

Klasifikasi *Multi Class* Menggunakan Metode *Backpropagation* *Neural Network* untuk Prediksi Stunting pada Balita

Uswatun Khasanah^{1*}

^{1,2,3}Program Studi Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Billfath
Komplek PP. Al Fattah Siman Sekaran, Lamongan, 62261, Indonesia

Email Penulis Korespondensi: * uswatunkhasanah@billfath.ac.id

ABSTRAK

Riwayat Artikel:

Tanggal Masuk 01-02-2025

Revisi 18-02-2025

Diterima 20-02-2025

Kata Kunci:

Stunting;
Multiclass;
Prediksi;
Backpropagation Neural
Network

Stunting merupakan sebuah masalah gizi kronis yang menghambat pertumbuhan anak dan menyebabkan efek jangka panjang yang serius. Salah satu upaya yang dapat dilakukan untuk mengetahui stunting lebih dini yaitu dengan melakukan prediksi. Pada penelitian ini dilakukan klasifikasi multiclass menggunakan Metode Backpropagation Neural Network untuk prediksi stunting pada balita. Proses pada penelitian ini yaitu pengumpulan data, preprocessing data, pembagian data, pembangunan model, pelatihan, pengujian dan evaluasi model. Model yang dibangun dapat mengklasifikasi status stunting menjadi 4 kategori yaitu normal, tinggi, stunting, dan sangat stunting. Data yang digunakan pada penelitian ini yaitu sebanyak 120.999 data. Data dibagi menjadi dua yaitu sebanyak 80% digunakan sebagai data latih dan 20% sebagai data uji. Perhitungan akurasi menggunakan metode cross entropy dan evaluasi akurasi. Hasil penelitian menunjukkan bahwa akurasi training yang didapatkan sebesar 99% dan akurasi testing sebesar 99%. Berdasarkan hasil tersebut menunjukkan bahwa model sistem klasifikasi yang dibangun dengan menggunakan metode Backpropagation Neural Network mampu mencapai hasil yang sangat baik untuk melakukan klasifikasi stunting ke dalam beberapa kelas.



Artikel ini adalah artikel akses terbuka yang didistribusikan berdasarkan syarat dan ketentuan [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).

Cara mengutip artikel ini:

Uswatun Khasanah., "KLASIFIKASI MULTI CLASS MENGGUNAKAN METODE BACKPROPAGATION NEURAL NETWORK UNTUK PREDIKSI STUNTING PADA BALITA," *MathVision: Jurnal Matematika*, vol. 07, iss. 02, pp. 13-21, 2025.

KONTAK:

Uswatun Khasanah,  uswatunkhasanah@billfath.ac.id

 Program Studi Matematika FMIPA Universitas Billfath

 Artikelnya dapat diakses di sini. <https://doi.org/10.55719/mv.v7i1.1650>

1. PENDAHULUAN

Stunting merupakan sebuah gangguan pertumbuhan yang biasanya terjadi pada balita. Stunting ditandai dengan bentuk badan yang pendek akibat asupan nutrisi yang tidak memadai dan kekurangan gizi kronis [1]. Beberapa faktor yang menyebabkan terjadinya stunting pada balita yaitu pengetahuan ibu yang tidak memadai mengenai gizi balita, pemberian makanan yang buruk, akses air bersih yang kurang memadai, dan layanan kesehatan yang terbatas. Studi menekankan pentingnya pemberian ASI eksklusif, pemberian Makanan Pendamping ASI (MPASI) yang berkualitas, pencegahan penyakit menular, pemberian ilmu pengetahuan ibu, serta melakukan pengasuhan yang efektif dalam mengurangi angka stunting pada balita [2]. Stunting pada balita memiliki dampak terhadap perkembangan kognitif dan juga pertumbuhan fisik. Masalah ini menjadi perhatian yang utama dalam kesehatan masyarakat terutama di negara-negara berkembang yang memiliki prevalensi stuntingnya masih tinggi [3]. Oleh karena itu, dibutuhkan sebuah metode teknologi yang dapat memprediksi gejala-gejala dari stunting. Salah satu penelitian terkait diagnosa stunting dengan menggunakan beberapa algoritma yaitu dengan metode Naïve Bayes memberikan hasil akurasi sebesar 90%, metode *Support Vector Machine* memberikan hasil akurasi sebesar 86.56%, dan metode *K-Nearest Neighbor* dengan akurasi sebesar 79.43%. Kecepatan teknologi komputasinya yang tinggi dan efisiensi dengan data besar menjadikannya pilihan yang sangat baik untuk diagnosa stunting [4].

