

**SISTEM KLASIFIKASI STUNTING, WASTING, UNDERWEIGHT,  
DAN OVERWEIGHT PADA ANAK USIA DI BAWAH DUA TAHUN  
MENGGUNAKAN METODE LIGHT GRADIENT BOOSTING MACHINE**

**LAPORAN TUGAS AKHIR**

Laporan ini Disusun untuk Memenuhi Salah Satu Syarat Memperoleh  
Gelar Sarjana Strata 1 (S1) pada Program Studi Teknik Informatika  
Fakultas Teknologi Industri Universitas Islam Sultan Agung



**DISUSUN OLEH:**

**BAGUS DESNA MUKTI**

**NIM 32602100035**

**PROGRAM STUDI TEKNIK INFORMATIKA  
FAKULTAS TEKNOLOGI INDUSTRI  
UNIVERSITAS ISLAM SULTAN AGUNG  
SEMARANG  
2025**

**A CLASSIFICATION SYSTEM FOR STUNTING, WASTING,  
UNDERWEIGHT, AND OVERWEIGHT IN CHILDREN UNDER TWO  
YEARS OF AGE USING THE LIGHT GRADIENT BOOSTING MACHINE  
METHOD**

**FINAL PROJECT**

*This report is prepared to fulfill one of the requirements to obtain a Bachelor's Degree (S1) in the Informatics Engineering Study Program, Faculty of Industrial Technology, Sultan Agung Islamic University*



**BAGUS DESNA MUKTI**

**32602100035**

**INFORMATICS ENGINEERING STUDY PROGRAM  
FACULTY OF INDUSTRIAL TECHNOLOGY  
SULTAN AGUNG ISLAMIC UNIVERSITY  
SEMARANG  
2025**

**LEMBAR PENGESAHAN**  
**TUGAS AKHIR**

**SISTEM KLASIFIKASI STUNTING, WASTING, UNDERWEIGHT,  
DAN OVERWEIGHT PADA ANAK USIA DI BAWAH DUA TAHUN  
MENGGUNAKAN METODE LIGHT GRADIENT BOOSTING MACHINE**

**BAGUS DESNA MUKTI**  
**NIM 32602100035**

Telah dipertahankan di depan tim penguji ujian sarjana tugas akhir  
Program Studi Teknik Informatika  
Universitas Islam Sultan Agung  
Pada tanggal : 26 November 2025

**TIM PENGUJI UJIAN SARJANA:**

Mustafa, S.T., M.M., M.Kom.  
NIK. 210610040  
(Ketua Penguji)

01-12-2025

Imam Much Ibnu Subroto, S.T., M.Sc., Ph.D  
NIK. 210600017  
(Anggota Penguji)

01-12-2025

Dedy Kurniadi, S.T., M.Kom.  
NIK. 210615048  
(Pembimbing)

02-12-2025

Semarang, 02 Desember 2025

Mengetahui,  
Kaprodi Teknik Informatika  
Universitas Islam Sultan Agung

**Moch Taufik, ST.,MIT.**  
NIK. 210604034

## SURAT PERNYATAAN KEASLIAN TUGAS AKHIR

Yang bertanda tangan di bawah ini :

Nama : Bagus Desna Mukti

NIM : 32602100035

Judul Tugas Akhir : Sistem Klasifikasi *Stunting, Wasting, Underweight, dan Overweight* Pada Anak Usia Di Bawah Dua Tahun Menggunakan Metode *Light Gradient Boosting Machine*

Dengan ini saya menyatakan bahwa judul dan isi Tugas Akhir yang saya buat dalam rangka menyelesaikan Pendidikan Strata Satu (S1) Teknik Informatika tersebut adalah asli dan belum pernah diangkat, ditulis ataupun dipublikasikan oleh siapapun baik keseluruhan maupun sebagian, kecuali yang secara tertulis diacu dalam naskah ini dan disebutkan dalam daftar pustaka, dan apabila di kemudian hari ternyata terbukti bahwa judul Tugas Akhir tersebut pernah diangkat, ditulis ataupun dipublikasikan, maka saya bersedia dikenakan sanksi akademis. Demikian surat pernyataan ini saya buat dengan sadar dan penuh tanggung jawab.

Semarang, 03 Desember 2025

Yang Menyatakan,



Bagus Desna Mukti

## PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH

Saya yang bertanda tangan di bawah ini :

Nama : Bagus Desna Mukti  
NIM : 32602100035  
Program Studi : Teknik Informatika  
Fakultas : Teknologi Industri  
Alamat Asal : Semarang, Jawa Tengah

Dengan ini menyatakan Karya Ilmiah berupa Tugas Akhir dengan Judul : Sistem Klasifikasi *Stunting, Wasting, Underweight, dan Overweight* Pada Anak Usia Di Bawah Dua Tahun Menggunakan Metode *Light Gradient Boosting Machine*. Menyetujui menjadi hak milik Universitas Islam Sultan Agung serta memberikan Hak Bebas Royalti Non-Eksklusif untuk disimpan, dialihmediakan, dikelola dalam pangkalan data, dan dipublikasikan di internet ataupun media lain untuk kepentingan akademis selama tetap mencantumkan nama penulis sebagai pemilik hak cipta. Pernyataan ini saya buat dengan sungguh-sungguh. Apabila di kemudian hari terbukti ada pelanggaran Hak Cipta/Plagiarisme dalam karya ilmiah ini, maka segala bentuk tuntutan hukum yang timbul akan saya tanggung secara pribadi tanpa melibatkan Universitas Islam Sultan Agung.

Semarang, 03 Desember 2025

Yang menyatakan,

  
278F6ANX174319267

Bagus Desna Mukti

## KATA PENGANTAR

Dengan mengucap syukur Alhamdulillah atas kehadiran Allah SWT yang telah melimpahkan rahmat dan karunia-Nya, sehingga penulis dapat menyelesaikan Tugas Akhir yang berjudul "Sistem Klasifikasi *Stunting, Wasting, Underweight*, dan *Overweight* Pada Anak Usia Di Bawah Dua Tahun Menggunakan Metode *Light Gradient Boosting Machine*" dengan baik.

Tugas Akhir ini disusun dan dibuat dengan adanya bantuan dari berbagai pihak berupa materi maupun teknis, oleh karena itu saya selaku penulis mengucapkan terima kasih kepada :

1. Rektor Universitas Islam Sultan Agung Semarang Bapak Prof. Dr. H. Gunarto, S.H., M.H yang mengizinkan penulis menimba ilmu di kampus ini.
2. Dekan Fakultas Teknologi Industri Ibu Dr. Ir. Hj. Novi Marlyana, S.T., M.T., IPU., ASEAN Eng
3. Dosen pembimbing penulis Bapak Dedy Kurniadi, S.T., M.Kom yang telah memberikan arahan, bimbingan, dan saran dalam penyusunan tugas akhir.
4. Orang tua penulis, Bapak Sunaryo dan Ibu Tumiati, beserta seluruh keluarga yang telah memberikan doa dan dukungan untuk menyelesaikan penelitian ini.
5. Teman-teman dan rekan seperjuangan yang telah memberikan dukungan moral, motivasi, serta semangat dalam proses penyelesaian tugas akhir
6. Dan kepada semua pihak yang tidak dapat saya sebutkan satu per satu.

Dengan segala kerendahan hati, penulis menyadari masih terdapat banyak kekurangan dari segi kualitas, kuantitas, maupun ilmu pengetahuan dalam penyusunan laporan sehingga penulis mengharapkan adanya saran dan kritik yang bersifat membangun demi kesempurnaan laporan ini pada masa mendatang.

Semarang, 23 September 2025



Bagus Desna Mukti

## DAFTAR ISI

<b>COVER .....</b>	<b>i</b>
<b>LEMBAR PENGESAHAN .....</b>	<b>iii</b>
<b>SURAT PERNYATAAN KEASLIAN TUGAS AKHIR .....</b>	<b>iv</b>
<b>PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH .....</b>	<b>v</b>
<b>KATA PENGANTAR.....</b>	<b>vi</b>
<b>DAFTAR ISI.....</b>	<b>vii</b>
<b>DAFTAR GAMBAR.....</b>	<b>ix</b>
<b>DAFTAR TABEL .....</b>	<b>x</b>
<b>ABSTRAK .....</b>	<b>xi</b>
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1    Latar Belakang .....	1
1.2    Perumusan Masalah.....	3
1.3    Pembatasan Masalah .....	4
1.4    Tujuan.....	4
1.5    Manfaat.....	4
1.6    Sistematika Penulisan.....	5
<b>BAB II TINJAUAN PUSTAKA DAN DASAR TEORI .....</b>	<b>6</b>
2.1    Tinjauan Pustaka .....	6
2.2    Dasar Teori .....	9
2.2.1 <i>Stunting</i> .....	9
2.2.2 <i>Wasting</i> .....	10
2.2.3 <i>Underweight</i> .....	10
2.2.4 <i>Overweight</i> .....	11
2.2.5    Standar Antropometri Anak .....	11
2.2.6 <i>Machine Learning</i> .....	14
2.2.7 <i>Light Gradient Boosting Machine</i> .....	14
<b>BAB III METODOLOGI PENELITIAN .....</b>	<b>16</b>
3.1    Jenis Penelitian .....	16
3.2    Sumber dan Jenis Data .....	16

3.3	Tahapan Penelitian .....	17
3.3.1	Pengumpulan data .....	18
3.3.2	<i>Data Cleaning</i> .....	18
3.3.3	Pelabelan Data.....	19
3.3.4	Pra-Pemrosesan Data .....	21
3.3.5	Penerapan Model.....	21
3.3.6	Evaluasi Model.....	24
3.3.7	<i>Model Deployment</i> .....	26
3.4	Rancangan Sistem .....	26
3.4.1	Alur Kerja Sistem.....	27
3.4.2	<i>Data Flow Diagram</i> .....	28
<b>BAB IV HASIL DAN ANALISIS PENELITIAN .....</b>		<b>31</b>
4.1	Hasil Persiapan Data .....	31
4.1.1	Hasil <i>Data Cleaning</i> .....	31
4.1.2	Hasil pelabelan data .....	31
4.1.3	Hasil Pra-pemrosesan Data .....	33
4.1.4	Karakteristik Dataset Final.....	37
4.2	Hasil Penerapan Model .....	38
4.3	Hasil Evaluasi Model .....	39
4.3.1	Evaluasi Kinerja Model Klasifikasi <i>Stunting</i> .....	40
4.3.2	Evaluasi Kinerja Model Klasifikasi <i>Wasting/Overweight</i> .....	42
4.3.3	Evaluasi Kinerja Model Klasifikasi <i>Underweight</i> .....	44
4.3.4	Perbandingan Kinerja Model LightGBM dan <i>Decision Tree</i> .....	46
4.4	Analisis Penelitian .....	47
4.5	Hasil Implementasi Sistem .....	48
4.6	Pengujian Sistem .....	50
<b>BAB V KESIMPULAN DAN SARAN .....</b>		<b>52</b>
5.1	Kesimpulan.....	52
5.2	Saran .....	53
<b>DAFTAR PUSTAKA .....</b>		<b>54</b>
<b>LAMPIRAN</b>		

## DAFTAR GAMBAR

Gambar 3. 1 <i>Flowchart</i> Tahapan Penelitian .....	17
Gambar 3. 2 Arsitektur <i>input-proses-output</i> pelabelan <i>stunting</i> (PB/U).....	20
Gambar 3. 3 Arsitektur Pengembangan Model Klasifikasi Status Gizi.....	22
Gambar 3. 4 <i>Flowchart</i> Rancangan Sistem .....	27
Gambar 3. 5 DFD Level 0 Sistem.....	29
Gambar 3. 6 DFD Level 1 Sistem.....	30
Gambar 4. 1 Distribusi <i>Z-score Length-for-Age (Stunting)</i> .....	34
Gambar 4. 2 Distribusi <i>Z-score Weight-for-Length (Wasting/Overweight)</i> .....	34
Gambar 4. 3 Distribusi <i>Z-score Weight-for-Age (Underweight)</i> .....	34
Gambar 4. 4 Distribusi Jenis Kelamin Dataset Final .....	37
Gambar 4. 5 <i>Confusion Matrix</i> Model <i>Stunting</i> .....	41
Gambar 4. 6 <i>Confusion Matrix</i> Model <i>Wasting/Overweight</i> .....	43
Gambar 4. 7 <i>Confusion Matrix</i> Model <i>Underweight</i> .....	45
Gambar 4. 8 Tampilan Utama Website .....	48
Gambar 4. 9 Tampilan Hasil Klasifikasi Sistem.....	49



