

KLASIFIKASI MULTI-CLASS STATUS GIZI BALITA MENGGUNAKAN ARSITEKTUR DEEP NEURAL NETWORK

Alizha Nur Arspandy¹⁾, Desi Anggreani²⁾, Muhyiddin A.M Hayat³⁾, Muhammad Faisal⁴⁾, Muhammad Syafaat⁵⁾, Indriyanti⁶⁾, Emil Aguslaim Habi Thalib⁷⁾

1. Informatika, Universitas Muhammadiyah Makassar
email: 105841105522@student.unismuh.ac.id
2. Informatika, Universitas Muhammadiyah Makassar
email: desianggreani@unismuh.ac.id
3. Informatika, Universitas Muhammadiyah Makassar
email: muhyiddin@unismuh.ac.id
4. Informatika, Universitas Muhammadiyah Makassar
email: muhfaisal@unismuh.ac.id
5. Teknik Sipil, Universitas Muhammadiyah Makassar
email: syafaat_skuba@unismuh.ac.id
6. Teknik Sipil, Universitas Muhammadiyah Makassar
email: indriyanti@unismuh.ac.id
7. Informatika, Universitas Muhammadiyah Makassar
email: emil@unismuh.ac.id

Abstract

This study aims to develop a classification model for toddler nutritional status using a Deep Neural Network (DNN) with a multi-class classification approach. The research utilizes anthropometric data of toddlers aged 0-60 months obtained from UPTD Puskesmas Cendana Putih, North Luwu Regency, covering the period 2023–2025. The dataset consists of 156 records with features including age, weight, height, and Z-score indicators. Data preprocessing involves validation, normalization, and splitting into training and testing sets with a ratio of 85:15. The DNN model is constructed with multiple hidden layers (128, 64, and 32 neurons) and trained using the Adam optimizer and categorical cross-entropy loss function. The results show that the model achieves an accuracy of 91.67% on the testing data, indicating good performance in classifying nutritional status into categories such as undernutrition, normal, and obesity. Evaluation using confusion matrix and classification metrics (precision, recall, and F1-score) reveals that the model performs well on dominant classes but shows limitations in minority classes due to data imbalance. Overall, the proposed model demonstrates potential as a decision support tool to assist healthcare workers in identifying toddler nutritional status more accurately and efficiently.

Keywords: Deep Learning, Deep Neural Network, Nutritional Status, Toddler, Multi-Class Classification

A. PENDAHULUAN

Status gizi balita memegang peranan penting dalam menentukan kualitas kesehatan masyarakat serta pembangunan sumber daya manusia di masa depan. Permasalahan gizi seperti gizi kurang, *stunting*, dan gizi lebih masih menjadi isu utama di berbagai daerah, termasuk di Kabupaten Luwu Utara, yang berdampak langsung pada pertumbuhan dan perkembangan anak [1]. Berdasarkan hasil penelitian terdahulu, kondisi gizi yang tidak optimal dapat mempengaruhi perkembangan kognitif dan kesehatan jangka panjang anak [2].

Namun demikian, proses penentuan status gizi di fasilitas pelayanan kesehatan masih banyak dilakukan secara manual, sehingga berpotensi menimbulkan kesalahan interpretasi dan keterlambatan dalam pengambilan keputusan [3]. Kondisi ini menunjukkan adanya kebutuhan akan sistem yang mampu membantu tenaga kesehatan dalam melakukan klasifikasi status gizi secara lebih cepat dan akurat.

Berbagai penelitian telah menunjukkan bahwa metode *machine learning* dapat digunakan untuk mengklasifikasikan status gizi balita dengan tingkat akurasi yang cukup baik [4]. Beberapa algoritma seperti *Random Forest*, *Naïve Bayes*, dan *Decision Tree* telah diterapkan dan menunjukkan performa yang efektif dalam pengolahan data antropometri. Selain itu, pendekatan *Support Vector Machine* (SVM) juga mampu memberikan hasil klasifikasi yang cukup akurat dalam menentukan status gizi balita [5].

