rata-rata standar populasi acuan untuk usia dan jenis kelamin masing-masing.
3. Mengkonversi data kategorikal menjadi numerik, di mana laki-laki direpresentasikan dengan nilai 0 dan perempuan dengan nilai 1.
4. Proses pelabelan otomatis berdasarkan nilai Z-score yang diperoleh. Anak-anak dengan Z-score < -2 dikategorikan sebagai anak yang mengalami stunting dengan label 1, sedangkan anak dengan Z-score ≥ -2 dikategorikan sebagai normal dengan label 0.

f. Random Forest

Metode yang digunakan dalam penelitian ini adalah algoritma Random Forest, sebuah metode machine learning berbasis ensemble yang digunakan untuk klasifikasi data. Algoritma ini bekerja dengan membangun sejumlah *decision tree* dan menggabungkan hasil prediksi dari setiap pohon untuk menghasilkan keputusan yang lebih akurat dan stabil.

Random Forest bekerja menggunakan teknik bootstrap sampling, yang melibatkan pengambilan sampel data secara acak dengan pengembalian (*with replacement*) untuk membangun setiap *decision tree*. Selain itu, pada setiap node, fitur dipilih secara acak untuk menentukan pembagian data yang optimal. Hal ini bertujuan untuk mengurangi korelasi antar pohon dan meningkatkan kemampuan generalisasi model.

Secara matematis, prediksi dalam Random Forest dapat dirumuskan sebagai berikut:

$$H(x) = \text{mode} \{h_1(x), h_2(x), h_3(x), \dots, h_n(x)\}$$

di mana $H(x)$ adalah hasil prediksi akhir, $h_i(x)$ adalah hasil prediksi dari pohon ke- i , dan n adalah jumlah pohon dalam model. Pada penelitian ini, setiap pohon Keputusan melakukan klasifikasi terhadap data anak berdasarkan variabel usia, jenis kelamin, tinggi badan, dan berat badan yang telah diproses sebelumnya.

Hasil akhir prediksi ditentukan berdasarkan mayoritas suara (*majority voting*) dari seluruh *decision tree*, yang kemudian digunakan untuk mengklasifikasikan status anak ke dalam kategori stunting atau tidak stunting.

Dengan pendekatan ini, model mampu mengakomodasi variasi data pertumbuhan anak berdasarkan standar WHO serta meningkatkan akurasi prediksi.

Penggunaan algoritma Random Forest pada penelitian ini diharapkan dapat memberikan hasil klasifikasi yang lebih stabil dan akurat, serta mampu mengurangi risiko overfitting dibandingkan dengan penggunaan satu *decision tree* tunggal.

g. Evaluasi Model

Evaluasi model dilakukan untuk mengukur kinerja algoritma Random Forest dalam mengklasifikasikan status stunting berdasarkan data yang telah diolah. Metode evaluasi yang digunakan dalam penelitian ini adalah *confusion matrix*, yang berfungsi untuk membandingkan hasil prediksi model dengan data aktual.

Confusion matrix terdiri dari empat komponen utama, yaitu *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). *True Positive* menunjukkan jumlah data stunting yang berhasil diprediksi dengan benar, sedangkan *True Negative* menunjukkan jumlah data tidak stunting yang berhasil diprediksi dengan benar. *False Positive* merupakan data tidak stunting yang diprediksi sebagai stunting dan *False Negative* merupakan data stunting yang diprediksi sebagai tidak stunting.

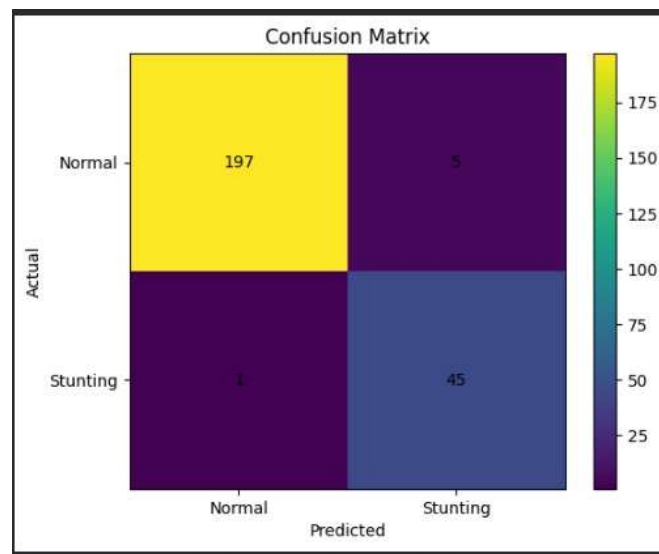
Berdasarkan nilai evaluasi tersebut, kinerja model selanjutnya diukur menggunakan beberapa metrik evaluasi, seperti akurasi, presisi, recall, dan F1-score, untuk memperoleh gambaran yang lebih komprehensif terhadap performa model.