Dengan kemajuan teknologi, berbagai metode terus dikembangkan termasuk *machine learning* dan *deep learning*. Saat ini, metode-metode tersebut banyak diterapkan untuk memberikan solusi terhadap banyak permasalahan, salah satunya di bidang kesehatan [5]. *Deep learning* merupakan bagian dari *machine learning* yang memiliki fokus pada *neural network* (jaringan syaraf tiruan) [6]. Metode *Deep Learning* banyak diminati karena kemampuannya dalam mengenali objek dengan tingkat akurasi yang cukup tinggi. Selain itu, metode ini mampu menyederhanakan konsep yang kompleks menjadi lebih mudah dipahami. Konsep *Deep Learning* bekerja dengan memanfaatkan data sebagai masukan (*input*) yang kemudian diproses melalui beberapa lapisan tersembunyi untuk menghasilkan nilai keluaran (*output*). Selain itu, jaringan syaraf mampu membuat sistem prediksi yang akurat dalam menyelesaikan suatu permasalahan, bahkan ketika jumlah data yang tersedia cukup terbatas [7].

Salah satu metode yang termasuk kedalam jaringan syaraf tiruan yaitu metode *Backpropagation Neural Network* [8]. Metode *Backpropagation Neural Network* memiliki kemampuan adaptasi yang baik terhadap data masukan dan mampu untuk melakukan prediksi hubungan antara kelas target dan atribut objek dengan cukup baik. Kelebihan tersebut mampu mempopulerkan metode ini sebagai metode yang mampu bekerja dengan baik dalam proses klasifikasi [9]. Salah satu penelitian yang berkaitan dengan klasifikasi ginjal kronis ke dalam dua kelas yaitu termasuk ginjal kronis dan tidak. Hasil yang didapatkan pada penelitian tersebut yaitu mampu mendapatkan nilai akurasi sebesar 92.5%. Hal ini membuktikan bahwa metode ini memiliki akurasi yang tinggi untuk melakukan klasifikasi penyakit ginjal kronis [10]. Penelitian lainnya [7] menggunakan metode *Backpropagation Neural Network* untuk mengklasifikasi penyakit stroke dengan nilai akurasi sebesar 96.14%. Penelitian lain [11] menggunakan metode *Backpropagation Neural Network* untuk mengklasifikasi penyakit kanker payudara ke dalam dua kelas. Hasil yang didapatkan yaitu nilai akurasi sebesar 96.93%.

Pada penelitian sebelumnya telah menunjukkan keunggulan bahwa metode *Backpropagation Neural Network* mampu mengklasifikasi penyakit ke dalam dua kelas dengan baik. Oleh karena itu, pada penelitian ini akan dilakukan klasifikasi *multiclass* menggunakan Metode *Backpropagation Neural Network* untuk prediksi stunting pada balita. Penelitian ini dilakukan untuk meningkatkan kinerja model dari metode *Backpropagation Neural Network* dalam memprediksi stunting pada balita, sehingga memberikan kontribusi yang signifikan terhadap upaya deteksi dini dan intervensi stunting pada balita.

2. METODE

2.1. Deskripsi Data

Penelitian ini menggunakan data sekunder yang diperoleh dari <https://www.kaggle.com/datasets/rendiputra/stunting-balita-detection-121k-rows>. Data tersebut terdiri dari 120.999 data yang mencakup informasi mengenai usia (dalam bulan), jenis kelamin, tinggi badan (cm), serta status gizi balita [12].