Meskipun demikian, sebagian besar penelitian tersebut masih menggunakan metode *machine learning* konvensional yang memiliki keterbatasan dalam menangkap pola data yang kompleks [6]. Pendekatan *multi-class classification* diperlukan untuk mengelompokkan status

gizi ke dalam beberapa kategori secara simultan [7]. Oleh karena itu, diperlukan metode yang lebih canggih seperti *Deep Learning* yang mampu mempelajari pola *non-linear* secara lebih mendalam dan meningkatkan performa klasifikasi [8].


Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk mengembangkan model klasifikasi status gizi balita menggunakan *Deep Neural Network* (DNN). Dengan pendekatan *multi-class classification*, sehingga dapat memberikan hasil prediksi yang lebih akurat dan dapat digunakan sebagai sistem pendukung keputusan dalam bidang Kesehatan [9].

Selain faktor teknis dalam penentuan status gizi, aspek sosial dan lingkungan juga turut mempengaruhi kondisi gizi balita. Faktor seperti tingkat pendidikan orang tua, pola asuh, akses terhadap layanan kesehatan, serta kondisi ekonomi keluarga memiliki kontribusi signifikan terhadap pemenuhan kebutuhan gizi anak. Kurangnya pengetahuan mengenai pola makan seimbang dan keterbatasan akses terhadap pangan bergizi dapat memperburuk kondisi gizi balita. Oleh karena itu, upaya peningkatan akurasi klasifikasi status gizi perlu diiringi dengan pemahaman yang komprehensif terhadap faktor-faktor tersebut agar intervensi yang dilakukan dapat lebih tepat sasaran dan berkelanjutan [10].

B. METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain *supervised learning* untuk membangun model klasifikasi status gizi balita berbasis *Deep Neural Network* (DNN). Objek penelitian berupa data kesehatan balita usia 0–60 bulan yang diperoleh dari UPTD Puskesmas Cendana Putih, Kabupaten Luwu Utara, Provinsi Sulawesi Selatan, dengan rentang data tahun 2023–2025 yang bersumber dari

sistem e-PPGBM. Keseluruhan alur kerja penelitian ini, mulai dari pengumpulan data hingga evaluasi model, digambarkan dalam diagram alur sistem pada Gambar 1.



Gambar 1. Flowchart Perancangan sistem

1. Pengumpulan dan Pemuatan Data

Tahap awal penelitian dimulai dengan pengumpulan data kesehatan balita yang mencakup variabel antropometri seperti usia, berat badan, tinggi badan, serta indikator Z-score (BB/U, TB/U, dan BB/TB). Dataset yang digunakan terdiri dari 156 data balita dalam format tabular.

Pada tahap komputasi, dilakukan proses verifikasi terhadap kelengkapan atribut dan konsistensi data untuk memastikan tidak terdapat nilai yang tidak valid atau tidak logis yang dapat mempengaruhi hasil analisis. Proses ini menjadi penting untuk menjamin kualitas

data sebelum digunakan dalam pelatihan model.

Tabel 1. Tahap *Preprocessing* data

Tahapan	Jumlah Data	Missing Value	Duplikasi
Data Awal	156	Tidak ada	Tidak ada
Setelah Cleaning	156	0	0
Setelah Transformasi	156	0	0
Dataset Final	156	0	0

Dataset awal terdiri dari 156 data balita yang diperoleh dari pencatatan kesehatan di UPTD Puskesmas Cendana Putih. Berdasarkan hasil pemeriksaan awal, dataset tidak memiliki *missing value* maupun duplikasi, sehingga seluruh data dapat langsung digunakan dalam proses analisis. Meskipun demikian, proses validasi tetap dilakukan untuk memastikan konsistensi nilai pada setiap variabel serta meminimalisir kemungkinan adanya data yang tidak logis. Dengan demikian, jumlah data tetap 156 dan dataset akhir telah bersih serta siap digunakan untuk proses selanjutnya.

