

Implementasi Algoritma LightGBM (*Light Gradient Boosting Machine*) untuk Sistem Deteksi Stunting pada Balita

Adittia Fathah
Informatika, Sekolah Tinggi Teknologi Cipasung
Tasikmalaya, Indonesia
adittiafathah@sttcipasung.ac.id

Abstract— Balita adalah anak usia dibawah 5 tahun atau 0-60 bulan. Usia tersebut termasuk ke dalam kelompok yang beresiko tinggi terhadap penyakit. Kekurangan asupan zat gizi pada balita dapat berdampak pada status gizi dan kesehatannya. Salah satu masalah pada balita yang harus dipantau secara serius adalah *stunting*. *Stunting* adalah gangguan tumbuh pada balita yang disebabkan karena kekurangan gizi dalam jangka panjang. Tujuan dari penelitian ini adalah untuk mengimplementasikan algoritma LightGBM dalam sistem deteksi *stunting* pada balita. Tahapannya mengikuti KDD (*Knowledge Discovery in Database*) dan algoritma yang digunakan adalah LightGBM. Sedangkan evaluasinya dilakukan dengan *Confusion Matrix*. Sumber data yang digunakan berasal dari Kaggle dengan jumlah 121.000 baris. Hasil *Confusion Matrix* menunjukkan bahwa model mampu mengklasifikasikan data pada keempat kategori status gizi anak (*normal, severely stunted, stunted, tinggi*) dengan tingkat kesalahan yang sangat rendah. *Classification report* memperkuat temuan tersebut, di mana nilai presisi, *recall*, dan *f1-score* rata-rata mencapai 0,99, serta akurasi keseluruhan sebesar 99%. Analisis *feature importance* mengungkapkan bahwa variabel tinggi badan (cm) dan umur (bulan) merupakan faktor dominan dalam prediksi model, sedangkan jenis kelamin memiliki kontribusi yang jauh lebih kecil. Hal ini konsisten dengan konsep medis bahwa perbandingan tinggi badan terhadap umur merupakan indikator utama dalam penentuan status gizi anak.

Kata kunci — Sistem Deteksi, Stunting, Balita, LightGBM, Confusion Matrix, Feature Importance

I. PENDAHULUAN

Balita adalah anak usia dibawah 5 tahun atau 0-60 bulan. Usia tersebut termasuk kedalam kelompok yang beresiko tinggi terhadap penyakit. Kekurangan asupan zat gizi pada balita dapat berdampak pada status gizi dan kesehatannya. Berdasarkan data laporan kesehatan dari *World Health Organization* (WHO) dan posyandu balita, ada beberapa masalah status gizi yang dapat mempengaruhi kesehatannya, seperti kekurangan energi, protein, obesitas, kurang vitamin A, gangguan akibat kekurangan iodium dan anemia atau kurang zat besi. Status Gizi pada balita adalah faktor penting yang harus diperhatikan karena pada masa balita perkembangan menjadi hal yang sangat penting bagi tubuh mereka yang masih sangat rentan dengan namanya kekurangan gizi [1]. Pemantauan kesehatan balita perlu dilakukan untuk memastikan pertumbuhan dan perkembangan yang tepat bagi balita [20]. Salah satu masalah pada balita yang harus dipantau secara serius adalah *stunting*. *Stunting* adalah gangguan tumbuh pada balita yang disebabkan karena kekurangan gizi dalam jangka panjang. Stunting tidak hanya berdampak pada tinggi badan yang lebih pendek dari standar usia, tetapi juga dapat menghambat perkembangannya mental dan kesehatan anak di masa depan [2] [3].

Dampak negatif pada *stunting* dapat dibagi menjadi dua, yaitu dampak jangka panjang dan jangka pendek. Dampak jangka pendek *stunting* yaitu terganggunya perkembangan otak, pertumbuhan fisik, kecerdasan, dan gangguan metabolisme pada tubuh. Sedangkan untuk jangka panjang, yaitu mudah munculnya penyakit diabetes, penyakit jantung dan pembuluh darah, kegemukan, kanker, *stroke*, disabilitas pada usia tua, dan kualitas kerja yang kurang baik, sehingga membuat produktifitas menjadi rendah [4]. Selain dua faktor tersebut, *stunting* juga dapat dipengaruhi faktor yang tidak langsung. Faktor tersebut diantaranya status sosial ekonomi, pelayanan kesehatan, kurangnya pemberdayaan perempuan, serta masalah degrasi lingkungan [5].

Meskipun upaya penanggulangan stunting terus dilakukan, permasalahan ini masih menjadi tantangan di berbagai wilayah [7]. Artinya *stunting* bisa terjadi dimana saja. *Stunting* masih menjadi salah satu masalah gizi kronis yang serius di dunia. Berdasarkan data terbaru, beberapa negara dengan prevalensi stunting tertinggi adalah Burundi (55,9–57,6 %), Yaman (hingga 48,5 %), Niger (47,7 %), Guatemala (42,8 %), Democratic Republic of the Congo (40,8 %), Madagascar (40,2 %), Mozambik (37,8 %), Angola (37,7 %), Malawi (37,0 %), dan Pakistan (36,7 %). Negara-negara tersebut memiliki kesamaan berupa tingkat kemiskinan tinggi, keterbatasan akses pangan bergizi, sanitasi yang buruk, serta keterbatasan layanan kesehatan dasar. Faktor-faktor inilah yang menjadi penyebab utama tingginya angka stunting pada anak balita. Fenomena ini menunjukkan bahwa stunting merupakan masalah multifaktor yang tidak hanya dipengaruhi oleh faktor gizi, tetapi juga kondisi sosial, ekonomi, kesehatan, dan lingkungan. Kompleksitas penyebab stunting tersebut menjadikan pendekatan analisis konvensional kurang optimal dalam mengidentifikasi pola dan faktor risiko yang paling dominan [8].

