

**ANALISIS PERBANDINGAN ALGORITMA DECISION TREE DAN
DEEP LEARNING UNTUK KLASIFIKASI BALITA STUNTING
MENGUNAKAN RAPIDMINER**

Nazhifatul Muthohharoh, Zaehol Fatah
Universitas Ibrahimy, Indonesia
E-mail: nsfh2502@gmail.com, zaeholfatah@gmail.com

ABSTRAK

Stunting pada balita merupakan salah satu masalah kesehatan yang signifikan di negara berkembang seperti Indonesia, yang disebabkan oleh kekurangan gizi kronis. Identifikasi dini stunting sangat penting untuk mengurangi dampaknya terhadap perkembangan anak. Penelitian ini bertujuan untuk membandingkan efektivitas metode decision tree Algoritma C4.5 dan deep learning dalam mengidentifikasi stunting pada balita dengan menggunakan perangkat lunak RapidMiner. Metode penelitian ini menggunakan pendekatan komparatif dengan dua model pembelajaran mesin, yakni Algoritma C4.5 dan deep learning, yang diterapkan pada data stunting. Hasil penelitian menunjukkan bahwa metode deep learning memiliki tingkat akurasi yang lebih tinggi dibandingkan dengan Algoritma C4.5 dalam mendeteksi stunting. Kesimpulannya, deep learning lebih efektif dalam mengidentifikasi stunting pada balita dibandingkan dengan Algoritma C4.5, sehingga direkomendasikan untuk digunakan dalam sistem pendeteksian stunting di Indonesia.

Kata Kunci: pengerdilan; pohon keputusan; algoritma c4.5; pembelajaran mendalam; rapidminer

ABSTRACT

Stunting in children under five is a significant health issue in developing countries such as Indonesia, primarily caused by chronic malnutrition. Early identification of stunting is crucial to minimize its impact on children's development. This study aims to compare the effectiveness of the decision tree C4.5 Algorithm and deep learning in identifying stunting in children using RapidMiner software. The research employs a comparative approach with two machine learning models, C4.5 Algorithm and deep learning, applied to stunting data. The results indicate that the deep learning method has a higher accuracy rate compared to the C4.5 Algorithm in detecting stunting. In conclusion, deep learning is more effective in identifying stunting in children under five compared to the C4.5 Algorithm, and it is recommended for use in stunting detection systems in Indonesia.

Keywords: *stunting; children under five; decision tree; rapidminer; identification.*



PENDAHULUAN

Stunting merupakan salah satu permasalahan gizi yang berdampak serius pada pertumbuhan fisik dan perkembangan kognitif anak, terutama pada balita. Menurut data dari World Health Organization (2020), stunting mempengaruhi sekitar 149 juta anak di seluruh dunia dan merupakan salah satu indikator penting dalam menilai kesehatan masyarakat serta pertumbuhan ekonomi suatu negara. Di Indonesia, prevalensi stunting masih tinggi, dengan angka mencapai 27,67% pada tahun 2019 (Mayasari et al., 2022). Masalah ini sangat memprihatinkan karena stunting pada balita berkaitan erat dengan masalah kesehatan jangka panjang, seperti rendahnya produktivitas dan peningkatan risiko penyakit kronis di masa dewasa. Oleh karena itu, identifikasi dini faktor-faktor yang menyebabkan stunting sangat penting guna memberikan intervensi yang tepat dan efektif (Shamshirband et al., 2021).

