



Klasifikasi Data Balita Stunting dengan Metode *Decision Tree*

I Made Gde Bagus Baskara^{1*}, I Wayan Sudiarsa², I Made Hendra Wijaya³,
I Kadek ShandyDwi Putra Andikha⁴, Avento Maria Honestra Pratama Onggot⁵

¹Program Studi Bisnis Digital, Fakultas Bisnis dan Desain Kreatif, Institut Bisnis dan Teknologi Indonesia, Indonesia

²Program Studi Rekayasa Sistem Komputer, Fakultas Teknik dan Informatika, Institut Bisnis dan Teknologi Indonesia, Indonesia

*Penulis Korespondensi: sudiarsa@instiki.ac.id

Abstract. *Stunting is a chronic malnutrition condition that significantly impacts the physical growth and cognitive development of toddlers, often leading to irreversible damage to physical and mental capabilities during the critical first 1,000 days of life. In Indonesia, stunting remains a critical public health concern that requires early and accurate detection to mitigate long-term adverse effects. Conventional methods of determining nutritional status often rely on manual measurements and look-up tables, which can be time-consuming and susceptible to human error when processing large datasets. This study aims to address these challenges by developing an automated classification model for toddler stunting status using the Decision Tree algorithm. The research methodology includes data collection, preprocessing (cleaning and attribute selection), and model training using the Python programming language within the Google Colab environment, leveraging the Scikit-Learn library for efficient computation. The dataset utilized comprises key anthropometric attributes such as age, gender, body height, and weight. The experimental results demonstrate that the Decision Tree model effectively classifies nutritional status with an accuracy of 99,91%, indicating a high degree of reliability for practical implementation. Furthermore, the model generates interpretable decision rules, enabling healthcare practitioners to easily understand the primary determinants of stunting. Consequently, this model reliably aids in early stunting detection and prevention, potentially facilitating real-time monitoring in remote areas where access to specialized pediatric care is limited.*

Keywords: *Automatic Classification; Decision Tree; Early Detection; Nutritional Status; Stunting.*

Abstrak. Stunting adalah kondisi malnutrisi kronis yang berdampak signifikan terhadap pertumbuhan fisik dan perkembangan kognitif balita, yang sering kali menyebabkan kerusakan permanen pada kemampuan fisik dan mental selama 1.000 hari pertama kehidupan yang kritis. Di Indonesia, stunting masih menjadi masalah kesehatan masyarakat yang kritis yang memerlukan deteksi dini dan akurat untuk memitigasi dampak buruk jangka panjang. Metode konvensional dalam menentukan status gizi sering kali bergantung pada pengukuran manual dan tabel rujukan, yang dapat memakan waktu serta rentan terhadap kesalahan manusia saat memproses kumpulan data yang besar. Penelitian ini bertujuan untuk mengatasi tantangan tersebut dengan mengembangkan model klasifikasi otomatis untuk status stunting balita menggunakan algoritma *Decision Tree*. Metodologi penelitian meliputi pengumpulan data, pra-pemrosesan (pembersihan dan seleksi atribut), serta pelatihan model menggunakan bahasa pemrograman Python di lingkungan Google Colab, dengan memanfaatkan pustaka *Scikit-Learn* untuk komputasi yang efisien. Dataset yang digunakan terdiri dari atribut antropometri kunci seperti usia, jenis kelamin, tinggi badan, dan berat badan. Hasil eksperimen menunjukkan bahwa model *Decision Tree* secara efektif mengklasifikasikan status gizi dengan akurasi sebesar 99,91% yang menunjukkan tingkat keandalan tinggi untuk implementasi praktis. Selain itu, model ini menghasilkan aturan keputusan yang dapat diinterpretasikan, memungkinkan praktisi kesehatan untuk memahami penentu utama stunting dengan mudah. Akibatnya, model ini dapat diandalkan untuk membantu deteksi dini dan pencegahan stunting, serta berpotensi memfasilitasi pemantauan *real-time* di daerah terpencil di mana akses ke perawatan pediatrik khusus terbatas.

