

Perbandingan Efektivitas Random Forest, XGBoost, SVM, dan ANN dalam Mengidentifikasi Stunting pada Anak Balita

Rando^{✉1}, Darmawan², La Ode Reza Apriliyanto³, Alkanza Patih R⁴
Universitas Muhammadiyah Buton^{1,2,3,4} (Rekayasa Sistem Komputer, Universitas Muhammadiyah Buton, Indonesia)
email: rando@umbuton.ac.id¹

Received 16 Februari 2025

Accepted 28 September 2025

Published 30 September 2025

Abstrak

Stunting merupakan salah satu masalah gizi kronis yang masih menjadi tantangan kesehatan masyarakat di Indonesia, khususnya pada balita, karena berdampak terhadap tumbuh kembang anak dalam jangka panjang. Penelitian ini bertujuan untuk mengevaluasi performa metode machine learning dan deep learning dalam mengklasifikasikan stunting anak dengan menggunakan data UPTD Puskesmas Lakologuo yang dikombinasikan dengan dataset eksternal dari Kaggle. Model yang diuji meliputi Random Forest, XGBoost, SVM, LSTM, dan ANN. Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score untuk membandingkan efektivitas tiap model. Hasil penelitian menunjukkan bahwa metode ensemble, khususnya Random Forest dan XGBoost, memberikan kinerja terbaik dengan akurasi hingga 99%, sedangkan SVM mencapai akurasi 90% dan F1-score 87%. Sebaliknya, model deep learning seperti LSTM dan terutama ANN masih menghadapi keterbatasan, dengan akurasi ANN hanya sebesar 37% pada skenario multiclass. Temuan ini menegaskan bahwa metode ensemble lebih direkomendasikan untuk klasifikasi stunting, sementara pendekatan deep learning memerlukan variasi data yang lebih besar serta teknik pelatihan lanjutan agar dapat meningkatkan akurasi prediksi.

Kata Kunci: *Stunting; Machine Learning; Deep Learning; Random Forest; XGBoost,*

Abstract

Stunting is one of the most prevalent chronic nutritional problems in Indonesia, particularly among toddlers, as it has long-term impacts on children's growth and development. This study aims to evaluate the performance of machine learning and deep learning methods in classifying childhood stunting using data from UPTD Puskesmas Lakologuo combined with an external dataset from Kaggle. The models tested include Random Forest, XGBoost, SVM, LSTM, and ANN. The evaluation was carried out using accuracy, precision, recall, and F1-score metrics to compare the effectiveness of each model. The results show that ensemble methods, particularly Random Forest and XGBoost, achieved the best performance with accuracy up to 99%, while SVM reached 90% accuracy and an F1-score of 87%. In contrast, deep learning models such as LSTM and especially ANN still faced limitations, with ANN achieving only 37% accuracy in multiclass scenarios. These findings highlight that ensemble methods are more recommended

for stunting classification, while deep learning approaches require larger data variations and advanced training techniques to improve predictive performance.

Keywords: *Stunting; Machine Learning; Deep Learning; Random Forest; XGBoost,*

✉ Corresponding author

PENDAHULUAN

Malnutrisi adalah kondisi yang terjadi ketika tubuh tidak mendapatkan jumlah gizi yang cukup atau seimbang, yang dapat memengaruhi kesehatan secara keseluruhan [1]. Malnutrisi mencakup berbagai kondisi, seperti kekurangan gizi (*under-nutrition*) yang mengarah pada masalah seperti *stunting*, *wasting*, dan berat badan rendah, serta kelebihan gizi (*over-nutrition*) yang dapat menyebabkan obesitas dan penyakit terkait. Salah satu bentuk malnutrisi yang paling umum dan memprihatinkan di Indonesia adalah *stunting*, yaitu kondisi gagal tumbuh pada anak yang disebabkan oleh kekurangan gizi kronis dalam waktu lama. *Stunting* dapat terjadi mulai janin masih dalam kandungan dan baru nampak saat anak berusia dua tahun [2]. Berdasarkan data dari [3] bahwa angka malnutrisi di Indonesia salah satu tertinggi di dunia yaitu 1 dari 10 balita mengalami *wasting* (kurus) dan 3 dari 10 anak mengalami *stunting*.