Stunting dapat dideteksi saat mengandung hingga melahirkan. Maka dari itu, metode yang efektif dan efisien sangat dibutuhkan untuk mengidentifikasi balita yang berisiko stunting. Dalam beberapa tahun terakhir, penggunaan *machine learning* di bidang kesehatan terus berkembang pesat, terutama untuk identifikasi dan prediksi risiko kesehatan. [7]. Salah satu metode yang relevan adalah *data mining*, khususnya teknik klasifikasi. *Data mining* adalah metode pengolahan data untuk menemukan pola tersembunyi dari data. *Data mining* memiliki beberapa teknik dalam proses pengolahan data, teknik-teknik tersebut memiliki fungsi penting yang memungkinkan organisasi untuk mengolah dan menganalisis data besar secara efektif. Dengan *data mining*, berbagai variabel seperti usia anak, berat lahir, pendidikan ibu, pendapatan keluarga, akses sanitasi, hingga riwayat kesehatan dapat diolah untuk memprediksi risiko stunting. Teknik klasifikasi memberikan manfaat penting bagi organisasi dengan memungkinkan pengelompokan data ke dalam kategori yang telah ditentukan sebelumnya berdasarkan pola yang dipelajari dari *data training* berlabel. Teknik ini

kemampuan untuk membuat prediksi yang lebih akurat, memahami hubungan antara variabel, serta menyederhanakan proses pengambilan keputusan dengan menyajikan informasi yang terstruktur dan mudah dipahami[9]. Selain itu, diperlukan algoritma yang tepat untuk membuat model prediksi stunting. Salah satu algoritma yang dapat digunakan adalah LightGBM. Algoritma ini memiliki kinerja yang lebih cepat dari XGBoost dan belum digunakan pada penelitian sebelumnya. Hasil klasifikasi ini tidak hanya bermanfaat untuk penelitian akademik, tetapi juga dapat digunakan oleh pemerintah dan lembaga kesehatan untuk membuat sistem peringatan dini dan intervensi gizi yang lebih tepat sasaran.

Berdasarkan pemaparan tersebut, tujuan dari penelitian ini adalah untuk mengimplementasikan Algoritma LightGBM untuk sistem deteksi *stunting* pada balita.

II. TINJAUAN PUSTAKA

Penelitian sebelumnya tentang klasifikasi *stunting* pada balita sudah banyak dilakukan dengan algoritma yang berbeda-beda. Berdasarkan *literature review* yang telah dilakukan, algoritma yang digunakan adalah *Decision Tree*, *Naive Bates*, *Random Forest*, *K Nearest Neighbor* (KNN) dan *XGBoost*. Nilai akurasi yang diperoleh juga bervariasi.

Algoritma *Decision Tree* paling banyak digunakan pada penelitian sebelumnya. Contohnya adalah penelitian yang dilakukan oleh [4] yang menghasilkan akurasi 83%, [11] dengan hasil akurasi 95,73%, [13] dengan akurasi 95%, [14] dengan akurasi 97,92% dan [15] dengan akurasi sebesar 98,87%. Selain itu, algoritma *Naive Bayes* juga banyak digunakan. Contohnya pada penelitian yang dilakukan oleh [5] dengan algoritma dengan akurasi 98,40 %, [16] dengan akurasi 91,84% dan [7] dengan akurasi 91,58%.

Algoritma *Random Forest* dan KNN juga ada yang menggunakan meskipun tidak sebanyak *Decision Tree*. Penelitian yang menggunakan *Random Forest* adalah [17] dengan akurasi 97% dan [15] dengan akurasi 99,72%. Sedangkan algoritma KNN digunakan pada penelitian [9] dengan akurasi 80% dan [1] dengan nilai AUC 85,1%. XGBoost menjadi algoritma yang hanya digunakan pada penelitian [15] yang menghasilkan akurasi sebesar 99,58%. Secara singkat, perbandingan akurasi untuk algoritma yang digunakan pada penelitian sebelumnya dapat dilihat pada Tabel 1.

Tabel 1. Nilai Akurasi Pada Penelitian Sebelumnya

Algoritma	Akurasi (dalam persen)
<i>Decision Tree</i>	83 - 98,87
<i>Naive bayes</i>	91,5 - 98,40
<i>Random Forest</i>	97 - 99,72
<i>KNN</i>	80 - 85,1
<i>XGBoost</i>	99,58

Berdasarkan Tabel 1, algoritma *Random Forest* memiliki akurasi tertinggi. Namun, ada juga algoritma yang belum digunakan yaitu LightGBM. LightGBM adalah algoritma yang dirancang oleh Microsoft Research Asia menggunakan kerangka *Gradient Boosting Decision Tree* (GBDT). Tujuannya untuk meningkatkan efisiensi komputasi, sehingga masalah prediksi dengan big data dapat diselesaikan dengan efisien. Dibandingkan dengan XGBoost, LightGBM memiliki beberapa keunggulan, yaitu kecepatan pelatihan yang lebih cepat, efisiensi lebih tinggi, penggunaan memori lebih rendah, tingkat akurasi lebih baik, kemampuan dalam menangani data dengan skala yang besar dan dukungan pembelajaran paralel dan GPU. LightGBM adalah kerangka *Gradient Boosting* yang cepat, terdistribusi dan berkinerja tinggi berdasarkan algoritma pohon keputusan yang dapat digunakan untuk peringkat, klasifikasi, regresi dan banyak tugas pembelajaran mesin lainnya [18].

Selain itu, untuk melakukan penyiembangan data latih, teknik SMOTE seperti pada penelitian [7] juga akan digunakan namun dengan penambahan Tomek. SMOTE-Tomek adalah *hybrid sampling*, kombinasi dari SMOTE (*Synthetic Minority Over-sampling Technique*) dan *Tomek Links* yang dirancang untuk mengatasi distribusi kelas yang tidak seimbang pada dataset. SMOTE digunakan untuk menyeimbangkan distribusi kelas, sementara *Tomek Links* digunakan untuk mengidentifikasi dan menghapus sampel yang berpotensi menimbulkan gangguan atau garis batas yang dapat menyebabkan kesalahan klasifikasi [6]. SMOTE-Tomek biasanya diterapkan pada data latih agar algoritma LightGBM bisa belajar dengan distribusi kelas yang lebih seragam.