Kata kunci: *Decision Tree; Deteksi Dini; Klasifikasi Otomatis; Status Gizi Balita; Stunting.*

1. LATAR BELAKANG

Stunting merupakan kondisi gagal tumbuh pada anak balita (bayi di bawah lima tahun) akibat dari kekurangan gizi kronis sehingga anak terlalu pendek untuk usianya. Kekurangan gizi ini terjadi sejak bayi dalam kandungan dan pada masa awal setelah bayi lahir, akan tetapi

kondisi stunting baru nampak setelah bayi berusia 2 tahun. Di Indonesia, stunting bukan sekadar isu kesehatan semata, melainkan ancaman serius terhadap kualitas sumber daya manusia (SDM) di masa depan. Anak yang mengalami stunting berisiko memiliki tingkat kecerdasan di bawah rata-rata, sistem kekebalan tubuh yang lemah, serta rentan terhadap penyakit degeneratif di masa tua. Hal ini tentunya menjadi tantangan besar bagi Indonesia yang sedang menyongsong bonus demografi dan visi Indonesia Emas 2045.

Berdasarkan data dari Kementerian Kesehatan Republik Indonesia, angka prevalensi stunting di Indonesia masih tergolong tinggi jika dibandingkan dengan standar yang ditetapkan oleh Organisasi Kesehatan Dunia (WHO), yaitu di bawah 20%. Merujuk pada hasil Studi Status Gizi Indonesia (SSGI) tahun 2022, angka prevalensi stunting nasional berada pada angka 21,6%. Meskipun angka ini telah mengalami penurunan dari tahun-tahun sebelumnya, namun masih berada di atas target ambisius yang ditetapkan oleh Presiden Republik Indonesia, yaitu menurunkan angka stunting menjadi 14% pada tahun 2024.

Badan Kependudukan dan Keluarga Berencana Nasional (BKKBN) sebagai ketua pelaksana percepatan penurunan stunting terus mengupayakan berbagai intervensi, baik spesifik maupun sensitif, untuk mencapai target tersebut.

Salah satu kunci keberhasilan dalam penanganan stunting adalah deteksi dini yang akurat. Selama ini, pemantauan status gizi balita di tingkat Posyandu atau Puskesmas umumnya dilakukan dengan cara mengukur berat dan tinggi badan secara manual, kemudian hasilnya dicocokkan dengan tabel standar antropometri penilaian status gizi anak. Metode konvensional ini memiliki beberapa kelemahan, di antaranya adalah memakan waktu yang cukup lama karena petugas harus mencari indeks pada tabel referensi secara manual, serta tingginya risiko human error (kesalahan manusia) dalam pembacaan atau pencatatan data, terutama ketika menghadapi jumlah balita yang sangat banyak dalam satu waktu layanan.

Seiring dengan pesatnya perkembangan teknologi informasi, pemanfaatan kecerdasan buatan atau Artificial Intelligence (AI) menawarkan solusi efisien untuk mengatasi permasalahan tersebut. Teknik Data Mining dan Machine Learning dapat digunakan untuk memprediksi dan mengklasifikasikan status gizi balita secara otomatis dan presisi. Salah satu algoritma klasifikasi yang populer dan memiliki kinerja baik adalah Decision Tree. Algoritma ini dipilih karena memiliki kemampuan untuk menghasilkan struktur pohon keputusan yang mudah diinterpretasikan oleh manusia, sehingga tenaga kesehatan dapat memahami variabel apa saja (seperti umur, berat, atau tinggi badan) yang paling berpengaruh dalam penentuan status stunting. Penelitian ini bertujuan untuk menerapkan metode Decision Tree dalam mengklasifikasikan status stunting pada balita, yang diharapkan dapat menjadi alat bantu

sistem pendukung keputusan bagi tenaga medis untuk melakukan intervensi yang lebih cepat dan tepat sasaran.

2. KAJIAN TEORITIS

Stunting

Stunting adalah kondisi kegagalan tumbuh pada anak yang disebabkan oleh kekurangan gizi kronis dan infeksi berulang, sehingga anak memiliki tinggi badan yang rendah untuk usianya. Menurut Kementerian Kesehatan Republik Indonesia (Kemenkes RI, 2020), balita dikategorikan mengalami stunting jika Z-score Panjang Badan menurut Umur (PB/U) atau Tinggi Badan menurut Umur (TB/U) berada di bawah -2 Standar Deviasi (SD) Rahmadhita, 2020). Stunting ini dianggap sebagai indikator yang baik untuk menilai kesejahteraan anak dan mencerminkan ketimpangan sosial, karena mencakup akumulasi akibat kekurangan nutrisi dalam jangka panjang (Paramashanti et al., 2017)Lestari & Z.R, 2023). Data menunjukkan bahwa stunting dapat berkontribusi terhadap gangguan perkembangan kognitif dan fisik anak, serta meningkatkan risiko kesehatan di kemudian hari (Paramashanti et al., 2017).