Dalam upaya menurunkan jumlah *stunting*, deteksi dini *stunting* menjadi langkah yang sangat penting. Deteksi dini memungkinkan identifikasi risiko *stunting* sejak tahap awal kehidupan anak, sehingga intervensi gizi dan layanan kesehatan yang diperlukan dapat diberikan pada waktu yang tepat, khususnya dalam 1.000 hari pertama kehidupan. *Stunting*, yang diukur melalui parameter antropometri seperti berat badan, tinggi badan, dan umur, dapat diidentifikasi lebih efektif dengan menggunakan algoritma machine learning (ML). Penelitian terbaru menunjukkan bahwa berbagai algoritma ML, seperti Random Forest dan XGBoost, dapat digunakan untuk memprediksi status *stunting* berdasarkan data antropometri dan faktor-faktor demografis lainnya [4], [5].

Penelitian oleh Ndagijimana [5]. menunjukkan bahwa model ML yang dilatih dengan menggunakan data antropometri dapat memberikan prediksi yang akurat mengenai status *stunting* pada anak di Rwanda. Mereka menggunakan metode validasi silang 10-lipat dan enam teknik ML yang berbeda, termasuk regresi logistik dan Random Forest, untuk mengevaluasi kinerja model. Hasilnya menunjukkan bahwa algoritma XGBoost memiliki performa terbaik dalam klasifikasi *stunting*, yang juga didukung oleh penelitian lain yang menunjukkan efektivitasnya dalam prediksi malnutrisi [5], [6].

Di Indonesia, penelitian oleh Haris menyoroti prevalensi *stunting* yang tinggi di provinsi Jawa Timur, dengan penggunaan algoritma Random Forest untuk

memprediksi status gizi anak. Data yang diperoleh dari Kementerian Kesehatan menunjukkan bahwa prevalensi stunting mencapai 26,8%, yang menunjukkan perlunya intervensi yang lebih efektif [7]. Selain itu, penelitian oleh Purwati menunjukkan bahwa metode KNN (K-Nearest Neighbors) juga dapat digunakan untuk mendeteksi stunting dengan akurasi yang cukup tinggi, mencapai 85,1% [8].

Selain itu, penelitian lain menunjukkan bahwa pendekatan deep learning dapat digunakan untuk mendeteksi malnutrisi, termasuk stunting, dengan memanfaatkan gambar anak-anak. Dalam penelitian yang dilakukan oleh Ankalaki, model deep learning yang dikembangkan menunjukkan kemampuan yang baik dalam mengklasifikasikan gambar anak-anak untuk mendeteksi malnutrisi [9]. Ini menunjukkan bahwa deep learning tidak hanya terbatas pada analisis data numerik, tetapi juga dapat diterapkan pada data gambar untuk mendukung deteksi dini stunting.

Model *machine learning* dapat menganalisis data rekam kesehatan anak untuk mengidentifikasi pola yang berhubungan dengan risiko stunting. Dengan teknik *supervised learning*, sistem dapat mempelajari hubungan antara faktor-faktor seperti gizi, pola pertumbuhan, dan lingkungan terhadap kemungkinan stunting. Sementara itu, algoritma *deep learning* mampu mengenali pola kompleks dalam data citra medis, seperti struktur tulang dan pertumbuhan tubuh, untuk mendeteksi tanda-tanda awal stunting. Dengan arsitektur jaringan saraf dalam (*deep neural networks*), model dapat meningkatkan akurasi prediksi dengan memahami keterkaitan non-linear antar berbagai faktor risiko.

Penelitian ini bertujuan untuk membandingkan performa *machine learning* dan *deep learning* dalam deteksi dini stunting. Kedua pendekatan ini memiliki kelebihan yang berbeda: *machine learning* unggul dalam interpretabilitas dan efisiensi pada dataset berukuran kecil hingga menengah, sedangkan *deep learning* lebih mampu mengenali pola kompleks dan non-linear ketika tersedia data dalam jumlah besar. Untuk menguji hal ini, penelitian menggunakan dua sumber dataset, yaitu data lapangan dari UPTD Puskesmas Lakologuo sebagai representasi kondisi nyata di masyarakat, dan dataset publik dari Kaggle sebagai data augmentasi untuk memperkaya variasi dan melengkapi informasi yang tidak sepenuhnya tersedia pada data lokal. Dengan menggabungkan kedua dataset tersebut, penelitian ini tidak hanya membandingkan performa *machine learning* dan *deep learning*, tetapi juga menekankan pentingnya integrasi data lokal dan publik dalam membangun model yang lebih relevan.

