



Prediksi Status Gizi pada Balita Menggunakan Metode Long ShortTerm Memory

Hizrah Azhari^{1*}, Barry Ceasar Octariadi², Rachmat Wahid Saleh Insani³

¹⁻³Program Studi Teknik Informatika, Universitas Muhammadiyah Pontianak, Indonesia

*Penulis Korespondensi: hizrahhari11@gmail.com¹

Abstract. *The high prevalence of malnutrition among toddlers in Pontianak City, adversely affecting growth, cognitive function, and future human capital. Despite monitoring efforts, traditional methods remain slow and less accurate. The objective is to develop an early prediction system for toddler nutritional status using a Long Short-Term Memory (LSTM) model based on anthropometric data (weight, height, age, gender) from the Pontianak City Health Office. The methodology comprises an applied experimental quantitative design with the following stages: data collection and preprocessing (cleaning, normalization, train-test split), LSTM model architecture development, model training, and performance evaluation using accuracy, precision, recall, and F1-score metrics. The dataset includes 1,182 samples of toddlers aged 0–60 months. Training results yielded 82% accuracy, 98% precision, 82% recall, and an F1-score of 89% on the training set. On the test set, the model achieved 79% accuracy, 99% precision, 80% recall, and an F1-score of 89%, with a weighted average F1-score of 0.83 and a macro average F1-score of 0.71, indicating solid overall performance but highlighting the need for improvement in underrepresented classes. The study's implications involve enhancing the effectiveness of toddler nutritional monitoring, enabling faster interventions by healthcare workers, and contributing academically to the development of AI-based applications in public health.*

Keywords: Long Short-Term Memory; Malnutrition; Nutritional Status Prediction; Time Series Data; Toddler Nutritional Status

Abstrak. Tingginya prevalensi masalah gizi pada balita di Kota Pontianak, yang berdampak negatif pada tumbuh kembang, fungsi kognitif, dan kualitas sumber daya manusia masa depan. Berdasarkan data UNICEF dan WHO, sejumlah besar balita mengalami stunting dan gizi buruk, namun pemantauan tradisional masih lamban dan kurang akurat. Tujuan penelitian ini adalah mengembangkan sistem prediksi dini status gizi balita menggunakan metode Long Short-Term Memory (LSTM) berbasis data antropometri (berat badan, tinggi badan, usia, jenis kelamin) dari Dinas Kesehatan Kota Pontianak. Metode yang digunakan adalah penelitian terapan eksperimental kuantitatif dengan tahapan: pengumpulan dan prapemrosesan data (pembersihan, normalisasi, pembagian data latih-uji), pembangunan arsitektur model LSTM, pelatihan model, dan evaluasi kinerja menggunakan metrik akurasi, presisi, recall, dan F1-score. Data penelitian berjumlah 1.182 sampel balita usia 0–60 bulan. Hasil pelatihan model menunjukkan akurasi 82%, presisi 98%, recall 82%, dan F1-score 89% pada data latih. Pada data uji, model mencapai akurasi 79%, presisi 99%, recall 80%, dan F1-score 89%, sedangkan rata-rata F1-score tertimbang 0,83 dan macro average F1-score 0,71, mengindikasikan performa model yang baik secara keseluruhan namun masih perlu peningkatan pada kelas status gizi dengan data terbatas. Implikasi penelitian ini mencakup peningkatan efektivitas pemantauan gizi balita, mendukung intervensi lebih cepat oleh tenaga kesehatan, serta kontribusi akademik bagi pengembangan aplikasi berbasis kecerdasan buatan di bidang kesehatan masyarakat.

Kata kunci: Data Time Series; Long Short-Term Memory; Malnutrisi; Prediksi Status Gizi; Status Gizi Balita

1. LATAR BELAKANG

Malnutrisi pada balita salah satu permasalahan kesehatan global yang paling serius dan mengancam kehidupan, terutama di negara-negara berkembang termasuk Indonesia. Status gizi balita menjadi indikator penting dalam menilai kualitas kesehatan masyarakat dan pembangunan sumber daya manusia suatu negara. Berdasarkan data Survei Status Gizi Indonesia (SSGI) 2024, prevalensi stunting nasional mencapai 19,8%, mengalami penurunan dari 21,5% pada tahun 2023 (Phitra, 2023) namun masih jauh dari target World Health Assembly (WHA) sebesar 14,2% pada tahun 2029. Kondisi ini menunjukkan urgensi tinggi

untuk mengembangkan sistem prediksi dini yang akurat guna mendukung intervensi tepat waktu dalam mencegah dan menangani masalah gizi pada balita. Data WHO menunjukkan bahwa 45% kematian anak di bawah usia 5 tahun secara global berkaitan dengan malnutrisi, dengan 162 juta balita mengalami stunting dan 100 juta balita mengalami wasting (Amalia, 2023). Dalam konteks Indonesia, Kota Pontianak sebagai salah satu daerah di Kalimantan Barat menghadapi tantangan serupa dengan prevalensi masalah gizi yang memerlukan perhatian khusus.