Dampak jangka panjang dari stunting terhadap kesehatan dan perkembangan anak sangat mendalam. Program perhatian terhadap stunting oleh pemerintah diperlukan, karena masalah ini menjadi tantangan serius untuk masa depan sumber daya manusia di Indonesia yang berada dalam visi Indonesia Emas 2045 (Li et al., 2013). Belum adanya perubahan signifikan dalam prevalensi stunting di Indonesia menunjukkan perlunya langkah intervensi yang lebih efektif dan berbasis data untuk mencegah kelanjutan masalah ini.

Data Mining

Data Mining adalah proses penemuan pola dan pengetahuan dari sejumlah besar data, yang sering diperlakukan sebagai bagian dari proses Knowledge Discovery in Databases (KDD) (Wu et al., 2021). Dalam konteks kesehatan, data mining digunakan untuk menganalisis big data medis, termasuk dalam diagnosis penyakit dan pengembangan intervensi kesehatan yang lebih baik Rahman et al., 2019)(Islam et al., 2018; . Menggabungkan metode statistik, pembelajaran mesin, dan sistem basis data, teknik ini berusaha untuk mengekstrak informasi tersembunyi yang bisa memberikan wawasan baru yang berharga bagi para peneliti dan praktisi Yoo et al., 2011). Data mining telah terbukti berguna dalam menentukan pola infeksi, mengevaluasi efektivitas perawatan, dan mengklasifikasikan status kesehatan pasien (Islam et al., 2018; Yoo et al., 2011).

Contoh aplikasi data mining dalam konteks kesehatan mencakup prediksi durasi tinggal pasien di ruang gawat darurat, pemodelan risiko penyakit jantung, serta analisis pola perawatan yang efektif (Shah et al., 2020; Rahman et al., 2019). Dalam hal ini, pemanfaatan data mining sangat penting dalam mengelola dan menganalisis informasi kesehatan yang kompleks untuk mendukung keputusan klinis yang tepat (Huang et al., 2020).

Algoritma Decision Tree


Decision Tree adalah salah satu metode klasifikasi dalam Data Mining dan Machine Learning yang populer (Mohammed & Begum, 2022). Struktur pohon keputusan ini sederhana dan terdiri dari Root Node, Internal Node, dan Leaf Node. Pemilihan atribut yang digunakan untuk memecah data diambil berdasarkan perhitungan Information Gain atau Gini Index (Mohammed & Begum, 2022). Keunggulan metode ini dibandingkan model lain, seperti Neural Network, terletak pada sifatnya yang transparan dan mudah dimengerti, sehingga memudahkan tenaga kesehatan dalam memahami keputusan yang diambil oleh model (Raghavendra & J, 2020; Kolling et al., 2021).

Penggunaan Decision Tree dalam deteksi stunting di anak memungkinkan penanganan lebih terfokus, dengan memahami variabel yang berkontribusi terhadap risiko stunting, seperti pola asupan gizi dan faktor lingkungan anak. Hal ini memberikan kesempatan untuk melakukan intervensi yang tepat pada waktu yang tepat (Khanal, 2017; Ullah et al., 2016).

Evaluasi Model (Confusion Matrix)

Untuk mengevaluasi kinerja model klasifikasi menggunakan beberapa metrix klasifikasi sebagai berikut:

- 1) Akurasi (*Accuracy*), Representasi rasio keberhasilan model dalam mengklasifikasikan seluruh data uji secara tepat, baik untuk kelas positif maupun negatif.
- 2) Presisi (*Precision*), Nilai yang menggambarkan tingkat reliabilitas prediksi positif model, guna memastikan minimnya kesalahan dalam menetapkan label stunting (False Positive).
- 3) Recall (*Sensitivity*), indikator sensitivitas sistem dalam mengidentifikasi kembali seluruh kasus stunting yang ada dalam dataset, untuk menghindari adanya kasus yang terlewat (False Negative)."
- 4) F1-Score, Metrik komposit yang merupakan rata-rata harmonis antara presisi dan recall, digunakan untuk menilai kestabilan performa model secara menyeluruh.