METODOLOGI

Dataset

Dataset yang digunakan dalam penelitian ini berasal dari dua sumber utama, yaitu platform Kaggle dan UPTD Puskesmas Lakologuo. Dataset dari Kaggle Stunting

Toddler (Balita) Detection (121K rows) 120.999 data balita yang mencakup informasi umur dalam bulan, jenis kelamin, tinggi badan, dan status gizi. Status gizi dalam dataset ini dikelompokkan ke dalam empat kategori: 'severely stunting', yang menunjukkan kondisi gizi sangat serius; 'stunting', yang menunjukkan kondisi stunting; 'normal', yang menunjukkan status gizi sehat; dan 'tinggi', yang menunjukkan pertumbuhan di atas rata-rata. Detail dari atribut dataset Kaggle dapat dilihat pada Tabel 1.

Tabel 1. Atribut Dataset Kaggle

No.	Fitur	Tipe Data	Keterangan
1.	Umur	Integer	Umur dalam bulan
2.	L/P	Text	Jenis Kelamin
3.	Tinggi	Float	Tinggi badan (cm)
4.	Status Gizi	Object	Kategori gizi

Selanjutnya, dataset dari UPTD Puskesmas Lakologou mencakup 1.033 balita dengan data yang dihimpun selama periode 2022–2024. Dataset ini terdiri dari tanggal lahir, jenis kelamin, tinggi badan, dan berat badan yang diukur setiap bulan. Tanggal lahir digunakan untuk menghitung usia balita dalam bulan, yang menjadi parameter penting dalam analisis pertumbuhan. Data balita ini berasal dari dua wilayah kerja UPTD, yaitu Kelurahan Waruruma sebanyak 467 balita dan Kelurahan Lakologou sebanyak 566 balita, dengan total keseluruhan 1.033 balita. Detail dari atribut dataset UPTD Puskesmas Lakologou dapat dilihat pada Tabel 2.

Tabel 2. Atribut Dataset UPT Puskesmas Lakologuo

No.	Fitur	Tipe Data	Keterangan
1.	NIK	Integer	Nomor Induk Kependudukan
2.	Nama Anak	Text	Identitas balita
3.	Tanggal Lahir	Date	Tanggal lahi
4.	L/P	Text	Jenis Kelamin
5.	Nama Orang Tua	Text	Identitas orang tua
6.	Alamat RT/RW	Text	Alamat rumah
7.	Tinggi Badan (cm)	Float	Tinggi badan (cm)
8.	Berat Badan (kg)	Float	Berat badan (kg)

Kedua dataset ini digabungkan untuk menghasilkan data yang lebih kaya dan beragam, mengintegrasikan data lokal dari UPTD Puskesmas Lakologuo dengan data skala besar dari Kaggle. Kombinasi ini digunakan untuk membangun model berbasis

machine learning yang lebih akurat dalam mendeteksi status gizi dan kondisi stunting pada balita.

Preprocessing

Tahap preprocessing data adalah melakukan pembersihan. Proses ini mencakup penanganan nilai yang hilang (*missing values*), duplikasi data, serta pengidentifikasian dan koreksi nilai yang tidak valid atau anomali. Setelah data dibersihkan, langkah selanjutnya adalah konversi tipe data yang sesuai, normalisasi, dan standarisasi data numerik, serta *encoding* variabel kategori. Proses ini bertujuan agar data siap untuk digunakan dalam pembuatan model klasifikasi.

Pada dataset Kaggle, dilakukan penambahan fitur baru berupa z-score yang dihitung berdasarkan standar WHO untuk *Length/Height for Age* pada umur 0 sampai 60 Bulan [10]. Dalam tabel tersebut berisi Standar Deviasi WHO) adalah parameter yang digunakan untuk menghitung deviasi atau variasi dari tinggi badan balita dibandingkan dengan rata-rata tinggi badan yang telah ditetapkan oleh Organisasi Kesehatan Dunia (WHO) pada usia dan jenis kelamin tertentu. Z-score dihitung menggunakan rumus :

$$z - score = \frac{(Tinggi) - (Rata - rata WHO)}{Standar Deviasi} \quad (1)$$

Dimana:

