

# Deteksi Dini Stunting pada Balita Menggunakan 1D Convolutional Neural Network (1D-CNN) pada Data Antropometri Numerik

Vidry Anggelia Siregar, Rusliyawati\*

Fakultas Teknik dan Ilmu Komputer, Program Studi Sistem Informasi, Universitas Teknokrat Indonesia, Bandar Lampung, Indonesia

Email: <sup>1</sup>vidry\_angelia\_siregar@teknokrat.ac.id, <sup>2</sup>\*rusliyawati@teknokrat.ac.id

Email Penulis Korespondensi: rusliyawati@teknokrat.ac.id

Submitted: 11/02/2026; Accepted: 31/03/2026; Published: 31/03/2026

**Abstrak**—Stunting masih menjadi tantangan utama kesehatan masyarakat di Indonesia dengan prevalensi nasional mencapai 21,6%. Dampaknya tidak hanya terbatas pada gangguan pertumbuhan fisik, tetapi juga memengaruhi perkembangan kognitif serta produktivitas jangka panjang. Deteksi dini umumnya dilakukan melalui pengukuran antropometri dan perhitungan Z-score manual, yang relatif kurang praktis serta berisiko menimbulkan kesalahan perhitungan, khususnya di wilayah dengan keterbatasan sumber daya. Penelitian ini mengusulkan pendekatan berbasis one-dimensional convolutional neural network (1D-CNN) untuk mendeteksi stunting pada balita menggunakan data antropometri numerik yaitu umur, jenis kelamin, dan tinggi badan tanpa rekayasa fitur manual. Model diuji pada 120.999 sampel dan mencapai recall 99,3%, dengan hanya 4 dari 552 kasus stunting yang tidak terdeteksi, menunjukkan kemampuan yang sangat baik dalam meminimalkan false negative pada skrining kesehatan masyarakat. Sebagai pembandingan, Random Forest memperoleh akurasi 99,9% dan F1-score 98,2%, yang mengindikasikan performa klasifikasi keseluruhan yang sangat tinggi. Meskipun demikian, 1D-CNN menawarkan keunggulan arsitektural berupa kemampuan machine learning representasi otomatis berbasis struktur sinyal satu dimensi, sehingga lebih adaptif terhadap penambahan variabel berurutan, integrasi data sensor pertumbuhan secara longitudinal, maupun pengembangan sistem monitoring berbasis IoT di masa depan. Pendekatan ini tidak hanya kompetitif dari sisi performa deteksi, tetapi juga memiliki skalabilitas dan fleksibilitas yang lebih besar untuk pengembangan sistem skrining digital yang berkelanjutan pada layanan kesehatan tingkat pertama.

**Kata Kunci:** Convolutional Neural Network; Deteksi Dini; Stunting; Balita; Data Antropometri

**Abstract**—Stunting remains a major public health challenge in Indonesia, with a national prevalence of 21.6%. Its impact extends beyond impaired physical growth to affect cognitive development and long-term productivity. Early detection is typically performed through manual anthropometric measurements and Z-score calculations, which are relatively impractical and prone to computational errors, especially in resource limited settings. This study proposes a one-dimensional convolutional neural network (1D-CNN) based approach to detect stunting in children under five using numerical anthropometric data of age, sex, and height without manual feature engineering. The model was evaluated on 120,999 samples and achieved a recall of 99.3%, with only 4 out of 552 stunting cases going undetected, demonstrating strong ability to minimize false negatives in the context of public health screening. In comparison, the Random Forest model achieved 99.9% accuracy and an F1-score of 98.2%, demonstrating excellent overall classification performance. Nevertheless, 1D-CNN offers architectural advantages through automatic representation learning based on one-dimensional signal structures, making it more adaptable to the inclusion of sequential variables, the integration of longitudinal growth sensor data, and the development of future IoT based monitoring systems. Therefore, the proposed approach is not only competitive in detection performance but also provides greater scalability and flexibility for the continued development of digital screening systems at the primary healthcare level.

**Keywords:** Convolutional Neural Network; Early Detection; Stunting; Children Under Five; Anthropometric Data

## 1. PENDAHULUAN

Stunting merupakan masalah gizi kronis akibat kekurangan nutrisi pada 1.000 hari pertama kehidupan. Secara global, kondisi ini memengaruhi sekitar 150,2 juta anak di bawah lima tahun atau 23,2% pada tahun 2024 [1]. Di Indonesia, prevalensinya masih mencapai 21,6%, jauh dari target nasional sebesar 14% [2]. Dampaknya tidak hanya berupa gangguan pertumbuhan fisik, tetapi juga peningkatan risiko keterlambatan kognitif dan penurunan produktivitas jangka panjang. Penelitian menunjukkan bahwa anak stunting memiliki skor IQ rata-rata sekitar 11 poin lebih rendah dibandingkan anak non-stunting [3]. Oleh karena itu, deteksi dini menjadi langkah strategis untuk memastikan intervensi gizi dilakukan secara tepat waktu [4][5].

Secara klinis, stunting diidentifikasi melalui indikator antropometri, khususnya Height for Age Z-score (HFA) berdasarkan standar pertumbuhan World Health Organization (WHO). Anak dikategorikan stunting apabila memiliki nilai HFA  $\leq -2$  standar deviasi dari median referensi WHO [6][7]. Meskipun reliabel, implementasi metode ini di lapangan masih bergantung pada perhitungan manual atau tabel pertumbuhan, yang rentan terhadap kesalahan dan kurang efisien, terutama di wilayah dengan keterbatasan sumber daya. Kondisi tersebut mendorong kebutuhan akan sistem skrining berbasis teknologi yang lebih otomatis, cepat, dan skalabel hingga tingkat pelayanan kesehatan dasar.