Berbagai metode telah dikembangkan untuk mengidentifikasi faktor-faktor penyebab stunting, salah satunya adalah metode berbasis data mining yang dapat membantu dalam pengambilan keputusan (Taufiq, 2024). Salah satu algoritma yang sering digunakan dalam data mining adalah Algoritma C4.5 yang merupakan bagian dari metode decision tree (Kurniati, 2021). Sejumlah penelitian sebelumnya telah mengeksplorasi penggunaan algoritma decision tree untuk mengidentifikasi beberapa sejumlah data, baik data stunting dan lainnya. Penelitian yang dilakukan oleh Nirmalasari (2020) pada penelitiannya Klasifikasi Masalah Gizi Balita Indonesia Dengan Algoritma Decision Tree C4.5, membuktikan bahwa metode decision tree adalah model mampu mengklasifikasikan masalah gizi balita di Indonesia dengan tepat (Naufal, 2021). Hasil penelitian yang dilakukan oleh Prasetio (2019) pada penelitiannya Optimasi Klasifikasi Jenis Hutan Menggunakan Deep Learning Berbasis Optimize Selection membuktikan bahwa Algoritma deep learning memiliki fleksibilitas dalam Machine Learning, baik untuk supervised maupun unsupervised learning. Algoritma deep learning menunjukkan akurasi yang sangat tinggi dalam memprediksi umur transformator dibandingkan algoritma lainnya, pada penelitiannya Algoritma Deep Learning-LSTM untuk Memprediksi Umur Transformator yang dilakukan oleh (Ardiyansyah et al., 2018).

Namun, seiring dengan perkembangan teknologi, metode pembelajaran mesin yang lebih kompleks seperti deep learning telah mulai diaplikasikan dalam analisis data kesehatan (A'la & Fata, 2024). Deep learning adalah salah satu cabang machine learning yang memungkinkan komputer untuk belajar dari data yang sangat besar dan kompleks dengan menggunakan arsitektur jaringan saraf tiruan (LeCun, Bengio, & Hinton, 2015). Penelitian terbaru menunjukkan bahwa deep learning mampu menghasilkan tingkat akurasi yang lebih tinggi dibandingkan metode tradisional seperti decision tree dalam berbagai aplikasi kesehatan, termasuk deteksi penyakit (Guo et al., 2016). Meskipun demikian, penggunaan deep learning untuk deteksi stunting pada balita masih jarang diteliti, terutama di Indonesia (Robbani, 2024).

Kebaruan ilmiah dari penelitian ini terletak pada perbandingan langsung antara dua metode pembelajaran mesin, yaitu *decision tree* Algoritma C4.5 dan *deep learning*, dalam mendeteksi stunting pada balita. Sebagian besar penelitian sebelumnya hanya fokus pada satu metode tanpa membandingkan kinerja keduanya secara langsung (Prasetio & Ripandi, 2019). Dengan demikian, penelitian ini berupaya menjawab pertanyaan penelitian: metode manakah yang lebih efektif dalam mendeteksi stunting pada balita, apakah Algoritma C4.5 atau *deep learning*?

Tujuan dari penelitian ini adalah untuk membandingkan efektivitas dua metode pembelajaran mesin, yakni *decision tree* Algoritma C4.5 dan *deep learning*, dalam mengidentifikasi stunting pada balita dengan menggunakan perangkat lunak RapidMiner. Penelitian ini diharapkan dapat memberikan kontribusi dalam pemilihan metode terbaik yang dapat diimplementasikan dalam sistem deteksi dini stunting di Indonesia (Karyanta et al., 2020).

METODE PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif dengan desain penelitian komparatif (Sari et al., 2023). Penelitian komparatif dilakukan untuk membandingkan dua metode pembelajaran mesin, yaitu *decision tree* Algoritma C4.5 dan *deep learning*, dalam mengidentifikasi stunting pada balita. Desain penelitian ini dipilih karena bertujuan untuk menganalisis perbedaan akurasi antara kedua metode tersebut dalam mendeteksi kasus stunting berdasarkan data yang tersedia (Machali, 2021).

Jenis penelitian ini adalah kuantitatif eksperimental, dimana dua metode pembelajaran mesin diuji dan dibandingkan kinerjanya dalam mengklasifikasikan data balita yang mengalami stunting. Algoritma C4.5 dan *deep learning* dipilih sebagai objek perbandingan untuk menentukan metode yang paling efektif dalam mendeteksi stunting berdasarkan data kesehatan balita.

Dataset stunting balita yang digunakan adalah data public yang dapat diakses melalui <https://www.kaggle.com/datasets/rendiputra/stunting-balita-detection-121k-rows> data terdiri dari beberapa variable (umur/bulan, jenis kelamin, tinggi badan, status gizi).