Tabel 1. Detail Dataset Stunting

No	Usia (Bulan)	Jenis Kelamin	Tinggi Badan (cm)	Status Gizi
1	0	laki-laki	44.59197329	<i>stunted</i>
2	0	laki-laki	56.70520337	tinggi
3	0	laki-laki	46.8633576	normal
4	0	laki-laki	47.50802563	normal
5	0	laki-laki	42.74349389	<i>severely stunted</i>
⋮	⋮	⋮	⋮	⋮
120997	60	perempuan	121.3	normal
120998	60	perempuan	112.2	normal
120999	60	perempuan	109.8	normal

Sumber Data: [13]

- Usia (Bulan)
Variabel usia digunakan untuk mengidentifikasi fase pertumbuhan anak serta membandingkannya dengan standar pertumbuhan anak yang sehat.
- Jenis Kelamin
Pada variabel ini terdapat dua kategori yaitu perempuan dan laki-laki. Jenis kelamin merupakan faktor penting untuk menganalisis pola pertumbuhan dan risiko terjadinya stunting.
- Tinggi Badan
Variabel ini merupakan indikator utama dalam melakukan penilaian pertumbuhan fisik pada balita. Data ini dapat digunakan untuk menentukan apakah pertumbuhan balita sesuai dengan standar usia.
- Status Gizi
Pada variabel status gizi masing-masing dikategorikan menjadi 4 status yaitu *severely stunted* yang menandakan kondisi sangat serius, *stunted* yang menandakan kondisi stunting, normal yang menandakan status gizi yang sehat, dan tinggi yang menandakan pertumbuhan di atas rata-rata. Data status gizi yang didapatkan yaitu normal sebanyak 67.755 data, tinggi sebanyak 19.560, *severely stunted* sebanyak 19.869, dan *stunted* sebanyak 13.815.

2.2. Analisis Data

Dari data di atas kemudian dilakukan prediksi stunting pada balita menjadi 4 kelas yaitu normal, tinggi, *stunted*, dan *severely stunted* dengan menggunakan metode *Backpropagation Neural Network* dengan input menggunakan 3 fitur yaitu umur (bulan), jenis kelamin, dan tinggi badan (cm). Ketiga fitur tersebut digunakan karena menjadi peran penting untuk menentukan kategori status gizi balita. Data kemudian diolah dan akan memberikan kesimpulan apakah model yang dibangun dengan metode *Backpropagation Neural Network* memberikan hasil yang baik untuk memprediksi stunting pada klasifikasi *multiclass*.

2.3. Metode *Backpropagation Neural Network*

Metode *Backpropagation Neural Network* merupakan salah satu algoritma yang mampu mengubah bobot-bobot yang terhubung dengan layer tersembunyi (*hidden layer*). Metode *Backpropagation Neural Network* terdiri atas dua fase yakni fase maju dan fase mundur. Oleh karena itu, fase ini dikenal dengan metode *feed-forward* dan termasuk dalam algoritma yang terawasi. Nilai kesalahan yang dihasilkan dari sistem digunakan untuk mengubah bobot yang terhubung dengan layer tersembunyi pada sistem. Dalam metode ini terdiri atas dua proses yakni fase propagasi maju dan fase propagasi mundur.

Langkah-langkah dari *Backpropagation Neural Network* dapat dilihat sebagai berikut [14]:

- Menginisialisasi bobot awal dengan menggunakan nilai *random* yang cukup kecil.
- Apabila kondisi berhenti belum terpenuhi, lanjutkan ke langkah 3 hingga langkah 10. Kondisi ini berlaku apabila nilai *error* yang didapatkan dari langkah terakhir masih melebihi batas *error* yang telah ditetapkan.