## DAFTAR TABEL

Tabel 2. 1 Kategori dan Ambang Batas Status Gizi Anak .....	13
Tabel 4. 1 Hasil Pelabelan Status <i>Stunting</i> .....	32
Tabel 4. 2 Perbandingan label awal dan label baru.....	33
Tabel 4. 3 Hasil pembagian data indikator <i>stunting</i> .....	35
Tabel 4. 4 Hasil pembagian data indikator <i>wasting/overweight</i> .....	36
Tabel 4. 5 Hasil pembagian data indikator <i>underweight</i> .....	36
Tabel 4. 6 Statistik Deskriptif Dataset Final .....	37
Tabel 4. 7 <i>Hyperparameter</i> Optimal Model LightGBM.....	38
Tabel 4. 8 <i>Hyperparameter</i> Optimal Model <i>Decision Tree</i> .....	39
Tabel 4. 9 <i>Classification Report</i> Model <i>Stunting</i> .....	40
Tabel 4. 10 <i>Classification Report</i> Model <i>Wasting/Overweight</i> .....	42
Tabel 4. 11 <i>Classification Report</i> Model <i>Underweight</i> .....	44
Tabel 4. 12 Perbandingan model LightGBM dengan model <i>Decision Tree</i> .....	46
Tabel 4. 13 Pengujian Fungsionalitas .....	50

## ABSTRAK

Masalah malnutrisi seperti *stunting*, *wasting*, *underweight*, dan *overweight* pada anak di bawah dua tahun (baduta) masih menjadi tantangan utama dalam peningkatan kesehatan di Indonesia. Penelitian ini bertujuan mengembangkan sistem klasifikasi status gizi baduta menggunakan algoritma Light Gradient Boosting Machine (LightGBM) berdasarkan standar World Health Organization (WHO) dan Peraturan Menteri Kesehatan Republik Indonesia No. 2 Tahun 2020. Dataset dari Kaggle berisi 100.000 data antropometri diproses menjadi 66.480 data valid melalui *data cleaning*, perhitungan ulang *z-score* dengan metode Lambda-Mu-Sigma (LMS), dan relabelan ulang status gizi sesuai ambang WHO. Tiga model klasifikasi dikembangkan untuk indikator *stunting* (PB/U), *wasting/overweight* (BB/PB), dan *underweight* (BB/U) dengan *hyperparameter tuning* dan validasi silang 5-fold. Hasil evaluasi menunjukkan LightGBM mencapai akurasi 99,28% untuk *stunting*, 97,83% untuk *wasting/overweight*, dan 100% untuk *underweight*, disertai nilai *recall* dan *F1-score* tinggi pada kelas minoritas. Model diimplementasikan melalui aplikasi berbasis Streamlit yang mampu memberikan hasil klasifikasi gizi secara cepat dan akurat, sehingga efektif sebagai alat bantu deteksi dini untuk mendukung peningkatan kesehatan anak di Indonesia.

Kata Kunci: *Stunting, Wasting, Underweight, Overweight, LightGBM, Machine Learning*

## ABSTRACT

*Malnutrition issues such as stunting, wasting, underweight, and overweight among children under two years old remain a major challenge in improving public health in Indonesia. This study aims to develop a nutritional status classification system for children under two using the Light Gradient Boosting Machine (LightGBM) algorithm, in accordance with the World Health Organization (WHO) standards and the Regulation of the Minister of Health of the Republic of Indonesia No. 2 of 2020. A Kaggle dataset containing 100,000 anthropometric records was processed into 66,480 valid entries through data cleaning, z-score recalculation using the Lambda-Mu-Sigma (LMS) method, and relabeling based on WHO thresholds. Three classification models were built for stunting (length-for-age), wasting/overweight (weight-for-length), and underweight (weight-for-age) using hyperparameter tuning and 5-fold cross-validation. The results show that LightGBM achieved accuracies of 99.28% for stunting, 97.83% for wasting/overweight, and 100% for underweight, with high recall and F1-scores on minority classes. The model was deployed through a Streamlit-based application that provides fast and accurate nutritional status classification, demonstrating LightGBM's effectiveness as an early detection tool to support child health improvement in Indonesia.*

*Keywords: Stunting, Wasting, Underweight, Overweight, LightGBM, Machine Learning*

## **BAB I**

### **PENDAHULUAN**

#### **1.1 Latar Belakang**

Malnutrisi pada anak masih menjadi salah satu hambatan besar dalam peningkatan kualitas kesehatan di Indonesia, terutama pada kelompok usia di bawah dua tahun atau yang biasa disebut baduta. Berdasarkan data antropometri, kondisi malnutrisi terbagi menjadi dua kelompok utama, yakni kategori gizi kurang dan gizi lebih. Gizi kurang mencakup *stunting* yang menggambarkan tinggi badan anak berada di bawah kisaran pertumbuhan yang dianggap normal untuk usianya, *wasting* yang menunjukkan berat badan tidak proporsional terhadap tinggi badan, dan *underweight* yang menunjukkan berat badan berada di bawah nilai standar untuk kelompok usianya. Sementara itu, gizi lebih mencakup *overweight* dan obesitas yang mengindikasikan berat badan anak melebihi standar untuk tinggi badannya (UNICEF dkk., 2023).

Menurut data Survey Status Gizi Indonesia (SSGI) tahun 2024, prevalensi *stunting* pada balita dilaporkan mencapai angka 19,8%, menurun dari tahun sebelumnya yaitu 21,5% (Badan Kebijakan Pembangunan Kesehatan, 2025). Meski ada perbaikan, angka ini masih memerlukan upaya signifikan guna memenuhi target yang tercantum dalam Rencana Pembangunan Jangka Menengah Nasional (RPJMN), yaitu 18,8% pada 2025 dan 14,2% pada 2029 (Badan Perencanaan Pembangunan Nasional, 2025). Sementara itu, prevalensi *wasting* turun dari 8,5% menjadi 7,4%, *underweight* justru meningkat dari 15,9% menjadi 16,9%, dan *overweight* mengalami penurunan dari 4,2% menjadi 3,4%. Meskipun data prevalensi khusus untuk baduta belum tersedia dalam laporan tersebut, kondisi balita dapat mencerminkan gambaran umum gizi anak di Indonesia. Temuan ini menegaskan bahwa isu malnutrisi masih menjadi persoalan serius, terutama bagi kelompok usia baduta yang rentan terhadap dampak jangka panjang kekurangan gizi.

Periode baduta, yang mencakup usia 0-24 bulan, adalah kelompok dengan kerentanan yang tinggi terhadap masalah ini karena termasuk dalam periode emas,

yaitu 1000 Hari Pertama Kehidupan (HPK) yang krusial bagi proses perkembangan anak. Masalah malnutrisi pada tahap ini dapat memberikan dampak jangka panjang yang bersifat permanen, karena bukan sekadar menghambat pertumbuhan fisik, tetapi juga berpengaruh pada kualitas hidup anak secara menyeluruh, termasuk perkembangan kognitif, sosial, dan emosional (Bahar dkk., 2024). Selain itu, malnutrisi juga dapat menyebabkan gangguan fungsi mental dan pencernaan, keterlambatan perkembangan kepribadian, hingga risiko keterbelakangan mental yang dalam beberapa kasus dapat bertahan seumur hidup (Setyoningsih, 2024).

Di Indonesia, pemantauan status gizi badut masih banyak dilakukan secara manual oleh tenaga kesehatan atau kader Pos Pelayanan Terpadu (Posyandu). Pendekatan manual ini memiliki sejumlah kendala seperti potensi kesalahan pencatatan, kurangnya pelatihan petugas, serta keterbatasan waktu dan sumber daya, sehingga berisiko menyebabkan keterlambatan dalam deteksi dini malnutrisi. Untuk mengatasi masalah ini, diperlukan pendekatan berbasis teknologi, salah satunya melalui pemanfaatan *Artificial Intelligence* (AI) dan *machine learning* (ML). Dengan memanfaatkan data antropometri, misalnya usia, jenis kelamin, tinggi badan, dan berat badan, algoritma ML dapat dikembangkan menjadi sistem klasifikasi status gizi anak yang lebih cepat, objektif, dan akurat.

Berbagai metode *machine learning* telah banyak digunakan dalam penelitian sebelumnya untuk klasifikasi status gizi, khususnya *stunting*. Salah satunya adalah penelitian oleh Lonang dkk. (2023) yang membandingkan lima algoritma, yaitu *Logistic Regression*, *Support Vector Machine* (SVM), *Decision Tree*, *Random Forest*, dan *K-Nearest Neighbor* (KNN), dengan hasil terbaik diperoleh KNN dengan nilai  $K = 3$ . Selain itu, pendekatan *ensemble boosting* seperti *Catboost* dan *LightGBM* juga mulai banyak diterapkan dalam studi terkait. Penelitian Pahlevi dkk. (2024) melaporkan bahwa *Catboost* dapat menghasilkan kinerja klasifikasi yang unggul pada data *stunting* berbasis Kaggle. Temuan tersebut mengindikasikan bahwa pendekatan *boosting* memiliki potensi yang kuat dalam mengolah data antropometri dan memberikan hasil klasifikasi yang kompetitif dalam kasus serupa, sehingga menjadi dasar pertimbangan dalam pemilihan metode pada penelitian ini.

Namun demikian, kualitas algoritma *machine learning* memiliki ketergantungan kuat terhadap kualitas label yang digunakan dalam pelatihan model. Ketersediaan dataset publik seperti platform Kaggle seringkali belum menyertakan label status gizi secara lengkap, sehingga diperlukan proses pelabelan ulang berdasarkan perhitungan *z-score*. Salah satu metode paling direkomendasikan secara internasional untuk menghitung *z-score* adalah metode *Lambda-Mu-Sigma* (LMS) yang dikembangkan oleh *World Health Organization* (WHO) pada tahun 2006. Hasil *z-score* ini kemudian diklasifikasikan sesuai dengan kategori serta batasan status gizi yang tercantum dalam Peraturan Menteri Kesehatan Nomor 2 Tahun 2020.

Dengan pelabelan *z-score* yang akurat berdasarkan standar WHO dan klasifikasi sesuai regulasi nasional, sistem klasifikasi status gizi badut dibangun dengan memanfaatkan algoritma *Light Gradient Boosting Machine* (*LightGBM*). Algoritma tersebut dipilih karena mampu mengolah data tabular berukuran besar dengan efisien, memiliki waktu pemrosesan yang cepat, dan menghasilkan prediksi yang presisi, sekaligus cukup efektif dalam menghadapi permasalahan ketidakseimbangan kelas. Dengan pendekatan ini, model yang dihasilkan diharapkan dapat memberikan keluaran klasifikasi yang reliabel dan bernilai praktis, baik bagi tenaga kesehatan dalam membantu penerapan intervensi gizi yang lebih sesuai kebutuhan, maupun bagi orang tua sebagai alat skrining mandiri dalam upaya deteksi dini status gizi anak.

## 1.2 Perumusan Masalah

Perumusan masalah dalam penelitian ini adalah sebagai berikut:

1. Bagaimana melakukan pelabelan ulang status gizi anak usia di bawah dua tahun berdasarkan standar WHO dan PMK No. 2 Tahun 2020?
2. Bagaimana mengimplementasikan model klasifikasi *stunting*, *wasting*, *underweight*, dan *overweight* menggunakan metode *LightGBM*?
3. Bagaimana performa algoritma *LightGBM* dalam mengklasifikasikan status gizi anak berdasarkan hasil evaluasi model dan perbandingannya secara umum dengan *Decision Tree*?

### 1.3 Pembatasan Masalah

Penelitian ini memiliki sejumlah batasan agar pelaksanaannya tetap terarah dan menghindari terjadinya kegiatan di luar fokus penelitian. Batasan masalah tersebut meliputi:

1. Dataset yang digunakan terbatas pada variabel-variabel usia, jenis kelamin, tinggi badan, dan berat badan.
2. Subjek penelitian ini terbatas pada anak di bawah usia dua tahun (baduta), yaitu anak dengan rentang usia 0-24 bulan.
3. Label *stunting*, *wasting*, *underweight*, dan *overweight* akan ditambahkan serta dihitung ulang berdasarkan rumus *z-score* WHO dengan klasifikasi status gizi menurut PMK No. 2 Tahun 2020.