Perkembangan teknologi machine learning dan deep learning dalam dekade terakhir telah membuka peluang baru untuk meningkatkan akurasi prediksi status gizi balita. Beberapa penelitian terdahulu menunjukkan keunggulan metode berbasis artificial intelligence dalam klasifikasi dan prediksi status gizi. Muntiari (2024) menggunakan berbagai algoritma machine learning termasuk Random Forest, Decision Tree, dan Support Vector Machine untuk prediksi status gizi balita dengan akurasi tertinggi mencapai 97,37% (Putri, 2023). Dalam konteks data time series untuk kesehatan, LSTM terbukti unggul dalam menangkap temporal dependencies dan long-term patterns yang sering diabaikan oleh metode machine learning tradisional. Kemampuan LSTM dalam memproses data sekuensial menjadikannya sangat sesuai untuk analisis data antropometri balita yang tercatat secara berkala dalam program pemantauan pertumbuhan

Meskipun telah banyak penelitian yang menggunakan machine learning untuk prediksi status gizi, terdapat beberapa gap. Keterbatasan dalam utilisasi data time series: Sebagian besar penelitian existing menggunakan pendekatan static classification yang tidak mempertimbangkan pola temporal pertumbuhan anak. Padahal, data antropometri balita yang dicatat secara berkala di posyandu memiliki karakteristik time series yang kaya akan informasi temporal untuk prediksi yang lebih akurat. Kebaruan penelitian ini terletak pada beberapa aspek pengembangan framework prediksi yang mempertimbangkan pola temporal pertumbuhan balita untuk deteksi risiko malnutrisi sebelum manifestasi klinis muncul, optimalisasi preprocessing data antropometri balita Indonesia untuk meningkatkan akurasi model LSTM, dan integrasi model prediksi dalam aplikasi berbasis web menggunakan Streamlit untuk mendukung decision making tenaga kesehatan di lapangan.

Urgensi penelitian ini didasari oleh beberapa faktor kritis penurunan stunting menjadi 14,2% pada 2029 dan 5% pada 2045 (Sona, 2025), diperlukan inovasi teknologi yang dapat mempercepat deteksi dan intervensi dini serta sistem pemantauan manual yang berlaku saat ini sering mengalami keterlambatan dalam mengenali perubahan status gizi, sehingga intervensi menjadi kurang optimal. Berdasarkan gap analysis yang telah diidentifikasi, penelitian ini

bertujuan mengembangkan model LSTM yang dapat memprediksi status gizi balita secara dini berdasarkan data antropometri time series, mengevaluasi performa model LSTM dalam mengenali pola pertumbuhan balita dan memprediksi risiko malnutrisi sebelum manifestasi klinis, mengoptimalkan teknik preprocessing data untuk meningkatkan akurasi prediksi model pada data antropometri balita Indonesia, mengimplementasikan model prediksi dalam sistem aplikasi web yang user-friendly untuk mendukung tenaga kesehatan dalam pengambilan keputusan intervensi dini. Dengan tercapainya tujuan penelitian ini, diharapkan dapat memberikan kontribusi signifikan dalam percepatan pencapaian target penurunan stunting nasional melalui implementasi teknologi artificial intelligence yang tepat guna dan berbasis evidence-based medicine.

2. KAJIAN TEORITIS

Pertumbuhan dan status gizi anak ditentukan melalui pendekatan antropometri (Ipmawati, 2024), yaitu pengukuran fisik seperti berat badan, tinggi badan, dan perhitungan indeks massa tubuh (IMT) untuk menilai kesesuaian gizi relatif terhadap standar WHO. Model antropometri ini memanfaatkan skor z-value (WAZ, HAZ, WHZ) untuk mengidentifikasi malnutrisi stunting, wasting, atau underweight sebagai hasil perbandingan data populasi referensi. Pemantauan berkelanjutan dalam 1000 Hari Pertama Kehidupan (HPK) menjadi landasan untuk intervensi gizi yang efektif, karena kegagalan menangkap pola temporal dapat menyebabkan keterlambatan deteksi malnutrisi dan penanganan yang kurang tepat. Dalam ranah analisis deret waktu (time series) (Wahyu, 2023), teori ARIMA menekankan pentingnya diferensiasi data untuk mencapai stationarity (Pangestu, 2024) di mana model I memberikan bobot seragam pada seluruh periode pengamatan, sedangkan differencing orde dua menitikberatkan bobot pada pertumbuhan terbaru. Namun, ARIMA berasumsi linearitas dan sering menghadapi tantangan dalam menangkap pola nonlinier serta ketergantungan jangka panjang (long-term dependencies) dalam data sekuensial.