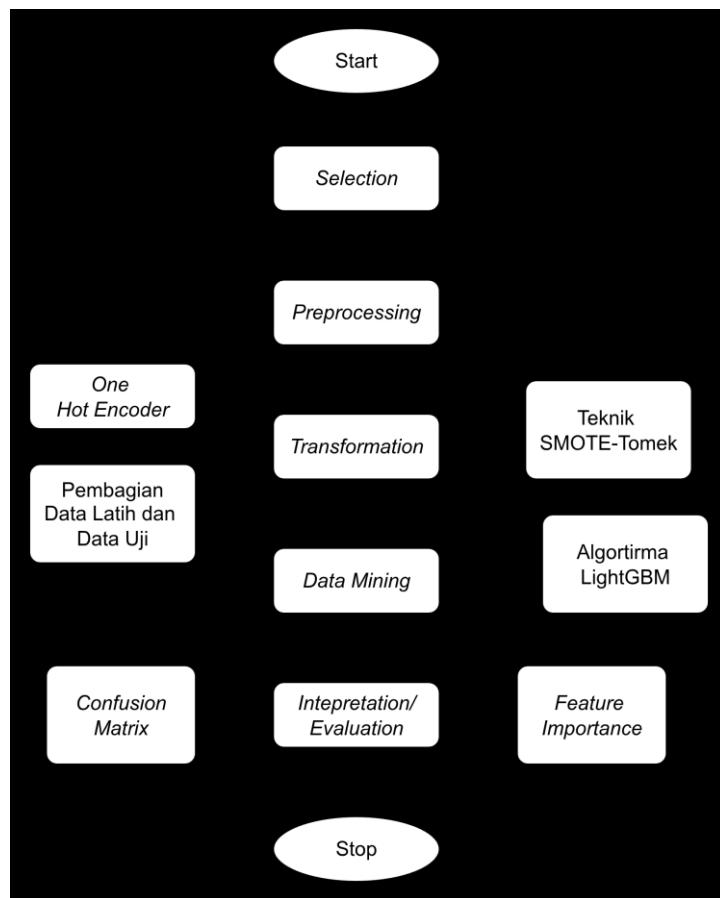
Confusion matriks juga digunakan untuk mempermudah dalam melakukan evaluasi model. *Confusion Matrix* adalah metode yang digunakan untuk mengevaluasi sejauh mana keberhasilan model dalam melakukan prediksi klasifikasi ketika output terdiri dari dua kelas atau lebih [10]. *Confusion Matrix* merupakan metode pengujian yang memberikan gambaran tentang sejauh mana algoritma dalam klasifikasi berhasil melakukan prediksi dengan benar. *Confusion Matrix* memberikan gambaran tentang performa model dalam melakukan klasifikasi berdasarkan data yang diberikan. *Confusion Matrix* dapat merepresentasikan hasil dalam bentuk matriks yang dirancang khusus. Dalam kasus klasifikasi biner, informasi yang disajikan mencakup *True Positive* (TP) sebagai data positif benar, *True Negatif* (TN) sebagai data negatif benar, *False Positive* (FP) sebagai data negatif salah, *False Negative* (FN) sebagai data positif salah. Analisis hasil dapat memberikan pemahaman mengenai hasil penelitian yang dilakukan [12]. Bentuk *Confusion Matrix* dapat dilihat pada Gambar 1.

		True Class	
		Positive	Negative
Predicted Class	Positive	TP	FP
	Negative	FN	TN

Gambar 1. Confusion matrix

III. METODE PENELITIAN

Metode dalam penelitian ini menggunakan pendekatan KDD (*Knowledge Discovery in Database*). Pengolahan datanya dilakukan menggunakan Google Colab. Sedangkan bahasa pemrograman yang digunakan adalah python. Tahapan pada metode KDD ditunjukkan pada Gambar 2.



Gambar 2. Tahapan Penelitian

1) Selection

Tahap pertama dalam metodologi deteksi stunting adalah *selection*, yaitu pemilihan data yang relevan untuk dianalisis. Data yang digunakan pada tahap ini dapat berupa umur anak, jenis kelamin, tinggi badan, berat badan, lingkar lengan atas, serta faktor lain yang berkaitan dengan status gizi, seperti riwayat penyakit, kondisi ekonomi keluarga, dan pendidikan orang tua. Data yang telah dipilih kemudian ditampilkan dengan memanfaatkan library Pandas. Pemilihan data ini bertujuan untuk menyaring variabel yang signifikan sehingga analisis dapat lebih fokus serta menghasilkan keluaran yang valid dan akurat.

2) Preprocessing

Tahap *preprocessing* berfungsi untuk menyiapkan data agar bersih, konsisten, dan siap diproses lebih lanjut. Proses pra-

pemrosesan meliputi penanganan nilai yang hilang (*missing values*), penghapusan data ganda, serta deteksi dan penanganan data ekstrem (*outlier*) yang tidak sesuai dengan kondisi nyata. Selain itu, dilakukan pula proses normalisasi terhadap atribut numerik agar berada pada skala yang sebanding. Tahap ini sangat penting untuk menghindari bias pada algoritma yang digunakan di tahap pemodelan.

3) Transformation

Tahap ketiga adalah *transformation*, yaitu proses mengubah data mentah menjadi data yang lebih sesuai dengan kebutuhan analisis. Pada tahap ini dilakukan pembuatan atribut turunan, misalnya menghitung Z-Score tinggi badan menurut umur berdasarkan standar WHO, rasio berat terhadap umur, atau pengelompokan status sosial-ekonomi. Data kategorikal seperti jenis kelamin juga diubah menjadi data numerik dengan menggunakan library OneHotEncoder agar dapat diproses oleh algoritma klasifikasi. Selain itu, dataset dibagi menjadi data latih dan data uji menggunakan library *train_test_split* dengan perbandingan 75:25. Seluruh hasil transformasi kemudian disimpan dalam basis data yang terstruktur sehingga memudahkan dalam tahap pemodelan selanjutnya.

4) Data Mining

Tahap inti dalam metodologi ini adalah *data mining*, yaitu penerapan algoritma untuk menemukan pola maupun membangun model prediksi. Pada tahap ini digunakan teknik klasifikasi LightGBM dengan menggunakan library *LGBMClassifier* untuk menentukan apakah seorang anak tergolong *stunting* atau normal. Dataset dibagi ke dalam data latih dan data uji guna memastikan kinerja model dapat diukur secara objektif. Sebelum dibuat modelnya, data latih akan diperiksa terlebih dahulu untuk mengetahui distribusi masing-masing kelas. Jika tidak seimbang, data latih akan diseimbangkan dulu dengan menggunakan teknik SMOTE-Tomek.

5) Interpretation/Evaluation

Tahap terakhir adalah *interpretation/evaluation*, yaitu interpretasi sekaligus evaluasi terhadap hasil model yang diperoleh. Evaluasi dilakukan menggunakan ukuran kinerja seperti akurasi, *precision*, *recall*, *F1-score*, serta *Confusion Matrix* untuk menilai kemampuan model dalam mengklasifikasikan data dengan benar. Selanjutnya, hasil analisis diinterpretasikan agar dapat dipahami oleh pihak terkait, misalnya tenaga kesehatan atau pengambil kebijakan.

IV. HASIL DAN PEMBAHASAN

4.1 Selection

Data yang dipilih pada penelitian ini bersumber dari kaggle yang di upload oleh [19]. Dataset “Deteksi Stunting pada Bayi/Balita” ini didasarkan pada rumus *z-score* untuk menentukan stunting sesuai dengan pedoman WHO (*World Health Organization*), yang berfokus pada deteksi *stunting* pada anak di bawah lima tahun. Dataset ini terdiri dari 121.000 baris data, yang mencakup informasi tentang usia, jenis kelamin, tinggi badan, dan status gizi balita. Dataset ini bertujuan untuk membantu peneliti, ahli gizi, dan membuat kebijakan memahami dan menangani masalah stunting pada anak di bawah lima tahun. Berikut atribut yang ada dalam dataset tersebut.