### 1.4 Tujuan

Tujuan dilakukannya penelitian ini dapat dirumuskan sebagai berikut:

1. Menentukan label status gizi anak usia di bawah dua tahun berdasarkan perhitungan *z-score* dari standar WHO dan diklasifikasikan sesuai kategori dalam Peraturan Menteri Kesehatan Republik Indonesia No. 2 Tahun 2020.
2. Membangun sistem klasifikasi status gizi yang mencakup *stunting*, *wasting*, *underweight*, dan *overweight* menggunakan algoritma *Light Gradient Boosting Machine* (*LightGBM*).
3. Mengevaluasi performa algoritma *LightGBM* dalam mengklasifikasikan status gizi anak dan membandingkan hasilnya secara umum dengan model pembanding *Decision Tree*.

### 1.5 Manfaat

Penelitian ini diharapkan dapat memberikan manfaat berupa pengembangan penerapan algoritma *machine learning* pada bidang kesehatan, khususnya dalam klasifikasi status gizi baduta (0-24 bulan). Selain itu, hasil penelitian ini juga diharapkan dapat mendukung tenaga kesehatan dan masyarakat dalam menjalankan proses deteksi dini terhadap risiko *stunting* maupun masalah gizi lainnya sehingga dapat mendukung upaya peningkatan kualitas kesehatan anak di Indonesia.

## 1.6 Sistematika Penulisan

Untuk memastikan laporan tugas akhir ini tersusun secara runtut dan mudah dipahami, maka sistematika penulisannya disusun sebagai berikut:

**BAB I : PENDAHULUAN**

Menjelaskan mengenai latar belakang yang mendasari pemilihan judul penelitian, perumusan masalah yang akan diselesaikan, batasan masalah yang digunakan agar penelitian tetap berada dalam batasan kajian yang telah ditetapkan, serta tujuan utama dari penelitian ini. Bab ini juga memaparkan manfaat yang diharapkan dari hasil penelitian, serta sistematika penulisan yang digunakan sebagai pedoman dalam penyusunan laporan tugas akhir secara keseluruhan.

**BAB II : TINJAUAN PUSTAKA DAN DASAR TEORI**

Membahas penelitian terdahulu dan teori-teori yang relevan dengan topik penelitian sebagai dasar dalam memahami permasalahan yang berkaitan dengan penerapan algoritma *Light Gradient Boosting Machine (LightGBM)* yang digunakan dalam penelitian.

**BAB III : METODOLOGI PENELITIAN**

Menjelaskan proses dan langkah-langkah penelitian yang diterapkan, seperti jenis data yang dimanfaatkan, proses pemodelan, hingga perancangan sistem.

**BAB IV : HASIL DAN ANALISIS PENELITIAN**

Membahas hasil dan temuan penelitian yang telah dilakukan, yaitu hasil klasifikasi status gizi baduta (0-24 bulan) dengan metode *LightGBM* beserta perbandingan hasilnya dengan metode *Decision Tree*.

**BAB V : KESIMPULAN DAN SARAN**

Bab terakhir menyajikan ringkasan dari seluruh pembahasan pada bab-bab sebelumnya dan juga saran dari hasil yang diperoleh untuk membantu pengembangan dalam penelitian berikutnya.

## **BAB II**

### **TINJAUAN PUSTAKA DAN DASAR TEORI**

#### **2.1 Tinjauan Pustaka**

Tinjauan Pustaka dilakukan terhadap sejumlah studi sebelumnya terkait klasifikasi status gizi anak menggunakan algoritma *machine learning*. Tinjauan ini bertujuan untuk memahami pendekatan yang digunakan, mengevaluasi hasil, mengidentifikasi keterbatasan yang ada, serta menjadi dasar penyusunan penelitian agar memiliki landasan yang kuat dan mengisi celah yang belum banyak dieksplorasi.

Penelitian yang dilakukan oleh Hidayat dkk. menerapkan algoritma *Naïve Bayes Classifier* untuk mengklasifikasikan status gizi *stunting* pada anak balita berdasarkan data demografis dan antropometri dari Bulan Penimbangan Balita (BPB) di Kabupaten Majalengka. Dalam penelitian ini, dataset yang digunakan berjumlah 1.000 data dengan enam atribut *input*, yaitu usia, tinggi badan, berat badan, jenis kelamin, lingkar lengan atas, dan *z-score* tinggi badan per umur, serta satu atribut target berupa kategori status gizi *stunting* (normal, pendek, sangat pendek). Model pada penelitian tersebut dilaporkan mencapai tingkat akurasi sebesar 94,65%, dengan presisi yang tinggi untuk setiap kategori status gizi, yaitu sebesar 97%, 87%, dan 80%. (Hidayat dkk., 2024)

Pada Studi sebelumnya oleh Lonang dkk. membandingkan lima algoritma *machine learning* yaitu *Logistic Regression*, *K-Nearest Neighbor*, *Support Vector Machine*, *Random Forest*, dan juga *Decision Tree* untuk melakukan evaluasi kinerja dalam mendekripsi *stunting* pada balita. Dataset yang digunakan adalah data Elektronik Pencatatan dan Pelaporan Gizi Balita Berbasis Masyarakat (EPPGBM) dari Puskesmas Ubung, Lombok Tengah, Indonesia yang terdiri dari 1.295 sampel, yang mencakup 1.000 balita tanpa *stunting* dan 295 balita dengan status *stunting*. Dataset ini mencakup empat atribut utama, yaitu usia, jenis kelamin, berat badan, dan tinggi badan, serta label kelas biner yang membedakan kategori balita *stunting* dan *non-stunting*. Penelitian tersebut mendapatkan hasil akurasi tertinggi yaitu sebesar 94,85% menggunakan algoritma KNN dengan nilai K=3 dengan presisi

sebesar 91,39%, *recall* 87,62%, *F1-score* 89,47%, dan AUC-ROC sebesar 0,924. (Lonang dkk., 2023)

Penelitian oleh Insany dkk. bertujuan untuk membangun model klasifikasi status gizi balita dengan menggunakan dua pendekatan algoritma *machine learning*, yaitu *K-Nearest Neighbor* (KNN) dan *Artificial Neural Network* (ANN). Data yang digunakan mencakup variabel umur, berat badan, tinggi badan, dan jenis kelamin, yang kemudian diklasifikasikan ke dalam tiga indeks status gizi, yaitu berat badan menurut umur, berat badan menurut tinggi badan, dan tinggi badan menurut umur. Hasil evaluasi menunjukkan bahwa algoritma ANN dan KNN (dengan variasi nilai  $k$ , yakni:  $k=3$ ,  $k=5$ , dan  $k=7$  tergantung pada dataset) mampu mencapai akurasi optimum sebesar 99% dengan tingkat error sangat rendah (0,007). Model yang dikembangkan kemudian dimuat ke dalam aplikasi web untuk mendukung identifikasi status gizi balita secara praktis dan berbasis teknologi. (Insany dkk., 2023)

Penelitian oleh Pahlevi dkk. bertujuan merancang model klasifikasi risiko *stunting* pada balita dengan memanfaatkan algoritma *Catboost Classifier*, yang dipilih karena kemampuannya menangani variabel kategorikal tanpa encoding kompleks serta menangani permasalahan ketidakseimbangan data. Dataset yang digunakan berasal dari "*Stunting Toddler Detection*" di Kaggle yang memiliki 121.000 entri data dengan atribut utama seperti usia, jenis kelamin, tinggi badan, dan status gizi anak balita, yang dikategorikan ke dalam Normal, *Stunted*, *Severely Stunted*, dan *Tinggi*. Hasil evaluasi memperlihatkan bahwa model yang dibangun memperoleh akurasi sebesar 98,47%, dengan ROC-AUC mencapai 1,00 untuk beberapa kelas, menandakan kemampuan tinggi dalam mengklasifikasikan risiko *stunting* dengan akurat serta memberikan kontribusi dalam deteksi dini untuk upaya pencegahan *stunting* yang lebih optimal. (Pahlevi dkk., 2024)

Penelitian oleh Azahra dan Kartikasari bertujuan mengembangkan model klasifikasi status *stunting* pada balita menggunakan metode *LightGBM*, dengan fokus pada peningkatan akurasi prediksi untuk intervensi dini. Dataset yang digunakan berasal dari Puskesmas Rowosari I, Kendal, Jawa Tengah, mencakup 2.039 observasi anak berusia 0-59 bulan per September 2024. Penelitian ini

menganalisis tujuh variabel utama, yaitu jenis kelamin, usia (bulan), berat lahir, panjang lahir, berat badan saat ini, tinggi badan saat ini, dan status *stunting*. Hasil evaluasi memperlihatkan bahwa model *LightGBM* memiliki akurasi sebesar 97% dan AUC mencapai 0,99, menunjukkan kemampuan tinggi dalam membedakan status *stunting* serta mengidentifikasi faktor risiko penting seperti usia, tinggi badan, dan berat badan sebagai prediktor paling berpengaruh. Temuan tersebut mengindikasikan bahwa *LightGBM* berpotensi menjadi alat yang efisien dalam sistem deteksi dini *stunting* untuk mendukung kebijakan kesehatan masyarakat berbasis data. (Azahra dan Kartikasari, 2025)

Pada penelitian oleh Rufo dkk. bertujuan mengembangkan sekaligus mengoptimalkan model diagnosis diabetes mellitus berbasis *machine learning* menggunakan metode *LightGBM*, dengan fokus pada peningkatan akurasi dan efisiensi komputasi dalam skrining awal. Dataset yang digunakan berasal dari Ethiopia (ZMHDD dataset), yang mencakup berbagai indikator medis seperti insulin dan glukosa darah puasa. Model dikembangkan melalui *tuning hyperparameter* dan validasi silang 10-fold, menghasilkan konfigurasi optimal dengan akurasi sebesar 98,1%, sensitivitas 99,9%, spesifitas 96,3%, dan AUC 98,1. Temuan penelitian tersebut memperlihatkan bahwa *LightGBM* memiliki performa yang sangat baik dalam mengidentifikasi pasien dengan diabetes, serta unggul dibandingkan enam metode pembanding lainnya (KNN, SVM, *Naive Bayes*, *Bagging*, *Random Forest*, dan *XGBoost*) dalam seluruh metrik evaluasi. Dengan waktu komputasi yang rendah dan efektivitas klasifikasi yang tinggi, model *LightGBM* dinilai sebagai alat potensial untuk mendukung diagnosis diabetes secara cepat dan berbasis data medis. (Rufo dkk., 2021)

Penelitian oleh Rizky dkk. melakukan perbandingan antara dua algoritma dalam *machine learning*, yaitu *LightGBM* dan *XGBoost* dalam menangani dataset yang memiliki distribusi kelas tidak seimbang. Dataset penelitian diperoleh dari UCI Repository, meliputi lima jenis dataset dengan berbagai tingkat ketidakseimbangan, di mana tiga dataset memiliki ketidakseimbangan tinggi, sementara dua lainnya memiliki ketidakseimbangan rendah. Hasil penelitian mengindikasikan bahwa *XGBoost* memiliki akurasi dan sensitivitas yang lebih

tinggi dibandingkan dengan *LightGBM* dalam sebagian besar dataset. Sementara *LightGBM* lebih unggul pada prediksi kelas minoritas dengan rata-rata performa mencapai 80,41% dibandingkan XGBoost yang hanya mencapai 74,64%, sehingga *LightGBM* lebih efektif dalam menangani kelas dengan jumlah sampel kecil. (Rizky dkk., 2022)

Berdasarkan kajian terhadap penelitian-penelitian sebelumnya, penerapan algoritma *machine learning* dalam klasifikasi status gizi anak telah menunjukkan hasil prediksi yang cukup akurat. Namun, sebagian besar masih terbatas pada satu indikator saja dan belum banyak memanfaatkan algoritma *LightGBM*. Padahal, sejumlah penelitian menunjukkan bahwa *LightGBM* unggul dalam menangani ketidakseimbangan distribusi kelas, meningkatkan akurasi pada kelas minoritas, serta mampu memberikan hasil klasifikasi yang tinggi. Dengan demikian, penelitian ini difokuskan pada pengembangan model klasifikasi status gizi pada baduta berdasarkan ketiga indikator utamanya menggunakan algoritma *LightGBM*.

## 2.2 Dasar Teori

### 2.2.1 *Stunting*

*Stunting* merupakan gangguan pertumbuhan pada balita yang timbul akibat kekurangan gizi yang berlangsung dalam jangka waktu lama, sehingga tinggi badan anak berada di bawah ukuran normal untuk usianya. Kondisi ini biasanya dimulai sejak masa kehamilan dan berlanjut hingga dua tahun pertama kehidupan, yang sering disebut sebagai fase 1000 Hari Pertama Kehidupan (Latifah A dkk., 2024), dan jika terjadi dalam periode tersebut, dampaknya bisa menjadi permanen serta sulit untuk diperbaiki di kemudian hari (Laily dan Indarjo, 2023).