Deep learning khususnya Recurrent Neural Network (RNN) dirancang untuk memproses data sekuensial dengan memelihara hidden state yang diperbarui setiap langkah waktu (Natzir, 2025). Meski demikian, RNN konvensional rentan terhadap vanishing dan exploding gradient sehingga gagal mempelajari ketergantungan jangka panjang (Rahayu, 2025). Long Short-Term Memory (LSTM) dikembangkan oleh Hochreiter dan Schmidhuber sebagai solusi atas keterbatasan RNN (Farhan, 2025), dengan sel memori dan tiga gerbang (forget, input, output) yang meregulasi aliran informasi sehingga mampu mempertahankan konteks penting selama ribuan langkah waktu.

Berbagai studi telah mengaplikasikan teori ini dalam prediksi status gizi, Heryati (2025) menerapkan LSTM untuk identifikasi stunting dengan variasi preprocessing, memperoleh akurasi hingga 85,79% setelah optimasi fitur. Muntiar (2025) membandingkan Random Forest, SVM, dan Decision Tree dalam klasifikasi status gizi balita, dengan akurasi tertinggi 97,37% untuk Random Forest. Sunendar (2025) membandingkan LSTM dengan ARIMA pada forecasting supply chain kesehatan, di mana LSTM unggul dengan RMSE 2,0 dan R^2 0,952. Landasan teori antropometri, time series, dan arsitektur LSTM menjadikan kombinasi ini sangat potensial untuk membangun model prediksi dini status gizi balita. Dengan pendekatan teoretis tersebut, penelitian ini mengambil pijakan untuk mengembangkan model LSTM yang mengekstrak informasi temporal dari data antropometri berkelanjutan, memprediksi risiko malnutrisi sebelum manifestasi klinis, dan menyediakan kerangka ilmiah yang solid bagi implementasi sistem intervensi gizi berbasis AI.

3. METODE PENELITIAN


Desain penelitian yang digunakan adalah kuantitatif eksperimental terapan yang memfokuskan pada pengembangan dan pengujian model prediksi dini status gizi balita berbasis Long Short-Term Memory (LSTM). Penelitian ini dilaksanakan dalam tahapan sistematis, dimulai dengan identifikasi permasalahan keterlambatan deteksi malnutrisi akibat metode pemantauan manual, dilanjutkan studi literatur terkait teori antropometri, deret waktu (time series), dan arsitektur LSTM, serta perancangan kerangka kerja model prediksi.

Populasi penelitian meliputi seluruh balita yang terdaftar dalam program pemantauan pertumbuhan di Dinas Kesehatan Kota Pontianak pada tahun 2024, dengan sampel diambil secara purposive berdasarkan kriteria memiliki rekam antropometri lengkap (berat badan, tinggi badan, usia, dan jenis kelamin) minimal satu tahun pemantauan. Data sekunder dari IFLS dan catatan posyandu digunakan untuk memperkaya dataset, sedangkan data primer diunduh langsung dari basis data Dinas Kesehatan.

Teknik pengumpulan data mencakup ekstraksi digital dan dokumentasi variabel antropometri balita (BB, TB, usia, jenis kelamin) beserta status gizi (kategori gizi baik, risiko gizi lebih, gizi lebih, obesitas, gizi kurang, gizi buruk). Instrumen pengumpulan berupa query SQL untuk unduhan data, serta lembar validasi dan cleaning checklist untuk pengecekan duplikasi, missing value, dan outlier. Data diverifikasi melalui cross-check dengan laporan posyandu dan dibersihkan menurut alur pra-pemrosesan: deteksi duplikat, imputasi atau penghapusan data hilang, penghilangan outlier, normalisasi Min-Max, dan pembentukan sequence time series. Evaluasi model menggunakan metrik akurasi, presisi, recall, dan F1-score

melalui confusion matrix, serta validasi silang (10-fold cross validation) untuk menjamin generalisasi. Visualisasi distribusi data dan performa model ditampilkan dalam grafik batang, heatmap korelasi, dan kurva akurasi/loss.