2. Normalisasi Data

Data yang telah dimuat kemudian melalui proses normalisasi untuk menyelaraskan rentang nilai antar fitur numerik seperti usia, berat badan, dan tinggi badan. Dalam konteks jaringan saraf tiruan, perbedaan skala antar variabel dapat menyebabkan dominasi fitur tertentu dan memperlambat proses konvergensi [11]. Oleh karena itu,

normalisasi dilakukan untuk menciptakan kondisi pembelajaran yang stabil sehingga model mampu menangkap pola data secara lebih representatif dan tidak mengalami bias terhadap variabel tertentu.

3. Pembagian Data

Setelah data berada dalam kondisi terstandarisasi, dataset dibagi menjadi data latih (*training set*) dan data uji (*testing set*) dengan rasio 85:15. Dari total 156 data, diperoleh 132 data training dan 24 data *testing*. Pembagian ini dilakukan untuk mensimulasikan kondisi nyata di mana model dihadapkan pada data baru yang belum pernah dipelajari sebelumnya. Data latih digunakan sebagai media pembelajaran bagi model untuk mengenali pola hubungan antar variabel, sedangkan data uji digunakan sebagai instrumen evaluasi untuk menilai kemampuan generalisasi model.

4. Pelatihan dan Pembentukan Model

Tahap inti penelitian terletak pada proses pelatihan model *Deep Neural Network*. Pada fase ini, data pelatihan dialirkan ke dalam arsitektur jaringan yang terdiri atas lapisan input, beberapa lapisan tersembunyi (*hidden layer*) dengan jumlah neuron masing-masing 128, 64, dan 32, serta lapisan *output* yang menghasilkan probabilitas klasifikasi menggunakan fungsi aktivasi Softmax.

5. Evaluasi Model

Model yang telah dilatih dievaluasi menggunakan data pengujian (*testing set*) untuk mengukur kemampuan generalisasinya terhadap data yang tidak terlihat sebelumnya. Evaluasi utama dilakukan melalui Confusion Matrix guna mengidentifikasi distribusi kesalahan klasifikasi pada setiap kelas, yang selanjutnya digunakan untuk menghitung metrik akurasi, *precision*, *recall*, dan F1-score sebagai indikator kinerja model.

Pendekatan ini memungkinkan penilaian tidak hanya berfokus pada tingkat ketepatan prediksi, tetapi juga pada konsistensi dan keseimbangan performa antar kelas, khususnya pada klasifikasi status gizi balita yang terdiri dari beberapa kategori seperti gizi buruk/kurang, gizi normal, dan obesitas.

Akurasi digunakan untuk mengukur proporsi keseluruhan prediksi yang benar terhadap total data, sedangkan *precision* menunjukkan tingkat ketepatan prediksi pada suatu kelas tertentu. Recall mengukur kemampuan model dalam mendeteksi seluruh data yang benar pada setiap kelas, dan F1-score digunakan untuk menyeimbangkan nilai *precision* dan *recall*.

Selain metrik tersebut, evaluasi juga dilakukan dengan menganalisis hasil confusion matrix secara langsung untuk melihat pola kesalahan prediksi pada masing-masing kelas. Hal ini penting untuk mengetahui apakah model memiliki kecenderungan bias terhadap kelas tertentu, terutama pada kondisi data yang tidak seimbang.


Dengan pendekatan evaluasi ini, model yang dihasilkan tidak hanya dinilai dari tingkat akurasi, tetapi juga dari kemampuan dalam mengklasifikasikan setiap kategori status gizi secara konsisten dan representatif, sehingga dapat digunakan sebagai dasar dalam pengembangan sistem pendukung keputusan di bidang kesehatan.

C. HASIL DAN PEMBAHASAN

Tahap awal evaluasi dilakukan dengan menganalisis proses pelatihan model untuk memastikan bahwa model *Deep Neural Network* (DNN) mencapai kondisi konvergensi yang stabil tanpa indikasi *overfitting*. Model dilatih menggunakan data training dan diuji menggunakan 24 data *testing*.