*Stunting* dapat memengaruhi pertumbuhan fisik serta menunda perkembangan anak, mencakup aspek kognitif, motorik kasar maupun halus, kemampuan berkomunikasi, serta perkembangan sosial dan emosional. Kondisi ini diukur menggunakan indikator panjang badan menurut umur (PB/U) untuk anak usia 0-24 bulan dan tinggi badan menurut umur (TB/U) untuk anak usia di atas 24 bulan. Seorang anak dikategorikan stunting apabila nilai z-score indikator tersebut berada di bawah -2 standar deviasi (SD) berdasarkan standar pertumbuhan WHO.

### **2.2.2 *Wasting***

*Wasting* adalah kondisi kekurangan gizi yang bersifat akut pada anak, yang umumnya terlihat dari penurunan berat badan secara progresif hingga berat badan jauh lebih rendah dari batas normal berdasarkan ukuran tinggi badan. Anak dengan *wasting* mengalami kondisi tubuh yang sangat kurus, yang mencerminkan gangguan gizi bersifat akut dalam kurun waktu tertentu (Latifah A dkk., 2024). *Wasting* biasanya muncul karena asupan energi dan protein yang tidak mencukupi dalam waktu yang relatif singkat atau dipicu oleh penyakit infeksi seperti diare, yang membuat tubuh kehilangan cairan dan zat gizi secara cepat.

Anak dengan kondisi *wasting* berisiko lebih besar mengalami masalah kesehatan serius, hambatan pertumbuhan, serta peningkatan kemungkinan kematian pada usia balita (Hardjito dkk., 2024). WHO mendefinisikan *wasting* sebagai berat badan menurut tinggi atau panjang badan berada di bawah -2 SD dari standar pertumbuhan WHO, dan disebut *wasting* berat jika di bawah -3 SD.

### **2.2.3 *Underweight***

*Underweight* adalah keadaan ketika berat badan anak berada di bawah standar pertumbuhan berdasarkan usianya (Avindharin dkk., 2024). *Underweight* memiliki keterkaitan dengan *stunting*, *wasting*, atau bahkan keduanya (Thurstans dkk., 2022). Faktor yang memengaruhi kondisi ini meliputi kecukupan gizi yang rendah, infeksi yang terjadi secara berulang, gangguan penyerapan nutrisi, atau kombinasi dari faktor-faktor tersebut.

*Underweight* juga berpengaruh buruk terhadap pertumbuhan dan perkembangan anak, seperti menyebabkan menurunnya kemampuan berpikir, melemahnya imunitas tubuh, dan naiknya risiko menderita penyakit kronis. Untuk menilai kondisi ini, penilaian dilakukan menggunakan indikator berat badan menurut usia (BB/U) dan akan dikategorikan mengalami *underweight* apabila nilainya kurang dari -2 SD menurut standar pertumbuhan WHO.

#### 2.2.4 *Overweight*

*Overweight* dan obesitas merupakan keadaan ketika berat badan anak melebihi batas normal berdasarkan tinggi atau panjang badannya. Masalah ini muncul ketika asupan energi secara berlebihan berlangsung dalam jangka waktu lama, sehingga menyebabkan penumpukan lemak yang tidak normal di tubuh. Periode paling krusial dalam pencegahan gizi lebih adalah masa awal kehidupan. Pemberian ASI eksklusif selama enam bulan pertama, disertai dengan pengenalan MP-ASI yang sesuai dapat menurunkan risiko obesitas di masa depan (Fitriiani dkk., 2023).

Faktor penyebab *overweight* meliputi pola makan tinggi kalori dan rendah kualitas gizi, aktivitas fisik yang rendah, serta pengaruh genetik dan lingkungan keluarga. Gizi lebih pada anak dapat menimbulkan komplikasi kesehatan jangka panjang, termasuk risiko hipertensi, diabetes melitus tipe 2, serta berbagai gangguan metabolismik lainnya saat dewasa. Penilaian kondisi ini dilakukan menggunakan indikator BB/PB atau BB/TB, dengan klasifikasi *overweight* jika *z-score* berada pada rentang  $> +2$  SD hingga  $\leq +3$  SD, dan dikategorikan obesitas jika melebihi  $+3$  SD menurut standar WHO.

#### 2.2.5 Standar Antropometri Anak

Antropometri merupakan metode pengukuran dimensi tubuh manusia yang digunakan untuk menilai kondisi status gizi berdasarkan parameter fisik, seperti berat badan serta tinggi badan. Standar antropometri berfungsi membandingkan hasil pengukuran anak secara individu dengan distribusi referensi anak sehat sesuai usia dan jenis kelaminnya. Metode ini telah digunakan secara luas dalam pemantauan pertumbuhan dan status gizi anak, baik di tingkat individu untuk keperluan klinis maupun di tingkat populasi untuk surveilans gizi dan kebijakan kesehatan masyarakat.

Dalam konteks kesehatan anak global, standar yang menjadi acuan utama adalah WHO *Child Growth Standards* (2006). Standar ini bukan sekadar rata-rata pertumbuhan anak dari satu negara, melainkan hasil dari WHO *Multicentre Growth Reference Study* (MGRS) yang dilaksanakan pada tahun 1997 hingga 2003. Studi ini secara sengaja mengambil sampel anak-anak yang berasal dari beragam latar

etnis dan budaya (Brazil, Ghana, India, Norwegia, Oman, dan Amerika Serikat) yang dibesarkan dalam kondisi lingkungan yang optimal untuk pertumbuhan, seperti mendapatkan ASI eksklusif dan akses kesehatan yang baik. Hasilnya adalah standar preskriptif yang menggambarkan bagaimana anak-anak di seluruh dunia seharusnya tumbuh dalam kondisi ideal, bukan standar deskriptif yang hanya menggambarkan bagaimana anak di suatu wilayah tertentu tumbuh. Sifat universal inilah yang membuat Standar WHO dapat diterapkan secara valid di berbagai negara, termasuk Indonesia.

Penilaian status gizi berdasarkan standar WHO dilakukan dengan menggunakan *z-score* (skor deviasi standar). *Z-score* menunjukkan seberapa jauh nilai pengukuran seorang anak menyimpang dari median populasi referensi, yang dinyatakan dalam satuan standar deviasi. Perhitungan *z-score* ini menggunakan metode *Lambda-Mu-Sigma* (LMS), di mana *L* (*Lambda*) merepresentasikan tingkat kemiringan distribusi data dan digunakan dalam transformasi *Box-Cox*, *M* (*Mu*) merupakan nilai median distribusi, dan *S* (*Sigma*) adalah koefisien variasi yang menggambarkan sebaran data (WHO, 2006). Ketiga parameter tersebut bersifat spesifik untuk setiap indikator antropometri dan jenis kelamin anak. Tabel parameter LMS telah disusun dalam bentuk tabel resmi dan tersedia di situs WHO yang juga digunakan sebagai acuan internasional dalam perhitungan *z-score*. Ketersediaan parameter terstandar ini penting untuk menjamin konsistensi, akurasi, dan validitas penilaian status gizi anak secara global.

Di Indonesia, acuan resmi dalam penilaian status gizi anak ditetapkan melalui Peraturan Menteri Kesehatan (PMK) Republik Indonesia Nomor 2 Tahun 2020 tentang Standar Antropometri Anak. Peraturan ini secara eksplisit mengadopsi secara penuh Standar Pertumbuhan Anak WHO sebagai standar nasional. Standar antropometri yang ditetapkan oleh peraturan ini digunakan secara nasional di seluruh fasilitas pelayanan kesehatan, serta menjadi dasar bagi berbagai program pemantauan dan intervensi gizi anak (Kementerian Kesehatan Republik Indonesia, 2020). Fungsi utamanya adalah untuk memberikan definisi operasional dan kategori klasifikasi status gizi berdasarkan ambang batas (*cut-off*) nilai *z-score* yang telah dihitung menggunakan metode LMS dari WHO.

Anak usia 0–60 bulan, termasuk kelompok badut yang menjadi sasaran utama dalam penelitian ini, memiliki kategori serta ambang batas *z-score* sesuai ketentuan Peraturan Menteri Kesehatan Nomor 2 Tahun 2020 sebagaimana disajikan pada tabel 2.1.

Tabel 2. 1 Kategori dan Ambang Batas Status Gizi Anak

Indeks	Kategori Status Gizi	Ambang Batas (Z-score)
Berat Badan menurut Umur (BB/U) anak usia 0 - 60 bulan	Berat badan sangat kurang ( <i>severely underweight</i> )	< -3 SD
	Berat badan kurang ( <i>underweight</i> )	-3 SD s.d. < -2 SD
	Berat badan normal	≥ -2 SD s.d. ≤ +1 SD
	Risiko berat badan lebih	> +1 SD
Panjang Badan menurut Umur (PB/U) atau TB/U anak usia 0 - 60 bulan	Sangat pendek ( <i>severely stunted</i> )	< -3 SD
	Pendek ( <i>stunted</i> )	-3 SD s.d. < -2 SD
	Normal	≥ -2 SD s.d. ≤ +3 SD
	Tinggi	> +3 SD
Berat Badan menurut Panjang Badan atau Tinggi Badan (BB/PB atau BB/TB) anak usia 0 - 60 bulan	Gizi buruk ( <i>severely wasted</i> )	< -3 SD
	Gizi kurang ( <i>wasted</i> )	-3 SD s.d. < -2 SD
	Gizi baik (normal)	≥ -2 SD s.d. ≤ +1 SD
	Berisiko gizi lebih ( <i>possible risk of overweight</i> )	> +1 SD s.d. ≤ +2 SD
	Gizi lebih ( <i>overweight</i> )	> +2 SD s.d. ≤ +3 SD
	Obesitas ( <i>obese</i> )	> +3 SD

Klasifikasi ini berperan penting dalam mengidentifikasi kondisi gizi anak secara objektif dan menjadi referensi utama dalam pemantauan serta penetapan kebijakan di bidang kesehatan anak. Standar ini juga memastikan konsistensi penilaian di berbagai fasilitas layanan kesehatan dan digunakan sebagai dasar pelabelan data dalam penelitian ini.

### 2.2.6 Machine Learning

*Machine Learning* (ML) merupakan salah satu bidang dalam kecerdasan buatan yang berfokus pada perancangan algoritma yang dapat mengenali pola dari data dengan otomatis serta terus menyempurnakan kinerjanya seiring berjalannya waktu (Hanifa dkk., 2023). Secara umum, algoritma dalam *machine learning* terdiri dari empat kategori utama yang memiliki fungsi dan tujuan berbeda, meliputi *supervised learning*, *unsupervised learning*, *semi-supervised learning*, dan *reinforcement learning* (Alfarizi dkk., 2023).

Dari keempat algoritma tersebut, *supervised learning* menjadi pendekatan yang paling banyak digunakan untuk permasalahan klasifikasi, karena proses pembelajarannya memanfaatkan data yang sudah memiliki label sebagai dasar pembelajaran model. Dalam pendekatan ini, model dilatih dengan pasangan data masukan dan keluaran untuk mempelajari pola atau hubungan yang mendasari di antara keduanya. Beberapa metode yang termasuk dalam *supervised learning* antara lain *K-Nearest Neighbor* (KNN), *Support Vector Machine* (SVM), hingga algoritma berbasis *gradient boosting* seperti *Catboost* dan *LightGBM*.

### 2.2.7 Light Gradient Boosting Machine

*Light Gradient Boosting Machine* (LightGBM) adalah kerangka kerja *machine learning* yang dibangun di atas algoritma *Gradient Boosting Decision Tree* (GBDT). Algoritma ini dirancang agar dapat memberikan kecepatan pelatihan yang tinggi, pemakaian memori yang efisien, dan akurasi yang lebih optimal, sehingga mampu memproses data berskala besar secara efektif (Nisa, 2024). Sebagai bagian dari keluarga GBDT, *LightGBM* membangun model secara bertahap dalam bentuk *ensemble* pohon keputusan. Setiap pohon keputusan baru dilatih untuk mengoreksi kesalahan yang masih tersisa dari model yang telah terbentuk sebelumnya. Proses prediksi yang bersifat iteratif ini dapat direpresentasikan melalui rumus berikut:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(x_i) \quad (1)$$

Dengan  $\hat{y}_i^{(t)}$  adalah prediksi untuk data ke- $i$  pada iterasi ke- $t$ , yaitu penjumlahan dari prediksi sebelumnya  $\hat{y}_i^{(t-1)}$  dan pohon keputusan baru  $f_t(x_i)$ .