Fase Propagasi Maju

3. Menghitung semua *output* pada *hidden layer* (Z_j) dengan menggunakan Persamaan (1), kemudian gunakan fungsi aktivasi untuk menghitung keluaran pada Z_j .

$$Z_{net_j} = v_{jumlah\ input+1,j} + \sum_{i=1}^n x_i v_{ji} \quad (1)$$

4. Menghitung semua *output* jaringan pada lapisan keluaran sistem dengan menggunakan Persamaan (2), kemudian gunakan fungsi aktivasi untuk menghitung nilai *output* y_k .

$$Y_{net_k} = w_{hidden\ layer+1,k} + \sum_{j=1}^p z_j w_{kj} \quad (2)$$

Fase Propagasi Mundur

5. Menghitung nilai kesalahan (*error*) di setiap unit *output* dengan menggunakan Persamaan (3) dan memanfaatkan turunan fungsi pertama dari fungsi aktivasi yang digunakan.

$$s_k = (t_k - y_k) f'(y_{net_k}) \quad (3)$$

6. Menentukan koreksi nilai bias dengan menggunakan Persamaan (4) yang kemudian digunakan untuk memperbarui bobot.

$$\Delta w_{kj} = \alpha \cdot s_k \cdot z_j \quad (4)$$

7. Menghitung faktor kesalahan di setiap *hidden layer* dengan menggunakan Persamaan (5) sampai dengan (7) dan memanfaatkan turunan fungsi pertama dari fungsi aktivasi yang digunakan.

$$s_{net_j} = \sum_{k=1}^m s_k \cdot w_{kj} \quad (5)$$

$$ss_j = s_{net_j} \cdot f' \quad (6)$$

$$\Delta v_{ji} = \alpha \cdot ss_j \cdot x_i \quad (7)$$

8. Menghitung perubahan bobot dengan menggunakan Persamaan (8) dan Persamaan (9).

$$w_{kj}(\text{baru}) = w_{kj}(\text{lama}) + \Delta w_{kj} \quad (8)$$

$$v_{ji}(\text{baru}) = v_{ji}(\text{lama}) + \Delta v_{ji} \quad (9)$$

9. Menghitung *error* dari sistem yang dibangun dengan menggunakan Persamaan (10).

$$MSE = \frac{1}{n} \sum_{k=1}^p (t_k - y_k)^2 \quad (10)$$

10. Menguji apakah kondisi berhenti sudah terpenuhi. Jika belum maka kembali ke langkah 2.

2.4. Fungsi Aktivasi

Fungsi aktivasi merupakan lapisan yang berperan dalam menentukan apakah nilai dari jaringan sebelumnya perlu diaktifkan atau tidak [15]. Beberapa fungsi aktivasi yang sering digunakan dapat dilihat pada Persamaan (11) sampai (18).

2.4.1. Sigmoid

Fungsi aktivasi sigmoid merupakan sebuah fungsi yang mempunyai karakteristik kurva berbentuk “S” dan mengonversi nilai ke dalam rentang 0 hingga 1 [15]. Persamaan fungsi sigmoid dapat dilihat pada Persamaan (11) dan untuk turunan pertama fungsi sigmoid dapat dilihat pada Persamaan (12).

$y = \frac{1}{1 + e^{-x}}$	(11)
$\frac{\partial y}{\partial x} = y[1 - y]$	(12)

2.4.2. Linear

Fungsi aktivasi linear memiliki nilai *output* yang identik dengan nilai *input* [16]. Persamaan fungsi linear dapat dilihat pada Persamaan (13) dan untuk turunan pertama fungsi linear dapat dilihat pada Persamaan (14).

$y = x$	(13)
$\frac{\partial y}{\partial x} = 1$	(14)

2.4.3. ReLU

Fungsi aktivasi ReLU adalah salah satu fungsi aktivasi yang sederhana namun sangat efektif dalam menyelesaikan berbagai kasus [15]. Persamaan fungsi ReLU dapat dilihat pada Persamaan (15) dan untuk turunan pertama fungsi ReLU dapat dilihat pada Persamaan (16).