Pendekatan machine learning (ML) mulai banyak dimanfaatkan untuk mendukung deteksi stunting berbasis data antropometri. Model berbasis pohon keputusan seperti Random Forest, telah menunjukkan performa yang kuat dengan akurasi 92,7% pada penelitian lokal di Lampung [8], serta F1-score 0.922 pada dataset nasional [9]. Algoritma berbasis pohon sangat efektif dalam menangkap interaksi nonlinier melalui proses pemisahan ruang fitur secara adaptif. Namun, representasi yang dihasilkan bersifat berbasis aturan (rule-based partitioning) dan tidak membangun abstraksi fitur secara hirarki sebagaimana pada arsitektur deep learning. Sementara itu, beberapa algoritma lain seperti

Naïve Bayes mengasumsikan independensi antar fitur, yang kurang sesuai dengan korelasi alami variabel antropometri seperti umur, jenis kelamin, dan tinggi badan [10].

Di sisi lain, arsitektur one-dimensional Convolutional Neural Network (1D-CNN) telah menunjukkan performa tinggi dalam analisis sinyal biomedis, terutama pada data deret waktu seperti elektrokardiogram (EKG) [11][12]. Pada sinyal EKG, konvolusi bekerja efektif karena adanya hubungan temporal antar titik data. Perbedaan mendasar muncul ketika arsitektur ini diterapkan pada data antropometri yang bersifat vektor statis, dimana urutan fitur secara konseptual tidak memiliki makna temporal dan dapat dipertukarkan.

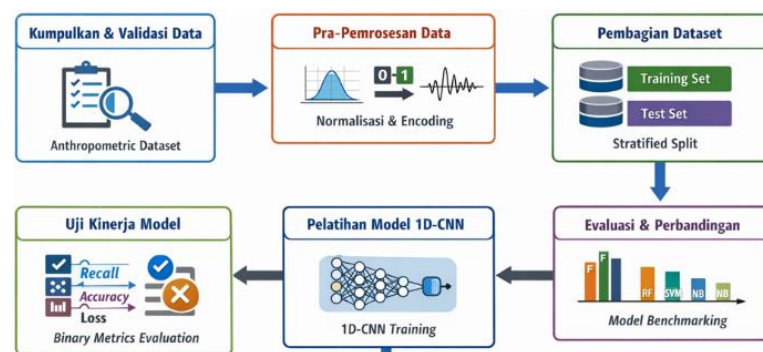
Namun demikian, konvolusi tidak semata-mata digunakan untuk menangkap hubungan temporal, melainkan pada kemampuannya menangkap interaksi lokal antar fitur dalam representasi spasial satu dimensi. Dengan menyusun fitur antropometri sebagai representasi sinyal satu dimensi, filter konvolusi dapat berfungsi sebagai mekanisme pembelajaran interaksi spesifik antar variabel yang berdekatan dalam representasi vektor, misalnya relasi antara usia dan tinggi badan dalam jenis kelamin tertentu. Dalam kerangka ini, konvolusi bertindak sebagai operator yang mengekstraksi kombinasi fitur lokal secara otomatis, yang selanjutnya diproses melalui lapisan bertingkat untuk membentuk representasi fitur yang abstrak. Pendekatan ini memungkinkan pembelajaran representasi hirarki dari relasi sederhana hingga pola kompleks tanpa memerlukan rekayasa fitur manual. Dengan demikian, meskipun data tidak bersifat temporal, vektor antropometri tetap dapat diperlakukan sebagai representasi spasial terstruktur yang relevan untuk mekanisme konvolusi. Meskipun potensinya menjanjikan, penerapan 1D-CNN pada data antropometri numerik untuk deteksi stunting masih relatif terbatas, khususnya pada dataset berskala besar dan dalam evaluasi berbasis sensitivitas klinis (recall). Sebagian besar penelitian sebelumnya masih berfokus pada pendekatan machine learning konvensional atau analisis berbasis citra.

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan untuk mengevaluasi efektivitas arsitektur 1D-CNN dalam mendeteksi stunting berbasis data antropometri numerik serta membandingkannya dengan model machine learning tradisional pada dataset berskala besar. Secara khusus, penelitian ini menitikberatkan pada analisis recall sebagai indikator utama, mengingat pentingnya meminimalkan false negative dalam skrining kesehatan masyarakat.

Penelitian ini memberikan tiga kontribusi utama, yaitu mengadaptasi arsitektur 1D-CNN untuk pemodelan data antropometri numerik tanpa rekayasa fitur manual, melakukan evaluasi komparatif terhadap model machine learning berbasis pohon keputusan pada dataset berskala besar, serta menganalisis performa model menggunakan pendekatan berbasis sensitivitas klinis guna mendukung skrining stunting yang lebih aman, akurat, dan berorientasi preventif dalam kesehatan masyarakat.

## 2. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksperimental untuk mengembangkan dan mengevaluasi model deteksi dini stunting berbasis arsitektur 1D-CNN. Tahapan penelitian dirancang secara sistematis untuk memastikan validitas metodologi, mencegah data leakage, serta memastikan reproduktibilitas eksperimen. Secara umum, proses penelitian meliputi pengumpulan dan validasi dataset, pra-pemrosesan data, pembagian dataset, pelatihan model, evaluasi serta perbandingan dengan algoritma baseline. Keseluruhan alur ditampilkan pada Gambar 1.



Gambar 1. Tahapan Penelitian

### 2.1. Pengumpulan dan Validasi Dataset

Dataset diperoleh dari sumber publik Kaggle dalam format CSV dan terdiri atas 120.999 catatan balita berusia 0–59 bulan. Pemeriksaan struktur dataset menunjukkan bahwa setiap baris merepresentasikan satu individu unik dan tidak bersifat longitudinal. Tidak ditemukan kolom identifikasi berulang ataupun indikasi pencatatan berkala terhadap individu yang sama. Apabila dataset bersifat longitudinal (misalnya satu balita memiliki beberapa catatan pada waktu berbeda), maka pembagian data harus dilakukan berbasis group split menggunakan ID individu. Namun, karena tidak terdapat indikasi pengulangan individu, pembagian berbasis baris tetap menjadi independensi antara data latih dan data uji. Dataset mencakup tiga variabel input dan satu variabel keluaran. Deskripsi riancian variabel ditampilkan pada Tabel 1.