Keunggulan performa *LightGBM* terletak pada beberapa inovasi teknis. Pertama, ia menggunakan algoritma berbasis histogram untuk mengelompokkan nilai fitur ke dalam sejumlah bin diskrit, yang secara signifikan mempercepat proses pencarian titik pemisahan (*split point*) terbaik. Kedua, *LightGBM* menerapkan strategi pertumbuhan pohon secara leaf-wise, yang berbeda dari metode *level-wise* pada GBDT konvensional. Strategi ini fokus pada pemisahan daun yang memberikan penurunan eror terbesar, sehingga konvergensi model menjadi lebih cepat. Untuk menangani data berskala besar, *LightGBM* memperkenalkan *Gradient-based One-Side Sampling* (GOSS) yang memprioritaskan data dengan gradien besar untuk efisiensi, serta *Exclusive Feature Bundling* (EFB) yang menggabungkan fitur-fitur eksklusif untuk mengurangi dimensionalitas data (Rufo dkk., 2021).

Seluruh proses pelatihan *LightGBM* diarahkan untuk meminimalkan sebuah fungsi objektif (objective function) yang tidak hanya mengukur kesalahan prediksi tetapi juga kompleksitas model guna mengurangi risiko *overfitting*. Fungsi objektif ini dapat dituliskan sebagai berikut:

$$\mathcal{L}^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \sum_{t=1}^T \Omega(f_t) \quad (2)$$

$$\Omega(f) = \gamma^T + \frac{1}{2} \lambda \|w\|^2 \quad (3)$$

Pada rumus (2), komponen pertama ( $\sum l(\dots)$ ) adalah *loss term* yang mengukur total kesalahan, sementara komponen kedua ( $\sum \Omega(f_t)$ ) adalah *regularization term* yang memberikan penalti terhadap kompleksitas model. Selanjutnya, pada komponen regularisasi dalam rumus (3),  $T$  adalah jumlah daun,  $w$  adalah bobot pada setiap daun, sementara  $\gamma$  dan  $\lambda$  adalah parameter penalti yang digunakan untuk mengontrol kompleksitas model, di mana dalam implementasinya, nilai default-nya diatur menjadi  $\gamma = 0$  dan  $\lambda = 1$  (Azahra dan Kartikasari, 2025). Dengan meminimalkan fungsi objektif gabungan ini, *LightGBM* dapat menghasilkan model yang akurat sekaligus memiliki kemampuan generalisasi yang kuat dan robust.

## **BAB III**

### **METODOLOGI PENELITIAN**

#### **3.1 Jenis Penelitian**

Penelitian ini merupakan studi kuantitatif dengan pendekatan eksperimental yang bertujuan mengembangkan dan mengevaluasi sistem *machine learning* untuk mengklasifikasikan status gizi badut, mencakup *stunting*, *wasting*, *underweight*, dan *overweight*. Pendekatan yang digunakan bersifat data-driven dengan memanfaatkan data numerik dari sumber daring untuk keperluan analisis dan pemodelan. Penelitian ini juga bersifat aplikatif karena menghasilkan sistem yang dapat diimplementasikan sebagai alat bantu klasifikasi status gizi secara praktis dan efisien.

#### **3.2 Sumber dan Jenis Data**

Data dalam penelitian ini merupakan data sekunder yang berasal dari platform repositori data Kaggle, dengan judul “*stunting\_wasting\_dataset.csv*”. Dataset ini berisi 100.000 data pertumbuhan anak berusia 0 hingga 24 bulan. Dataset ini memuat sejumlah fitur yang berfungsi sebagai variabel masukan (*input*) dalam penelitian, yaitu:

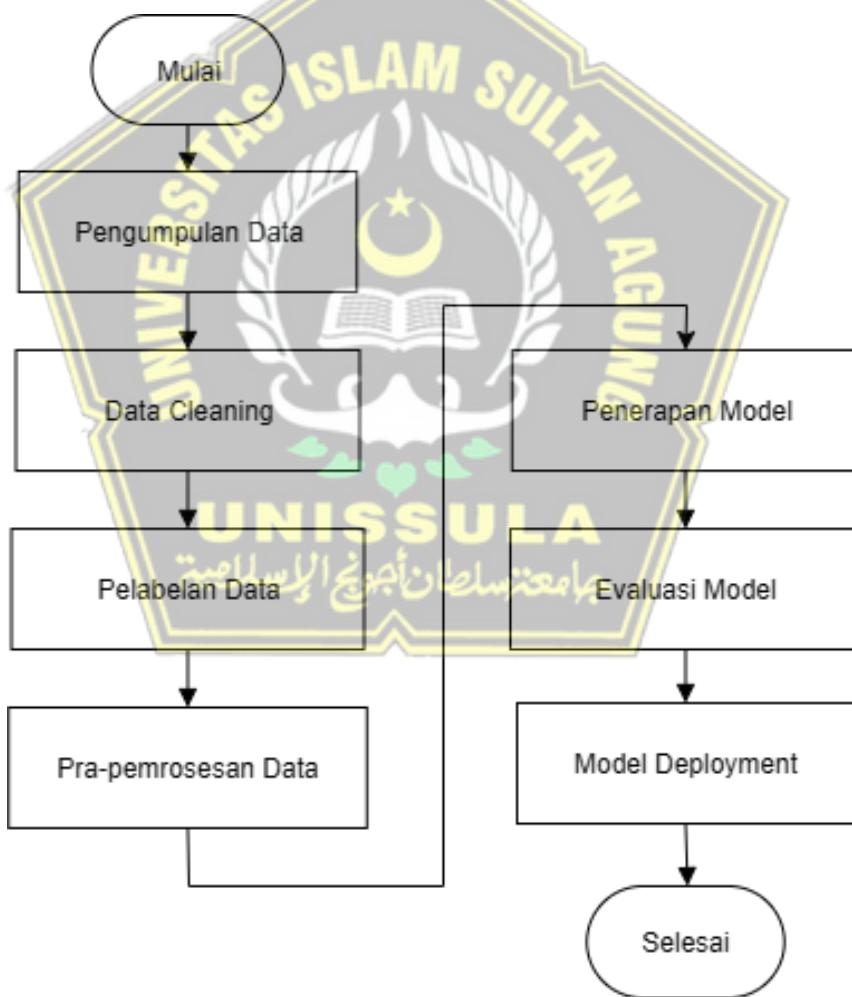
- a. Jenis Kelamin: Variabel kategorikal yang menunjukkan jenis kelamin anak, yaitu laki-laki dan perempuan.
- b. Usia (bulan): Variabel numerik yang merepresentasikan usia anak dalam satuan bulan (0-24 bulan).
- c. Tinggi Badan (cm): Variabel numerik kontinu yang menunjukkan panjang atau tinggi badan anak dalam satuan sentimeter. WHO membedakan antara panjang badan (PB) untuk anak usia di bawah 24 bulan dan tinggi badan (TB) untuk anak usia 24 bulan ke atas.
- d. Berat Badan (kg): Variabel numerik kontinu yang menunjukkan berat badan anak dalam satuan kilogram.

Meskipun dataset ini menyediakan fitur antropometri yang esensial, label status gizi yang tersedia masih belum lengkap dan kurang menjelaskan mengenai metode pelabelan maupun asal geografis data. Oleh karena itu, penelitian ini

melakukan proses perhitungan *z-score* dan pelabelan ulang untuk menghasilkan variabel target yang akurat dan valid berdasarkan Standar Pertumbuhan Anak WHO yang bersifat universal dan Peraturan Menteri Kesehatan Republik Indonesia Nomor 2 Tahun 2020.

### 3.3 Tahapan Penelitian

Penelitian ini terdiri atas beberapa tahapan untuk menghasilkan sistem klasifikasi status gizi anak menggunakan algoritma *Light Gradient Boosting Machine* (*LightGBM*). Untuk mempermudah pemahaman terhadap keseluruhan proses penelitian, tahapan-tahapan tersebut ditampilkan dalam bentuk *flowchart* pada Gambar 3.1.



Gambar 3. 1 *Flowchart* Tahapan Penelitian

Uraian dari masing-masing tahapan dalam Gambar 3.1 disampaikan pada bagian berikut.

### 3.3.1 Pengumpulan data

Langkah awal penelitian ini berupa proses pengumpulan data yang dilakukan dengan mengunduh dataset “*Stunting Wasting Dataset*” dari platform Kaggle yang disusun dan dipublikasikan oleh pengguna bernama Jabir Muktabir. Dataset ini berisi 100.000 catatan antropometri sintetis untuk anak usia 0 sampai 24 bulan dengan variabel jenis kelamin, umur (bulan), berat badan (kilogram), dan tinggi badan (sentimeter). Data yang digunakan kemudian diperiksa dari sisi kelengkapan dan konsistensinya, termasuk kesesuaian format usia dalam bulan, satuan berat badan, dan satuan tinggi badan. Pemeriksaan ini diperlukan guna memastikan data sesuai dengan kebutuhan analisis dan standar pengolahan selanjutnya.

### 3.3.2 Data Cleaning

Proses *data cleaning* dilakukan untuk meningkatkan kualitas dataset dengan mengeliminasi anomali, inkonsistensi, dan data yang tidak valid. Langkah ini krusial karena data yang bersih akan menghasilkan perhitungan *z-score* yang lebih akurat. Langkah-langkah yang diterapkan pada tahap ini meliputi:

- a. Penyesuaian Nama Kolom: Untuk konsistensi dengan standar antropometri, nama kolom ‘Tinggi Badan (cm)’ diubah menjadi ‘Panjang Badan (cm)’ karena subjek penelitian adalah anak di bawah 2 tahun yang pengukurannya dilakukan dalam posisi berbaring atau terlentang. Nama kolom pada label ‘Wasting’ juga diubah menjadi ‘Underweight’ agar sesuai dengan kelas dan indikator yang digunakan pada kolom tersebut.
- b. Penanganan Data Duplikat: Pemeriksaan dilakukan terhadap dataset untuk mengetahui apakah ada data yang terduplikasi atau tidak. Baris data duplikat yang ditemukan kemudian dihapus untuk menghindari bias pada model.
- c. Penanganan *Missing Values*: Tahap ini dilakukan dengan mencari apakah ada *missing values* pada dataset yang digunakan, jika ditemukan entri yang tidak memiliki nilai maka data tersebut dihapus dan tidak digunakan.
- d. Penanganan Data Tidak Konsisten: Seluruh data teks diubah ke huruf kecil (*lowercase*) dan spasi berlebih dihilangkan agar konsistensi tetap terjaga.
- e. Penanganan *Outlier*: Data disaring untuk menghilangkan nilai-nilai ekstrem yang berada di luar rentang biologis wajar menurut referensi WHO.

### 3.3.3 Pelabelan Data

Tahap pelabelan data dilakukan dengan maksud untuk menciptakan variabel target yang akurat dan terstandarisasi secara klinis dari data mentah. Dalam penelitian ini, pelabelan data dilakukan dengan mengimplementasikan metode *Lambda-Mu-Sigma* (LMS) yang direkomendasikan oleh *World Health Organization* (WHO) untuk menghitung nilai *z-score* pertumbuhan anak.

Perhitungan *z-score* dilakukan secara terprogram menggunakan skrip Python, dengan mengimplementasikan rumus LMS sebagai berikut:

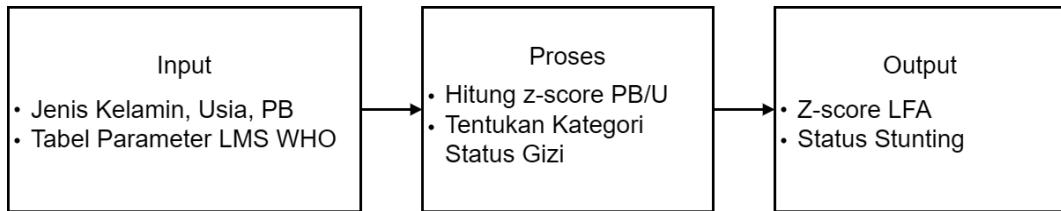
$$Z = \frac{\left(\frac{X}{M}\right)^L - 1}{S \cdot L} \quad (4)$$

Di mana  $Z$  adalah nilai *z-score* yang dihitung,  $X$  adalah nilai hasil pengukuran individu (berat badan atau tinggi badan), dan  $L$ ,  $M$ ,  $S$  adalah parameter kurva pertumbuhan spesifik yang diperoleh dari tabel referensi WHO berdasarkan usia dan jenis kelamin anak.