Table 1. Table dataset

Umur(bulan)	Jenis Kelamin	Tinggi Badan	Status Gizi
0	Laki- laki	44.59197	Stunted
0	Laki- laki	56.7052	Tinggi
0	Laki- laki	46.86335	Normal
0	Laki- laki	47.508003	Normal
0	Laki- laki	42.743449	Severely stunted
0	Laki- laki	44. 25772	Stunted
0	Laki- laki	59.57252	Tinggi
0	Laki- laki	42.7018	Severely stunted
0	Laki- laki	45.25178	Stunted
0	Laki - laki	57.20196	tinggi

Sumber : <https://www.kaggle.com/datasets/rendiputra/stunting-balita-detection-121k-rows>

Decision Tree

Decision tree adalah algoritma *supervised machine learning* yang digunakan untuk memecahkan masalah klasifikasi, tujuan utama menggunakan algoritma decision tree, karena algoritma c4.5 mampu menghasilkan model prediksi secara spesifik dalam bentuk aturan yang mudah di implementasikan. Dalam decision tree memiliki root node dan internode untuk melakukan prediksi dan klasifikasi. Ada beberapa tahap dalam membuat decision tree c4.5 (Siregar et al., 2017) yaitu:

1. Tentukan atribut yang akan dijadikan akar dengan menentukan nilai entropy terendah dan nilai gain tertinggi. Menentukan nilai entropy dengan rumus

$$Entropy(y) = -\sum_{i=1}^n p_i \log_2 p_i$$

2. Tentukan nilai gain dengan rumus :

Gain(y,A)=

$$Entropy(y) - \sum_{c \in \text{nilai}(A)} \frac{y_c}{y} \text{entropy}(y_c)$$

3. Membuat cabang untuk masing-masing nilai
4. Membagi sikap kasus menjadi cabang
5. Mengulang proses untuk masing- masing cabang, sehingga semua kasus memiliki kelas yang sama.

Deep Learning

Deep learning adalah bagian dari pembelajaran mesin yang berbasis pada jaringan saraf tiruan, yang dirancang untuk mensimulasikan cara otak manusia memproses informasi. Pembelajaran mendalam terdiri dari beberapa lapisan simpul yang saling terhubung (neuron), di mana setiap lapisan belajar untuk mengekstrak fitur yang semakin abstrak dari data masukan mentah. Tidak seperti model pembelajaran mesin tradisional, pembelajaran mendalam dapat secara otomatis mempelajari representasi data tanpa memerlukan ekstraksi fitur manual, yang sangat penting untuk tugas-tugas seperti pemrosesan gambar. Ada beberapa tahap dalam mengimplementasikan Algoritma *Deep learning* yaitu:

1. Perhitungan Neuron Pada Setiap Lapisan

$$z = \sum_{i=1}^n w_i x_i + b$$

2. Fungsi Aktivasi

- a. Sigmoid

$$\sigma(z) = \frac{1}{1 + e^{-z}}$$

- b. ReLU

$$f(z) = \max(0, z)$$

- c. Tanh

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

3. Fungsi Biaya

$$J = -\frac{1}{m} \sum_{i=1}^m [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)]$$

Mean Squared Error

$$J = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2$$

4. Algoritma Backpropagation

$$w = w - \alpha \frac{\partial J}{\partial w}$$

5. Proses Gradient Descent

Rumus Dasar SGD:

$$w = w - \alpha \nabla J(w)$$

Contoh proses penghitungan di Jaringan Saraf

Output Neuron 1 :

$$z = w_1x_1 + w_2x_2 + b$$


Output Neuron 2 menggunakan aktivasi Sigmoid :

$$a = \sigma(z) = \frac{1}{1 + e^{-z}}$$

Teknik Pengumpulan Data


Pengumpulan data dilakukan dengan menggunakan teknik dokumentasi, yaitu dengan mengumpulkan dataset dari instansi terkait yang memiliki data riil mengenai kesehatan balita. Data ini diolah dan dianalisis dengan menggunakan perangkat lunak RapidMiner, yang memungkinkan integrasi dan analisis data secara cepat dan efisien. Selain itu, instrumen utama dalam analisis ini adalah algoritma decision tree Algoritma C4.5, yang akan digunakan untuk membangun model prediktif stunting. Analisis Data Tahapan analisis data dalam penelitian ini melibatkan beberapa langkah utama, yaitu:

1. Import Data: Langkah pertama dalam analisis data adalah mengimpor data ke dalam lingkungan perangkat lunak yang akan digunakan, dalam hal ini RapidMiner. Data tersebut berformat CSV (Comma Separated Values), yang mudah diimpor dan diproses dalam berbagai alat analisis data.




Gambar 1. Import Data

2. Pemberian Label pada data : Setelah data diimpor, langkah berikutnya adalah memberikan label pada data. Dalam konteks penelitian ini, kita perlu mengklasifikasikan data balita menjadi dua kategori, yaitu "stunting" dan "non-stunting". Pemberian label bertujuan untuk menentukan status balita, apakah mereka mengalami stunting atau tidak, berdasarkan beberapa kriteria, seperti tinggi badan per usia.



Gambar 2. Pemberian Label pada Data


3. Preprocessing Data: Pada tahap ini, dilakukan pembersihan data (data cleaning) untuk mengatasi data yang hilang atau missing value dan normalisasi data untuk memastikan kualitas data yang diolah.




Gambar 3. Preprocessing Data

4. Split Data dan pemberian parameter: Setelah data diimpor dan label telah diberikan pada data, langkah berikutnya adalah memisahkan dataset menjadi dua bagian, yaitu data latih dan data uji. Data latih digunakan untuk melatih model pembelajaran mesin, sementara data uji digunakan untuk mengukur performa model pada data yang belum pernah dilihat sebelumnya. Pembagian umum adalah 80% data latih dan 20% data uji,

namun persentase ini dapat disesuaikan tergantung pada jumlah total data dan kebutuhan penelitian.




Gambar 4. Split data



Gambar 5. Pemberian Parameter


5. Pemodelan dengan Algoritma C4.5: Data yang telah diproses kemudian dianalisis menggunakan Algoritma C4.5 dalam perangkat lunak RapidMiner untuk membangun model decision tree. Algoritma C4.5 dipilih karena kemampuannya dalam menangani data yang bersifat kontinu dan diskrit serta memberikan hasil pohon keputusan yang mudah diinterpretasikan.



Gambar 6. Pemodelan Algoritma Decision tree C4.5


6. Pemodelan *deep learning*

Data yang sama kemudian akan dianalisis menggunakan metode deep learning. Model jaringan saraf tiruan (artificial neural network) dibangun dan dilatih menggunakan data tersebut, dengan tujuan untuk mendeteksi stunting berdasarkan variabel-variabel kesehatan balita.



Gambar 7. Pemodelan Algoritma deep learning


7. Apply Model : Setelah data dilatih menggunakan metode machine learning seperti Algoritma C4.5 atau deep learning, langkah berikutnya adalah menerapkan (apply) model tersebut pada data uji untuk memprediksi keluaran. Proses ini bertujuan untuk melihat seberapa baik model yang telah dilatih mampu memprediksi hasil pada data baru yang belum pernah dilihat oleh model.



Gambar 8. Apply model

8. Performance

Setelah model diterapkan pada data uji, langkah selanjutnya adalah mengevaluasi kinerja model. Evaluasi ini bertujuan untuk mengukur seberapa baik model dalam melakukan prediksi, dengan menggunakan metrik seperti akurasi, presisi, *recall*, dan *F1-score*.



Gambar 9. Performance

HASIL DAN PEMBAHASAN

Akurasi Model

Model yang dihasilkan dievaluasi berdasarkan beberapa metrik, seperti akurasi, presisi, recall, dan nilai F1. Selain itu, dilakukan validasi silang (cross-validation) untuk memastikan bahwa model yang dibangun memiliki performa yang baik dan dapat digunakan untuk memprediksi stunting secara akurat.