Gambar 1. Confusion Matrix.

Gambar 1 menyajikan hasil analisis tingkat kepentingan fitur (feature importance) dalam model Decision Tree yang dibangun untuk mengklasifikasikan status gizi balita berdasarkan dataset balita stunting. Grafik ini menunjukkan bahwa Umur (bulan) merupakan fitur paling dominan dengan kontribusi sekitar 50% dalam proses pengambilan keputusan model, diikuti oleh Tinggi Badan (cm) dengan kontribusi sekitar 44%, sedangkan Jenis Kelamin memiliki pengaruh yang relatif kecil, hanya sekitar 6%.

3. METODE PENELITIAN

Dataset dan Variabel

Data yang digunakan dalam penelitian ini mencakup 121.000 rekam medis balita, yang terdiri dari sejumlah atribut (fitur) untuk keperluan prediksi status gizi.

Tabel 1. Variabel pada Dataset.

Nama Variabel	Deskripsi
Umur (bulan)	Variabel umur menyajikan usia balita dalam satuan bulan, dengan rentang 0–60 bulan.
Tinggi badan	Variable tinggi badan menyajikan tinggi badan balita dalam satuan sentimeter, dengan rentang sekitar 40–128 cm.
Jenis kelamin	Variable jenis kelamin menyajikan kategorikal yang terdiri dari laki-laki dan perempuan
Status gizi	Variable status gizi menyajikan kategorikal yang berperan sebagai variabel target, terdiri dari empat kelas yaitu normal, stunted, severely stunted, dan tinggi.

Tabel 1 menampilkan atribut-atribut yang termasuk parameter antropometri standar yang relevan bagi kesehatan anak, dan target variabel terdiri dari empat kelas klasifikasi: Normal, Severely Stunted, Stunted, dan Tinggi. Stunting merupakan masalah global yang signifikan terkait kesehatan anak, dengan laporan yang menunjukkan adanya hubungan antara faktor sosial, ekonomi, dan nutrisi yang mempengaruhi status gizi ini (Vaivada et al., 2020; "Mapping child growth failure across low- and middle-income countries", 2020; Kusumawati et al., 2015).

Pra-pemrosesan Data (Data Preprocessing)

Pra-pemrosesan data adalah tahap penting dalam persiapan dataset sebelum digunakan untuk melatih model Decision Tree. Langkah-langkah yang diambil dalam pra-pemrosesan ini mencakup pengubahan fitur kategorikal menjadi format numerik, serta penanganan yang tepat terhadap outlier. Dengan melakukan ini, kita dapat memastikan bahwa data siap untuk menghasilkan hasil model yang efektif. Alur pra- pemrosesan data dapat digambarkan sebagai berikut:

- 1) Identifikasi Missing Values, dengan menghitung jumlah missing values untuk setiap kolom dalam dataset.
- 2) Penanganan Missing Values, dengan menggunakan rata-rata, median, atau modus untuk menggantikan nilai yang hilang, atau menghapus baris atau kolom yang memiliki nilai hilang, terutama jika persentase missing values cukup tinggi
- 3) Melakukan Encoding Data Kategorikal, dengan melakukan encoding pada fitur kategorikal.

```
df_processed = pd.get_dummies(df_balita, columns=['Jenis Kelamin', 'Status Gizi'])

print("First 5 rows of df_processed:")
print(df_processed.head())

print("\nDataFrame Info:")
df_processed.info()
```

First 5 rows of df_processed:			
	Umur (bulan)	Tinggi Badan (cm)	Jenis Kelamin_laki-laki \
0	0	44.591973	True
1	0	56.705203	True
2	0	46.863358	True
3	0	47.508026	True
4	0	42.743494	True

	Jenis Kelamin_perempuan	Status Gizi_normal	Status Gizi_severely stunted
0	False	False	False
1	False	False	False
2	False	True	False

Gambar 2. Implementasi Deklarasi Data.