1. Hasil Pelatihan dan Konvergensi Model

Proses pelatihan model dilakukan hingga 100 *epoch* dengan pemantauan akurasi dan *loss* pada data training dan *validation*. Hasil pelatihan menunjukkan bahwa model mengalami peningkatan akurasi secara bertahap dan mencapai kondisi konvergen pada epoch akhir.



Gambar 2. Grafik Akurasi Model DNN Selama 100 Epoch


Grafik *loss* menunjukkan penurunan yang signifikan pada awal pelatihan, kemudian melandai hingga mencapai kondisi stabil. Nilai *training loss* lebih rendah dibandingkan *validation loss*, namun keduanya menunjukkan pola yang konsisten, yang mengindikasikan proses pembelajaran berjalan dengan baik. Hasil pengujian model menghasilkan nilai [12]:

- Accuracy = 0.9167 (91.67%)
- Loss = 0.4596

Nilai tersebut menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data uji.


2. Distribusi Data

Distribusi data menunjukkan ketidakseimbangan kelas, di mana kategori gizi buruk/kurang mendominasi sebesar 78,85%, diikuti oleh gizi normal sebesar 14,74% dan obesitas sebesar 6,41%. Ketidakseimbangan ini berpotensi mempengaruhi performa model pada kelas minoritas.



Gambar 3. Distribusi Kelas Status Gizi Balita

3. Analisis Pengaruh Epoch terhadap Model




Gambar 4. Perbandingan Epoch

Hasil menunjukkan bahwa peningkatan jumlah epoch memberikan peningkatan performa model. Pada epoch 100, model menghasilkan akurasi yang lebih tinggi dan pola *loss* yang lebih stabil dibandingkan epoch 50. Hal ini menunjukkan bahwa model membutuhkan iterasi yang cukup untuk mempelajari pola data secara optimal.

4. Evaluasi Model Klasifikasi

Evaluasi model dilakukan menggunakan confusion matrix untuk melihat distribusi prediksi terhadap data uji.



Gambar 5. *Confusion Matrix Model Deep Neural Network (DNN)*

Berdasarkan confusion matrix, model mampu mengklasifikasikan sebagian besar data dengan benar, terutama pada kelas gizi buruk/kurang dan obesitas. Namun, masih terdapat kesalahan pada kelas gizi normal.

Tabel 2. Hasil Evaluasi Model

Kelas	Precision	Recall	F1-Score
Gizi Buruk/Kurang	0.90	1.00	0.95
Gizi Normal	1.00	0.33	0.50
Obesitas	1.00	1.00	1.00

D. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian, metode *Deep Neural Network* (DNN) dengan pendekatan *multi-class classification* mampu mengklasifikasikan status gizi balita dengan baik, ditunjukkan oleh nilai akurasi sebesar 91.67%. Model menunjukkan performa yang sangat baik pada kelas gizi buruk/kurang dan obesitas, namun masih memiliki keterbatasan pada kelas gizi normal akibat ketidakseimbangan distribusi data. Oleh karena itu, penelitian selanjutnya disarankan untuk menggunakan dataset

yang lebih besar dan seimbang serta menerapkan teknik penyeimbangan data agar performa model dapat meningkat secara merata. Selain itu, pengembangan model ke dalam bentuk aplikasi serta penambahan variabel pendukung juga dapat dilakukan untuk meningkatkan akurasi dan pemanfaatan model dalam bidang kesehatan.