Algoritma Decision tree c4.5

	True stunted	True tinggi	True normal	True severely stunted	Class precision
pred. stunted	185	0	9	16	88.10%
pred. tinggi	0	477	57	0	89.33%
pred. normal	1035	1479	6704	1421	63.01%
pred. severely stunted	161	0	5	550	76.82%
Class recall	13.40%	24.39%	98.95%	27.68%	

Gambar 10. Hasil Evaluasi Model Algoritma Decision tree c4.5 menggunakan Rapidminer

Secara keseluruhan, Algoritma Decision Tree C4.5 menunjukkan kinerja yang beragam tergantung pada kelas yang diprediksi. Model ini cukup baik dalam memberikan prediksi yang benar (presisi tinggi), namun kesulitan dalam mendeteksi semua kasus yang ada (recall rendah), khususnya pada kasus yang penting seperti "Stunted" dan "Severely Stunted". Rendahnya nilai recall menunjukkan bahwa model sering kali gagal mendeteksi banyak balita yang benar-benar mengalami stunting, sehingga ini bisa menjadi area yang perlu diperbaiki dalam pengembangan model lebih lanjut.

Table 2. Tabel hasil Evaluasi Model Algoritma Decision tree c4.5

	True Stunted	True Tinggi	True Normal	True Severely Stunted	Class Precision
Pred.Stunted	185	0	9	16	88.10%
Pred. tinggi	0	477	57	0	89.33%
Pred. normal	1035	1479	6704	1421	63.01%
Pred. severely stunted	161	0	5	550	76.82%
Class recall	13.40%	24.39%	98.95%	27.68%	

Tabel didapat dari hasil evaluasi model algoritma decision tree c4.5

Algoritma Deep Learning

	true stunted	true tinggi	true normal	true severely stunted	class precision
pred stunted	1290	0	155	2	89.15%
pred tinggi	0	1947	47	0	97.64%
pred normal	2	9	6550	0	99.83%
pred severely stunted	89	0	23	1985	94.66%
class recall	93.41%	99.54%	96.68%	99.90%	

Gambar 11. Hasil Evaluasi Model Algoritma Deep learning

Hasil evaluasi model Deep Learning ini menunjukkan performa yang sangat kuat di hampir semua kategori, dengan presisi dan recall yang sangat tinggi. Kategori Normal dan Severely Stunted memiliki kinerja terbaik, dengan recall mendekati 100%. Ini berarti model sangat sedikit melakukan kesalahan dalam mengidentifikasi balita yang normal atau yang mengalami stunting parah. Namun, pada kategori Stunted, meskipun presisi dan recall cukup tinggi (di atas 89%), masih ada ruang untuk perbaikan untuk lebih meningkatkan sensitivitas model terhadap deteksi kasus stunting. Kategori Tinggi juga menunjukkan performa yang sangat baik, baik dari segi presisi maupun recall. Secara keseluruhan, model ini sangat kuat dalam memprediksi berbagai kategori status gizi balita, terutama dalam mendeteksi kasus-kasus stunting dan stunting parah.

Table 3. Table Hasil Evaluasi Model Algoritma Decision tree c4.5

	True Stunted	True Tinggi	True Normal	True Severely Stunted	Class Precision
Pred.Stunted	1290	0	155	2	89.15%
Pred. tinggi	0	1947	47	0	97.64%
Pred. normal	2	9	6550	0	99.83%
Pred. severely stunted	89	0	23	1985	94.66%
Class recall	93.41%	99.54%	96.68%	99.90%	