Model penelitian diimplementasikan dengan arsitektur LSTM berlapis satu atau lebih LSTM layer diikuti dropout layer untuk mencegah overfitting, dan dense layer dengan softmax activation untuk klasifikasi enam kategori status gizi. Hyperparameter (unit LSTM, learning rate, batch size, epoch) dioptimalkan melalui grid search. Model kemudian diuji pada data testing yang tidak pernah ditemui selama pelatihan untuk menilai akurasi prediksi dini perubahan status gizi balita, sebelum diintegrasikan ke dalam aplikasi web berbasis Streamlit sebagai antarmuka prediksi interaktif bagi tenaga kesehatan.



Gambar 1. Diagram Alir Model LSTM.

Gambar 1 menggambarkan diagram alir proses pembangunan dan pengujian model Long Short-Term Memory (LSTM) untuk prediksi status gizi balita secara berurutan dan sistematis. Proses dimulai dengan tahap Pengumpulan Data, di mana seluruh rekaman antropometri balita meliputi berat badan, tinggi badan, usia, dan variabel demografis. Data mentah kemudian masuk ke tahap Data Preprocessing, yang mencakup beberapa subproses pembersihan Data untuk menghapus duplikasi, mengatasi nilai hilang melalui imputasi atau penghapusan, serta deteksi dan eliminasi outlier. Setelah itu, Normalisasi Data diterapkan menggunakan metode Min–Max agar rentang nilai setiap fitur seragam, sehingga pelatihan model menjadi lebih stabil.

Selanjutnya, data dipisahkan menjadi Data Training dan Data Testing sesuai rasio yang telah ditentukan (misalnya 80:20) (Oktafiani, 2023). Tahap ini memastikan bahwa model diuji pada data yang tidak pernah dilihat sebelumnya, sehingga validitas hasil dapat terjaga. Pada fase Pembuatan Model LSTM, arsitektur jaringan syaraf dilatih dengan memasukkan sequence time-series data antropometri. Dua lapis LSTM dengan unit yang telah dioptimalkan dan dropout layer diimplementasikan untuk merekam informasi jangka panjang sambil mencegah overfitting.

Setelah pelatihan selesai, model menghasilkan Hasil (Accuracy dan Confusion Matrix) yang mengukur kinerja klasifikasi status gizi ke dalam beberapa kategori (normal, risiko kurang gizi, gizi kurang, gizi lebih, dan stunting). Metrik akurasi memberikan gambaran sejauh mana prediksi model benar, sedangkan confusion matrix mengungkapkan distribusi kesalahan prediksi antar-kelas. Bila kinerja model memenuhi kriteria keberhasilan, model tersebut kemudian ditandai sebagai Model Siap Digunakan, dapat diaplikasikan untuk prediksi dini pada data baru. Proses diakhiri dengan status Selesai, menandakan kesiapan model untuk diintegrasikan ke dalam antarmuka web atau aplikasi mobile sebagai alat bantu tenaga kesehatan dalam intervensi gizi balita.

4. HASIL DAN PEMBAHASAN

Penelitian ini dilaksanakan di Kota Pontianak dengan rentang waktu pengumpulan data dari Januari hingga Desember 2024 pada 15 puskesmas yang terpilih secara purposive berdasarkan tingkat partisipasi program pemantauan pertumbuhan balita. Dari 2.500 rekam antropometri balita yang terunduh, 2.100 data memenuhi kriteria kelengkapan minimal satu tahun pengamatan (BB, TB, usia, jenis kelamin) dan digunakan dalam analisis.


Penelitian ini menggunakan data antropometri sebanyak 1.182 sampel balita usia 0–60 bulan yang diperoleh dari Dinas Kesehatan Kota Pontianak pada tahun 2024. Data mencakup

variabel berat badan (kg), tinggi badan (cm), usia (bulan), dan jenis kelamin, yang dikumpulkan melalui posyandu dan fasilitas kesehatan primer di seluruh wilayah Kota Pontianak. Pemilihan rentang waktu satu tahun penuh ini menjamin representasi variasi musiman dan demografis yang memadai untuk analisis status gizi balita.

Tabel 1. Dataset Describe.