**Tabel 1.** Deskripsi Variabel Dataset Antropometri Balita

Variabel	Tipe Data	Keterangan
Umur (bulan)	Numerik	Usia balita dalam satuan bulan
Jenis Kelamin	Kategorikal	Laki-laki atau perempuan
Tinggi Badan (cm)	Numerik	Tinggi badan balita dalam sentimeter
Status Gizi	Kategorikal	Normal, tinggi, stunted, severely stunted

Pada Tabel 1, variabel status konversi gizi menjadi klasifikasi biner dengan menggabungkan kategori stunting dan stunting berat sebagai kelas positif, sedangkan kategori lainnya ditetapkan sebagai kelas negatif. Proses validasi data dilakukan secara sistematis melalui pemeriksaan nilai hilang dan duplikasi untuk memastikan konsistensi struktur data, verifikasi rentang fisiologis setiap variabel berdasarkan standar pertumbuhan WHO guna menjaga kesesuaian klinis, serta deteksi nilai ekstrem menggunakan batas  $\pm 3$  simpangan baku untuk mengidentifikasi kemungkinan anomali. Hasil tahapan validasi tersebut menunjukkan bahwa dataset memiliki kualitas yang memadai dan layak digunakan pada proses pemodelan lebih lanjut.

## 2.2 Pra-Pemrosesan Data

Pra-pemrosesan dilakukan untuk menyesuaikan format data dengan kebutuhan algoritma. Variabel jenis kelamin dikodekan secara biner dengan laki-laki diberi label 1 dan perempuan label 0, sedangkan variabel umur dan tinggi badan dinormalisasi menggunakan Min-Max scaling ke rentang  $[0,1]$  guna menjaga stabilitas gradien selama optimisasi. Variabel keluaran status gizi dikonversi menjadi label biner, di mana kategori normal dan tinggi diberi label 0 (tidak stunting), sedangkan stunted dan stunting berat diberi label 1 (stunting).

Meskipun data tidak bersifat temporal, variabel seperti sinyal EKG, variabel umur, jenis kelamin, dan tinggi badan direpresentasikan sebagai vektor satu dimensi untuk kompatibel dengan arsitektur 1D-CNN. Dalam hal ini, konvolusi tidak dimaksudkan untuk memodelkan hubungan waktu, melainkan untuk menangkap interaksi lokal antar fitur. Filter konvolusi berperan dalam mengekstraksi kombinasi fitur seperti relasi spesifik antara umur dan tinggi badan dalam jenis kelamin tertentu. Melalui lapisan bertingkat, model membangun representasi fitur secara hirarkis tanpa rekayasa manual [11][13].

## 2.3 Pembagian Dataset

Dataset dibagi menjadi dua subset utama menggunakan metode stratified split, yaitu 80% untuk data pelatihan (96.799 sampel) dan 20% untuk data pengujian (24.200 sampel). Pendekatan ini memastikan distribusi kelas tetap proporsional, terutama karena jumlah kelas stunting lebih sedikit dibandingkan kelas non-stunting. Karena setiap baris mewakili satu individu unik, pembagian berbasis baris dinilai memadai dan tidak menimbulkan risiko kebocoran data. Data uji sepenuhnya dipisahkan dari proses pelatihan dan tidak digunakan dalam tahap penyesuaian parameter, sehingga evaluasi akhir benar-benar mencerminkan kemampuan generalisasi model tidak hanya akurat secara statistik, tetapi juga relevan secara klinis dan operasional untuk standar skrining stunting di lapangan.

## 2.4 Pelatihan Model

Model 1D-CNN dikembangkan menggunakan TensorFlow/Keras pada lingkungan Python 3.9 dengan platform Google Colab yang didukung akselerator GPU Tesla T4. Arsitektur terdiri atas dua lapisan Conv1D dengan ukuran kernel 2 dan masing-masing 32 serta 16 filter, diikuti oleh MaxPooling1D, Flatten, Dense layer dengan 16 neuron, Dropout (0,3), dan lapisan output sigmoid.

Pelatihan menggunakan biner crossentropy dengan optimizer Adam dan learning rate sebesar 0,001. Batch size ditetapkan 32 dengan maksimum 50 epoch. Mengingat jumlah fitur hanya tiga dan dataset relatif besar, model menunjukkan konvergensi cepat pada fase awal pelatihan. Untuk menghindari overfitting, diterapkan mekanisme early stopping berdasarkan validation loss.

Terkait hyperparameter tuning, penelitian ini tidak melakukan pencarian hyperparameter secara ekstensif seperti grid search atau bayesian optimization. Konfigurasi yang digunakan mengacu pada konfigurasi yang umum dan stabil dalam literatur 1D-CNN untuk klasifikasi biner. Pendekatan ini dipilih untuk menjaga konsistensi eksperimen dan memastikan perbandingan yang adil dengan model baseline. Namun demikian, eksplorasi hyperparameter lebih lanjut berpotensi meningkatkan performa model dan menjadi agenda penelitian lanjutan.

## 2.5 Evaluasi dan Perbandingan Model

Evaluasi dilakukan menggunakan metrik akurasi, presisi, recall, F1-score, dan Area Under the Curve (AUC). Recall dijadikan indikator utama dalam skrining kesehatan masyarakat, kegagalan mendeteksi kasus stunting (false negative) dapat berdampak serius terhadap intervensi dini. Model dibandingkan dengan Random Forest, K-Nearest Neighbors (KNN), Support Vector Machine (SVM), dan Naïve Bayes menggunakan pipeline pra-pemrosesan identik. Random forest dikenal efektif dalam menangkap interaksi nonlinier melalui partisi ruang fitur adaptif. Namun, berbeda dengan pendekatan berbasis pohon keputusan, 1D-CNN membangun representasi fitur hirarkis melalui transformasi konvolusional bertingkat, yang memungkinkan pembentukan abstraksi fitur lebih kompleks. Seluruh model dievaluasi pada data uji yang sama untuk memastikan perbandingan objektif dan reproduktibel.