Tabel didapat dari hasil evaluasi model algoritma *Deep learning*

Perbandingan dengan penelitian terdahulu

Hasil dari penelitian ini sejalan dengan penelitian sebelumnya yang menunjukkan bahwa deep learning memiliki keunggulan dalam menganalisis data kesehatan yang kompleks. Misalnya, penelitian oleh (Shamshirband, Fathi, Dehzangi, Chronopoulos, & Alinejad-Rokny, 2021) yang membandingkan metode deep learning dan pohon keputusan pada data prediksi penyakit diabetes, juga menemukan bahwa deep learning unggul dalam hal akurasi dan kemampuan deteksi pola kompleks. Studi ini menegaskan bahwa untuk masalah-masalah kesehatan dengan banyak variabel yang berinteraksi, metode deep learning dapat memberikan hasil yang lebih akurat dibandingkan metode tradisional seperti pohon keputusan. Namun, penelitian ini juga menggarisbawahi kelemahan dari

deep learning, yakni memerlukan waktu komputasi yang lebih lama dan sumber daya yang lebih besar dibandingkan dengan Algoritma C4.5. Pada implementasi di dunia nyata, seperti di lingkungan rumah sakit atau dinas kesehatan yang memiliki keterbatasan sumber daya, penggunaan deep learning mungkin tidak selalu praktis dibandingkan dengan Algoritma C4.5 yang lebih cepat dan lebih hemat sumber daya (Goodfellow, Bengio, & Courville, 2016).

Kompleksitas Data Stunting

Hasil penelitian ini juga memberikan wawasan lebih lanjut mengenai kompleksitas data stunting itu sendiri. Tingkat akurasi yang lebih tinggi dari deep learning menunjukkan bahwa faktor-faktor yang mempengaruhi stunting tidak hanya bergantung pada satu atau dua variabel utama seperti gizi atau tinggi badan, tetapi juga pada interaksi variabel yang kompleks, seperti kondisi sosial-ekonomi, lingkungan, dan pola asuh (Oktia, Dokter, & Bsmi, 2020). Hal ini mendukung argumen bahwa masalah stunting merupakan hasil dari interaksi multidimensional yang lebih baik dimodelkan oleh teknik pembelajaran mesin yang lebih canggih seperti deep learning (Palit et al., 2024).

KESIMPULAN

Penelitian ini membandingkan dua pendekatan algoritma, yaitu Decision Tree C4.5 dan Deep Learning, dalam mengidentifikasi stunting pada balita menggunakan perangkat lunak RapidMiner. Dari hasil penelitian, dapat disimpulkan bahwa kedua metode memberikan performa yang baik dalam melakukan klasifikasi, namun dengan karakteristik yang berbeda. Algoritma Decision Tree C4.5 menunjukkan hasil yang cukup akurat dalam memprediksi kelas dengan kompleksitas yang lebih rendah dan proses yang lebih interpretatif, tetapi hasilnya masih dapat ditingkatkan pada kelas-kelas tertentu, seperti Normal dan Severely Stunted. Kelemahan yang terlihat adalah dalam menangani kelas yang sangat tidak seimbang, seperti pada prediksi balita tinggi, di mana hasil prediksi kurang akurat dibandingkan metode Deep Learning. Sementara itu, model Deep Learning menghasilkan kinerja yang lebih unggul, dengan tingkat akurasi keseluruhan mencapai 97.30%. Model ini menunjukkan kekuatan khusus dalam mendeteksi kelas Normal dan Severely Stunted, dengan nilai recall hampir mencapai 99.90%, yang menunjukkan sensitivitas tinggi dalam mengidentifikasi kasus tersebut. Selain itu, performa presisi yang tinggi pada kategori Normal dan Tinggi menunjukkan kemampuan model ini untuk memprediksi dengan baik, walaupun memerlukan sumber daya komputasi yang lebih besar dan interpretasi hasil yang lebih kompleks. Dengan demikian, dari hasil penelitian ini, dapat disimpulkan bahwa algoritma Deep Learning lebih efektif dan akurat dalam menangani tugas klasifikasi yang kompleks seperti identifikasi stunting, terutama pada data yang memiliki distribusi kelas tidak seimbang. Namun, algoritma Decision Tree C4.5 masih menjadi pilihan yang baik untuk analisis yang membutuhkan interpretabilitas lebih tinggi, dengan proses komputasi yang lebih ringan. Penelitian ini diharapkan dapat memberikan kontribusi dalam pengembangan sistem deteksi dini stunting pada balita, serta sebagai acuan untuk pemilihan metode yang paling sesuai dengan karakteristik data dan kebutuhan analisis dalam studi kasus yang serupa.