3. Hasil dan Diskusi

a. Hasil

Bagian ini menyajikan hasil pengujian model Random Forest dalam mengklasifikasikan status stunting berdasarkan data yang telah di proses melalui tahap pelatihan dan pengujian. Hasil yang ditampilkan merupakan keluaran model setelah melalui tahap pelatihan dan pengujian sesuai dengan metode yang telah dijelaskan pada bagian sebelumnya.

Hasil evaluasi model ditampilkan dalam bentuk *confusion matrix* yang menunjukkan perbandingan antara data aktual dan hasil prediksi model, sebagaimana ditunjukkan pada Gambar 4.



Gambar 4. *Confusion Matrix* Model Random Forest

Berdasarkan Gambar 4, diperoleh nilai True Negative sebesar 197, yang menunjukkan bahwa data anak dengan kondisi normal telah diklasifikasikan dengan benar oleh model. Selain itu, nilai True Positive sebesar 45 menunjukkan bahwa model mampu mengidentifikasi anak-anak yang mengalami stunting secara tepat.

Adapun kesalahan klasifikasi yang terjadi relatif kecil, yaitu *False Positive* sebanyak 5 data, dan *False Negative* sebanyak 1 data. Hal ini menunjukkan bahwa model memiliki tingkat kesalahan yang rendah dalam membedakan antara kondisi stunting dan tidak stunting.

Selain *confusion matrix*, evaluasi model juga dilakukan dengan melihat *classification report* yang mencakup nilai precision, recall, dan F1-score untuk masing-masing kelas. Sebagaimana ditunjukkan pada Tabel 1.

Tabel 1. Classification Report Model Random Forest

	precision	recall	F1-score	support
0	0.99	0.98	0.98	202
1	0.90	0.98	0.94	46
accuracy			0.98	248
macro avg	0.95	0.98	0.96	248
weighted avg	0.98	0.98	0.98	248

Berdasarkan Tabel 1, model Random Forest menunjukkan performa yang sangat baik untuk kedua kelas. Untuk kelas tidak stunting (0), nilai precision sebesar 0,99, recall sebesar 0,98, dan F1-score sebesar 0,98. Sementara itu, untuk kelas stunting (1), nilai precision sebesar 0,90, recall sebesar 0,98, dan F1-score sebesar 0,94.

Nilai recall yang tinggi pada kelas stunting menunjukkan bahwa model ini memiliki kemampuan yang sangat baik dalam mendeteksi kasus stunting. Meskipun nilai precision pada kelas stunting sedikit lebih rendah, hal ini masih dapat diterima dalam konteks deteksi dini, karena yang lebih penting adalah meminimalkan kasus stunting yang tidak terdeteksi.

Secara keseluruhan, akurasi sebesar 98% menunjukkan bahwa model ini bekerja dengan sangat baik dalam mengklasifikasikan data. Hasil ini menunjukkan bahwa model mampu mengenali pola data dengan baik berdasarkan variabel yang digunakan.

b. Pembahasan

Berdasarkan hasil pengujian, algoritma Random Forest menunjukkan kinerja yang sangat baik dalam mengklasifikasikan status stunting pada anak. Hal ini dibuktikan dengan tingkat akurasi yang tinggi, yaitu sebesar 98%, yang menunjukkan bahwa sebagian besar data telah diklasifikasikan dengan benar.