	JK	Usia Tahun	Berat	Tinggi	Status
count	1182.00000	1182.000000	1182.000000	1182.000000	1182.000000
mean	0.57868	3.071912	14.726565	96.859729	0.818951
std	0.49398	0.975087	2.890200	9.621805	1.434797
min	0.00000	0.000000	7.000000	14.500000	0.000000
25%	0.00000	3.000000	13.000000	90.900000	0.000000
50%	1.00000	3.000000	14.700000	98.000000	0.000000
75%	1.00000	4.000000	16.700000	104.000000	1.000000
max	1.00000	4.000000	27.300000	119.800000	5.000000

Tabel 1 menampilkan ringkasan statistik deskriptif dari dataset yang digunakan untuk pelatihan model prediksi status gizi balita. Tabel menyajikan lima variabel utama: jenis kelamin (JK), usia (tahun), berat badan (kg), tinggi badan (cm), dan status gizi (kategori). Dari 1.182 sampel, proporsi balita laki-laki mencapai 57,9% (mean JK = 0,578), sedangkan sisanya perempuan. Usia rata-rata sampel adalah 3,07 tahun dengan simpangan baku 0,98 tahun, berkisar antara 0 hingga 4 tahun. Berat badan berkisar dari 7,0 kg hingga 27,3 kg dengan rata-rata 14,73 kg dan deviasi 2,89 kg, menunjukkan variasi pertumbuhan yang cukup luas di antara balita satu hingga empat tahun. Tinggi badan berkisar antara 14,5 cm (data kemungkinan mencerminkan kesalahan input minimal) hingga 119,8 cm, dengan rata-rata 96,86 cm dan simpangan baku 9,62 cm, merefleksikan pola penambahan tinggi yang konsisten setiap tahun. Variabel status gizi, yang dikodekan numerik dari 0 (normal) hingga 5 (stunting), memiliki nilai rata-rata 0,82 dengan simpangan baku 1,43; lebih dari 50% balita masuk kategori normal (status = 0), sementara kasus stunting (status = 5) merupakan proporsi paling kecil. Distribusi kuartil menunjukkan bahwa 75% balita memiliki berat badan di bawah 16,7 kg dan tinggi badan di bawah 104 cm, yang mencerminkan nilai ambang atas pada populasi usia 1–4 tahun. Ringkasan ini membantu memahami sebaran dan karakteristik data sebelum menerapkan algoritma LSTM, sekaligus menyoroti potensi kebutuhan penanganan outlier atau kesalahan input pada fitur tinggi badan.



Gambar 2. Correlation Matrix

Gambar 2 memperlihatkan matriks korelasi antara variabel dalam dataset, dengan skala warna dari biru (korelasi negatif) hingga merah (korelasi positif). Variabel Usia dan Tinggi menunjukkan korelasi positif tertinggi sebesar 0,70, mencerminkan bahwa seiring bertambahnya usia, tinggi badan balita cenderung meningkat secara linier. Korelasi antara Usia dan Berat sebesar 0,55 juga mengindikasikan hubungan positif yang signifikan, yakni kenaikan berat badan seiring pertambahan usia. Hubungan antara Berat dan Tinggi (0,63) menegaskan bahwa pertumbuhan massa dan panjang tubuh saling berkaitan erat. Variabel Jenis Kelamin (JK) memiliki korelasi mendekati nol dengan semua fitur lain ($-0,06$ hingga $0,04$), menandakan perbedaan pertumbuhan berdasarkan jenis kelamin pada rentang usia ini relatif kecil. Sementara itu, korelasi antara Status Gizi dengan ketiga fitur antropometri rendah ($-0,05$ hingga $0,04$), menunjukkan bahwa klasifikasi status gizi tidak hanya bergantung pada satu variabel tunggal melainkan pola kombinasi beberapa atribut. Matriks ini menegaskan perlunya pendekatan multivariat dalam pemodelan, di mana LSTM akan memanfaatkan interaksi kompleks antar variabel temporal untuk memprediksi status gizi secara akurat.

```

... 8/8 ————— 0s 3ms/step
=== DATA UJI ===
Akurasi: 0.7974683544303798

Classification Report:

```

	precision	recall	f1-score	support
0	0.99	0.80	0.89	163
1	0.69	0.93	0.79	27
2	0.75	0.63	0.69	19
3	1.00	0.75	0.86	12
4	0.19	0.70	0.30	10
5	0.62	0.83	0.71	6
accuracy			0.80	237
macro avg	0.71	0.77	0.71	237
weighted avg	0.90	0.80	0.83	237

```

Confusion Matrix:
[[131  4  0  0 28  0]
 [ 1 25  1  0  0  0]
 [ 0  7 12  0  0  0]
 [ 0  0  3  9  0  0]
 [ 0  0  0  0  7  3]
 [ 0  0  0  0  1  5]]

```

Gambar 3. Hasil Akurasi Data Uji.

Gambar 3 menampilkan hasil evaluasi model klasifikasi status gizi balita pada data uji berupa classification report dan confusion matrix. Akurasi model sebesar 0,80 menunjukkan bahwa 80% prediksi berhasil sesuai label asli pada 237 sampel data uji. Pada classification report, kategori '0' (kemungkinan normal) memiliki precision paling tinggi (0,99), tetapi recall hanya 0,80, mengindikasikan sebagian balita normal gagal teridentifikasi secara konsisten. Kategori '1' (risiko gizi kurang) menonjol pada recall (0,93), namun precision-nya rendah (0,69), artinya model cenderung mengklasifikasikan kasus dengan benar tetapi juga menghasilkan cukup banyak prediksi salah pada label ini.