1. Usia (Bulan): Menunjukkan usia bayi/balita dalam bulan. Rentang usia ini penting untuk menentukan fase pertumbuhan anak dan membandingkannya dengan standar pertumbuhan yang sehat. (usia 0 hingga 60 bulan).
2. Jenis Kelamin: Kolom ini memiliki dua kategori, ‘laki-laki’ dan ‘perempuan’. Jenis kelamin merupakan faktor penting dalam menganalisis pola pertumbuhan dan risiko stunting.
3. Tinggi Badan: Dicatat dalam sentimeter, tinggi badan merupakan indikator utama untuk menilai pertumbuhan fisik anak di bawah lima tahun. Data ini memungkinkan peneliti untuk menentukan apakah pertumbuhan anak sesuai dengan standar usia.
4. Status Gizi: Kolom ini dikategorikan menjadi 4 status - ‘stunting parah (*severely stunted*)’, ‘*stunting*’, ‘normal’, dan ‘tinggi’. ‘Stunting parah’ menunjukkan kondisi yang sangat serius (<-3 SD), ‘*stunting*’ menunjukkan kondisi stunting (-3 SD hingga <-2 SD), ‘normal’ menunjukkan status gizi sehat (-2 SD hingga +3 SD), dan ‘tinggi’ menunjukkan pertumbuhan di atas rata-rata (>+3 SD). Kategori-kategori ini membantu dalam identifikasi cepat dan intervensi terhadap anak-anak yang berisiko atau mengalami stunting.

Contoh isi dalam dataset dapat dilihat pada Gambar 3

Contoh data:

Umur (bulan)	Jenis Kelamin	Tinggi Badan (cm)	Status Gizi
0	0	laki-laki	44.591973 stunted
1	0	laki-laki	56.705203 tinggi
2	0	laki-laki	46.863358 normal
3	0	laki-laki	47.508026 normal
4	0	laki-laki	42.743494 severely stunted

Gambar 3. Contoh Data dalam Dataset

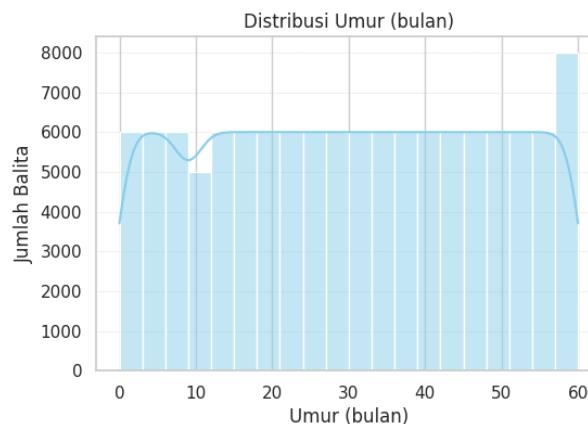
4.2 Preprocessing

Preprocessing dilakukan dengan beberapa tahap, yaitu melakukauan konversi tipe data dan membersihkan data pada nilai yang kosong. Prosesnya dapat dilihat pada Gambar 4.

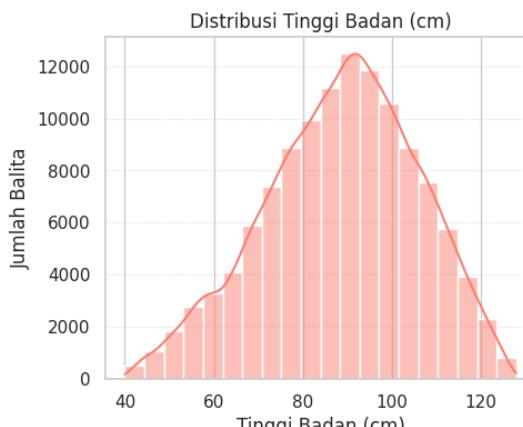
```
# Konversi tipe data dan bersihkan nilai kosong
df['Umur (bulan)'] = pd.to_numeric(df['Umur (bulan)'], errors='coerce')
df['Tinggi Badan (cm)'] = pd.to_numeric(df['Tinggi Badan (cm)'], errors='coerce')
df['Jenis Kelamin'] = df['Jenis Kelamin'].astype(str).str.strip().str.lower()
df['Status Gizi'] = df['Status Gizi'].astype(str).str.strip().str.lower()
df = df.dropna()
```

Gambar 4. Konversi data dan Pembersihan data Kosong

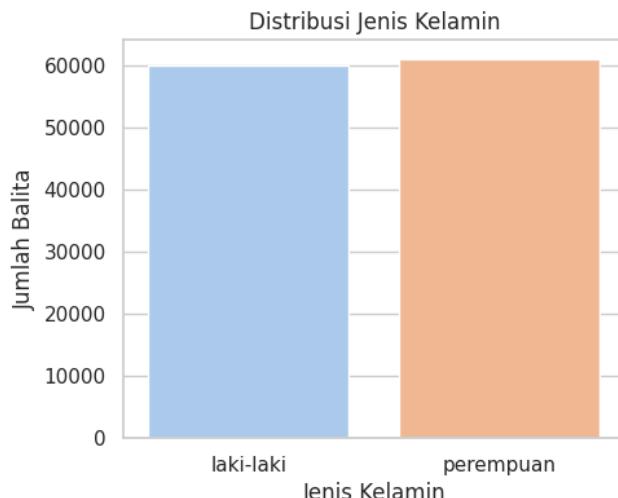
Pada Gambar 4, atribut umur dan tinggi badan di konversi ke dalam bentuk numerik, sedangkan jenis kelamin dan status gizi, semuanya nilainya diubah kedalam huruf kecil dengan fungsi *lower*. Langkah berikutnya, data kosong dihapus dengan perintah `df.dropna()`. Distribusi data untuk setiap atribut dapat dilihat pada Gambar 5. Gambar 6, Gambar 7 dan Gambar 8.



