


Deteksi Dini Stunting Balita Menggunakan Long Short-Term Memory Pada Data Posyandu Kabupaten Asahan

Rizky Riansyah Panjaitan¹, Suci Ramadani², Reni Surya Nanda³, Dicky Apdillah⁴

^{1,2,3,4} Program Studi Teknik Informatika, Fakultas Teknik, Universitas Asahan, Jl. Jend. Ahmad Yani No. 1, Kisaran, Kabupaten Asahan, Sumatera Utara 21214

E-mail: rizkyriansyahpanjaitan@gmail.com

* Corresponding Author

 <https://doi.org/10.31004/jerkin.v5i1.6598>

ARTICLE INFO

Article history

Received: 20 Juni 2026

Revised: 29 Juni 2026

Accepted: 07 Juli 2026

Kata Kunci

Stunting; Deep Learning; LSTM; Posyandu; Deteksi Dini

Keywords

Stunting; Deep Learning; LSTM; Posyandu; Early Detection



ABSTRACT

Stunting merupakan persoalan gizi bersifat kronis yang hingga kini masih menjadi beban kesehatan signifikan di berbagai daerah Indonesia, termasuk Kabupaten Asahan, Sumatera Utara. Survei Status Gizi Indonesia (SSGI) 2024 melaporkan prevalensi stunting nasional berada pada angka 21,5%. Guna menjawab persoalan tersebut, penelitian ini merancang sistem deteksi dini stunting yang memanfaatkan metode deep learning dengan arsitektur Long Short-Term Memory (LSTM), menggunakan data antropometri longitudinal dari 208 balita usia 0–59 bulan dengan enam kali pengukuran per balita, setara 1.248 rekaman, yang diperoleh dari posyandu di Kabupaten Asahan. Pembagian data dengan skema 80:20 per rekaman menghasilkan 998 data latih dan 250 data uji. Enam variabel input digunakan: usia, jenis kelamin, berat badan, tinggi/panjang badan, lingkaran kepala, dan LILA. Pra-pemrosesan melibatkan normalisasi Min-Max, KNN Imputer, dan SMOTE (target=581, hasil=2.324 sampel latih). Model LSTM dengan dua hidden layer (128 dan 64 unit), aktivasi ReLU, dan Dropout 0,3 mencapai akurasi 93,60%, presisi 90,33%, recall 92,74%, serta F1-Score 91,34%, melampaui Random Forest (88,20%) dan SVM (87,40%).

Stunting remains a serious public health challenge in Indonesia, including in Asahan Regency, North Sumatra. Based on the 2024 SSGI data, the national stunting prevalence rate was recorded at 21.5%. This study aimed to build an early stunting detection system based on a deep learning approach using the Long Short-Term Memory (LSTM) architecture. The data used consisted of longitudinal anthropometric records from 208 children aged 0 to 59 months, with each child having six monthly measurement points, totaling 1,248 records from active posyandu in Asahan Regency. Data was split at the record level with an 80:20 ratio, yielding 998 training records and 250 test records. Input variables consisted of six attributes: age, sex, body weight, height/length, head circumference, and upper arm circumference (LILA). Preprocessing included Min-Max normalization, missing value imputation using KNN Imputer, and minority class balancing with SMOTE to obtain 2,324 training samples. The proposed LSTM model achieved an accuracy of 93.60%, precision of 90.33%, recall of 92.74%, and F1-Score of 91.34%, surpassing the performance of Random Forest (88.20%) and SVM (87.40%).



This is an open access article under the CC-BY-SA license.

How to Cite Rizky Riansyah Panjaitan et al (2026) Deteksi Dini Stunting Balita Menggunakan Long Short-Term Memory Pada Data Posyandu Kabupaten Asahan <https://doi.org/10.31004/jerkin.v5i1.6598>

PENDAHULUAN

Stunting adalah kondisi di mana pertumbuhan tinggi badan anak terhambat secara permanen akibat asupan gizi yang tidak memadai dalam jangka panjang, khususnya selama 1.000 Hari Pertama

Kehidupan (HPK). Kondisi ini didiagnosis apabila nilai Z-score tinggi badan menurut umur (TB/U) berada di bawah -2 standar deviasi dari nilai median standar pertumbuhan WHO. Dampak stunting bersifat multidimensi: tidak hanya membatasi pertumbuhan fisik anak, tetapi juga berdampak pada kapasitas kognitif jangka panjang serta meningkatkan kerentanan terhadap penyakit tidak menular pada usia dewasa.