- Tinggi adalah tinggi badan balita yang diukur.
- Rata-rata WHO adalah nilai rata-rata tinggi badan untuk usia dan jenis kelamin yang sesuai.
- Standar Deviasi WHO adalah nilai deviasi standar yang telah ditentukan oleh WHO untuk kelompok usia dan jenis kelamin yang sesuai

Z-score untuk tinggi badan balita juga dihitung menggunakan standar WHO yang sama dengan klasifikasi status gizi ke dalam empat kategori seperti pada dataset Kaggle. Setelah itu, kedua dataset diselaraskan dengan format kolom yang sama, yaitu Umur (bulan), Jenis Kelamin, Tinggi, Umur/Tinggi, Z Score, dan Status Gizi. Dataset yang telah diproses ini siap digunakan untuk analisis lebih lanjut dan pengembangan model klasifikasi. Selain itu, dilakukan pula pembagian dataset menjadi dua bagian: data pelatihan (*training set*) dan data pengujian (*test set*), dengan proporsi umumnya adalah 80% untuk pelatihan dan 20% untuk pengujian. Detail pada dataset tersebut dapat dilihat pada Tabel 4.

Tabel 4. Atribut Dataset UPT Puskesmas Lakologuo

No.	Fitur	Keterangan
1.	Umur (bulan)	Usia balita dalam bulan
2.	Jenis Kelamin	Laki-laki (L) atau Perempuan (P)

3.	Tinggi Badan (cm)	Tinggi badan balita yang diukur
4.	Z-score	Nilai deviasi standar tinggi badan terhadap rata-rata WHO berdasarkan usia & jenis kelamin
5.	Status Gizi	Kategori hasil klasifikasi: severely stunted, stunted, normal, tinggi
6.	Tinggi Badan (cm)	Berat badan (kg)

Pada dataset UPTD Puskesmas Lakologuo, preprocessing dilakukan dengan menghitung umur balita dalam bulan dari tanggal lahir dan tanggal pengukuran. Selanjutnya, dihitung z-score untuk tinggi badan balita berdasarkan standar WHO, lalu digunakan untuk menentukan status gizi ke dalam empat kategori (*severely stunted*, *stunted*, normal, tinggi). Pada tahap ini, jumlah data awal 1.042 balita berkembang menjadi 9.292 data karena adanya pencatatan bulanan. Persebaran dataset berdasarkan dua dataset tersebut dapat dilihat pada Tabel 3.

Tabel 3. Persebaran Dataset berdasarkan kategori Gizi

No.	Kategori Gizi	Sumber Dataset	
		Kaggle	UPTD
1.	Normal	67.755	7.201
2.	Severely Stunted	19.869	-
3.	Stunting	13.815	1.155
4.	Tinggi	19.560	540
Total		120.999	9.292

Random Forest

Random Forest unggul dalam generalisasi, mengurangi risiko *overfitting*, dan bekerja baik pada dataset dengan fitur relevan yang tidak dominan. Selain itu, algoritma ini mampu menangani data yang tidak seimbang dan bekerja dengan baik tanpa memerlukan banyak penyesuaian parameter, menjadikannya pilihan yang handal untuk berbagai tugas klasifikasi dan regresi. *Random Forest* bekerja dengan membangun sejumlah pohon keputusan (*decision trees*) secara acak dan menggabungkan hasil prediksi dari masing-masing pohon untuk menghasilkan prediksi akhir yang lebih akurat. Proses ini dikenal sebagai "*bagging*" (*bootstrap aggregating*), di mana setiap pohon dilatih pada subset acak dari data pelatihan[11].

XGBoost

XGBoost mengoptimalkan proses pembelajaran dengan teknik seperti *sparsity-aware*, *cache-aware*, dan *parallel computation*, sehingga sangat efisien untuk data dalam skala besar. Selain itu, XGBoost fleksibel karena mendukung berbagai jenis data dan parameter yang dapat dikustomisasi sesuai kebutuhan. Dengan kemampuannya untuk meminimalkan *overfitting* dan memaksimalkan akurasi. XGBoost merupakan pengembangan dari algoritma gradient boosting yang mengoptimalkan proses pembelajaran dengan menggunakan teknik regularisasi untuk mengurangi *overfitting* dan meningkatkan akurasi model [12]. XGBoost bekerja dengan membangun model

secara bertahap, di mana setiap model baru berusaha untuk memperbaiki kesalahan dari model sebelumnya. Proses ini melibatkan penambahan pohon keputusan satu per satu, di mana setiap pohon baru dilatih untuk memprediksi residual (kesalahan) dari pohon sebelumnya.