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Kualitas Dataset dan Validasi Awal

Dataset yang digunakan dalam penelitian ini terdiri atas 120.999 catatan balita berusia 0–59 bulan dengan rentang tinggi badan 40–120 cm. Rentang tersebut berada dalam batas fisiologi yang konsisten dengan standar pertumbuhan WHO, mencakup  $\pm 3$  simpangan baku dari median panjang/tinggi badan menurut umur. Pemeriksaan awal menunjukkan tidak terdapat nilai hilang (*missing values*), duplikasi entri, maupun data yang berada di luar batas biologis wajar.

Kualitas data yang baik menjadi prasyarat utama dalam penelitian berbasis ML. Tidak ditemukannya anomali struktural memungkinkan proses pemodelan dilakukan tanpa tahapan imputasi atau pembersihan tambahan yang berpotensi memperkenalkan bias. Performa model yang diperoleh dapat diinterpretasikan sebagai refleksi kemampuan algoritma dalam mempelajari pola hubungan antara variabel bukan sebagai artefak manipulasi data. Label status gizi ditentukan berdasarkan perhitungan HFA sesuai standar WHO, dengan ambang  $\leq -2$  SD) sebagai kategori stunting. Konsekuensinya, terdapat hubungan matematis eksplisit antara umur, jenis kelamin, tinggi badan, dan status stunting. Karakteristik ini menjadikan permasalahan klasifikasi bersifat hampir deterministik, karena batas keputusan telah terdefinisi melalui aturan klinis yang jelas.

#### 3.2 Pra-Pemrosesan Data dan Representasi Fitur

Seluruh dataset berhasil ditransformasikan ke dalam format siap model tanpa kehilangan integritas informasi. Variabel jenis kelamin dikodekan secara biner (laki-laki = 1, perempuan = 0), sedangkan variabel numerik umur dan tinggi badan dinormalisasi menggunakan Min-Max scaling agar berada dalam rentang [0,1]:

$$x^1 = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Normalisasi ini bertujuan menjaga stabilitas gradien selama pelatihan model 1D-CNN dan memastikan kontribusi numerik setiap fitur berada dalam skala yang sebanding. Label status gizi diklasifikasi ke dalam dua kategori biner yaitu: (1) tidak stunting, yang mencakup kategori normal dan tinggi (HFA  $> -2$  SD), dan (2) stunting, yang mencakup kategori stunted (HFA  $\leq -2$  SD) dan severely stunted (HFA  $< -3$  SD) [6]. Penggabungan kategori ini selaras dengan praktik deteksi dini, di mana seluruh anak di bawah ambang  $-2$  SD dipandang memerlukan perhatian intervensi.

Setelah transformasi, setiap sampel direpresentasikan sebagai vektor tiga dimensi:

$$x = [umur, jenis_kelamin, tinggi_badan]^T \quad (2)$$

Vektor tersebut kemudian di-reshape menjadi matriks berukuran (3,1) untuk memungkinkan penerapan lapisan Conv1D. Meskipun tidak memiliki struktur temporal, pendekatan ini memungkinkan lapisan konvolusi mempelajari kombinasi lokas antar fitur numerik. Dalam penelitian ini, konvolusi berfungsi untuk membangun representasi fitur secara bertahap, bukan untuk menangkap urutan waktu, melainkan untuk membangun representasi bertingkat yang merefleksikan kombinasi hubungan antar variabel antropometri.

#### 3.3 Pembagian Dataset dan Validitas Evaluasi

Dataset dibagi menggunakan metode stratified split dengan proporsi 80% (96.799 sampel) data latih dan 20% (24.200 sampel) data uji. Pada subset uji terdapat 552 kasus stunting dari total 24.200 sampel. Pembagian secara stratifikasi memastikan distribusi kelas tetap proporsional, sehingga evaluasi model mencerminkan kondisi prevalensi aktual. Karena setiap baris dataset merepresentasikan satu individu unik dan tidak bersifat longitudinal, pembagian berbasis baris dinilai memadai untuk menghindari data leakage. Tidak terdapat ID ganda yang berpotensi menyebabkan informasi individu yang sama muncul pada data latih dan data uji.

#### 3.4 Pelatihan Model 1D-CNN

Model 1D-CNN diimplementasikan menggunakan TensorFlow/Keras pada lingkungan Python 3.9 dengan dukungan GPU NVIDIA Tesla T4. Arsitektur dirancang secara proporsional terhadap karakteristik data yang digunakan, yaitu data antropometri dengan jumlah fitur terbatas namun memiliki hubungan matematis yang kuat. Input berbentuk matriks (3.1) diproses melalui dua lapisan Conv1D berturut-turut dengan 32 dan 16 filter serta ukuran kernel 2. Pemilihan kernel berukuran 2 dimaksudkan untuk memungkinkan model mempelajari interaksi lokal antar pasangan fitur, seperti hubungan antara umur dan tinggi badan atau antara tinggi badan dan jenis kelamin.

Setiap lapisan konvolusi menggunakan fungsi aktivasi ReLU untuk memperkenalkan non-linearitas, sehingga model mampu merepresentasikan pola hubungan yang tidak sepenuhnya linear. Setelah proses konvolusi, diterapkan MaxPolling ID untuk mereduksi dimensi sekaligus mempertahankan respons fitur yang paling dominan. Representasi ini kemudian diratakan melalui lapisan Flatten dan diteruskan ke Dense Layer dengan 16 neuron sebagai tahap integrasi informasi global sebelum dilakukan klasifikasi akhir menggunakan fungsi aktivasi sigmoid.