Hasil Survei Status Gizi Indonesia (SSGI) tahun 2024 menunjukkan penurunan angka prevalensi stunting nasional menjadi 21,5%, dibandingkan 24,4% pada 2021. Meskipun demikian, Kabupaten Asahan di Sumatera Utara masih mencatat angka yang melampaui rata-rata nasional, sehingga masuk ke dalam daftar prioritas intervensi percepatan penurunan stunting sesuai amanat Perpres Nomor 72 Tahun 2021.

Posyandu menjalankan fungsi vital sebagai unit terdepan dalam pemantauan tumbuh kembang balita melalui pengukuran antropometri rutin setiap bulan. Data pertumbuhan yang terhimpun secara periodik ini pada dasarnya merupakan data deret waktu (time-series) yang berpotensi besar untuk dianalisis guna mengidentifikasi gejala perlambatan pertumbuhan (growth faltering) sebagai penanda awal risiko stunting. Sayangnya, proses analisis yang masih dilakukan secara manual memiliki kelemahan berupa potensi kesalahan dan lamanya waktu yang diperlukan.

Arsitektur Long Short-Term Memory (LSTM) sangat relevan diterapkan dalam konteks ini karena dirancang khusus untuk memproses dan menangkap dependensi jangka panjang dalam data sekuensial. Beberapa penelitian terdahulu telah mencoba berbagai pendekatan untuk masalah serupa, antara lain menggunakan SVM dengan akurasi 85,3% , ensemble berbasis voting classifier, dan SVM multikelas. Namun, penerapan LSTM secara langsung pada data posyandu longitudinal Kabupaten Asahan belum pernah dilakukan sebelumnya, sehingga membuka celah riset yang menjadi fokus penelitian ini.

Penelitian ini menetapkan tiga tujuan utama: (1) membangun dan melatih model LSTM untuk mengklasifikasikan status gizi balita berdasarkan rekaman posyandu longitudinal Kabupaten Asahan; (2) mengevaluasi dan membandingkan performa model terhadap beberapa algoritma pembandingan; serta (3) menganalisis tingkat kontribusi masing-masing fitur terhadap keluaran prediksi model.

METODE

Jenis dan Sumber Data

Studi ini berlandaskan pada data primer longitudinal yang dikumpulkan dari lima posyandu aktif di wilayah Kabupaten Asahan. Pengumpulan data dilaksanakan setelah memperoleh izin resmi dari Dinas Kesehatan Kabupaten Asahan serta persetujuan dari Komite Etik Penelitian Kesehatan setempat.

Dataset dan Struktur Data

Kumpulan data terdiri atas rekaman pengukuran dari 208 balita berusia 0–59 bulan. Setiap anak memiliki enam rekaman pengukuran secara berurutan dalam interval bulanan, sehingga total keseluruhan dataset mencapai $208 \times 6 = 1.248$ baris. Struktur sekuensial ini memungkinkan penerapan LSTM dengan konfigurasi `time_steps = 6`.

Enam atribut input: (1) usia (bulan); (2) jenis kelamin; (3) berat badan (kg); (4) tinggi/panjang badan (cm); (5) lingkar kepala (cm); (6) LILA (cm). Variabel Z-score tidak dimasukkan sebagai fitur input untuk menghindari data leakage.

Tabel 1. Distribusi Dataset (208 balita, 1.248 rekaman)

Kelas Gizi	Jumlah Balita	Jumlah Rekaman	Rentang Z-score TB/U	Kode Label
Stunting Berat	31	186	< -3 SD	0
Stunting	44	264	-3 s.d -2 SD	1
Normal	121	726	-2 s.d $+2$ SD	2
Tinggi	12	72	$> +2$ SD	3
Total	208	1.248	—	—

Pra-Pemrosesan Data

(1) Penanganan Nilai Hilang: 4,3% data tidak terisi dilengkapi menggunakan KNN Imputer ($k=5$). (2) Normalisasi Min-Max ke rentang $[0, 1]$:

$$x' = \frac{x - x_{min_{min}}}{x_{max_{max}} - x_{min_{min}}}$$

(3) Pengkodean: jenis kelamin dikodekan biner (0=perempuan; 1=laki-laki), label kelas dalam format one-hot encoding. (4) Pembagian Dataset 80:20 per rekaman: 998 data latih dan 250 data uji. (5) SMOTE diterapkan dengan target kelas Normal = 581 sampel, menghasilkan 2.324 sampel latih seimbang.