Nilai recall yang tinggi untuk kelas stunting, yaitu 98%, menunjukkan bahwa model ini memiliki kemampuan yang sangat baik dalam mendeteksi kasus stunting. Hal ini sangat penting dalam konteks kesehatan, karena kesalahan dalam mendeteksi anak yang mengalami stunting (*false negatives*) dapat menyebabkan keterlambatan intervensi. Dalam penelitian ini, jumlah *false negative* yang sangat rendah menunjukkan bahwa model ini cukup andal dalam mendeteksi stunting secara akurat.

Di sisi lain, nilai presisi untuk kelas stunting sebesar 90% menunjukkan bahwa masih ada sejumlah kecil titik data yang diprediksi sebagai stunting padahal sebenarnya tidak (*false positives*). Namun, dalam konteks deteksi dini, hal ini masih dapat diterima karena lebih baik melakukan pemeriksaan lebih lanjut daripada melewatkan kasus stunting yang sebenarnya.

Hasil ini juga menunjukkan bahwa penggunaan algoritma Random Forest mengatasi kelemahan metode *decision tree* tunggal, terutama dalam mengurangi risiko *overfitting* dan meningkatkan stabilitas model. Selain itu,

penggunaan dataset berbasis standar WHO dan penerapan metode LMS dalam perhitungan Z-score memainkan peran penting dalam meningkatkan kualitas data dan performa model.

Secara praktis, hasil penelitian ini memiliki implikasi bagi pengembangan aplikasi digital yang diintegrasikan ke dalam aplikasi mobile untuk membantu pengguna mendeteksi risiko stunting secara mandiri pada tahap awal. Namun, implementasi aplikasi dalam penelitian ini masih berada pada tahap pengembangan, sehingga diperlukan pengujian lebih lanjut untuk memastikan aplikasi tersebut dapat digunakan secara optimal dalam kondisi dunia nyata.

4. Kesimpulan

Berdasarkan hasil penelitian, dapat disimpulkan bahwa algoritma Random Forest mampu menunjukkan kinerja yang sangat baik dalam mengklasifikasikan status stunting pada anak-anak. Model ini mencapai tingkat akurasi sebesar 98%, dengan presisi 90%, recall 98%, dan F1-score sebesar 94%. Nilai evaluasi tersebut diperoleh berdasarkan perhitungan dari confusion matrix yang membandingkan hasil prediksi model dengan data aktual. Nilai recall yang tinggi menunjukkan bahwa model ini memiliki kemampuan yang sangat baik dalam mendeteksi kasus stunting, sehingga cocok digunakan sebagai alat untuk deteksi dini. Selain itu, tingkat kesalahan klasifikasi yang rendah menunjukkan bahwa model ini cukup andal dalam membedakan antara kondisi stunting dan non-stunting. Penggunaan dataset standar WHO dan penerapan metode LMS dalam perhitungan Z-score telah terbukti meningkatkan kualitas data dan kinerja model. Dengan demikian, pendekatan berbasis pembelajaran mesin dalam studi ini dapat berfungsi sebagai solusi efektif untuk membantu mengidentifikasi risiko stunting dengan lebih cepat dan akurat. Penelitian ini masih memiliki keterbatasan, yaitu penggunaan data yang sebagian diperoleh dari pemrosesan dan simulasi, serta fakta bahwa aplikasi tersebut masih dalam tahap pengembangan. Untuk penelitian selanjutnya, disarankan untuk mengembangkan sistem hingga tahap implementasi aplikasi penuh serta menambahkan fitur untuk edukasi gizi dan rekomendasi makanan sehat. Selain itu, penggunaan dataset yang lebih besar dan beragam juga dapat dieksplorasi untuk meningkatkan akurasi dan generalisasi model.