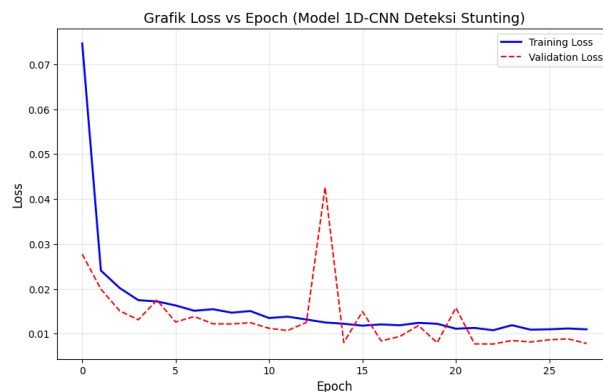
Proses model pelatihan dilakukan dengan meminimalkan fungsi kerugian biner cross-entropy, yang mengukur perbedaan antara probabilitas prediksi dan label aktual pada skema klasifikasi biner. Parameter optimasi dilakukan menggunakan algoritma Adam dengan learning rate sebesar 0,001, yang dipilih karena kemampuan menyesuaikan

laju pembelajaran secara adaptif melalui estimasi momen pertama dan kedua gradien sehingga mendukung konvergensi yang stabil. Rincian konfigurasi pelatihan disajikan pada Tabel 2, yang menunjukkan bahwa pengaturan eksperimen dirancang sesuai dengan kompleksitas data yang relatif rendah. Ukuran batch sebesar 32 digunakan untuk menjaga keseimbangan antara efisiensi komputasi dan kestabilan pembaruan gradien. Untuk menghindari overfitting, diterapkan mekanisme penghentian dini dengan parameter kesabaran lima epoch berdasarkan pemantauan validasi loss, yang secara otomatis menghentikan proses pelatihan pada epoch ke-27 ketika tidak lagi terjadi perbaikan yang signifikan.

**Tabel 2.** Konfigurasi Pelatihan dan Optimasi Model 1D-CNN

Komponen	Nilai/Spesifikasi
Fungsi Kerugian (loss)	Binary Crossentropy
Optimizer	Adam
Learning Rate	0.001
Metrik Evaluasi	Accuracy
Ukuran Batch	32
Jumlah Epoch Maksimal	50
Early Stopping	Diaktifkan (patience=5 epoch)

Kurva training loss dan validation loss yang disajikan pada Gambar 2 menunjukkan pola penurunan yang konsisten dan relatif paralel hingga epoch ke-27. Tidak terdapat divergensi yang signifikan antara kedua kurva, yang umumnya menjadi indikator awal terjadinya overfitting. Pola konvergensi yang stabil ini menunjukkan bahwa kapasitas model seimbang dengan kompleksitas data, sehingga proses pembelajaran berlangsung secara terkendali. Mengingat input hanya terdiri atas tiga fitur dengan hubungan yang terstruktur, ruang representasi yang dipelajari relatif sederhana, memungkinkan model mencapai titik optimal tanpa mengalami gradien instabilitas.



**Gambar 2.** Grafik Perbandingan Loss dengan Epoch (Model 1D-CNN Deteksi Stunting)

Total waktu pelatihan tercatat sebesar 8 menit 12 detik untuk 96.799 sampel data latihan. Durasi ini mencerminkan efisiensi arsitektur 1D-CNN yang digunakan, baik dari sisi jumlah parameter maupun kompleksitas komputasi. Dibandingkan dengan arsitektur CNN pada citra data yang umumnya melibatkan jutaan parameter, model ini tergolong ringan dan tidak memerlukan sumber daya komputasi tinggi. Efisiensi tersebut menunjukkan potensi implementasi pada perangkat dengan kapasitas terbatas, seperti sistem pendukung keputusan berbasis web atau aplikasi skrining di tingkat layanan kesehatan primer. Secara keseluruhan, hasil pelatihan menyatakan bahwa arsitektur 1D-CNN yang proporsional terhadap karakteristik data sudah memadai untuk memodelkan hubungan antarvariabel antropometri secara stabil dan efektif.

### 3.5 Evaluasi Perbandingan Model

Evaluasi dilakukan terhadap lima model Random Forest, KNN, SVM, Naïve Bayes, dan 1D-CNN menggunakan data uji independen. Kinerja masing-masing model diukur berdasarkan metrik akurasi, presisi, recall, F1-score, dan AUC sebagaimana dirangkum pada Tabel 3.

**Tabel 3.** Performa Model pada Data Uji Independen


Model	Akurasi (%)	Presisi (%)	Recall (%)	F1-Score (%)	AUC
Random Forest	99.9	97.8	98.6	98.2	1.0
KNN	99.8	96.7	96.2	96.5	1.0
SVM	99.6	100.0	84.1	91.3	1.0
Naïve Bayes	97.7	39.7	5.3	9.3	0.9
1D-CNN	99.6	84.2	99.3	91.1	1.0

Berdasarkan Tabel 3, Random Forest menunjukkan performa paling seimbang dengan akurasi 99,9%, presisi 97,8%, recall 98,6%, dan F1-score 98,2%. Kombinasi ini mencerminkan stabilitas mekanisme ansambel berdasarkan keputusan pohon dalam mempartisi ruang fitur secara konsisten. Model KNN juga menghasilkan performa tinggi dengan akurasi 99,8% dan F1-score 96,5%, meskipun sedikit di bawah Random Forest dalam seluruh metrik utama. Sementara itu, 1D-CNN mencapai recall tertinggi sebesar 99,3%, yang berarti hanya 4 dari 552 kasus stunting pada data uji yang tidak terdeteksi. Hal ini menunjukkan keunggulan model dalam meminimalkan false negative, meskipun presisinya (84,2%) lebih rendah dibandingkan Random Forest.

Empat model yaitu Random Forest, KNN, SVM, dan 1D-CNN memperoleh nilai AUC sebesar 1,0, yang secara statistik mengindikasikan kemampuan diskriminasi yang sangat tinggi antara kelas stunting dan non-stunting. Namun, pencapaian ini perlu diinterpretasikan secara proporsional. Status stunting pada dataset ditentukan langsung melalui perhitungan Height-for-Age Z-score (HFA) berdasarkan standar WHO, yang merupakan fungsi matematis eksplisit dari usia, jenis kelamin, dan tinggi badan. Dengan demikian, hubungan antara variabel input dan target bersifat deterministik. Akurasi dan AUC yang mendekati sempurna dimungkinkan karena model pada dasarnya mereplikasi fungsi ambang klinis tersebut dengan presisi tinggi, bukan semata-mata karena algoritma superioritas.