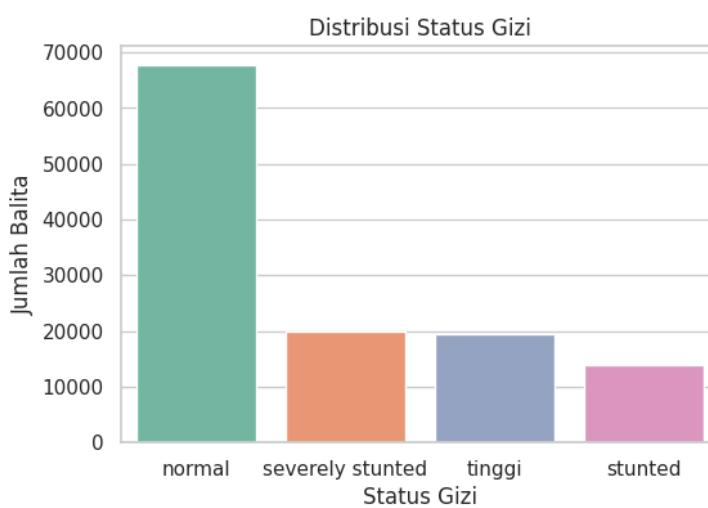
Gambar 5. Distribusi Data Umur



Gambar 6. Distribusi Data Tinggi Badan



Gambar 7. Distribusi Data Jenis Kelamin



Gambar 8. Distribusi Data Status Gizi

4.3 Transformation

Transformation dikakukan dengan beberapa langkah. Langkah pertama yaitu memisahkan atribut target dengan atribut lainnya. Pada penelitian ini, atribut targetnya adalah **Status Gizi**. Atribut target dimasukan ke dalam variabel y, sedangkan atribut lainnya dimasukan ke variabel x. Prosesnya dapat dilihat pada Gambar 9.

```
X = df[['Umur (bulan)', 'Jenis Kelamin', 'Tinggi Badan (cm)']]  
y = df['Status Gizi']
```

Gambar 9. Pemisahan Atribut Target

Langkah kedua adalah mengambil atribut dengan nilai numerik. Tujuannya adalah untuk mengisi nilai kosong (jika ada) dalam bentuk median. Prosesnya dapat dilihat pada Gambar 10.

```
numeric_features = ['Umur (bulan)', 'Tinggi Badan (cm)']  
numeric_transform = Pipeline([('imputer', SimpleImputer(strategy='median'))])
```

Gambar 10. Konversi Nilai Numerik

Langkah ketiga adalah melakukan konversi pada data kategorikal. Metode yang digunakan pada metode ini adalah *one-hot-encoding*. Prosesnya dapat dilihat pada Gambar 11.

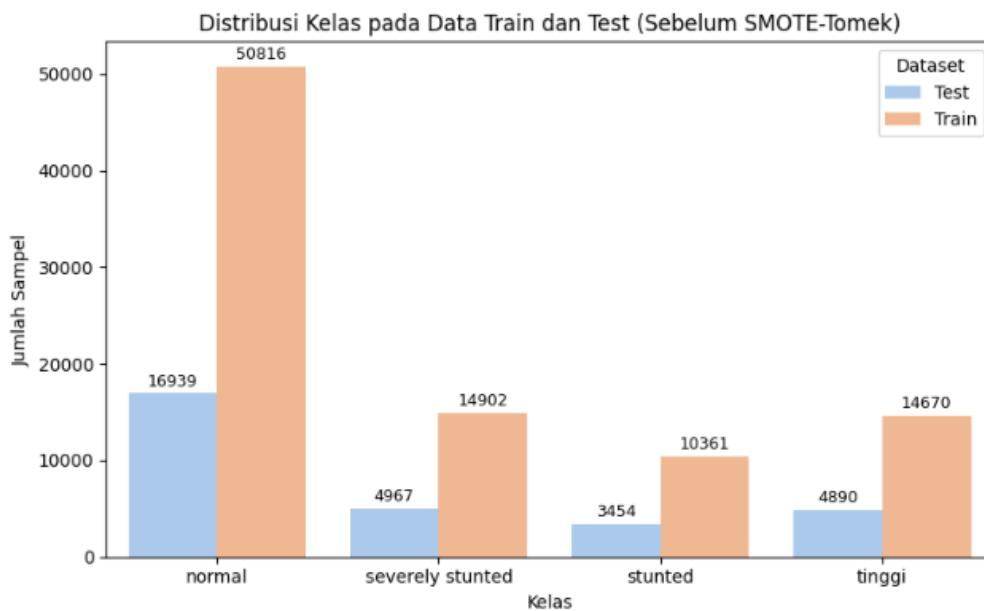
```
categorical_features = ['Jenis Kelamin']
categorical_transform = Pipeline([
    ('imputer', SimpleImputer(strategy='most_frequent')),
    ('onehot', OneHotEncoder(handle_unknown='ignore'))
])
```

Gambar 11. Proses One Hot Encoding

Langkah ketiga adalah *split data*. Pada tahap ini data dibagi menjadi dua, yaitu *data training* dan *data testing*. Perbandingan jumlah datanya adalah 75: 25 dengan 75% data latih dan 25% data uji. Proses pembagian dilakukan menggunakan perintah *train test split*. Proses lengkapnya dapat dilihat pada Gambar 12. Sedangkan distribusi untuk setiap kelas dapat dilihat pada Gambar 13.

```
# Split data
X_train, X_test, y_train, y_test = train_test_split(
    X, y, test_size=0.25, random_state=42, stratify=y
)
```

Gambar 12. Pembagian data Latih dan Data Uji



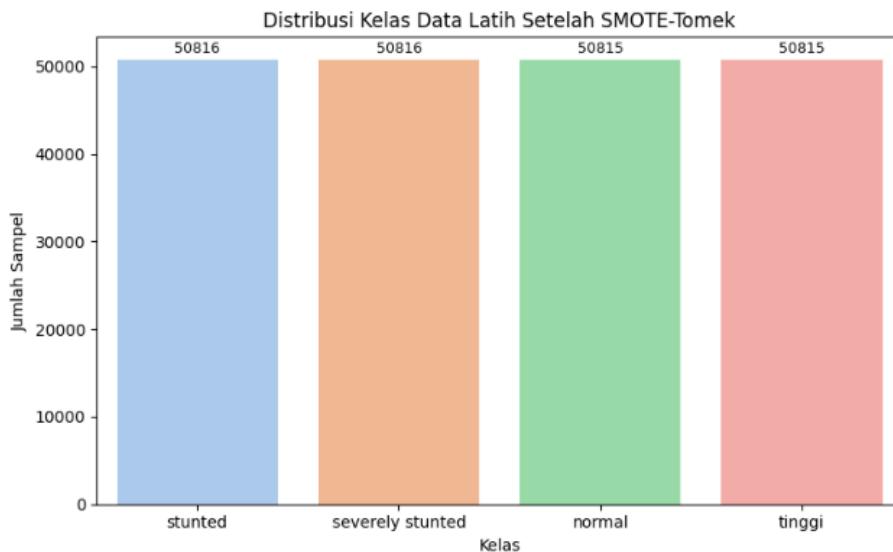
Gambar 13. Distribusi Data Latih dan Data Uji