E. REFERENSI

- [1] N. Matovu, N. Kizito, and M. Aljohani, "Understanding household economic influences on child stunting: A cross-sectional study in Eastern Uganda," *Nutrition*, vol. 147, p. 113187, Jul. 2026, doi: 10.1016/j.nut.2026.113187.
- [2] A. Hendy *et al.*, "Prediction of child nutritional status using deep neural networks: A cross-sectional study of Egypt DHS data (2005–2014)," *Medicine (Baltimore)*, vol. 104, no. 47, p. e46089, Nov. 2025, doi: 10.1097/MD.00000000000046089.
- [3] T. Hidayat, M. Ridwan, M. F. Iqbal, R. Rizky, and W. E. Manongga, "Determining Toddler's Nutritional Status with Machine Learning Classification Analysis Approach," vol. 24, no. 2, pp. 235–246, 2025, doi: 10.30812/matrik.v24i2.4092.
- [4] L. D. H. Monasari and Nunik Pratiwi, "Klasifikasi Stunting Pada Balita Menggunakan Algoritma Decision Tree Pada Machine Learning," *Decod. J. Pendidik. Teknol. Inf.*, vol. 5, no. 2, pp. 416–428, Jul. 2025, doi: 10.51454/decode.v5i2.1193.
- [5] E. Ramon, A. Nazir, N. Novriyanto, Y. Yusra, and L. Oktavia, "KLASIFIKASI STATUS GIZI BAYI POSYANDU

- KECAMATAN BANGUN PURBA MENGGUNAKAN ALGORITMA SUPPORT VECTOR MACHINE (SVM),” *J. Sist. Inf. dan Inform.*, vol. 5, no. 2, pp. 143–150, Aug. 2022, doi: 10.47080/simika.v5i2.2185.
- [6] Ayesa Aglystia Firdauzi, Syifa Tania Annaztasya, and Febriana, “SYSTEMATIC LITERATURE REVIEW: ANALYSIS AND PREDICTION OF E-COMMERCE CONSUMER BEHAVIOR USING MACHINE LEARNING,” *J. Informatics Interact. Technol.*, vol. 2, no. 3, pp. 455–465, Dec. 2025, doi: 10.63547/jiite.v2i3.100.
- [7] M. Ulfa and N. K. Azizah, “PENERAPAN PERILAKU IBU PADA BALITA YANG MENGALAMI MASALAH STATUS GIZI DI DESA WONOSALAM,” *JKM (Jurnal Kesehat. Masyarakat) Cendekia Utama*, vol. 10, no. 2, p. 256, Dec. 2022, doi: 10.31596/jkm.v10i2.1287.
- [8] M. Mardiwati, A. Paliling, and N. Mutmainnah, “Optimasi Model Deep Learning untuk Klasifikasi Stunting berdasarkan Data Antropometri dan Status Imunisasi,” *Semant. Tek. Inf.*, vol. 11, no. 2, 2025, doi: 10.55679/semantik.v11i2.233.
- [9] Gina Purnama Insany, Indra Yustiana, and Sri Rahmawati, “Penerapan KNN dan ANN pada klasifikasi status gizi balita berdasarkan indeks antropometri,” *J. CoSciTech (Computer Sci. Inf. Technol.*, vol. 4, no. 2, pp. 385–393, Aug. 2023, doi: 10.37859/coscitech.v4i2.5079.
- [10] M. Mukhlis, “Hubungan Status Sosial Ekonomi dan Pola Asuh terhadap Prevalensi Stunting pada Balita di Bima-NTB,” *J. Knowl. Collab.*, vol. 2, no. 1, pp. 434–443, 2024, doi: 10.59613/4pe20061.
- [11] M. Jumarlis *et al.*, “A hybrid hue saturation lightness, gray level co-occurrence matrix, and k-nearest neighbour for palm-sugar classification,” *IAES Int. J. Artif. Intell.*, vol. 13, no. 3, pp. 2934–2945, Sep. 2024, doi: 10.11591/ijai.v13.i3.pp2934-2945.
- [12] M. Faisal, T. K. A. Rahman, I. Mulyadi, K. Aryasa, Irmawati, and M. Thamrin, “A Novelty Decision-Making Based on Hybrid Indexing, Clustering, and Classification Methodologies: An Application to Map the Relevant Experts Against the Rural Problem,” *Decis. Mak. Appl. Manag. Eng.*, vol. 7, no. 2, pp. 132–171, Feb. 2024, doi: 10.31181/dmame7220241023.