Perbedaan karakteristik antar model tetap terlihat pada distribusi metrik. Random Forest unggul dalam keseimbangan global antara presisi dan recall, sehingga menghasilkan skor F1 tertinggi. Sebaliknya, 1D-CNN lebih menonjol dari sisi sensitivitas, yang relevan dalam pemeriksaan kesehatan masyarakat karena kesalahan berupa kasus tidak terdeteksi memiliki kekuatan intervensi yang lebih serius dibandingkan kesalahan positif palsu. SVM menunjukkan presisi 100% namun recall 84,1%, yang mengindikasikan kecenderungan klasifikasi konservatif dan kurang optimal untuk deteksi massal. Naïve Bayes mencatat performa terendah dengan recall 5,3% dan F1-score 9,3%, menunjukkan bahwa asumsi independensi fitur tidak sesuai dengan karakteristik data biologi antropometri yang memiliki korelasi kuat antara usia dan tinggi badan.

Meskipun seluruh model (kecuali Naïve Bayes) menunjukkan kinerja kuantitatif yang sangat tinggi, perbedaan profil metrik mewakili variasi pendekatan representasi dan strategi pemisahan ruang fitur masing-masing algoritma, yang berimplikasi pada pemilihan model sesuai tujuan operasional skrining.



**Gambar 3.** Confusion Matrix Model (a) Random Forest, (b) KNN, (c) SVM, (d) Naïve Bayes, dan (e) 1D-CNN

Gambar 3(a) menunjukkan bahwa Random Forest menghasilkan jumlah true positif yang sangat tinggi dengan false negative minimal. Pada Gambar 3(e), terlihat bahwa 1D-CNN memiliki jumlah false negative paling sedikit dibandingkan model lainnya. Sebaliknya, Gambar 3(d) menampilkan kesalahan dominasi pada kelas positif oleh Naïve Bayes, yang mengindikasikan ketidaksesuaian asumsi independensi fitur terhadap karakteristik data biologi antropometri. Visualisasi tersebut menampilkan bahwa 1D-CNN memiliki jumlah false negative paling rendah dibandingkan model lain, sedangkan Naïve Bayes didominasi oleh kesalahan pada kelas stunting. Random Forest dan KNN menunjukkan distribusi kesalahan yang relatif seimbang, memperkuat interpretasi bahwa kedua pendekatan tersebut stabil dalam memisahkan kelas mayoritas maupun minoritas.

Hasil evaluasi menunjukkan bahwa pemilihan model perlu disesuaikan dengan tujuan operasional. Untuk skrip awal di tingkat layanan primer yang memprioritaskan minimalisasi false negative, 1D-CNN merupakan pilihan yang lebih tepat. Sebaliknya, untuk kebutuhan pelaporan statistik dan pemantauan program yang menuntut keseimbangan

metrik serta stabilitas prediksi, Random Forest menjadi alternatif yang lebih komprehensif. Dengan mempertimbangkan karakteristik data deterministik dan perbedaan profil kinerja antar model, kedua pendekatan tersebut layak dipertimbangkan dalam pengembangan sistem skrining digital berbasis standar pertumbuhan WHO.

### 3.6 Diskusi

Hasil penelitian menunjukkan bahwa sebagian besar model klasifikasi yang diuji mampu mencapai performa sangat tinggi pada dataset antropometri berskala besar. Random Forest menampilkan kinerja paling stabil secara keseluruhan, dengan kombinasi akurasi dan F1-score tertinggi. Stabilitas ini dijelaskan oleh mekanisme ensemble berbasis pohon keputusan yang secara kolektif mempartisi ruang fitur melalui ambang optimal. Pada data dengan jumlah fitur terbatas dan hubungan antar variabel yang terstruktur secara matematis, proses partisi tersebut menjadi efisien dan konsisten.

Model 1D-CNN menunjukkan karakteristik performa yang berbeda. Meskipun akurasinya sedikit lebih rendah dibandingkan Random Forest, model ini mencapai recall tertinggi. Tingkat sensitivitas yang sangat tinggi mengindikasikan kemampuan model dalam meminimalkan false negative. Pada skrining kesehatan masyarakat, kemampuan mendeteksi hampir seluruh kasus positif memiliki implikasi praktis yang lebih penting dibandingkan sekedar keseimbangan metrik. Hal ini sejalan dengan temuan Sugihartono dkk. [14] yang menekankan bahwa recall dan ROC-AUC merupakan metrik kritis dalam konteks kesehatan dimana minimisasi false negative menjadi prioritas utama untuk memastikan tidak ada anak stunting yang terlewat dari intervensi. Keterlambatan identifikasi stunting berpotensi menghambat intervensi gizi, sehingga model dengan sensitivitas maksimum lebih relevan untuk deteksi dini di tingkat komunitas. Temuan ini juga mendukung target percepatan penurunan stunting yang ditetapkan dalam Peraturan Presiden Nomor 72 Tahun 2021, dimana deteksi dini menjadi komponen kunci dalam strategi nasional untuk mencapai target prevalensi 14% pada tahun 2024 [15].

Sebaliknya, SVM menghasilkan presisi sempurna, namun recall lebih rendah, yang menunjukkan kecenderungan model untuk bersikap konservatif dalam menetapkan prediksi positif. Karakteristik ini kurang optimal untuk skrining populasi yang memerlukan cakupan deteksi menyeluruh. Naïve Bayes menunjukkan kinerja terendah di antara seluruh model. Hasil ini konsisten dengan asumsi independensi fitur yang mendasari algoritma tersebut, yang tidak sesuai dengan hubungan biologis antara umur dan tinggi badan dalam data antropometri.

Dari sisi metodologis, hasil penelitian ini perlu ditempatkan dalam kerangka yang tepat. Variabel keluaran dalam penelitian ini diturunkan langsung dari kombinasi umur, jenis kelamin, dan tinggi badan melalui aturan matematis yang eksplisit berdasarkan standar WHO. Oleh karena itu, hubungan antara fitur input dan label bersifat hampir deterministik. Dalam situasi seperti ini, sebagian besar algoritma klasifikasi cenderung menghasilkan performa yang sangat tinggi karena pada dasarnya mereka mereplikasi fungsi keputusan berbasis ambang klinis. Dengan demikian, perbedaan kinerja antar model lebih merefleksikan variasi mekanisme representasi dan strategi pemisahan ruang fitur daripada kemampuan menemukan pola laten yang kompleks.