REFERENSI

- A'la, F. R., & Fata, Z. (2024). Perbandingan Algoritma Decision Tree dan Deep Learning dalam Prediksi Masalah Kesehatan berdasarkan Kebiasaan Gaya Hidup. *Mutiara: Multidiciplinary Scientifict Journal*, 2(10), 1034–1046.
- Ardiyansyah, A., Rahayuningsih, P. A., & Maulana, R. (2018). Analisis Perbandingan Algoritma Klasifikasi Data Mining Untuk Dataset Blogger Dengan Rapid Miner. *Jurnal Khatulistiwa Informatika*, 6(1).
- Karyanta, N. A., Suryanto, S., & Hendriani, W. (2020). Menggunakan metode historis komparatif dalam penelitian psikologi. *Jurnal Psikologi Sosial*, 18(2), 145–156.
- Kurniati, P. T. (2021). Penyuluhan tentang pencegahan stunting melalui pemenuhan gizi pada wanita usia subur. *Jurnal Alifani Penelitian Dan Pengabdian Kepada Masyarakat*, 1(2), 113–118.
- Machali, I. (2021). *Metode penelitian kuantitatif (panduan praktis merencanakan, melaksanakan, dan analisis dalam penelitian kuantitatif)*. Fakultas Ilmu Tarbiyah dan Keguruan Universitas Islam Negeri (UIN) Sunan
- Mayasari, E., Sari, F. E., & Yulyani, V. (2022). Hubungan Air Dan Sanitasi Dengan Kejadian Stunting Diwilayah Kerja Upt Puskesmas Candipuro Kabupaten Lampung Selatan Tahun 2021. *Indonesian Journal of Health and Medical*, 2(1).
- Naufal, M. F. (2021). Analisis Perbandingan Algoritma Svm, Knn, Dan Cnn untuk Klasifikasi Citra Cuaca. *Jurnal Teknologi Informasi Dan Ilmu Komputer*, 8(2), 311–317.
- Nirmalasari, N. O. (2020). Stunting pada anak: Penyebab dan faktor risiko stunting di Indonesia. *Qawwam*, 14(1), 19–28.
- Palit, O. O., Dhenanta, R. P., Susanto, A. I., Syawly, A. M., Ivansyah, A. L., Santika, A. P., Arifyanto, M. I., & Muttaqien, F. (2024). Akurasi Metode Mesin Pembelajaran dalam Analisis Variabel Penting Faktor Risiko Sindrom Down. *The Indonesian Journal of Computer Science*, 13(5).
- Prasetio, R. T., & Ripandi, E. (2019). Optimasi Klasifikasi jenis hutan menggunakan deep learning berbasis optimize selection. *Jurnal Informatika*, 6(1), 100–106.
- Robbani, F. (2024). *Klasifikasi Kejadian Berat Bayi Lahir Rendah Menggunakan Metode K-Nearest Neighbor (Studi Kasus Puskesmas Silo Ii Kabupaten Jember)*. Politeknik Negeri Jember.
- Sari, M., Rachman, H., Astuti, N. J., Afgani, M. W., & Siroj, R. A. (2023). Explanatory survey dalam metode penelitian deskriptif kuantitatif. *Jurnal Pendidikan Sains Dan Komputer*, 3(01), 10–16.
- Shamshirband, S., Fathi, M., Dehzangi, A., Chronopoulos, A. T., & Alinejad-Rokny, H. (2021). A review on deep learning approaches in healthcare systems: Taxonomies, challenges, and open issues. *Journal of Biomedical Informatics*, 113, 103627.
- Siregar, A. M., Kom, S., Puspabhuana, M. K. D. A. N. A., Kom, S., & Kom, M. (2017). *Data Mining: Pengolahan Data Menjadi Informasi dengan RapidMiner*. CV Kekata Group.
- Taufiq, Z. (2024). gizi dan kelompok. *Gizi Dan Kesehatan Masyarakat*, 51.