$y = \max(0, x)$	(15)
$\frac{\partial y}{\partial x} = \begin{cases} 0 & , x \leq 0 \\ 1 & , x > 0 \end{cases}$	(16)

2.4.4. Softmax

Fungsi aktivasi *softmax* digunakan untuk menghasilkan hasil klasifikasi dengan mengubahnya menjadi probabilitas yang belum dinormalisasi untuk setiap kelas [17]. Persamaan fungsi *softmax* dapat dilihat pada Persamaan (17) dan untuk turunan pertama fungsi *softmax* dapat dilihat pada Persamaan (18).

$y = \frac{e^{x_i}}{\sum_{k=1}^c e^{x_k}}$	(17)
$\frac{\partial y}{\partial x} = \begin{cases} y_i(1 - y_i) & , i = j \\ -(y_i)(y_j) & , i \neq j \end{cases}$	(18)

2.5. Cross Entropy

Cross Entropy merupakan sebuah fungsi *loss* yang berfungsi untuk mengukur seberapa baik prediksi suatu model untuk melakukan klasifikasi [18]. Pada persamaan (19) merupakan rumus matematis *cross entropy* untuk klasifikasi multi-kelas.

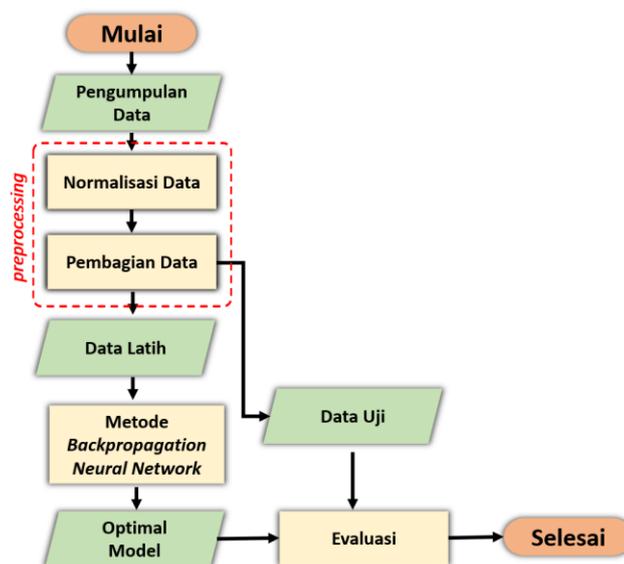
$$L = - \sum_{i=1}^n y_i \log(\hat{y}_i) \quad (19)$$

2.6. Evaluasi Akurasi

Evaluasi akurasi digunakan untuk mengukur seberapa sering model memprediksi kelas yang benar [19]. Persamaan (20) merupakan rumus matematis evaluasi akurasi.

$$\text{Akurasi} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Data Uji}} \times 100\% \quad (20)$$

Adapun *flowchart* pada penelitian ini dapat dilihat pada Gambar 1.



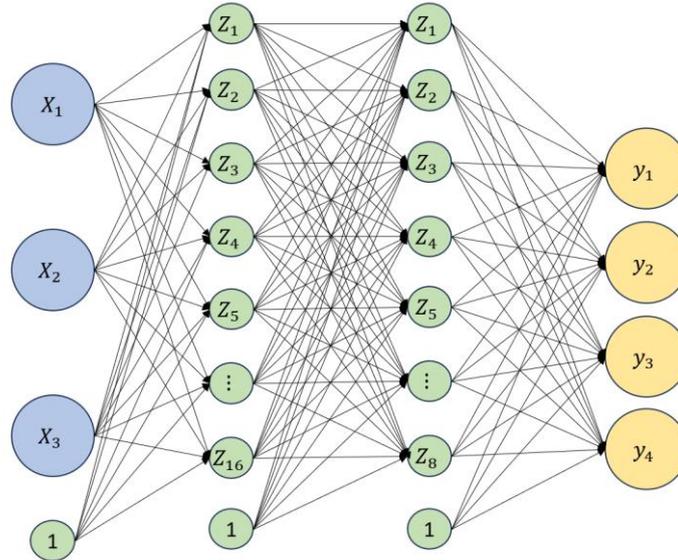
Gambar 1. Flowchart Prediksi Stunting dengan Menggunakan Metode *Backpropagation Neural Network*