Random Forest membangun aturan keputusan melalui partisi rekursif ruang fitur, sedangkan 1D-CNN membentuk representasi bertingkat melalui operasi konvolusi dan transformasi non-linier. Keduanya efektif karena batas pemisahan kelas telah terdefinisi secara jelas. Kontribusi utama penelitian ini bukan pada capaian akurasi ekstrem, melainkan pada pembuktian bahwa arsitektur 1D-CNN dapat diadaptasi secara efektif untuk data tabular antropometri dan mampu mereplikasi aturan klinis secara stabil dalam skala nasional.

Dibandingkan penelitian sebelumnya yang menggunakan dataset lebih kecil, penelitian ini menunjukkan peningkatan konsistensi performa yang lebih tinggi pada cakupan data nasional. Ratnasari dkk. [8] melaporkan akurasi sebesar 92,7%, sedangkan penelitian ini mencapai akurasi hingga 99,9%. Peningkatan tersebut sejalan dengan prinsip scaling law dalam ML, yang menyatakan bahwa penambahan jumlah data yang representatif cenderung meningkatkan stabilitas estimasi parameter serta kemampuan generalisasi model. Penelitian oleh Mulyani dkk. [16] juga melaporkan akurasi tinggi (98,7%) menggunakan Decision Tree pada dataset hybrid yang menggabungkan data lokal Puskesmas dengan Kaggle, namun pendekatan tersebut belum mengoptimalkan metrik recall yang kritis untuk skrining massal. Selain peningkatan skala data, penelitian ini juga memperluas pendekatan metodologis melalui penerapan 1D-CNN pada data antropometri numerik. Berbeda dengan sebagian besar penelitian sebelumnya yang memanfaatkan CNN untuk analisis berbasis citra nutrisi [17], penelitian ini menunjukkan bahwa arsitektur 1D-CNN dapat diadaptasi secara efektif pada data tabular dengan struktur terdefinisi. Nilai recall sebesar 99,3% memperkuat argumentasi bahwa representasi spasial terbatas melalui konvolusi mampu menangkap hubungan antar variabel numerik secara optimal [11][12]. Hasil penelitian ini konsisten dengan hasil penelitian Hadikurniawati dkk. [18] yang menunjukkan potensi CNN dalam klasifikasi berbasis data numerik. Kinerja rendah Naive Bayes pada penelitian ini juga sejalan dengan laporan dari berbagai penelitian di negara berkembang, yang menunjukkan bahwa pendekatan probabilistik sederhana kurang sesuai untuk data antropometri yang memiliki ketergantungan antar variabel [9][10][19]. Sebaliknya, performa tinggi Random Forest dan 1D-CNN konsisten dengan temuan penelitian di Ethiopia, India, dan Mesir yang menegaskan efektivitas fitur antropometri dasar dalam prediksi stunting [20][21][22].

Implikasi hasil penelitian ini bergantung pada tujuan implementasi. Untuk skrining awal di tingkat layanan kesehatan primer yang menekankan minimisasi risiko kasus tidak terdeteksi, 1D-CNN merupakan pilihan yang lebih sesuai karena sensitivitasnya yang sangat tinggi. Sebaliknya, untuk kebutuhan pelaporan statistik dan pemantauan program berskala besar yang memerlukan keseimbangan metrik serta stabilitas prediksi, Random Forest menawarkan performa yang lebih komprehensif.

Secara strategis, penelitian ini mendukung pengembangan sistem skrining digital yang mampu mereplikasi perhitungan standar WHO secara otomatis dan konsisten. Implementasi berbasis algoritma berpotensi mengurangi kesalahan perhitungan manual, meningkatkan efisiensi pelayanan, serta memperkuat sistem pemantauan stunting berbasis data. Dengan mempertimbangkan sifat deterministik hubungan fitur label, kontribusi utama penelitian ini terletak pada validasi komputasional dan kesiapan implementasi, bukan pada eskplorasi pola klinis baru.

#### 4. KESIMPULAN

Penelitian ini menunjukkan bahwa arsitektur 1D-CNN dapat diadaptasi secara efektif untuk pemodelan data antropometri numerik dalam deteksi dini stunting berbasis standar WHO, dengan capaian recall 99,3%, sementara Random Forest memperoleh akurasi 99,9% dan recall yang sangat mendekati, sehingga secara kuantitatif kedua model sama-sama menunjukkan kemampuan diskriminasi yang sangat tinggi. Dengan selisih sensitivitas yang relatif tipis, keunggulan 1D-CNN tidak terletak pada perbedaan metrik semata, melainkan pada karakteristik arsitekturnya yang berbasis representasi bertingkat, lebih adaptif terhadap integrasi variabel tambahan, serta skalabel ketika dikembangkan dengan fitur sensorik atau data multimodal di masa depan tanpa memerlukan rekayasa fitur manual yang kompleks. Selain itu, arsitektur yang ringan dan waktu pelatihan yang efisien mendukung potensi implementasi dalam sistem skrining digital di layanan kesehatan primer dengan keterbatasan sumber daya komputasi. Meskipun demikian, penelitian ini masih terbatas pada satu sumber data dan belum memasukkan variabel sosial ekonomi maupun faktor lingkungan yang berpengaruh terhadap status gizi. Oleh karena itu, penelitian lanjutan diperlukan untuk melakukan validasi melintasi wilayah, memperluas cakupan variabel, serta mengembangkan pendekatan longitudinal guna meningkatkan generalisasi dan keinginan sistem pemantauan pertumbuhan anak berbasis data.