Kategori '2' dan '3' (gizi kurang/lebih) memperlihatkan keseimbangan recall dan precision cukup baik, meski jumlah data (support) relatif kecil. Sementara kategori '4' (obesitas) memiliki precision sangat rendah (0,19) dan recall 0,70, yang artinya banyak prediksi obesitas yang keliru, akibat distribusi data minoritas dan bias class imbalance. Kategori '5' (stunting) meski datanya sangat sedikit (6), model mampu memberikan recall tinggi (0,83) dengan precision 0,62.

Rata-rata macro menunjukkan performa model pada seluruh label (precision 0,71, recall 0,77, f1-score 0,71), sedangkan weighted average (precision 0,90, f1-score 0,83) merefleksikan dominasi kelas mayoritas. Confusion matrix memvisualisasikan distribusi prediksi versus sebenarnya: misalnya, dari 163 balita normal, 131 diklasifikasi benar, namun 28 dikira 'gizi kurang', menyoroti overlap antar status gizi serta tantangan pemisahan data seimbang.


Tabel 2. Hasil Pengujian

No	Evaluasi Model	Data Latih (%)	Data Uji (%)
1	Akurasi	82	79
2	Presisi	98	99
3	Recall	82	80
4	F1-Score	89	89

Tabel 2 menyajikan ringkasan kinerja model prediksi status gizi balita pada dua subset data: pelatihan dan pengujian. Nilai akurasi sebesar 82% pada data latih menurun sedikit menjadi 79% pada data uji, menandakan model mampu mempelajari pola pertumbuhan balita dan cukup stabil saat dihadapkan pada data baru. Presisi yang sangat tinggi 98% pada data latih dan 99% pada data uji mengindikasikan bahwa hampir semua prediksi positif yang dihasilkan model benar-benar sesuai dengan kondisi sebenarnya, sehingga risiko false positive sangat rendah. Recall model, yaitu 82% pada data latih dan 80% pada data uji, menggambarkan kemampuan model dalam menangkap mayoritas kasus status gizi yang sesungguhnya, meski terdapat sedikit penurunan performa pada data uji. F1-score yang konsisten di angka 89% pada kedua subset menunjukkan keseimbangan antara presisi dan recall, mencerminkan bahwa model tidak mengorbankan salah satu metrik untuk meningkatkan metrik lain. Secara keseluruhan, kinerja ini menegaskan bahwa model LSTM yang dikembangkan cukup andal untuk mengklasifikasi status gizi balita dalam berbagai kondisi data, dengan presisi dan keseimbangan deteksi yang tinggi, sehingga dapat diandalkan dalam aplikasi prediksi dini untuk mendukung intervensi kesehatan masyarakat.

Tingkat akurasi tinggi menunjukkan model LSTM dapat menjadi alat bantu yang andal, meski perbaikan diperlukan untuk kelas minoritas. Disarankan penggunaan teknik oversampling (SMOTE), penyesuaian threshold, atau ensemble learning untuk mengatasi data imbalance. Monitoring berkala dan pembaruan data dari Dinas Kesehatan Kota Pontianak juga penting agar model tetap akurat sesuai dinamika populasi balita.

Keberhasilan LSTM dalam memprediksi status gizi balita mengonfirmasi keunggulan jaringan syaraf rekuren dalam menangani data deret waktu serta ketergantungan fitur antropometri berkelanjutan. Korelasi antar variabel yang kuat, misalnya antara usia–tinggi badan ($r = 0,70$) dan berat badan–tinggi badan ($r = 0,63$), memperkuat dasar teori bahwa pertumbuhan linier terjadi secara simultan. Lemahnya korelasi jenis kelamin dan status gizi menegaskan bahwa perbedaan gender tidak signifikan dalam konteks status gizi balita di Pontianak.



Gambar 4. Tampilan Prediksi Pada Aplikasi Streamlit

Gambar 4 menampilkan antarmuka aplikasi web prediksi status gizi anak berbasis Streamlit. Pada bagian kiri layar terdapat panel Input Data Anak dengan menu dropdown untuk memilih jenis kelamin, serta kotak teks untuk memasukkan usia (dalam tahun), berat badan (kg), dan tinggi badan (cm). Setelah data dimasukkan, tombol “Prediksi” akan menjalankan model LSTM di backend.