Gambar 2. Menyajikan penggunaan teknik One-Hot Encoding, variabel kategorikal dapat diubah menjadi representasi numerik biner yang diperlukan untuk pemodelan. Dalam konteks penelitian ini, variabel Jenis Kelamin dipecah menjadi dua fitur baru: Jenis Kelamin_laki-laki dan Jenis Kelamin_perempuan. Proses ini menjamin bahwa model dapat memahami perbedaan antara kategori yang ada pada data tersebut (Dahouda & Joe, 2021).

Pembagian Data

Pembagian dataset adalah langkah penting dalam pengembangan model Decision Tree, di mana data dibagi menjadi dua subset: data latih (training set) dan data uji (testing set). Setelah prapemrosesan data dilaksanakan, pembagian data dilakukan untuk memastikan model yang dilatih dapat diuji akurasi pada data yang belum pernah dilihat sebelumnya. Dalam studi ini, pembagian dilakukan dengan rasio 80:20, di mana 80% dari dataset digunakan untuk melatih model, sedangkan 20% sisanya digunakan untuk menguji kinerja model.

```
from sklearn.tree import DecisionTreeClassifier

# Initialize the Decision Tree Classifier
model_dt = DecisionTreeClassifier(random_state=42)

# Train the model
model_dt.fit(X_train, y_train)

print("Decision Tree model has been successfully trained.")
```

Decision Tree model has been successfully trained.

Gambar 3. Metode Klasifikasi.

Gambar 3 Menyajikan proses pelatihan model Decision Tree Classifier menggunakan pustaka scikit-learn, yang diawali dengan mengimpor kelas DecisionTreeClassifier dari modul sklearn.tree. Selanjutnya, sebuah objek model dibuat dan diinisialisasi dengan parameter random_state=42, yang bertujuan untuk memastikan konsistensi dan reproduktibilitas hasil pelatihan dengan mengontrol proses acak internal pada algoritma pohon keputusan. Model kemudian dilatih menggunakan metode fit() dengan memasukkan data fitur latih (X_train) dan label latih (y_train), di mana algoritma secara iteratif membangun struktur pohon dengan memilih atribut pemisah terbaik berdasarkan kriteria tertentu (seperti Gini impurity atau entropy) untuk memaksimalkan pemisahan kelas. Setelah proses pelatihan selesai, perintah print() digunakan untuk menampilkan pesan konfirmasi bahwa model Decision Tree telah berhasil dilatih, yang menandakan bahwa model siap digunakan untuk tahap evaluasi atau

prediksi pada data baru dalam konteks penelitian atau analisis lebih lanjut.

4. HASIL DAN PEMBAHASAN

Evaluasi Model

Mengevaluasi kinerja model Decision Tree yang telah dilatih menggunakan data uji. Metrik evaluasi yang akan digunakan meliputi akurasi (accuracy), presisi (precision), recall (recall), dan F1-score (f1-score). Hasil evaluasi ini akan memberikan gambaran tentang seberapa baik model dapat melakukan peramalan pada data baru.


Tabel 2. Metrik Evaluasi.

Metrik	Nilai
Accuracy	0.9991
Precision	0.9991
Recall	0.9991
F1-Score	0.9991

Tabel 2 menunjukkan hasil evaluasi model klasifikasi dengan nilai accuracy, precision, recall, dan F1-score yang semuanya mencapai 0,9991, menandakan bahwa model memiliki tingkat ketepatan, keandalan, dan keseimbangan kinerja yang sangat tinggi dalam melakukan klasifikasi, dengan kesalahan prediksi yang sangat minimal.

Visualisasi Pohon Keputusan

Visualisasi struktur Decision Tree yang telah dilatih adalah langkah penting dalam pemahaman model ini. Dengan memvisualisasikan pohon keputusan, kita dapat melihat bagaimana model membuat keputusan berdasarkan fitur-fitur yang ada dalam dataset. Visualisasi ini membantu dalam menginterpretasikan dan menganalisis logika pengambilan keputusan oleh model.



Gambar 4. Pohon Keputusan.

Gambar 4 menunjukkan visualisasi *Decision Tree* dengan kedalaman terbatas yang mengilustrasikan proses klasifikasi berdasarkan atribut tinggi badan dan umur, di mana setiap simpul menampilkan aturan pemisahan, nilai *gini impurity*, jumlah sampel, dan distribusi kelas, sehingga memberikan gambaran yang jelas dan interpretatif tentang mekanisme pengambilan keputusan model.