Tabel parameter LMS didapatkan melalui website WHO (<https://www.who.int/tools/child-growth-standards/standards>) yang juga disertakan dalam lampiran penelitian ini. Proses perhitungan dan pelabelan ini dilakukan secara otomatis melalui pemrograman Python sehingga setiap data anak memperoleh nilai *z-score* untuk masing-masing indikator berdasarkan kombinasi usia, jenis kelamin, serta nilai pengukuran panjang badan dan/atau berat badan yang relevan dengan indikator tersebut. Dengan cara ini, seluruh label status gizi yang dihasilkan telah sepenuhnya terstandardisasi menurut referensi WHO dan dapat digunakan secara universal tanpa ketergantungan pada konteks negara asal data. Tiga nilai *z-score* yang berbeda akan dihitung pada setiap anak untuk menilai aspek status gizi yang berbeda, ketiga aspek tersebut meliputi:

- a. *Z-score* PB/U (Panjang Badan menurut Umur): Indikator ini berfungsi dalam mengidentifikasi status *stunting*.
- b. *Z-score* BB/PB (Berat Badan menurut Panjang Badan): Indikator ini berfungsi dalam mengidentifikasi status *wasting* dan *overweight*.
- c. *Z-score* BB/U (Berat Badan menurut Umur): Indikator ini digunakan dalam menentukan status *underweight*.

Arsitektur *input-proses-output* pada tahap pelabelan indikator *stunting* (Panjang Badan menurut Umur) ditampilkan pada Gambar 3.2.



Gambar 3. 2 Arsitektur *input-proses-output* pelabelan *stunting* (PB/U)

Pada tahap *input*, sistem menerima data jenis kelamin, usia dalam bulan, dan panjang badan (PB) setiap anak, kemudian menggabungkannya dengan parameter L, M, dan S untuk indikator *length-for-age* (LFA) sesuai usia dan jenis kelamin. Pada tahap proses, data tersebut digunakan untuk menghitung nilai *z-score* panjang badan menurut umur (*Z-score\_LFA*) dengan rumus LMS dan memetakan nilai tersebut ke dalam kategori status *stunting* (*severely stunted*, *stunted*, *normal*, *tall*) berdasarkan ambang batas pada PMK No. 2 Tahun 2020. Pada tahap *output*, sistem menghasilkan dua atribut baru untuk setiap anak, yaitu nilai *Z-score\_LFA* dan label *Status\_Stunting* yang digunakan sebagai variabel target pada model *stunting*.

Mekanisme *input-proses-output* yang serupa juga diterapkan pada indikator *wasting/overweight* (BB/PB) dan *underweight* (BB/U) dengan menyesuaikan kombinasi variabel antropometri serta tabel referensi WHO yang digunakan. Secara keseluruhan, proses pelabelan pada ketiga indikator tersebut menghasilkan tiga kolom label baru dalam dataset, yaitu *status\_stunting*, *status\_wasting\_overweight*, dan *status\_underweight*. Ketiga kolom ini berisi kategori status gizi yang juga telah disesuaikan dengan batasan pada PMK Nomor 2 Tahun 2020 dan digunakan sebagai variabel target pada tahap pelatihan model.

Dalam proses pelabelan ini, setiap indikator status gizi juga mencakup kategori normal sebagai representasi anak dengan pertumbuhan sesuai standar WHO. Pada indikator *stunting* digunakan label normal, pada indikator *underweight* digunakan label normal *weight*, dan pada indikator *wasting/overweight* digunakan label gizi baik (normal). Keberadaan kelas normal ini memastikan bahwa model tidak hanya mendeteksi kondisi gizi kurang atau lebih, tetapi juga mengenali anak yang memiliki status gizi normal sebagai acuan dalam klasifikasi multikelas.

### 3.3.4 Pra-Pemrosesan Data

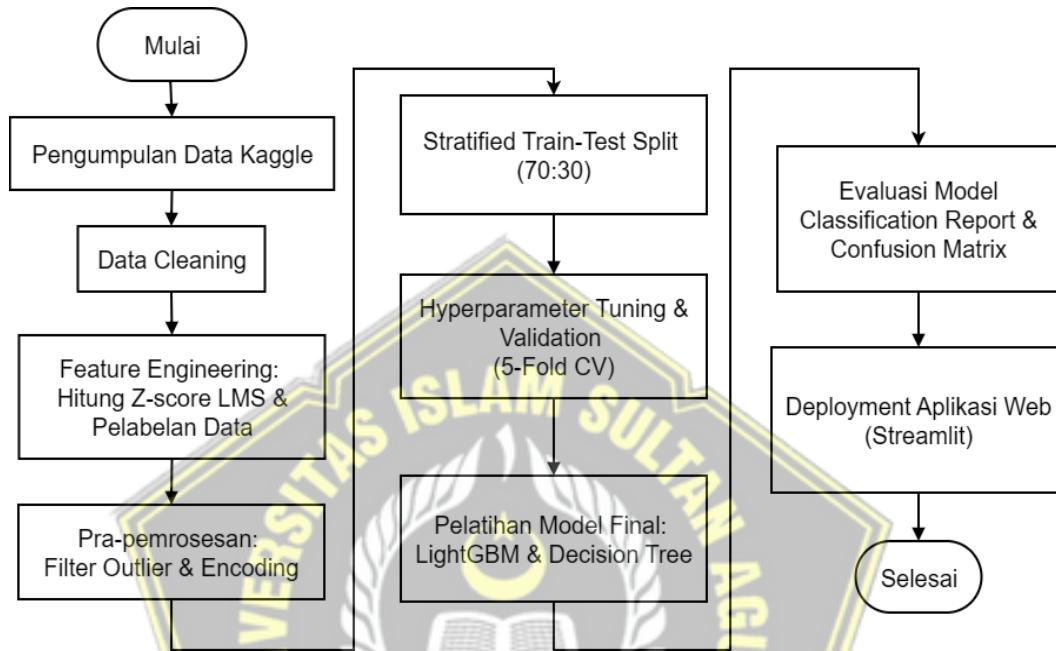
Tahapan pra-pemrosesan data dilakukan agar data yang digunakan dalam proses pelatihan tetap bersih, konsisten, dan optimal untuk pemodelan *machine learning*. Tahapan yang dilakukan meliputi:

- a. Penanganan *outlier z-score*: Tahapan ini dilakukan dengan menyaring nilai-nilai *z-score* yang sangat ekstrem agar data pelatihan tidak terdistorsi oleh pengukuran yang tidak wajar. Dalam praktik analisis gizi, nilai di luar  $\pm 4$  standar deviasi diperlakukan sebagai observasi yang sangat ekstrem dan jarang, serta memiliki risiko tinggi mengandung kesalahan pengukuran atau pencatatan. Oleh karena itu, penelitian ini hanya menggunakan data dengan rentang *z-score* dari -4 SD sampai +4 SD, sedangkan nilai di luar rentang tersebut akan dihapus secara otomatis. Langkah ini membuat dataset lebih bersih dan lebih representatif untuk keperluan pemodelan.
- b. *Encoding* variabel kategorikal: Tahapan ini dilakukan dengan mengonversi nilai kategorikal menjadi bentuk numerik. Dalam penelitian ini, variabel jenis kelamin direpresentasikan secara biner, yaitu laki-laki = 1, dan perempuan = 0. Variabel status gizi juga diubah menjadi integer dari nilai 0, 1, 2 dan seterusnya dengan urutan yang sesuai kategori status gizi, contohnya *severely stunted* diberi kode 0, *stunted* 1, normal 2, dan *tall* atau tinggi 3. Proses ini diperlukan agar data lebih mudah diproses secara optimal oleh algoritma *machine learning*.
- c. Pembagian Data Latih dan Data Uji: Dataset dibagi menjadi data latih (*training set*) dan data uji (*testing set*) dengan proporsi rasio 70:30. Proses pembagian dilakukan secara acak dengan metode stratifikasi sehingga distribusi untuk setiap kelas tetap seimbang pada kedua set data.

### 3.3.5 Penerapan Model

Penerapan model pada penelitian ini dilakukan melalui rangkaian tahapan terstruktur mulai dari pengolahan data hingga implementasi ke dalam aplikasi web menggunakan Algoritma *Light Gradient Boosting Machine* (LightGBM). Algoritma ini dipilih sebagai model utama karena mampu menangani dataset dengan distribusi kelas yang tidak merata serta memiliki kecepatan pelatihan yang

tinggi dengan akurasi yang tetap optimal. Karakteristik tersebut menjadikan *LightGBM* sesuai digunakan untuk menganalisis data antropometri dan mengklasifikasikan status gizi anak secara efektif. Alur lengkap untuk pengembangan model ditunjukkan pada *flowchart* Gambar 3.3.



Gambar 3. 3 Arsitektur Pengembangan Model Klasifikasi Status Gizi

Gambar 3.3 Menjelaskan alur pengembangan model secara keseluruhan, mulai dari data hasil rekayasa fitur dan pra-pemrosesan, pembagian data menjadi data latih dan data uji, pelatihan serta penyetelan model, hingga evaluasi dan *deployment* ke dalam aplikasi *web*. Pipeline ini memastikan setiap model dikembangkan melalui tahapan yang terstruktur dan konsisten. Untuk memberikan penilaian status gizi yang komprehensif, penelitian ini membangun tiga model klasifikasi multi-kelas yang terpisah, sesuai dengan tiga indikator status gizi utama:

- Model 1 (Klasifikasi *Stunting*): Model ini dilatih untuk memprediksi status *stunting* menggunakan fitur usia, jenis kelamin, dan panjang badan.
- Model 2 (Klasifikasi *Wasting/Overweight*): Model ini dilatih untuk memprediksi status *wasting/overweight* menggunakan fitur jenis kelamin, panjang badan, dan berat badan.
- Model 3 (Klasifikasi *Underweight*): Model ini dilatih untuk memprediksi status *underweight* menggunakan fitur usia, jenis kelamin, dan berat badan.

Untuk meningkatkan performa model, akan dilakukan proses penyetelan *hyperparameter* atau *fine-tuning* secara sistematis. Proses ini menjadi krusial karena adanya data yang tidak seimbang, di mana konsekuensinya adalah model cenderung menjadi bias dan memiliki performa sangat buruk pada kelas minoritas, seperti *wasting* dan *underweight*. Hal ini dapat menyebabkan metrik *recall* dan *F1-score* yang rendah, sehingga tujuan sistem untuk deteksi dini menjadi tidak efektif.

Proses *hyperparameter tuning* dilakukan menggunakan pendekatan pencarian sistematis yang dikombinasikan dengan validasi silang (*cross-validation*). Di mana untuk LightGBM digunakan *Randomized Search*, sedangkan untuk model pembanding *Decision Tree* digunakan *Grid Search*. Keduanya dijalankan menggunakan skema *5-fold cross-validation* dengan metrik penilaian *recall\_macro*. Metrik ini dipilih karena kemampuannya mengevaluasi performa model secara seimbang di semua kelas, tanpa berfokus pada kelas mayoritas saja.

Ruang pencarian *hyperparameter* yang dieksplorasi pada LightGBM mencakup parameter-parameter kunci yang mengontrol kompleksitas dan mencegah *overfitting*. Parameter yang diuji meliputi:

- a. *n\_estimators*: [200, 400, 600, 800]
- b. *learning\_rate*: [0.03, 0.05, 0.08]
- c. *num\_leaves*: [31, 63]
- d. *max\_depth*: [5, 7, 10]
- e. *min\_child\_samples*: [50, 100, 200]
- f. *subsample*: [0.7, 0.8, 0.9]
- g. *min\_split\_gain*: [0.0, 0.1]
- h. *reg\_lambda*: [1.0, 5.0]
- i. *subsample\_freq*: [1]

Sebagai bagian dari proses validasi, hasil dari model LightGBM akan dibandingkan dengan metode *Decision Tree*, yaitu model non-parametrik berbasis pohon keputusan yang menghasilkan prediksi variabel target dengan mempelajari pola aturan keputusan berbasis fitur data. Pemilihan metode ini didasarkan pada relevansinya sebagai algoritma dasar dari metode *ensemble* berbasis pohon seperti LightGBM. Dengan demikian, perbandingan ini dapat menunjukkan secara efektif

peningkatan performa yang dihasilkan oleh teknik *boosting* dari *LightGBM*.