4.4 Data Mining

Tahap *Data Mining* menerapkan algoritma untuk membuat model prediksi. Algoritma yang digunakan adalah LightGBM. Namun, berdasarkan Gambar 13, distribusi data latih masih belum seimbang. Karena itu, dilakukan penyeimbangan data latih dengan menggunakan SMOTE-Tomek. Tujuannya untuk menambahkan variasi data sehingga sistem deteksi pada data uji menjadi lebih akurat. Proses penerapan SMOTE-Tomek dapat dilihat pada Gambar 14, sedangkan hasil penyeimbangan kelas dapat dilihat pada Gambar 15.

```
smote_tomek = SMOTETomek(random_state=42)
X_resampled, y_resampled = smote_tomek.fit_resample(X_train_pre, y_train)
```

Gambar 14. Proses SMOTE-Tomek



Gambar 15. Distribusi Data Latih setelah SMOTE-Tomek

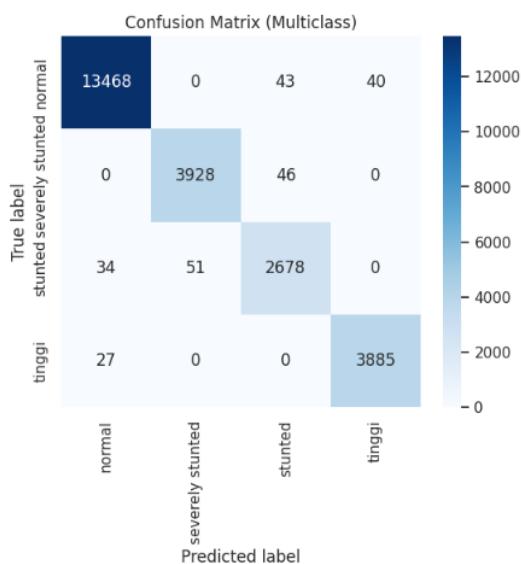
Setelah data seimbang, pelatihan dapat dilakukan. Untuk algoritma LightGBM, ada beberapa parameter yang harus diatur. *Parameter objective* diatur ke ‘multiclass’ karena kelas target lebih dari dua. Pengaturan dan proses pelatihan dapat dilihat pada Gambar 16.

```
model = LGBMClassifier(
    objective='multiclass',
    num_class=len(y.unique()),
    n_estimators=200,
    learning_rate=0.05,
    random_state=42,
    n_jobs=-1
)
model.fit(X_resampled, y_resampled)
```

Gambar 16. Parameter dan Proses Pelatihan Model

4.5 Interpretation/Evaluation

Tahapan evaluasi dilakukan dengan membuat *Confusion Matrix*. Tujuannya untuk melihat kualitas model deteksi *stunting* yang telah dibuat. *Confusion Matriks* yang dihasilkan dapat dilihat pada Gambar 17. Sedangkan *clasification reportnya* dapat dilihat Gambar 18.



Gambar 17. Confusion Matriks Model Deteksi Stunting

Gambar 17 menunjukkan *Confusion Matrix* dari model deteksi *stunting* dengan empat kelas, yaitu normal, *severely stunted*, *stunted*, dan tinggi. Matriks ini menggambarkan distribusi prediksi model dibandingkan dengan label sebenarnya. Dari hasil yang ditampilkan, terlihat bahwa model memiliki performa prediksi yang sangat baik pada kelas normal dengan jumlah prediksi benar sebanyak 13.468 kasus, meskipun terdapat sejumlah kecil kesalahan klasifikasi ke kelas *stunted* (43 kasus) dan tinggi (40 kasus). Pada kelas *severely stunted*, model mampu memprediksi dengan benar sebanyak 3.928 kasus, tetapi masih terdapat kesalahan klasifikasi ke kelas *stunted* (46 kasus). Untuk kelas *stunted*, prediksi benar berjumlah 2.678 kasus dengan sebagian kecil salah diklasifikasikan ke kelas normal (34 kasus) dan *severely stunted* (51 kasus). Sementara itu, pada kelas tinggi, model berhasil mengklasifikasikan 3.885 kasus secara benar, dengan kesalahan klasifikasi kecil ke kelas normal (27 kasus). Secara keseluruhan, *Confusion Matrix* ini memperlihatkan bahwa model cenderung sangat akurat dalam mengidentifikasi kelas mayoritas (normal), serta cukup baik dalam membedakan kategori lain meskipun masih ada kesalahan klasifikasi pada kelas yang relatif mirip, khususnya antara *severely stunted* dan *stunted*. Hal ini menunjukkan bahwa model sudah cukup andal, namun diperlukan penyempurnaan untuk meningkatkan kemampuan diskriminasi pada kelas dengan distribusi data yang lebih kecil.

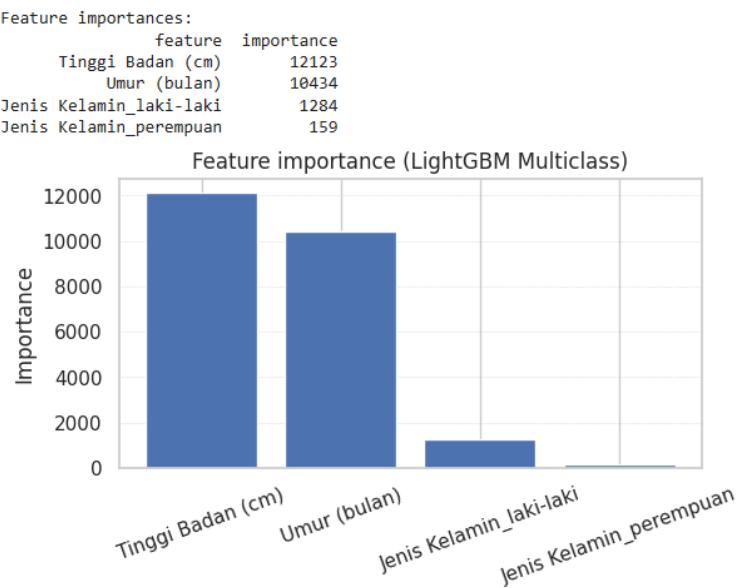
Classification Report:					
	precision	recall	f1-score	support	
severely stunted	normal	1.00	0.99	0.99	13551
	stunted	0.99	0.99	0.99	3974
	tinggi	0.97	0.97	0.97	2763
	accuracy			0.99	24200
	macro avg	0.99	0.99	0.99	24200
	weighted avg	0.99	0.99	0.99	24200