Keunggulan lain dari XGBoost adalah kemampuannya untuk memberikan informasi tentang pentingnya fitur (feature importance), yang memungkinkan peneliti untuk memahami variabel mana yang paling berpengaruh terhadap hasil prediksi. Ini sangat berguna dalam konteks aplikasi medis dan bisnis, di mana pemahaman tentang faktor-faktor yang mempengaruhi hasil sangat penting [13].

Support Vector Machine

Support Vector Machine (SVM) *Support Vector Machine* (SVM) adalah salah satu metode pembelajaran mesin yang paling populer dan efektif, terutama dalam konteks klasifikasi dan regresi. SVM merupakan algoritma yang termasuk dalam kategori supervised learning, yang berarti bahwa ia dilatih menggunakan data yang sudah diberi label. Konsep dasar dari SVM adalah untuk menemukan hyperplane yang optimal yang memisahkan dua kelas dalam ruang fitur. Hyperplane ini adalah garis (atau bidang dalam dimensi lebih tinggi) yang memisahkan data dengan margin maksimum, sehingga meminimalkan kesalahan klasifikasi [14], [15].

Artificial Neural Network

Artificial Neural Network (ANN) adalah model komputasi yang terinspirasi oleh cara kerja otak manusia, dirancang untuk mengenali pola dan menyelesaikan berbagai masalah kompleks dalam bidang pembelajaran mesin dan kecerdasan buatan. ANN terdiri dari sejumlah neuron yang terhubung dalam lapisan-lapisan, termasuk lapisan input, satu atau lebih lapisan tersembunyi, dan lapisan output. Setiap neuron dalam jaringan menerima input, memprosesnya melalui fungsi aktivasi, dan menghasilkan output yang kemudian diteruskan ke neuron-neuron berikutnya [16], [17].

HASIL DAN PEMBAHASAN

Pada penelitian ini dilakukan komparasi metode machine learning dan deep learning. Tahap pertama adalah penggabungan dataset, di mana dataset yang digunakan berasal dari dua sumber, yaitu UPTD Puskesmas Lakologuo dan Kaggle Dataset. Ini dilakukan untuk menambah kuantitas dari dataset sehingga memiliki performa yang baik. Karena kedua dataset memiliki fitur yang berbeda, dilakukan penyesuaian fitur agar bisa digabungkan dengan baik. Beberapa fitur utama yang dipertahankan meliputi Umur (bulan), Tinggi, Tinggi/Umur, Z-score Tinggi, dan Status Gizi/Stunting. Penyesuaian fitur ini penting agar model dapat belajar dari informasi yang konsisten.

Selanjutnya, dilakukan penanganan *missing value* untuk mengatasi data yang tidak lengkap. Jika hanya terdapat sedikit nilai yang hilang, data diisi menggunakan metode mean/mode imputation, sedangkan jika jumlahnya terlalu banyak, maka data tersebut dihapus agar tidak menyebabkan ketidakseimbangan dalam distribusi informasi. Proses ini memastikan bahwa data yang digunakan dalam model memiliki integritas yang baik. Penelitian ini dilakukan dalam 2 bagian, yaitu data UPTD Puskesmas Lakologuo dan Kaggle dengan, yang masing-masing digunakan untuk mengevaluasi performa *machine learning* dan *deep learning* dalam mengklasifikasikan

status gizi balita pada berbagai skenario dataset yang berbeda. Detail atribut pada dataset dapat dilihat pada Tabel 5.