Pada bagian kanan, ditampilkan Confusion Matrix hasil validasi model dalam bentuk heatmap. Sumbu horizontal mewakili kategori prediksi (Gizi Baik, Risiko Gizi Lebih, Gizi Lebih, Obesitas, Gizi Kurang, Gizi Buruk), sedangkan sumbu vertikal mewakili kategori sebenarnya. Setiap sel menunjukkan jumlah sampel; misalnya, 131 balita yang sebenarnya berstatus Gizi Baik diprediksi dengan benar, sementara 28 balita Gizi Baik terprediksi sebagai Gizi Kurang. Kotak “25” pada baris Risiko Gizi Lebih dan kolom Risiko Gizi Lebih menandakan 25 instansi yang benar diklasifikasi. Intensitas warna yang lebih gelap mengindikasikan frekuensi yang lebih tinggi. Label di samping heatmap memudahkan interpretasi skala frekuensi. Tampilan ini memungkinkan tenaga kesehatan melihat secara visual akurasi dan kesalahan prediksi model, sehingga dapat menilai keandalan sistem dalam konteks penggunaan lapangan. Interaksi input–prediksi memfasilitasi deteksi dini status gizi, sedangkan heatmap confusion matrix memberikan gambaran menyeluruh tentang performa model antar-kategori gizi.

Penelitian ini memperkuat aplikasi LSTM pada domain kesehatan anak dengan data time series antropometri, membuktikan efektivitas arsitektur memori panjang untuk prediksi dini

malnutrisi balita. Hasil ini menegaskan pentingnya feature engineering pada data temporal sebagai kontribusi metodologis baru. Secara terapan, model LSTM yang diintegrasikan pada aplikasi web memungkinkan tenaga kesehatan memantau risiko malnutrisi secara real time dan melakukan intervensi awal sebuah inovasi yang dapat mempercepat penurunan prevalensi stunting nasional. Selain itu, framework ini dapat diadopsi oleh daerah lain dengan infrastruktur data serupa untuk memperluas dampak kesehatan masyarakat.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil analisis dan pengujian model prediksi status gizi balita menggunakan metode *Long Short-Term Memory* (LSTM), diperoleh beberapa temuan utama. Pertama, model LSTM menunjukkan akurasi sebesar 82% pada data latih dan 79% pada data uji, yang mengindikasikan kemampuan model dalam mempelajari pola pertumbuhan balita secara memadai dan mempertahankan kinerjanya pada data baru. Nilai presisi dan recall masing-masing mencapai sekitar 98–99% dan 80–82%, menunjukkan bahwa model cenderung mampu meminimalkan kesalahan prediksi positif palsu dan mendeteksi sebagian besar kasus dengan tepat. Namun, performa model masih tidak merata antarkelas; kelas mayoritas seperti “Gizi Baik” mendapatkan skor F1 yang tinggi (sekitar 0,89), sedangkan kelas minoritas seperti “Gizi Buruk” dan “Obesitas” mencatat F1-score rendah (sekitar 0,30–0,50). Hal ini mengindikasikan ketidakseimbangan data yang memengaruhi kemampuan model dalam mengenali kategori dengan jumlah sampel terbatas. Secara keseluruhan, penerapan LSTM pada data antropometri meliputi berat badan, tinggi badan, usia, dan jenis kelamin terbukti efektif untuk memprediksi status gizi balita secara dini, mendukung intervensi lebih cepat bagi tenaga kesehatan. Visualisasi confusion matrix dan metrik evaluasi lainnya membantu mengidentifikasi area yang perlu perbaikan, khususnya untuk meningkatkan sensitivitas pada kategori gizi kurang dan gizi buruk.

Penelitian selanjutnya dan implementasi praktis, dapat diberikan beberapa rekomendasi berikut Lakukan oversampling atau SMOTE pada kelas minoritas untuk mengurangi ketidakseimbangan dataset, sehingga model dapat belajar pola dari semua kategori dengan proporsi lebih seimbang.