Gambar 18. Classification Report Model Deteksi Stunting

Gambar 18 menampilkan *Classification Report* dari model deteksi *stunting* yang mengevaluasi performa model berdasarkan metrik *precision*, *recall*, dan *f1-score* untuk setiap kelas, yaitu normal, *severely stunted*, *stunted*, dan tinggi. Hasil evaluasi menunjukkan bahwa model memiliki kinerja yang sangat tinggi dengan nilai rata-rata *precision*, *recall*, dan *f1-score* sebesar 0,99. Pada kelas normal, presisi mencapai 1,00 dengan recall 0,99 dan f1-score 0,99, yang menandakan model hampir sempurna dalam mengenali individu dengan status gizi normal. Untuk kelas *severely stunted*, ketiga metrik bernilai 0,99, menunjukkan kemampuan yang konsisten dan sangat baik dalam membedakan kasus anak dengan kondisi sangat pendek. Pada kelas *stunted*, performa sedikit lebih rendah dengan nilai presisi, recall, dan f1-score sebesar 0,97, yang berarti masih ada sebagian kecil kasus yang salah terkласifikasi. Sementara itu, kelas tinggi kembali menunjukkan performa yang hampir sempurna dengan nilai 0,99 pada semua metrik. Secara keseluruhan, akurasi model mencapai 0,99 dari total 24.200 data uji, dengan rata-rata makro dan *weighted average* juga sebesar 0,99. Hasil ini mengindikasikan bahwa model sangat andal dan stabil dalam melakukan deteksi stunting pada berbagai kategori, meskipun masih perlu perhatian khusus pada peningkatan klasifikasi kelas *stunted* yang relatif lebih menantang. Selain itu, model yang dihasilkan juga tidak *overfitting*. Pernyataan tersebut didasarkan pada selisih setiap metrik pada data latih dan dan uji kurang dari 0,5. Secara rinci, nilai selisih untuk setiap metrik evaluasi dapat dilihat pada Tabel 1.2.

Tabel 2. Hasil Perbandingan Selisih Nilai untuk Setiap Matrik Evaluasi

Kelas	Precision (Train)	Precision (Test)	Selisih	Recall (Train)	Recall (Test)	Selisih	F1-Score (Train)	F1-Score (Test)	Selisih
normal	1.00	1.00	0.00	0.97	0.97	0.00	0.99	0.98	0.01
severely stunted	0.99	0.99	0.00	0.99	0.99	0.00	0.99	0.99	0.00
stunted	0.90	0.90	0.00	0.99	0.99	0.00	0.94	0.94	0.00
tinggi	0.97	0.97	0.00	1.00	1.00	0.00	0.98	0.98	0.00
macro avg	0.97	0.96	0.01	0.99	0.99	0.00	0.98	0.98	0.00
weighted avg	0.98	0.98	0.00	0.98	0.98	0.00	0.98	0.98	0.00



Gambar 19. Fitur Penting pada Model

Gambar 19 memperlihatkan analisis *feature importance* pada model deteksi stunting berbasis LightGBM multiclass. Hasil visualisasi menunjukkan bahwa variabel tinggi badan (cm) memiliki kontribusi terbesar terhadap prediksi model dengan nilai *importance* sebesar 12.123, diikuti oleh umur (bulan) dengan nilai 10.434. Hal ini sejalan dengan definisi *stunting* yang pada dasarnya mengukur pertumbuhan tinggi badan anak relatif terhadap usianya, sehingga kedua fitur tersebut memang menjadi indikator utama dalam klasifikasi status gizi. Sementara itu, fitur jenis kelamin laki-laki dan jenis kelamin perempuan memiliki pengaruh yang jauh lebih kecil dengan nilai *importance* masing-masing 1.284 dan 159. Temuan ini mengindikasikan bahwa meskipun faktor jenis kelamin dapat memengaruhi variasi pertumbuhan, kontribusinya terhadap prediksi model relatif minor dibandingkan tinggi badan dan umur. Dengan demikian, dapat disimpulkan bahwa model secara konsisten memprioritaskan variabel yang paling relevan secara biologis dan medis dalam menentukan status *stunting*, yang menunjukkan kesesuaian antara pendekatan komputasional dan dasar ilmiah permasalahan gizi anak.

V. KESIMPULAN DAN SARAN

Penelitian ini berhasil membangun model deteksi *stunting* berbasis *machine learning* (LightGBM multiclass) dengan performa yang sangat tinggi. Hasil *confusion matrix* menunjukkan bahwa model mampu mengklasifikasikan data pada keempat kategori status gizi anak (*normal*, *severely stunted*, *stunted*, *tinggi*) dengan tingkat kesalahan yang sangat rendah. *Classification report* memperkuat temuan tersebut, di mana nilai presisi, *recall*, dan *f1-score* rata-rata mencapai 0,99, serta akurasi keseluruhan sebesar 99%. Analisis *feature importance* mengungkapkan bahwa variabel tinggi badan (cm) dan umur (bulan) merupakan faktor dominan dalam prediksi model, sedangkan jenis kelamin memiliki kontribusi yang jauh lebih kecil. Hasil tersebut konsisten dengan konsep medis bahwa perbandingan tinggi badan terhadap umur merupakan indikator utama dalam penentuan status gizi anak. Namun, perlu diperhatikan bahwa atribut yang digunakan tidak melibatkan faktor eksternal seperti sosial dan ekonomi. Penelitian ini membuktikan bahwa LightGBM mampu mengklasifikasikan status gizi balita secara efisien meskipun pada data besar dan tidak seimbang.

Sedangkan saran untuk penelitian selanjutnya, yaitu :

1. Pengayaan Data: Penelitian selanjutnya disarankan menggunakan *dataset* yang lebih besar dan beragam dari berbagai wilayah, sehingga model dapat menangkap variasi pertumbuhan anak secara lebih komprehensif.
2. Penambahan Variabel: Perlu dipertimbangkan penambahan fitur lain, seperti status ekonomi keluarga, asupan gizi, riwayat kesehatan, serta faktor lingkungan, untuk melihat sejauh mana variabel non-antropometri berpengaruh terhadap deteksi stunting.
3. Perbandingan Algoritma: Perlu dilakukan evaluasi terhadap berbagai algoritma *machine learning* atau *deep learning* untuk mengetahui model mana yang paling optimal dalam klasifikasi stunting.
4. Implementasi Aplikasi: Hasil penelitian dapat dikembangkan menjadi aplikasi berbasis web atau *mobile* yang mudah digunakan oleh tenaga kesehatan maupun masyarakat, sehingga deteksi dini *stunting* dapat dilakukan secara lebih luas dan praktis.
5. Validasi Lapangan: Perlu dilakukan uji validasi langsung di lapangan untuk memastikan performa model sesuai dengan kondisi nyata, sehingga hasil penelitian tidak hanya kuat secara teoretis, tetapi juga bermanfaat secara praktis dalam mendukung program pencegahan stunting.