Tabel 5. Atribut Dataset

Atribut	Tipe data
L/P	Integer
Umur	float
Tinggi	float
Z_score	float
Stunted	Integer

Pada percobaan awal dilakukan pada dataset UPTD Puskesmas Lakologuo model diuji untuk mengklasifikasikan. Hasil evaluasi kinerja berdasarkan metrik akurasi, presisi, recall, dan F1-score ditunjukkan dalam tabel berikut:


Tabel 3. Evaluasi Model UPTD Puskesmas Lakologuo

Metode	Akurasi	Precision	Recall	F1-score
RF	99	99	99	99
XGBoost	99	99	99	99
SVM	60	20	33	61
LSTM	59	40	60	41
ANN	39	31	34	42

Random Forest dan XGBoost menunjukkan hasil terbaik dengan akurasi dan F1-score mencapai 100% pada dataset UPTD Puskesmas Lakologuo, dan hanya mengalami sedikit penurunan menjadi 99% ketika diuji pada dataset gabungan dengan Kaggle. Hal ini menegaskan konsistensi kedua model berbasis ensemble tree dalam menangani variasi data. Sementara itu, SVM memiliki performa yang cukup baik pada dataset gabungan dengan akurasi 90% dan F1-score 87%, namun hasilnya tetap lebih rendah dibandingkan Random Forest dan XGBoost.

Random Forest dan XGBoost menunjukkan hasil terbaik dengan akurasi dan F1-score mencapai 100% pada dataset UPTD Puskesmas Lakologuo, menegaskan konsistensi kedua model berbasis *ensemble tree* dalam menangani variasi data. Analisis *feature importance* memperlihatkan bahwa variabel Zscore_Tinggi menjadi faktor dominan pada kedua model, diikuti oleh atribut Umur, sementara variabel lain seperti jenis kelamin memberikan kontribusi yang sangat kecil terhadap prediksi. Pada Random Forest, fitur Zscore_Tinggi mendominasi dengan kontribusi lebih dari 70%, disusul oleh Umur, sementara fitur lain seperti Tinggi, Berat, dan Jenis Kelamin

hampir tidak berperan. Kondisi ini lebih ekstrem pada XGBoost, di mana Zscore_Tinggi mencapai hampir 100% bobot *feature importance*, sehingga variabel lain sama sekali tidak memberikan kontribusi. Pola ini mengindikasikan adanya potensi overfitting, karena model terlalu bergantung pada satu variabel dominan dalam melakukan klasifikasi.




Gambar 2. *Feature Importances* dataset UPTD Puskesmas Lakologuo (a) Random Forest dan (b) XGBoost.

Pada percobaan selanjutnya berdasarkan hasil evaluasi pada Tabel 4, terlihat bahwa performa model menunjukkan variasi yang cukup jelas antara metode ensemble, deep learning, dan SVM. Random Forest menempati posisi terbaik dengan akurasi, precision, recall, dan F1-score masing-masing mencapai 98%, diikuti oleh XGBoost dengan akurasi 97,5% dan metrik lainnya di kisaran 97%, yang menegaskan keunggulan metode ensemble dalam menjaga konsistensi performa pada data gabungan. ANN juga menunjukkan hasil yang sangat baik dengan akurasi 97%, precision dan recall 96%, serta F1-score 96%, menandakan kestabilan dalam klasifikasi. Sementara itu, LSTM mencatatkan akurasi 94% dengan precision, recall, dan F1-score konsisten di angka 93%, sehingga tetap dapat diandalkan meski sedikit lebih rendah. Di sisi lain, SVM menampilkan performa terendah dengan akurasi 90%, precision 90%, recall 86%, dan F1-score 87%, yang menunjukkan keterbatasan dalam menangani variasi data positif dibandingkan model lainnya. Secara keseluruhan, hasil ini menegaskan bahwa metode berbasis ensemble, khususnya Random Forest dan XGBoost, merupakan pilihan paling optimal untuk klasifikasi status gizi pada dataset gabungan UPTD Puskesmas Lakologuo dan Kaggle.

Tabel 4. Evaluasi Model UPTD Puskesmas Lakologuo + Kaggle

Metode	Akurasi	Precision	Recall	F1-score
RF	98.3	98	98	98
XGBoost	97.5	97	97	97
SVM	90	90	86	87
LSTM	94	93	93	93
ANN	97	96	96	96


Setelah penambahan dataset Kaggle, distribusi feature importance menjadi lebih seimbang dan beragam. Pada Gambar 2 (a) Random Forest, fitur Tinggi (≈ 0.6) dan Umur (≈ 0.4) muncul sebagai variabel penting, sementara Jenis Kelamin mulai memiliki kontribusi meskipun kecil. Hal serupa juga terlihat pada Gambar 2 (b) XGBoost, di mana Umur dan Tinggi memiliki bobot hampir seimbang (≈ 0.47 dan 0.45), serta Jenis Kelamin yang ikut diperhitungkan (≈ 0.08). Perubahan ini menunjukkan bahwa dengan adanya variasi data tambahan, model tidak hanya bergantung pada satu variabel, tetapi juga belajar dari kombinasi beberapa fitur penting. Hal ini meningkatkan kemampuan generalisasi model dan mengurangi risiko overfitting yang terlihat pada dataset awal.