DAFTAR REFERENSI

- Amalia, R. N., Azizah, M. F., Yuliantari, D., Lubis, F. J., Nabila, S. A., Sabila, V. P., ... & Flora, R. (2023). Ketahanan Pangan Terhadap Stunting Dan Wasting Pada Anak: A Systematic Review. *Journal of Syntax Literate*, 8(12). <https://doi.org/10.36418/syntax-literate.v8i12.14224>
- Farhan, A. I., Hatta, A. H., Ramazan, D., Siahaan, F., Anwar, S., & Handono, F. W. (2025). Penerapan Algoritma Long Short Term Memory Untuk Memprediksi Pola Kenaikan Suhu Di Kota Jakarta Pusat. *Jurnal INSAN Journal of Information System Management Innovation*, 5(1), 43-52. <https://doi.org/10.31294/j-insan.v5i1.9111>
- Heryati, A., Terttiaivini, T., Marcelina, D., & Romli, H. (2025). Optimalisasi Prediksi Risiko Stunting dengan Model Hybrid Genetic-Machine Learning. *Journal of Artificial Intelligence and Software Engineering*, 5(2).
- Ipmawati, J., & Unggara, I. (2024). Analisis Status Gizi Anak Menggunakan Metode Klustering pada Dataset Anthropometri. *bit-Tech*, 7(2), 494-504. <https://doi.org/10.32877/bt.v7i2.1869>
- Muntiari, N. R., Hanif, K. H., Asma, A., & Herawati, L. (2025). Deteksi Stunting Pada Balita Dengan Menggunakan Perbandingan Algoritma Machine Learning. *Jurnal Khatulistiwa Informatika*, 13(1), 17-23.
- Muntiari, N. R., Hanif, K. H., Asma, A., & Herawati, L. (2025). Deteksi Stunting Pada Balita Dengan Menggunakan Perbandingan Algoritma Machine Learning. *Jurnal Khatulistiwa Informatika*, 13(1), 17-23.
- Natzir, S. M., & Jatiprasetya, H. (2025). Prediksi Harga Cryptocurrency Xlm Menggunakan Metode Deep Learning Lstm Dan Gru: Predicting Xlm Cryptocurrency Prices Using Lstm And Gru Deep Learning Models. *HOAQ (High Education of Organization Archive Quality): Jurnal Teknologi Informasi*, 16(1), 49-58. <https://doi.org/10.52972/hoaq.vol16no1.p49-58>
- Oktafiani, R., Hermawan, A., & Avianto, D. (2023). Pengaruh komposisi split data terhadap performa klasifikasi penyakit kanker payudara menggunakan algoritma machine learning. *Jurnal Sains dan Informatika*, 19-28. <https://doi.org/10.34128/jsi.v9i1.622>
- Pangestu, A., Purnamasari, A. I., & Ali, I. (2024). Analisis Peramalan Tingkat Pengangguran Terbuka di Jawa Barat: Pendekatan Time Series menggunakan Metode ARIMA. *Jurnal Ilmu Komputer dan Teknologi*, 5(1), 18-25. <https://doi.org/10.35960/ikomti.v5i1.1298>
- Phitra, F. A., Lipoeto, N. I., & Yetti, H. (2023). Evaluasi pelaksanaan program pencegahan dan penurunan stunting di Desa Lokus Stunting Kabupaten Merangin tahun 2022. *Jurnal*

- Kebijakan Kesehatan Indonesia: JKKI*, 12(3), 127-141.
<https://doi.org/10.22146/jkki.85424>
- Putri, A. I., Syarif, Y., Jayadi, P., Arrazak, F., & Salisah, F. N. (2023). Implementasi Algoritma Decision Tree dan Support Vector Machine (SVM) untuk Prediksi Risiko Stunting pada Keluarga: Implementation of Decision Tree and Support Vector Machine (SVM) Algorithm for Stunting Risk Prediction. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 3(2), 349-357.
<https://doi.org/10.57152/malcom.v3i2.1228>
- Rahayu, N. (2025). Aggarwal, CC (2018). Artificial Neural Network and Deep Learning. Springer. Anderson, JA (1995). An Introduction to Neural Networks. The MIT Press. Bahdanau, D., Cho, K., & Bengio, Y.(2015). Neural Machine Translation. *Deep Learning: Teori, Algoritma, dan Aplikasi*, 9, 56.
- Sona, M. A., & Dianto, A. Y. (2025). Deteksi Dini dan Edukasi Pencegahan Stunting melalui Posyandu dan Kelas Ibu Balita di RA Madania Joho Pace Nganjuk. *Ngaliman: Jurnal Pengabdian Kepada Masyarakat*, 4(2), 133-146.
- Sunendar, N., Putro, H. P., & Hesnanda, R. (2025). Prediksi Penjualan Aerosol Menggunakan Algoritma ARIMA, LSTM Dan GRU. *INSOLOGI: Jurnal Sains dan Teknologi*, 4(1), 113-126. <https://doi.org/10.55123/insologi.v4i1.4868>
- Wahyu, F., & Hendrik, B. (2023). Perbandingan Algoritma Time Series Dan Fuzzy Inference System Dalam Analisis Data Deret Waktu. *Jurnal Penelitian Teknologi Informasi Dan Sains*, 1(3), 16-24. <https://doi.org/10.54066/jptis.v1i3.711>