3. HASIL DAN PEMBAHASAN

Pada penelitian ini dilakukan klasifikasi *multiclass* menggunakan Metode *Backpropagation Neural Network* untuk prediksi stunting pada balita. Langkah awal setelah mendapatkan data yaitu dengan melakukan *preprocessing* data, *preprocessing* data ini dilakukan untuk membantu model belajar lebih cepat dan membuat skala menjadi seragam dengan normalisasi data. Normalisasi data dilakukan dengan mentransformasikan data ke dalam skala yang seragam dengan mean 0 dan standar deviasi 1. Langkah ini sangat penting untuk menjamin bahwa setiap fitur berkontribusi yang sama dan membantu mencegah dominasi fitur dalam proses pembelajaran karena variabel-variabel yang digunakan mempunyai rentang nilai yang berbeda-beda. Setelah data di normalisasi, data kemudian dibagi menjadi dua yaitu data latih dan data uji. Dataset pada penelitian ini dibagi menjadi 80% data latih dan 20% data uji.

Data kemudian dilatih dengan menggunakan Metode *Backpropagation Neural Network* dengan arsitektur yang digunakan pada penelitian ini dapat dilihat pada Gambar 2. Proses pelatihan berfungsi untuk membangun model klasifikasi stunting ke dalam 4 kelas dengan menggunakan 50 *epoch*. Arsitektur pada penelitian ini yaitu dimulai dengan *input layer* yang terdiri atas variabel umur, jenis kelamin, dan tinggi badan. Kemudian dilanjutkan ke *hidden layer* pertama dengan 16 *neuron*, pada *hidden layer* 1 menggunakan fungsi aktivasi ReLU. *Hidden Layer* 1 berfungsi untuk menangkap pola kompleks yang didapatkan dari *input layer*. Setelah itu, diproses ke *hidden layer* 2 yang terdiri atas 8 *neuron* dan menggunakan fungsi aktivasi

ReLU. *Hidden Layer 2* ini berfungsi untuk pemahaman fitur yang telah diproses oleh sistem. Setelah itu, didapatkanlah output layer yang terdiri atas 4 *neuron* dan menggunakan fungsi aktivasi *softmax*.



Gambar 2. Arsitektur Metode *Backpropagation Neural Network* yang Digunakan pada Penelitian

Tabel 2. Perbandingan Akurasi dengan Beberapa Penelitian Sebelumnya

Metode	Tipe Klasifikasi	Akurasi (%)
C4.5 [20]	Klasifikasi Biner	61.82
<i>Machine Learning</i> [21]	Klasifikasi Biner	79
LSTM [22]	Klasifikasi Biner	81.53
<i>Deep Neural Network</i> [12]	Klasifikasi Multi-Kelas	93.83
<i>Backpropagation Neural Network</i>	Klasifikasi Multi-Kelas	99

Hasil klasifikasi *multiclass* dievaluasi dengan menghitung *loss* dan akurasi. Hasil akurasi *training* pada penelitian ini didapatkan nilai sebesar 99% dan hasil akurasi *testing* sebesar 99%. Hasil pada penelitian ini lebih baik daripada penelitian-penelitian terhadap klasifikasi stunting yang telah dilakukan sebelumnya dengan hasil perbandingan dapat dilihat pada Tabel 2. Penelitian yang telah dilakukan [20] yaitu klasifikasi stunting ke dalam dua kelas dengan menggunakan metode C4.5 mendapatkan hasil akurasi sebesar 61.82%. selain itu, penelitian klasifikasi stunting kedalam dua kelas juga telah dilakukan dengan menggunakan metode *machine learning* dengan hasil akurasi sebesar 79% [21]. Penelitian lain juga dilakukan dengan menggunakan metode *Long Short Term Memory* pada klasifikasi biner stunting dengan mendapatkan hasil akurasi sebesar 81.53% [22]. Penelitian lainnya yang terkait dengan klasifikasi multikelas telah dilakukan dengan menggunakan metode *Deep Neural Network* dengan hasil akurasi sebesar 93.83% [12]. Hasil penelitian ini masih lebih baik daripada beberapa penelitian lain dengan menggunakan metode lainnya.