5. KESIMPULAN

Penelitian ini berfokus pada pengembangan dan evaluasi model Decision Tree Classifier untuk mengklasifikasikan status gizi balita, khususnya dalam identifikasi kondisi stunting. Dengan menggunakan dataset yang terdiri dari data rekam medis balita yang telah diproses, model dilatih dan diuji untuk menentukan kemampuannya dalam memprediksi status gizi berdasarkan fitur-fitur yang relevan.

Melalui analisis yang dilakukan, hasil evaluasi menunjukkan bahwa model Decision Tree mampu mencapai akurasi, presisi, recall, dan F1-score yang sangat tinggi, semua berada pada nilai 0,9991. Ini menandakan bahwa model ini tidak hanya efektif dalam memprediksi kondisi gizi tetapi juga mempunyai tingkat keandalan dan keseimbangan performa yang sangat baik. Dengan kesalahan prediksi yang sangat minimal, model ini dapat diandalkan dalam konteks kesehatan masyarakat untuk mendeteksi stunting pada balita. Hasil penelitian menegaskan bahwa Decision Tree adalah metode yang efektif untuk klasifikasi status gizi balita. Keunggulan model ini terletak pada kemampuannya dalam menangkap pola yang kompleks dalam data dan memberikan interpretabilitas yang baik kepada pengguna. Model ini membantu dalam pengambilan keputusan berbasis data yang lebih terinformasi, khususnya dalam mengatasi masalah gizi di kalangan anak-anak, yang merupakan isu penting bagi kesehatan masyarakat global.

Dengan demikian, penggunaan Decision Tree dalam penelitian ini tidak hanya memberikan hasil klasifikasi yang akurat, tetapi juga menunjukkan potensi aplikasi dalam program intervensi gizi yang ditujukan untuk meningkatkan kesehatan anak dan mengurangi prevalensi stunting di kalangan balita.

Keterbatasan

Dalam penelitian ini, model Decision Tree menunjukkan akurasi, presisi, recall, dan F1-score yang sangat tinggi, masing-masing mencapai 0,9991. Meskipun hasil ini tampak menjanjikan, nilai akurasi yang ekstrem dapat mengindikasikan potensi overfitting. Overfitting terjadi ketika model belajar dengan sangat mendalam dari data pelatihan, termasuk noise dan outlier, sehingga mengalami kesulitan dalam generalisasi ke dataset yang tidak terlihat. Hal ini

berarti model yang sangat akurat pada data latih mungkin memiliki kinerja yang buruk ketika dihadapkan dengan data baru

Saran

Berdasarkan hasil penelitian yang menunjukkan performa model Decision Tree yang sangat tinggi dengan nilai akurasi, presisi, recall, dan F1-score mendekati sempurna, penelitian selanjutnya disarankan untuk melakukan pengujian tambahan seperti *cross-validation* guna memastikan bahwa model tidak mengalami overfitting, mengingat dataset memiliki pola yang sangat kuat sebagaimana ditunjukkan dalam proses pelatihan pada file Colab.

Selain itu, disarankan untuk membandingkan metode Decision Tree dengan metode ensemble seperti Random Forest atau Gradient Boosting agar diperoleh model yang lebih stabil dan memiliki kemampuan generalisasi yang lebih baik. Penelitian berikutnya juga dapat menambahkan variabel antropometri lain seperti berat badan atau indikator gizi tambahan untuk meningkatkan akurasi dan kedalaman analisis. Terakhir, visualisasi pohon keputusan yang dihasilkan dalam penelitian ini dapat dimanfaatkan sebagai alat bantu interpretatif bagi tenaga kesehatan, namun tetap perlu diuji menggunakan data dari wilayah dan periode yang berbeda agar hasilnya lebih representatif secara umum.