Gambar 2. Feature Importances dataset UPTD Puskesmas Lakologuo + Kaggle (a) Random Forest dan (b) XGBoost.

Perbandingan akurasi pada Gambar 3 menunjukkan bahwa penambahan dataset Kaggle memberikan dampak signifikan terhadap peningkatan performa sebagian besar model, terutama pada metode berbasis deep learning seperti LSTM dan ANN yang awalnya memiliki akurasi rendah pada dataset UPTD Puskesmas Lakologuo (59% dan 39%), kemudian meningkat tajam menjadi 94% dan 97%. Sementara itu, SVM juga mengalami peningkatan akurasi dari 60% menjadi 90%, menandakan bahwa penambahan variasi data mampu memperbaiki generalisasi model. Berbeda halnya dengan Random Forest dan XGBoost yang sejak awal sudah menunjukkan kinerja optimal dengan akurasi sangat tinggi (99%), sehingga setelah penambahan data hanya mengalami sedikit penurunan menjadi 98,3% dan 97,5%.

Hasil ini menegaskan bahwa penambahan variasi data sangat penting, khususnya bagi model deep learning yang sensitif terhadap keterbatasan variasi, sementara model *ensemble* seperti Random Forest dan XGBoost tetap konsisten meskipun terjadi perubahan distribusi data. Dengan demikian, integrasi dataset lokal dan eksternal dapat menjadi strategi efektif dalam meningkatkan performa model klasifikasi status gizi secara lebih andal dan general.



Gambar 3. Perbandingan Akurasi Dataset

SIMPULAN

Penelitian ini membandingkan performa model machine learning dan deep learning dalam klasifikasi status gizi balita menggunakan dataset UPTD Puskesmas Lakologuo dan dataset tambahan dari Kaggle. Hasil penelitian menunjukkan bahwa model berbasis ensemble, yaitu Random Forest dan XGBoost, konsisten memberikan performa terbaik dengan akurasi tinggi, masing-masing mencapai 99% pada dataset lokal dan sedikit menurun menjadi 98,3% serta 97,5% pada dataset gabungan. Sebaliknya, model SVM, LSTM, dan ANN menunjukkan kinerja yang rendah ketika hanya menggunakan dataset lokal (akurasi 60%, 59%, dan 39%), namun mengalami peningkatan signifikan setelah ditambahkan dataset Kaggle dengan akurasi masing-masing meningkat menjadi 90%, 94%, dan 97%. Temuan ini menegaskan bahwa penambahan variasi data memiliki pengaruh besar terhadap performa model deep learning yang sensitif terhadap keterbatasan jumlah dan keragaman data, sementara model ensemble tree lebih stabil dan mampu menjaga kinerjanya meskipun terjadi perubahan distribusi data.

Namun demikian, penelitian ini masih memiliki keterbatasan, terutama terkait jumlah dan variasi data. Oleh karena itu, penelitian selanjutnya disarankan untuk mengeksplorasi teknik ensemble lanjutan seperti stacking atau blending, serta memperluas cakupan dataset dengan menambahkan sumber data baru agar model lebih robust dalam menghadapi kondisi nyata. Penambahan fitur tambahan seperti pola konsumsi makanan, riwayat kesehatan keluarga, dan kondisi lingkungan juga berpotensi meningkatkan akurasi klasifikasi. Selain itu, pengembangan aplikasi digital berbasis hasil penelitian ini penting dilakukan agar model dapat diterapkan secara langsung dalam sistem layanan kesehatan, khususnya di tingkat puskesmas. Dengan demikian, hasil penelitian ini diharapkan tidak hanya memperkuat kontribusi akademis, tetapi juga memberikan manfaat praktis dalam upaya pencegahan dan penanganan masalah gizi balita di masyarakat.