Referensi

1. Akbar, I., Supriadi, F., & Junaedi, D. I. (2025). PEMANFAATAN MACHINE LEARNING DI BIDANG KESEHATAN. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 9, Number 1).
2. Alwi Prayoga, A., Hasanuddin, M., Khodijah, S., & Atika Rizki, C. (2025). Analisis Penerapan Machine Learning dalam Sistem Prediksi dan Pengambilan Keputusan. *Journal of Electrical Engineering Research*, 1(3). <https://doi.org/10.64803/joeer.v1i3.19>
3. Atmaka Dominikus Raditya, S. Gz., M. PH. (2024). *Pengaruh Pengetahuan Gizi Orang Tua Terhadap Gizi Anak*. Universitas Airlangga.
4. Budi Setyawan, A., Herlina, N., Ekowati, E., Nawangsari, S., & Nugroho, W. (2024). *PENCEGAHAN STUNTING DENGAN MENGGUNAKAN APLIKASI MOBILE EDBUSUI PADA IBU DAN ANAK DI DESA PASEH KALER*. 3(2), 2829–0496. <https://doi.org/10.56127/ja>
5. Fachrudin Ali. (2025). *POTRET STUNTING DI INDONESIA*. Kemenkes BKPK.
6. Herlina Puji Angesti, Dini Ria Oktavia, & Dian Asih Ning Utami. (2025). *Systematic Review: Efektivitas Aplikasi Mobile dalam Edukasi Kesehatan Reproduksi Remaja*.
7. Janssen, S. M., Bouzembrak, Y., & Tekinerdogan, B. (2024). Artificial Intelligence in Malnutrition: A Systematic Literature Review. In *Advances in Nutrition* (Vol. 15, Number 9). Elsevier B.V. <https://doi.org/10.1016/j.advnut.2024.100264>
8. Kementerian Kesehatan RI. (2024). *MEMBENTENGI ANAK DARI STUNTING*. <https://link.kemkes.go.id/mediakom>
9. Knop, M. R., Nagashima-Hayashi, M., Lin, R., Saing, C. H., Ung, M., Oy, S., Yam, E. L. Y., Zahari, M., & Yi, S. (2024). Impact of mHealth interventions on maternal, newborn, and child health from conception to 24 months postpartum in low- and middle-income countries: a systematic review. In *BMC Medicine* (Vol. 22, Number 1). BioMed Central Ltd. <https://doi.org/10.1186/s12916-024-03417-9>
10. Leo, D. G., Buckley, B. J. R., Chowdhury, M., Harrison, S. L., Isanejad, M., Lip, G. Y. H., Wright, D. J., & Lane, D. A. (2022). Interactive Remote Patient Monitoring Devices for Managing Chronic Health Conditions: Systematic Review and Meta-analysis. In *Journal of Medical Internet Research* (Vol. 24, Number 11). JMIR Publications Inc. <https://doi.org/10.2196/35508>
11. Malini, R. S., & Adinandra, S. (2025). LITERATURE REVIEW: PERAN SISTEM SMART HEALTH SEBAGAI INOVASI DIGITAL DALAM UPAYA PENCEGAHAN STUNTING. *Jurnal ELKON*, 5(2), 2809–140.
12. Martony, O. (2023). Stunting di Indonesia: Tantangan dan Solusi di Era Modern. *Journal of Telenursing (JOTING)*, 5(2), 1734–1745. <https://doi.org/10.31539/joting.v5i2.6930>
13. Nugroho, M. W. (2025). *Analisis Performa Algoritma Random Forest dalam Mengatasi Overfitting pada Model Prediksi*.
14. Passarelli, S., Bromage, S., Darling, A. M., Wang, J. S., Aboud, S., Mugusi, F., Griffiths, J. K., & Fawzi, W. (2020). Aflatoxin exposure in utero and birth and growth outcomes in Tanzania. *Maternal and Child Nutrition*, 16(2). <https://doi.org/10.1111/mcn.12917>
15. WHO. (2014). *Global Nutrition Targets 2025 Stunting Policy Brief*.
16. Wijaya, A. P., Penulis, *, & Diajukan, K. (2025). Perbandingan Algoritma Klasifikasi Random Forest dengan Naïve Bayes Classifier pada Studi Penyakit Berdasarkan Pola Nutrisi. *Remik: Riset Dan E-Jurnal Manajemen Informatika Komputer*, 9(1). <https://doi.org/10.33395/remik.v9i1.14652>
17. World Health Organization. (2020). *Length/height-for-age*. WHO.
18. Yuliana. (2023). *POTENSI KECERDASAN BUATAN UNTUK MENGGANTIKAN PERAN TENAGA KESEHATAN*.

DOI: <https://doi.org/10.31004/riggs.v5i2.8721>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)