DAFTAR PUSTAKA

- Afroze, F., Das, S., Ahmed, S., Sarmin, M., Shaly, N., Khan, S., ... Ahmed, T. (2020). Pathogen-specific risk of seizure in children with moderate-to-severe diarrhoea: Case-control study with follow-up. *Tropical Medicine & International Health*, 25(8), 1032–1042. <https://doi.org/10.1111/tmi.13445>
- Appoh, L., & Krekling, S. (2005). Maternal nutritional knowledge and child nutritional status in the Volta Region of Ghana. *Maternal & Child Nutrition*, 1(2), 100–110. <https://doi.org/10.1111/j.1740-8709.2005.00016.x>
- Bitew, F., Sparks, C., & Nyarko, S. (2021). Machine learning algorithms for predicting undernutrition among under-five children in Ethiopia. *Public Health Nutrition*, 1–12. <https://doi.org/10.1017/S1368980021004262>
- Chen, R., Dewi, C., Huang, S., & Caraka, R. (2020). Selecting critical features for data classification based on machine learning methods. *Journal of Big Data*, 7(1). <https://doi.org/10.1186/s40537-020-00327-4>
- Durán, P., Caballero, B., & Onís, M. (2006). The association between stunting and overweight in Latin American and Caribbean preschool children. *Food and Nutrition Bulletin*, 27(4), 300–305. <https://doi.org/10.1177/156482650602700403>
- Fenta, H., Zewotir, T., & Muluneh, E. (2021). A machine learning classifier approach for

- identifying the determinants of under-five child undernutrition in Ethiopian administrative zones. *BMC Medical Informatics and Decision Making*, 21(1). <https://doi.org/10.1186/s12911-021-01652-1>
- Flynn, J., Alkaff, F., Sukmajaya, W., & Salamah, S. (2021). Comparison of WHO growth standard and national Indonesian growth reference in determining prevalence and determinants of stunting and underweight in children under five: A cross-sectional study from Musi sub-district. *F1000Research*, 9, 324. <https://doi.org/10.12688/f1000research.23156.4>
- Gkikas, D., & Theodoridis, P. (2024). Predicting online shopping behavior: Using machine learning and Google Analytics to classify user engagement. *Applied Sciences*, 14(23), 11403. <https://doi.org/10.3390/app142311403>
- Insany, G., Yustiana, I., & Rahmawati, S. (2023). Penerapan KNN dan ANN pada klasifikasi status gizi balita berdasarkan indeks antropometri. *Jurnal Coscitech (Computer Science and Information Technology)*, 4(2), 385–393. <https://doi.org/10.37859/coscitech.v4i2.5079>
- Kino, S., Hsu, Y., Shiba, K., Chien, Y., Mita, C., Kawachi, I., ... Daoud, A. (2021). A scoping review on the use of machine learning in research on social determinants of health: Trends and research prospects. *SSM – Population Health*, 15, 100836. <https://doi.org/10.1016/j.ssmph.2021.100836>
- Kusumawati, E., Rahardjo, S., & Sari, H. (2015). Model pengendalian faktor risiko stunting pada anak bawah tiga tahun. *Kesmas: National Public Health Journal*, 9(3), 249.
- Lee, J., Houser, R., Must, A., Fulladolsa, P., & Bermúdez, O. (2012). Socioeconomic disparities and the familial coexistence of child stunting and maternal overweight in Guatemala. *Economics & Human Biology*, 10(3), 232–241. <https://doi.org/10.1016/j.ehb.2011.08.002>
- Manggala, A., Kenwa, K., Kenwa, M., Sakti, A., & Sawitri, A. (2018). Risk factors of stunting in children aged 24–59 months. *Paediatrica Indonesiana*, 58(5), 205–212. <https://doi.org/10.14238/pi58.5.2018.205-12>
- Rahman, S., Ahmed, N., Abedin, M., Ahammed, B., Ali, M., Rahman, M., ... Maniruzzaman, M. (2021). Investigate the risk factors of stunting, wasting, and underweight among under-five Bangladeshi children and its prediction based on machine learning approach. *PLOS ONE*, 16(6), e0253172. <https://doi.org/10.1371/journal.pone.0253172>
- Yazdan, S., Ahmad, R., Iqbal, N., Rizwan, A., Khan, A., & Kim, D. (2022). An efficient multi-scale convolutional neural network-based multi-class brain MRI classification for SaMD. *Tomography*, 8(4), 1905–1927. <https://doi.org/10.3390/tomography8040161>
- Yin, L., Lin, X., Liu, J., Li, N., He, X., Zhang, M., ... Xu, H. (2021). Classification tree-based machine learning to visualize and validate a decision tool for identifying malnutrition in cancer patients. *Journal of Parenteral and Enteral Nutrition*, 45(8), 1736–1748. <https://doi.org/10.1002/jpen.2070>