DAFTAR PUSTAKA

- [1] World Health Organization (WHO), "Malnutrition," 2015. [Online]. Available:

- <https://www.who.int/health-topics/malnutrition>. [Accessed: 25-Nov-2024].
- [2] Kementerian Kesehatan Republik Indonesia, "Situasi Balita Pendek," *Infodatin*, pp. 1–10, 2016.
 - [3] UNICEF Indonesia, "Laporan Tahunan Indonesia 2022," *UNICEF Lap. Tah. Indones.* 2022, p. 6, 2022.
 - [4] 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, 2023, doi: 10.30865/mib.v7i4.6553.
 - [5] S. Ndagijimana, I. H. Kabano, E. Masabo, and J. M. Ntaganda, "Prediction of Stunting among Under-5 Children in Rwanda Using Machine Learning Techniques," *J. Prev. Med. Public Heal.*, vol. 56, no. 1, pp. 41–49, 2023, doi: 10.3961/jpmph.22.388.
 - [6] F. H. Bitewm, C. S. Sparks, and S. H. Nyarko, "Machine learning algorithms for predicting undernutrition among under-five children in Ethiopia," *Public Health Nutr.*, vol. 25, no. 2, pp. 269–280, 2021.
 - [7] M. S. Haris, M. Anshori, and A. N. Khudori, "Prediction of Stunting Prevalence in East Java Province With Random Forest Algorithm Prediksi Nilai Prevalensi Stunting Di Provinsi Jawa Timur Menggunakan Algoritma Random Forest," *J. Tek. Inform.*, vol. 4, no. 1, pp. 11–13, 2023.
 - [8] N. Purwati and G. B. Sulisty, "Stunting Early Warning Application Using KNN Machine Learning Method," *J. Ris. Inform.*, vol. 5, no. 3, pp. 373–378, 2023, doi: 10.34288/jri.v5i3.550.
 - [9] S. Ankalaki, V. G. Biradar, P. Kishor Kumar Naik, and G. S. Hukkeri, "A Deep Learning Approach for Malnutrition Detection," *Int. J. online Biomed. Eng.*, vol. 20, no. 6, pp. 116–138, 2024, doi: 10.3991/ijoe.v20i06.46919.
 - [10] World Health Organization, "Length/height-for-age." [Online]. Available: <https://www.who.int/tools/child-growth-standards/standards/length-height-for-age>. [Accessed: 02-Jan-2025].
 - [11] G. Biau and E. Scornet, "A random forest guided tour," *TEST*, vol. 25, no. 2, pp. 197–227, Jun. 2016, doi: 10.1007/s11749-016-0481-7.
 - [12] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," *KDD '16 Proc. 22nd ACM SIGKDD Int. Conf. Knowl. Discov. Data Min.*, pp. 785–794, 2016, doi: 10.1145/2939672.2939785.
 - [13] C. Cui, J. Lan, Z. Lao, T. Xia, and T. Long, "Predicting the recurrence of spontaneous intracerebral hemorrhage using a machine learning model," *Front. Neurol.*, vol. 15, May 2024, doi: 10.3389/fneur.2024.1407014.
 - [14] R. Sahak, W. Mansor, K. Y. Lee, and A. Zabidi, "Performance of Principal Component Analysis and Orthogonal Least Square on Optimized Feature Set in Classifying Asphyxiated Infant Cry Using Support Vector Machine," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 9, no. 1, p. 139, Jan. 2018, doi: 10.11591/ijeecs.v9.i1.pp139-145.
 - [15] N. Artiyati and A. Ahdika, "Implementation of the Support Vector Machine (SVM) Method for Classification of Underdeveloped Areas in Indonesia," *J. MEDIA Inform. BUDIDARMA*, vol. 8, no. 2, p. 854, Apr. 2024, doi: 10.30865/mib.v8i2.7598.
 - [16] T. Viet Huynh, "Evaluation of Artificial Neural Network Architectures for Pattern Recognition on FPGA," *Int. J. Comput. Digit. Syst.*, vol. 6, no. 3, pp. 133–138, May 2017, doi: 10.12785/IJCDs/060305.
 - [17] A. Géron, *Hands-On Machine Learning with Skicit-Learn, Keras, & TensorFlow*, Second Edi. O'Reilly Media, Inc, 2019.