Pada model *Decision Tree*, eksplorasi penyetelan parameter dilakukan untuk menghindari *overfitting* dan mendapatkan performa terbaik sebagai pembanding. Ruang pencarian parameter yang diterapkan dalam penelitian ini meliputi:

- a. *max\_depth*: [5, 8, 10, 12]
- b. *min\_samples\_split*: [10, 20, 40]
- c. *min\_samples\_leaf*: [10, 20, 30]

### 3.3.6 Evaluasi Model

Evaluasi model dilakukan untuk menilai kemampuan prediktif secara objektif terhadap data uji yang tidak pernah digunakan pada tahap pelatihan. Penelitian ini menggunakan *Confusion Matrix* sebagai metrik evaluasi utama dan serangkaian metrik turunannya yang umum digunakan dalam tugas klasifikasi. Model ini menyajikan ringkasan visual atas kinerja model dalam membedakan setiap kelas pada data uji. Metrik ini membantu dalam mengidentifikasi jenis kesalahan yang paling sering dilakukan model.

Tabel *Confusion Matrix* tersusun atas empat komponen utama yang menjadi dasar untuk perhitungan metrik kinerja. Keempat komponen tersebut adalah:

- a. *True Positif* (TP): menunjukkan jumlah data yang diklasifikasikan model sebagai positif, dan memang benar termasuk dalam kelas positif.
- b. *True Negatif* (TN): menunjukkan jumlah data yang diklasifikasikan model sebagai negatif, dan memang benar termasuk dalam kelas negatif.
- c. *False Positif* (FP): menunjukkan jumlah data yang diklasifikasikan model sebagai positif, padahal data tersebut termasuk dalam kelas negatif.
- d. *False Negatif* (FN): menunjukkan jumlah data yang diklasifikasikan model sebagai negatif, padahal data tersebut termasuk dalam kelas positif.

Keempat komponen fundamental yang telah diuraikan tersebut menjadi landasan untuk analisis kuantitatif kinerja model. Nilai-nilai ini kemudian digunakan untuk menurunkan serangkaian metrik evaluasi yang lebih canggih dan terstandarisasi. Berbagai metrik berikut memberikan wawasan yang lebih mendalam terhadap berbagai aspek kinerja model, mulai dari akurasi secara umum hingga presisi dan kelengkapan dalam mengenali setiap kelas.

a. *Accuracy*

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (5)$$

*Accuracy* atau akurasi merupakan metrik yang paling sering digunakan untuk menilai kinerja keseluruhan dari suatu model. Rumus ini menghitung perbandingan antara jumlah prediksi benar terhadap total keseluruhan data yang diuji. Secara sederhana, akurasi menggambarkan proporsi data yang berhasil diprediksi dengan tepat dibandingkan dengan total data yang ada.

b. *Precision*

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

*Precision* berfokus pada sejauh mana prediksi positif yang dihasilkan model benar-benar akurat. Metrik presisi digunakan untuk menilai ketepatan model dalam mengidentifikasi kelas positif yang benar dibandingkan seluruh prediksi positif yang ada, sehingga meminimalkan terjadinya alarm palsu.

c. *Recall*

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

*Recall*, atau yang sering disebut *Sensitivity* menggambarkan sejauh mana model mampu mengenali seluruh data yang benar-benar termasuk dalam kategori positif. Metrik ini sangat penting untuk mengevaluasi tingkat keberhasilan model agar tidak melewatkannya kasus-kasus penting.

d. *F1 Score*

$$F1 Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (8)$$

*F1 Score* digunakan sebagai indikator untuk menilai keseimbangan performa antara *Precision* dan *Recall*. Rumus ini menghitung rata-rata harmonik antara nilai kedua metrik tersebut. Nilai F1 Score menjadi penting ketika kita ingin sebuah model yang tidak hanya akurat dalam prediksi positifnya (*Precision* tinggi) tetapi juga mampu menemukan sebagian besar kasus positif yang ada (*Recall* tinggi).

Selain menilai performa model *LightGBM* melalui metrik akurasi, presisi, *recall*, dan *F1-score*, penelitian ini juga membandingkan hasil kinerjanya dengan algoritma *Decision Tree*. Model ini juga akan dilatih dan diuji menggunakan dataset serta skema pembagian data yang sama agar hasil evaluasi dapat dibandingkan secara adil.

Proses perbandingan dilakukan dengan mengevaluasi versi terbaik dari setiap model yang telah dioptimalkan melalui proses *hyperparameter tuning* pada himpunan data uji yang sama. Kinerja kuantitatif dari model *LightGBM* akan dibandingkan secara berdampingan dengan kinerja model *Decision Tree*. Tujuan dari evaluasi komparatif ini adalah untuk memperkuat justifikasi pemilihan model dan memastikan bahwa *LightGBM* merupakan metode yang unggul untuk tugas klasifikasi status gizi anak, sejalan dengan tujuan penelitian untuk membangun sistem yang akurat dan andal.

### 3.3.7 Model Deployment

Proses deployment model dilakukan menggunakan Streamlit, yaitu sebuah *framework open-source* Python yang dipilih karena kemampuannya dalam membangun antarmuka pengguna secara cepat dan efisien. Streamlit juga menyediakan serangkaian komponen interaktif siap pakai, seperti formulir masukan dan tombol, yang memungkinkan pembuatan aplikasi yang responsif dan intuitif. Dalam implementasinya, aplikasi ini memuat model *LightGBM* yang telah disimpan, menyajikan antarmuka bagi pengguna untuk memasukkan data antropometri anak, kemudian menampilkan hasil dari klasifikasi ketiga status gizi.

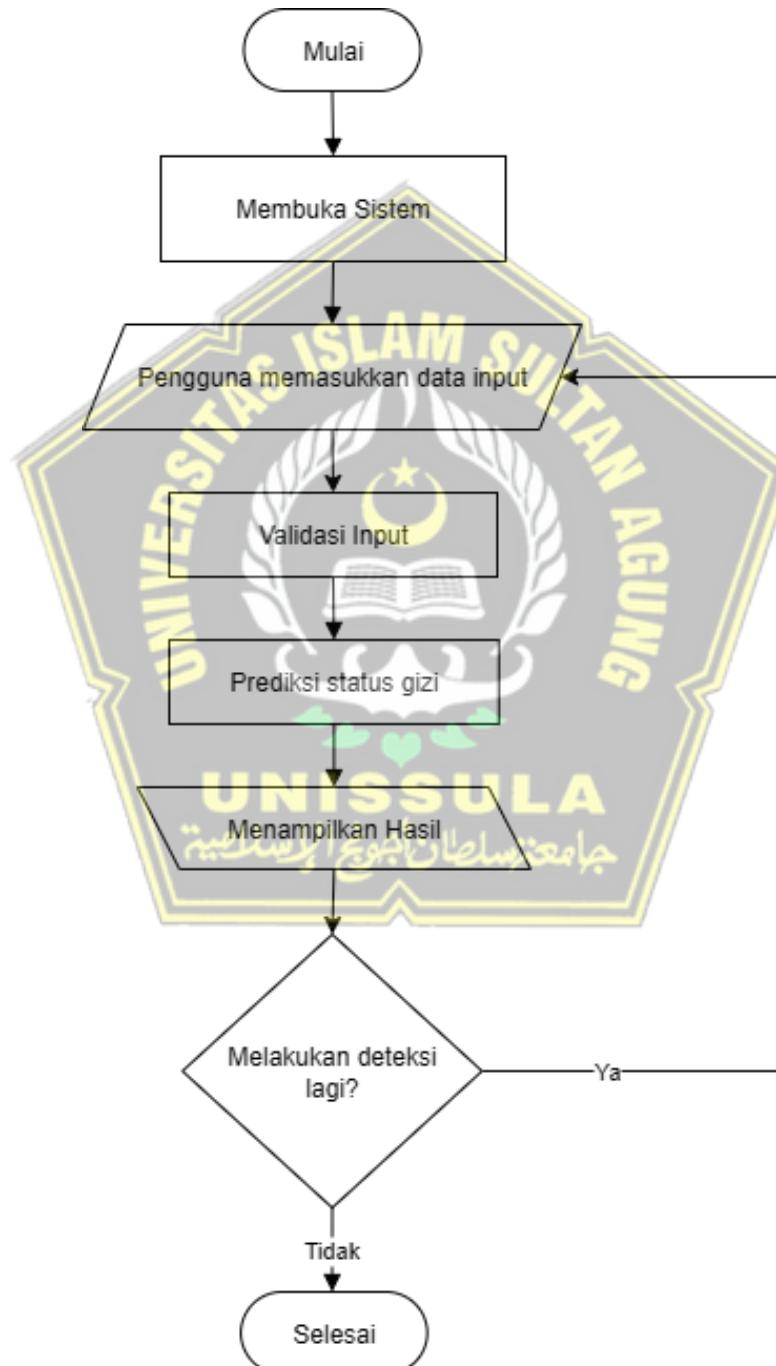
## 3.4 Rancangan Sistem

Setelah proses pengembangan dan evaluasi selesai dilakukan, model *LightGBM* diintegrasikan ke dalam sistem dengan antarmuka pengguna yang interaktif. Perancangan sistem ini bertujuan untuk meningkatkan usabilitas bagi pengguna akhir, seperti orang tua atau tenaga kesehatan, sehingga dapat digunakan sebagai alat bantu skrining status gizi anak secara praktis.

Untuk menggambarkan rancangan perangkat lunak yang diusulkan, digunakan dua jenis diagram, yaitu *flowchart* sistem untuk menjelaskan alur kerja dan Data Flow Diagram (DFD) untuk menjelaskan aliran data.

### 3.4.1 Alur Kerja Sistem

Alur kerja sistem dari sudut pandang pengguna digambarkan dalam bentuk *flowchart*. Diagram ini menjelaskan langkah-langkah yang akan dilalui pengguna saat berinteraksi dengan sistem, mulai dari memasukkan data hingga mendapatkan hasil klasifikasi.



Gambar 3. 4 *Flowchart* Rancangan Sistem

Gambar 3.4 merupakan *flowchart* rancangan sistem klasifikasi status gizi badut yang dibangun menggunakan Streamlit. Alur dimulai dari pengguna yang mengakses sistem dan memasukkan data *input* berupa usia, jenis kelamin, berat badan, dan panjang badan. Setelah data dimasukkan, sistem melakukan validasi untuk memastikan *input* tersebut lengkap, dalam format yang benar, dan berada pada rentang nilai yang wajar. Jika terjadi kesalahan, sistem menampilkan pesan peringatan dan meminta pengguna memperbaiki data terlebih dahulu. Data yang telah valid kemudian diproses oleh model *LightGBM* untuk melakukan prediksi status gizi berdasarkan ketiga indikator. Hasil prediksi kemudian ditampilkan kepada pengguna melalui antarmuka, dan proses diakhiri dengan penutupan sesi penggunaan sistem.

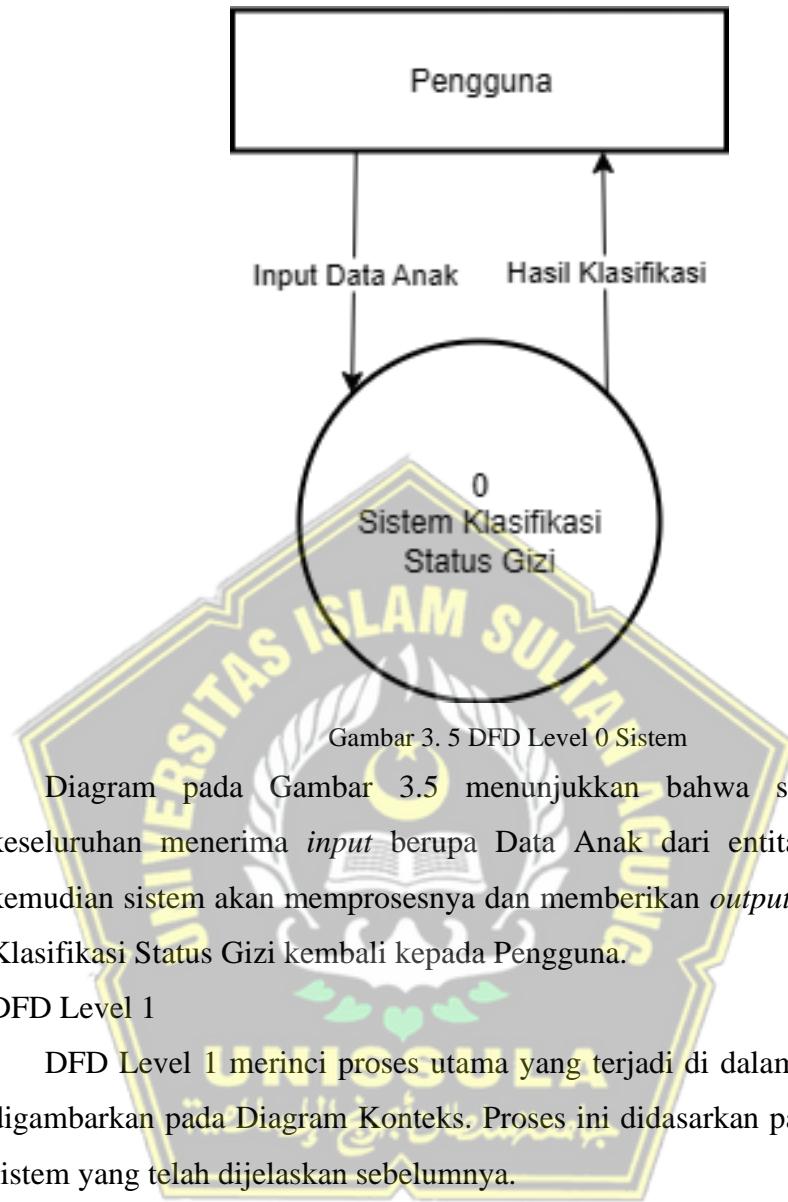
#### **3.4.2 Data Flow Diagram**

Selain alur kerja, perancangan perangkat lunak ini juga dimodelkan menggunakan Data Flow Diagram (DFD) untuk memberikan gambaran mengenai aliran data. DFD berfokus pada bagaimana data bergerak antara entitas eksternal, proses-proses di dalam sistem, dan tempat penyimpanan data (*data store*).