Arsitektur Model LSTM

Konfigurasi input: time_steps = 6, features = 6. Hyperparameter optimal dipilih melalui grid search dengan 5-fold cross-validation.

Tabel 2. Arsitektur Model LSTM

L	Tipe Layer	Konfigurasi	Output Shape	Parameter
1	Input	time_steps=6, features=6	(N, 6, 6)	0
2	LSTM-1	128 unit, return_seq=True, Dropout=0,3	(N, 6, 128)	69.120
3	LSTM-2	64 unit, return_seq=False, Dropout=0,3	(N, 64)	49.408
4	Dense+BN	32 unit, ReLU, Batch Norm, Dropout=0,3	(N, 32)	2.208
5	Output	4 unit, Softmax	(N, 4)	132
	Total			120.868

Verifikasi: LSTM-1: $4 \times [(6+128) \times 128 + 128] = 69.120$. LSTM-2: $4 \times [(128+64) \times 64 + 64] = 49.408$. Dense+BN: 2.208. Output: 132. Total=120.868.

Pemilihan Hyperparameter

Pencarian hyperparameter terbaik dilakukan melalui grid search berbasis 5-fold cross-validation.

Tabel 3. Hasil Grid Search Hyperparameter

Hyperparameter	Nilai yang Diuji	Nilai Optimal
Unit LSTM Layer-1	64, 128, 256	128
Unit LSTM Layer-2	32, 64, 128	64
Dropout rate	0,1; 0,2; 0,3; 0,5	0,3
Learning rate	0,01; 0,001; 0,0001	0,001
Batch size	16, 32, 64	32
Maksimum epoch	50, 100, 200	100 (early stop=10)

HASIL DAN PEMBAHASAN

Riwayat Pelatihan Model

Proses pelatihan berlangsung selama 82 epoch hingga mekanisme early stopping (patience=10) menghentikan pelatihan lebih awal.

Tabel 4. Ringkasan Riwayat Pelatihan (82 epoch)

Indikator	Nilai Akhir Epoch	Nilai Terbaik	Epoch Optimal (ke-)
Training Loss	0,1512	0,1421	72
Validation Loss	0,1934	0,1876	72
Training Accuracy	95,82%	96,14%	72
Validation Accuracy	93,10%	93,60%	72

Perbandingan Performa Model

Tabel 5 menyajikan perbandingan komprehensif antara model LSTM yang diusulkan dan empat algoritma pembanding pada set data yang sama (250 rekaman).

Tabel 5. Perbandingan Performa Model (n=250 rekaman)

Model Klasifikasi	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)
LSTM (Usulan)	93,60	90,33	92,74	91,34
Random Forest	88,20	87,50	88,80	88,14
SVM (RBF)	87,40	86,90	87,10	87,00
Decision Tree	82,80	81,60	83,40	82,49
Naive Bayes	79,60	78,30	80,20	79,24

Confusion Matrix dan Verifikasi

Tabel 6 menyajikan confusion matrix model LSTM dari 250 rekaman data uji.

Tabel 6. Confusion Matrix LSTM (n=250 rekaman uji)

Aktual \ Prediksi	SB	S	N	T
Stunting Berat (37)	34	2	1	0
Stunting (53)	1	48	4	0
Normal (145)	0	3	138	4
Tinggi (15)	0	0	1	14

Verifikasi perhitungan metrik:

$$Accuracy = \frac{34 + 48 + 138 + 14}{250} = \frac{234}{250} = 93,60\%$$

$$Macro Precision = \frac{97,14 + 90,57 + 95,83 + 77,78}{4} = 90,33\%$$

$$Macro Recall = \frac{91,89 + 90,57 + 95,17 + 93,33}{4} = 92,74\%$$

$$Macro F1 - Score = \frac{94,44 + 90,57 + 95,50 + 84,85}{4} = 91,34\%$$

Analisis Kepentingan Fitur

Analisis permutation importance menghasilkan urutan kontribusi fitur: TB/U 34,1%, Usia 21,3%, Berat Badan 18,7%, Lingkar Kepala 12,4%, LILA 8,9%, Jenis Kelamin 4,6%. Dominasi TB/U sejalan dengan standar diagnostik WHO.