4. KESIMPULAN

Hasil penelitian klasifikasi *multiclass* dengan metode *Bacpropagation Neural Network* untuk orediksi stunting pada balita menghasilkan model yang optimal dengan nilai akurasi sebesar 99%. Hasil pengujian pada penelitian ini menunjukkan bahwa metode *Backpropagation Neural Network* mampu membangun model yang optimal untuk memprediksi adanya stunting pada balita.

Pada penelitian selanjutnya diharapkan adanya evaluasi lebih lanjut dan tambahan dengan kombinasi eksperimen dengan metode yang lebih terbaru dan lebih baik.

REFERENSI

- [1] J. Fauziah, K. D. Trisnawati, K. P. S. Rini, and S. U. Putri, “Stunting: Penyebab, Gejala, dan Pencegahan,” *Jurnal Parenting dan Anak*, vol. 1, no. 2, p. 11, Dec. 2023, doi: 10.47134/jpa.v1i2.220.
- [2] F. De Gomes, P. Redy, and P. Jaya, “Pemahaman Kaum Ibu tentang Stunting dan Dampaknya Terhadap Asupan Gizi Anak Balita,” *Pusat Studi Gender dan Anak UIN Alauddin Makassar Sipakalebbi*, vol. 7, no. 1, 2023.
- [3] H. Rahman, M. Rahmah, and N. Saribulan, “Upaya Penanganan Stunting di Indonesia,” *Jurnal Ilmu Pemerintahan Suara Khatulistiwa (JIPSK)*, no. 01, Jun. 2023.
- [4] A. Subadi, “Diagnosa Stunting Berdasarkan Gejala Medis Menggunakan Algoritma Naive Bayes, SVM dan K-NN,” *JIP (Jurnal Informatika Polinema)*, vol. 10, Aug. 2024.
- [5] I. Akbar, F. Supriadi, and D. I. Junaedi, “Pemanfaatan Machine Learning di Bidang Kesehatan,” *Jurnal Mahasiswa Teknik Informatika*, vol. 9, no. 1, Feb. 2025.
- [6] J. Nurhakiki *et al.*, “Studi Kepustakaan: Pengenalan 4 Algoritma Pada Pembelajaran Deep Learning Beserta Implikasinya,” *Jurnal Pendidikan Berkarakter*, no. 1, pp. 270–281, 2024, doi: 10.51903/pendekar.v2i1.598.
- [7] M. Azhima, I. Afrianty, E. Budianita, and S. Kurnia Gusti, “Penerapan Metode Backpropagation Neural Network untuk Klasifikasi Penyakit Stroke,” *Media Online*, vol. 4, no. 6, pp. 3013–3021, Jun. 2024, doi: 10.30865/klik.v4i6.1956.
- [8] B. Satria, “Prediksi Volume Penggunaan Air PDAM Menggunakan Metode Jaringan Syaraf Tiruan Backpropagation,” *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 2, no. 3, pp. 674–684, 2018, doi: 10.29207/resti.v2i3.575.
- [9] P. I. Ashuri, I. A. Cahyani, and C. S. K. Aditya, “Klasifikasi Penyakit Stunting Menggunakan Algoritma Multi-Layer Perceptron,” *Journal MIND Journal | ISSN*, vol. 9, no. 1, pp. 52–63, Mar. 2024, doi: 10.26760/mindjournal.v9i1.52-63.
- [10] S. Vashisth, I. Dhall, and S. Saraswat, “Chronic kidney disease (CKD) diagnosis using multi-layer perceptron classifier,” in *Proceedings of the Confluence 2020 - 10th International Conference on Cloud Computing, Data Science and Engineering*, Institute of Electrical and Electronics Engineers Inc., Jan. 2020, pp. 346–350. doi: 10.1109/Confluence47617.2020.9058178.