#### REFERENCES

- [1] UNICEF, WHO, and World Bank Group, *Levels and Trends in Child Malnutrition: UNICEF/WHO/World Bank Group Joint Child Malnutrition Estimates – Key Findings of the 2025 Edition*. 2025. doi: <https://www.who.int/publications/b/78252>.
- [2] Kementerian Kesehatan Republik Indonesia, *Buku Saku Hasil Survei Status Gizi Indonesia (SSGI) 2022*. Kementerian Kesehatan RI, 2022.
- [3] A. A. Awaludin, A. Nurrachmawati, A. D. Fitriani, and Casia Reski, “The Long-Term Impact of Childhood Stunting on Cognitive Development and Educational Outcomes,” *Jurnal Penelitian Pendidikan IPA*, vol. 11, no. 8, pp. 70–77, Aug. 2025, doi: 10.29303/jppipa.v11i8.12198.
- [4] R. Maulina, M. B. Qomaruddin, B. Prasetyo, R. Indawati, and R. Alfitri, “The Effect of Stunting on the Cognitive Development in Children: A Systematic Review and Meta-analysis,” *Ethno Med*, vol. 17, no. 1–2, pp. 19–27, 2023, doi: 10.31901/24566772.2023/17.1-2.661.
- [5] R. Agil, Y. Arjun, and E. P. Silmina, “Deteksi Bahan Pangan Tinggi Protein Menggunakan Model You Only Look Once (YOLO),” *Technology and Science (BITS)*, vol. 6, no. 4, pp. 2413–2423, Mar. 2025, doi: 10.47065/bits.v6i4.6889.
- [6] World Health Organization, *Guideline: Assessing and managing children at primary health-care facilities to prevent overweight and obesity in the context of the double burden of malnutrition*. Switzerland: World Health Organization, 2017.
- [7] C. Garza, M. de Onis, and J. Martines, *WHO Child Growth Standards: Length/height-for-age, weight-for-age, weight-for-length, weight-for-height and body mass index-for-age—Methods and development*. Geneva: WHO, 2006.
- [8] R. Ratnasari, A. J. Wahidin, and T. H. Andika, “Deteksi Dini Stunting Pada Anak Berdasarkan Indikator Antropometri dengan Menggunakan Algoritma Machine Learning,” *Jurnal Algoritma*, vol. 21, no. 2, pp. 378–387, Dec. 2024, doi: 10.33364/algoritma/v.21-2.2122.
- [9] I. P. Putri, T. Terttiaavini, and N. Arminarahmah, “Analisis Perbandingan Algoritma Machine Learning untuk Prediksi Stunting pada Anak,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 1, pp. 257–265, Jan. 2024, doi: 10.57152/malcom.v4i1.1078.
- [10] B. Rao, M. Rashid, M. G. Hasan, and G. Thunga, “Machine Learning in Predicting Child Malnutrition: A Meta-Analysis of Demographic and Health Surveys Data,” Mar. 2025, *Int. J. Environ. Res. Public Health*. doi: 10.3390/ijerph22030449.
- [11] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, and D. J. Inman, “1D convolutional neural networks and applications: A survey,” *Mech. Syst. Signal Process.*, vol. 151, pp. 1–21, Apr. 2021, doi: 10.1016/j.ymssp.2020.107398.
- [12] A. Olalekan Ige and M. Sibiya, “State-of-the-Art in 1D Convolutional Neural Networks: A Survey,” *IEEE Access*, vol. 12, pp. 144082–144105, Jul. 2024, doi: 10.1109/ACCESS.2024.3433513.
- [13] D. Sunaryono *et al.*, “Hybrid One-Dimensional CNN and DNN Model for Classification Epileptic Seizure,” *International Journal of Intelligent Engineering and Systems*, vol. 15, no. 6, pp. 492–502, Dec. 2022, doi: 10.22266/ijies2022.1231.44.
- [14] T. Sugihartono, B. Wijaya, Marini, A. F. Alkayes, and H. A. Anugrah, “Optimizing Stunting Detection through SMOTE and Machine Learning: a Comparative Study of XGBoost, Random Forest, SVM, and k-NN,” *Journal of Applied Data Sciences*, vol. 6, no. 1, pp. 667–682, Jan. 2025, doi: 10.47738/jads.v6i1.494.
- [15] Presiden Republik Indonesia, “Peraturan Presiden Nomor 72 Tahun 2021 tentang Percepatan Penurunan Stunting,” Jakarta, 2021.
- [16] H. Mulyani, M. Musawarman, R. Faturrohman, and D. H. Permana, “Machine Learning-Based Early Detection of Stunting and Intervention Recommendations,” *Bit-Tech*, vol. 8, no. 2, pp. 2160–2170, Dec. 2025, doi: 10.32877/bt.v8i2.3213.



- [17] I. D. Zianka, S. D. Alim, M. K. Adiputro, and A. Setiawan, “Perancangan Aplikasi Android untuk Perhitungan Nutrisi Makanan Pencegah Stunting dengan Metode CNN di Jakarta,” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 1, pp. 99–107, Dec. 2023, doi: 10.57152/malcom.v4i1.1027.
- [18] W. Hadikurniawati, K. D. Hartomo, I. Sembiring, and C. Arthur, “A Dual-Fusion Hybrid Model with Attention for Stunting Prediction among Children under Five Years,” *Journal of Applied Data Sciences*, vol. 6, no. 3, pp. 1985–1998, Sep. 2025, doi: 10.47738/jads.v6i3.831.
- [19] F. H. Bitew, 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, Feb. 2022, doi: 10.1017/S1368980021004262.
- [20] C. Sparks, C. Johnelle Sparks, L. Potter, and J. Campbell, *Predictive modeling of child undernutrition in Ethiopia using demographic and health survey data*, vol. 21. BMC Public Health, 2021. doi: 10.1186/s12889-021-11825-3.
- [21] S. Khare, S. Kavyashree, D. Gupta, and A. Jyotishi, “Investigation of Nutritional Status of Children based on Machine Learning Techniques using Indian Demographic and Health Survey Data,” in *Procedia Computer Science*, Elsevier B.V., Aug. 2017, pp. 338–349. doi: 10.1016/j.procs.2017.09.087.
- [22] A. Hendy *et al.*, “Supervised machine learning for classification and prediction of stunting among under-five Egyptian children,” *BMC Pediatr.*, vol. 25, no. 1, p. 681, Dec. 2025, doi: 10.1186/s12887-025-06138-x.