Pembahasan

Dengan enam fitur antropometri murni tanpa Z-score, model LSTM mencapai akurasi 93,60%. Keunggulan LSTM berasal dari kemampuannya menangkap pola temporal dari enam rekaman berurutan untuk mendeteksi growth faltering. SMOTE terbukti meningkatkan recall kelas minoritas rata-rata 4,2%. Keterbatasan studi meliputi jumlah subjek yang terbatas (208 balita) dan cakupan geografis satu kabupaten.

SIMPULAN

Berdasarkan eksperimen yang telah dilakukan, temuan utama penelitian ini adalah:

1. Model LSTM berhasil mengklasifikasikan status gizi balita dengan akurasi 93,60%, presisi 90,33%, recall 92,74%, dan F1-Score 91,34%, konsisten dengan verifikasi confusion matrix.
2. LSTM melampaui Random Forest (88,20%), SVM (87,40%), Decision Tree (82,80%), dan Naive Bayes (79,60%).
3. Penggunaan enam fitur tanpa Z-score mencegah data leakage sekaligus mempertahankan akurasi tinggi.
4. Struktur data longitudinal enam titik pengukuran memberi keuntungan bagi LSTM dalam mendeteksi growth faltering secara sekuensial.

Penelitian selanjutnya disarankan memperluas cakupan data ke lebih banyak kabupaten/kota dan mengeksplorasi arsitektur hybrid LSTM-CNN.

UCAPAN TERIMA KASIH

Para penulis mengucapkan terima kasih kepada Dinas Kesehatan Kabupaten Asahan atas izin akses data posyandu, kepada seluruh kader posyandu yang berkontribusi dalam pengumpulan data, serta kepada Laboratorium Komputasi Fakultas Teknik Universitas Asahan atas fasilitas yang mendukung penelitian ini.

REFERENSI

- M. Al-Husaini, I. Hoeronis, H. H. Lukmana, and L. D. Puspareni, "Early detection of stunting in toddlers based on ensemble machine learning in Purbaratu Tasikmalaya," *JUSTIN*, vol. 11, no. 3, pp. 487-495, 2023.
- S. Hochreiter and J. Schmidhuber, "Long short-term memory," *Neural Computation*, vol. 9, no. 8, pp. 1735-1780, 1997.
- N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic minority over-sampling technique," *JAIR*, vol. 16, pp. 321-357, 2002.
- F. Febriyanti et al., "Akurasi dan presisi pengukuran antropometri balita oleh kader posyandu," *Jurnal Kesehatan Masyarakat*, vol. 13, no. 1, pp. 27-42, 2025.
- I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge: MIT Press, 2016.
- F. Chollet, *Deep Learning with Python*, 2nd ed. Shelter Island: Manning, 2021.
- Kementerian Kesehatan RI, *Survei Status Gizi Indonesia (SSGI) 2024*. Jakarta: Kemenkes RI, 2024.
- Kementerian Kesehatan RI, *Peraturan Menteri Kesehatan RI No. 2 Tahun 2020 tentang Standar Antropometri Anak*. Jakarta: Kemenkes RI, 2020.
- D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," in *Proc. ICLR 2015*, 2015.
- M. R. Nugroho, R. N. Sasongko, and M. Kristiawan, "Faktor-faktor yang mempengaruhi kejadian stunting pada anak usia dini di Indonesia," *Jurnal Obsesi*, vol. 5, no. 2, pp. 2269-2276, 2021.
- Presiden Republik Indonesia, *Peraturan Presiden No. 72 Tahun 2021 tentang Percepatan Penurunan Stunting*. Jakarta: Setneg RI, 2021.
- I. Rahmi, M. Susanti, H. Yozza, and F. Wulandari, "Classification of stunting in children under five using SVM," *BAREKENG*, vol. 16, no. 3, pp. 771-778, 2022.
- M. A. Syakur et al., "Multiclass classification of toddler nutritional status using SVM," *BIO Web of Conferences*, vol. 146, p. 01082, 2024.
- M. Sokolova and G. Lapalme, "A systematic analysis of performance measures for classification tasks," *Inf. Process. Manag.*, vol. 45, no. 4, pp. 427-437, 2009.
- World Health Organization, *WHO Child Growth Standards: Methods and Development*. Geneva: WHO Press, 2006.