DAFTAR PUSTAKA

- [1] S. S. Choeriyah, R. S. Fanhas, A. Fathah, and H. Pebriyansyah, "Implementasi Algoritma k-Nearest Neighbor (k-NN) dalam Klasifikasi Status Gizi Balita," CTP : Cipasung Tecno Pesantren, vol. 16, no. 2, 2022.
- [2] P. Meriyana, A. R. Pratama, E. Nurlaelasari, and A. R. Juwita, "Penerapan Algoritma KNN dan Naive Bayes untuk Klasifikasi Stunting pada Balita di Desa Pasirjengkol," Jurnal PETISI, vol. 06, no. 02, pp. 72–84, 2025
- [3] D. Mahardika and A. N. Raihanah, "Klasifikasi Status Gizi Balita Menggunakan Algoritma Random Forest dan Feature Selection Relief-F," Journal Of Information Technology, vol. 1, no. 1, pp. 1–9, 2025.
- [4] A. B. Umam, M. R. Pratama, B. H. Prakoso, and I. Muflihat, "Sistem Deteksi Dini Stunting Pada Balita Menggunakan Teknik Klasifikasi Dengan Algoritma C4.5 Sebagai Upaya Penekan Angka Kasus Stunting Di Puskesmas Sumberjambe Kabupaten Jember," bios, vol. 6, no. 2, pp. 54–66, June 2025, doi: 10.37148/bios.v6i2.164.
- [5] N. Kusumawardhani and I. N. Abdullah, "Penerapan Metode Naïve Bayes Untuk Mendeteksi Secara Dini Stunting Pada Balita," INFOTEK, vol. 8, no. 2, pp. 378–390, July 2025, doi: 10.29408/jit.v8i2.30385.
- [6] R. Mahesa Cadi, "ANALISIS PERFORMA TEKNIK RESAMPLING UNTUK MENGATASI KETIDAKSEIMBANGAN DATA LATIH PADA MODEL DETEKSI INTRUSI JARINGAN," FAKULTAS TEKNOLOGI INDUSTRI UNIVERSITAS ISLAM INDONESIA, 2024.
- [7] S. Januarto, A. A. Murtopo, and Z. Arif, "Klasifikasi Status Stunting Balita Tegal Menggunakan Teknik Smote Pada Metode Naïves Bayes Gaussain," RIGGS, vol. 4, no. 3, pp. 2484–2490, Aug. 2025, doi: 10.31004/riggs.v4i3.2349.
- [8] H. Bett, "Countries with the highest percentage of child stunting: 2019 - 2023," The Star. Accessed: Sept. 07, 2025. [Online]. Available: <https://www.the-star.co.ke/news/infographics/2025-03-05-countries-with-the-highest-percentage-of-child-stunting-2019-2023>
- [9] L. Nurcholifah, D. Hartanti, and S. Sundari, "Klasifikasi Penentuan Gizi Balita dengan Algoritma K-Nearest Neighbor (Studi Kasus: Puskesmas Bringin)," Smart Comp, vol. 14, no. 2, Apr. 2025, doi: 10.30591/smartcomp.v14i2.7244.
- [10] N. Kamilatutsaniya, E. Daniati, and M. N. Muzaki, "Pemodelan Klasifikasi Popularitas Produk Skincare Menggunakan Support Vector Machine (SVM): Studi Komparatif Kinerja Kernel," vol. 4, no. 2, 2025.
- [11] L. D. H. Monasari and N. Pratiwi, "Klasifikasi Stunting Pada Balita Menggunakan Algoritma Decision Tree Pada Machine Learning," DECODE: Jurnal Pendidikan Teknologi Informasi, vol. 5, no. 2, 2025, doi: dx.doi.org/10.51454/decode.v5i2.1193.
- [12] F. N. Rahman, T. Listyorini, and E. Supriyati, "ANALISIS AKURASI CNN PADA DATA OLAH SUARA MANUSIA MENGGUNAKAN PARAMETER KOEFISIEN MFCC DAN MAX LENGTH," JURNAL DIGIT, vol. 1, no. 12, pp. 1–9, 2025.
- [13] H. Prayoga and R. Kurniawan, "Implementasi Algoritma C4.5 Pada Klasifikasi Status Gizi Balita Menggunakan Framework Flask," DECODE: Jurnal Pendidikan Teknologi Informasi, vol. 5, no. 2, pp. 573–588, 2025, doi: dx.doi.org/10.51454/decode.v5i2.1194.
- [14] N. S. B. Nugrahani and A. Prapanca, "Implementasi Algoritma C5.0 Pada Klasifikasi Status Gizi Balita Di Kecamatan Ponorogo," JINACS: Journal of Informatics and Computer Science, vol. 06, no. 4, 2025.
- [15] Dhika Malita Puspita Arum, Kartika Imam Santoso, Andri Triyono, Eko Supriyadi, Agus Susilo Nugroho, and E. Widodo, "ALGORITMA RANDOM FOREST, DECISION TREE, DAN XGBOOST UNTUK KLASIFIKASI STUNTING PADA BALITA," JT, vol. 23, no. 1, pp. 67–76, July 2025, doi: 10.26623/transformatika.v23i1.12202.
- [16] W. Kurniawan, D. Muriyatmoko, and S. A. Taufiq, "Klasifikasi Status Gizi Balita Menggunakan Algoritma Naive Bayes Berdasarkan Pengukuran Antropometri," vol. 9, no. 1, 2025
- [17] C. P. W. Kase and S. Y. J. Prasetyo, "Analisis Faktor Risiko Stunting pada Balita di Desa Kesetnana Menggunakan Metode Random Forest," Jurnal Indonesia : Manajemen Informatika dan Komunikasi, vol. 6, no. 3, pp. 1556–1566, 2025, doi: doi.org/10.63447/jimik.v6i3.1449.
- [18] P. Septiana Rizky, R. Haiban Hirzi, and U. Hidayaturrohman, "Perbandingan Metode LightGBM dan XGBoost dalam Menangani Data dengan Kelas Tidak Seimbang," J Statistika, vol. 15, no. 2, pp. 228–236, 2022, doi: 10.36456/jstat.vol15.no2.a5548.
- [19] R. P. PRADANA, "Stunting Toddler (Balita) Detection (121K rows)." Accessed: Sept. 07, 2025. [Online]. Available: <https://www.kaggle.com/datasets/rendiputra/stunting-balita-detection-121k-rows>
- [20] A. H. Painneon, Y. P. K. Kelen, and P. G. Manek, "Sistem Pendukung Keputusan Untuk Menentukan Klasifikasi Tumbuh Kembang Balita Menggunakan Metode Weighted Aggregated Sum Product Assesment (Waspas) Studi Kasus: Posyandu Manektob," MJI: Media Jurnal Informatika, vol. 17, no. 1, pp. 118–127, 2025.