- [11] D. Nasien, V. Enjeslina, M. Hasmil Adiya, and Z. Baharum, “Breast Cancer Prediction Using Artificial Neural Networks Back Propagation Method,” in *Journal of Physics: Conference Series*, Institute of Physics, 2022. doi: 10.1088/1742-6596/2319/1/012025.
- [12] W. S. Lestari, Y. M. Saragih, and C. Caroline, “Multiclass Classification for Stunting Prediction Using Deep Neural Networks,” *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 10, no. 2, pp. 386–393, Nov. 2024, doi: 10.33480/jitk.v10i2.5636.
- [13] R. P. Pradana, “<https://www.kaggle.com/datasets/rendiputra/stunting-balita-detection-121k-rows> .”
- [14] U. Khasanah and N. Ulinuha, “Prediksi Biaya Konsumsi Bahan Bakar Gas Menggunakan Metode Backpropagation Neural Network (Studi Kasus: PLTU PT. Pembangkit Jawa Bali Unit Pembangkitan Gresik),” *Jurnal Sains Matematika dan Statistika*, vol. 5, no. 2, 2019.
- [15] K. Kurniawan, B. Ceasaro, and S. #3, “Perbandingan Fungsi Aktivasi Untuk Meningkatkan Kinerja Model LSTM Dalam Prediksi Ketinggian Air Sungai,” *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 10, no. 1, Apr. 2024.
- [16] I. Pamungkas and S. Alam, “Studi Komparasi Fungsi Aktivasi Sigmoid Biner, Sigmoid Bipolar dan Linear pada Jaringan Saraf Tiruan dalam Menentukan Warna RGB Menggunakan Matlab,” *Serambi Engineering*, vol. VII, no. 4, 2022.
- [17] M. Hamsy Romario, E. Ihsanto, and T. Maya Kadarina, “Sistem Hitung Dan Klasifikasi Objek Dengan Metode Convolutional Neural Network,” vol. 11, no. 2, p. 108, 2020.
- [18] G. Eka Saputra, A. Faisal, and dan Ahmad Apandi, “Perbandingan Penerapan Algoritma Neural Network Backpropagation dengan Optimasi Algoritma LBFGS dan SGD untuk

- Prediksi Penyakit Jantung,” *Seminar Nasional Teknologi Informasi dan Komunikasi STI&K (SeNTIK)*, vol. 4, no. 1, Sep. 2020.
- [19] M. Akbar and W. Yustanti, “Pemilihan Algoritma Klasifikasi Terbaik Untuk Prediksi Jenis Keluhan MI User Interface (MIUI) 14,” *Journal of Informatics and Computer Science*, vol. 06, 2024.
- [20] M. Yunus, M. K. Biddinika, and A. Fadlil, “Classification of Stunting in Children Using the C4.5 Algorithm,” *Jurnal Online Informatika*, vol. 8, no. 1, pp. 99–106, Jun. 2023, doi: 10.15575/join.v8i1.1062.
- [21] O. N. Chilyabanyama *et al.*, “Performance of Machine Learning Classifiers in Classifying Stunting among Under-Five Children in Zambia,” *Children*, vol. 9, no. 7, Jul. 2022, doi: 10.3390/children9071082.
- [22] F. M. Amin, D. Candra, and R. Novitasari, “Identification of Stunting Disease using Anthropometry Data and Long Short-Term Memory (LSTM) Model,” *Computer Engineering and Applications*, vol. 11, no. 1, 2022.