##### a. DFD Level 0

Diagram Konteks menggambarkan sistem sebagai satu proses tunggal dan menunjukkan interaksinya dengan entitas eksternal.

- 1) Entitas Eksternal: Pengguna (Orang tua, tenaga kesehatan).
- 2) Alur Data Masuk: Data Anak (Usia, Jenis Kelamin, Berat Badan, Tinggi Badan).
- 3) Alur Data Keluar: Hasil Klasifikasi Status Gizi.



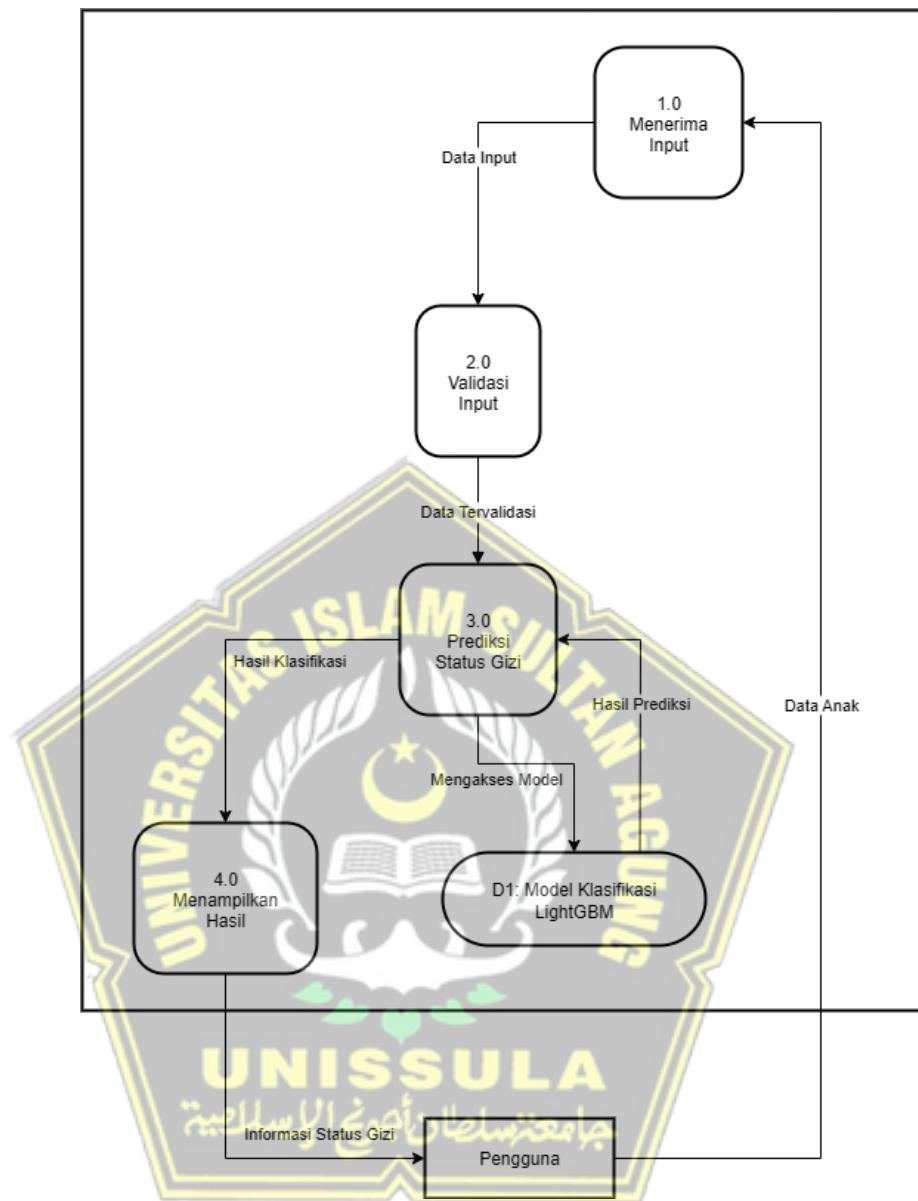
Gambar 3. 5 DFD Level 0 Sistem

Diagram pada Gambar 3.5 menunjukkan bahwa sistem secara keseluruhan menerima *input* berupa Data Anak dari entitas Pengguna, kemudian sistem akan memprosesnya dan memberikan *output* berupa Hasil Klasifikasi Status Gizi kembali kepada Pengguna.

b. DFD Level 1

DFD Level 1 merinci proses utama yang terjadi di dalam sistem yang digambarkan pada Diagram Konteks. Proses ini didasarkan pada alur kerja sistem yang telah dijelaskan sebelumnya.

- 1) Proses:
  - a) Menerima *Input* Pengguna
  - b) Validasi *Input*
  - c) Prediksi Status Gizi
  - d) Menampilkan Hasil
- 2) Penyimpanan Data (*Data Store*):
  - a) D1: Model Klasifikasi *LightGBM*: Merupakan tempat penyimpanan model-model *LightGBM* yang telah dilatih untuk melakukan prediksi.



Gambar 3. 6 DFD Level 1 Sistem

Penjelasan alur data DFD Level 1 pada Gambar 3.6 adalah sebagai berikut, pengguna memasukkan data anak yang diterima oleh Proses 1.0. Data kemudian divalidasi oleh Proses 2.0. Jika valid, data tervalidasi dikirim ke Proses 3.0 untuk diprediksi. Proses 3.0 mengakses model klasifikasi *LightGBM* yang tersimpan di data store D1 dan menerima hasil prediksi. Hasil ini kemudian dikirim ke Proses 4.0 untuk disajikan sebagai informasi status gizi kepada Pengguna.

## **BAB IV**

### **HASIL DAN ANALISIS PENELITIAN**

#### **4.1 Hasil Persiapan Data**

Tahap persiapan data bertujuan untuk memastikan data yang digunakan untuk melatih model berkualitas tinggi, valid, dan representatif. Berikut adalah hasil dari setiap proses yang dilakukan.

##### **4.1.1 Hasil *Data Cleaning***

Proses pembersihan data dilakukan pada dataset awal yang terdiri 100.000 baris data. Hasil dari proses ini adalah sebagai berikut:

a. Penanganan Data Duplikat

Berdasarkan pengecekan awal, ditemukan sebanyak 7.308 baris data yang terduplikasi secara sempurna. Seluruh baris duplikat tersebut berhasil dihapus sehingga menyisakan 92.692 baris data.

b. Penanganan *Outlier*

Berdasarkan standar pertumbuhan anak WHO, data yang memasuki nilai *outlier* diidentifikasi dan dihapus. Rentang Nilai Panjang badan yang digunakan adalah 45 cm hingga 100 cm, sedangkan untuk berat badan menggunakan rentang 2 kg hingga 18 kg. Proses ini menghasilkan dataset yang bersih dan valid sebanyak 91.519 baris data, yang siap digunakan untuk tahapan selanjutnya yaitu pelabelan data.

##### **4.1.2 Hasil pelabelan data**

Setelah data dibersihkan, dilakukan proses pelabelan ulang status gizi berdasarkan perhitungan *z-score* sesuai standar WHO dan PMK No. 2 Tahun 2020. Proses ini secara efektif menambahkan tiga kolom target baru beserta nilai *z-score* masing-masing indikator ke dalam dataset. Tabel 4.1 menyajikan contoh struktur data setelah proses pelabelan untuk memberikan gambaran visual.

Tabel 4. 1 Hasil Pelabelan Status *Stunting*

Jenis Kelamin	Usia	PB	BB	Zscore_LFA	Status_ <i>Stunting</i>
laki-laki	19	91.6	13.3	3.03	<i>tall</i>
laki-laki	20	77.7	8.5	-2.31	<i>stunted</i>
laki-laki	10	79	10.3	2.5	normal
perempuan	2	50.3	8.3	-3.32	<i>severely stunted</i>
perempuan	5	56.4	10.9	-3.44	<i>severely stunted</i>
...	...	...	...	...	...
laki-laki	21	93.7	14.8	2.98	normal
perempuan	18	82.9	12.6	0.75	normal

91.519 rows × 6 columns

Tabel 4.1 adalah potongan tampilan struktur data yang telah ditambahkan label baru *stunting* dari hasil perhitungan *z-score* berdasarkan indikator panjang badan menurut usia menggunakan rumus LMS dari WHO. Pemberian label status\_*stunting* telah disesuaikan dengan nilai ambang batas *z-score* pada PMK No.2 Tahun 2020, contohnya pada baris pertama dengan nilai *z-score* lebih dari 3 masuk ke dalam kategori *tall* atau tinggi dan baris keempat serta kelima dengan *z-score* di bawah -3 termasuk ke dalam kategori *severely stunted*. Untuk status gizi yang lain, yaitu *wasting/overweight* dan *underweight* juga telah dilakukan proses yang sama dengan menghitung *z-score* dan memberi label berdasarkan indikatornya masing-masing sehingga dataset tersebut kini memiliki 3 label baru yaitu status\_*stunting*, status\_*wasting\_overweight*, dan status\_*underweight*.

Setelah berhasil membuat kolom label target baru berdasarkan nilai *z-score* pada masing-masing indikator status gizi, langkah selanjutnya adalah membandingkan data dari label baru tersebut dengan data dari label status gizi yang telah disediakan dataset sebelumnya dari kaggle. Hal ini bertujuan untuk melihat seberapa banyak label target yang berbeda antara data yang sudah ada dengan data baru hasil perhitungan *z-score*.

Tabel 4. 2 Perbandingan label awal dan label baru

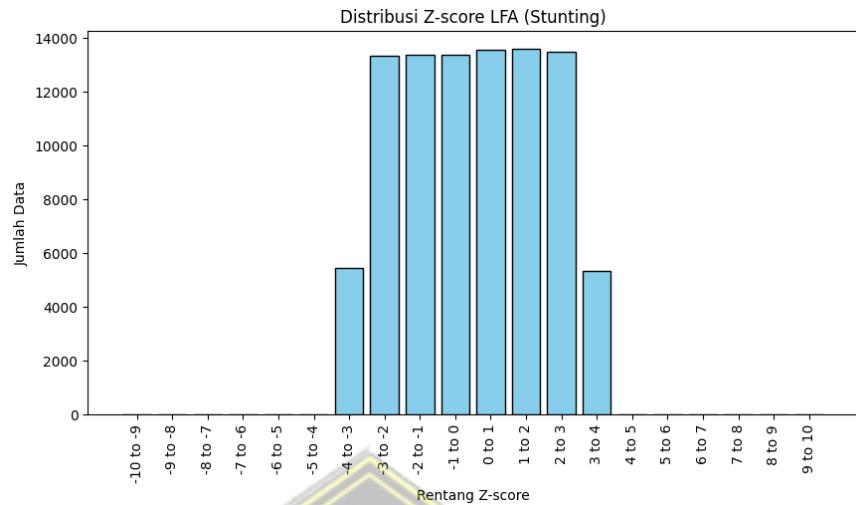
No	Stunting	Status_ Stunting	Underweight	Status_ Underweight
36	normal	normal	<i>risk of overweight</i>	<i>normal weight</i>
70	<i>stunted</i>	normal	<i>risk of overweight</i>	<i>risk of overweight</i>
78	<i>stunted</i>	normal	<i>normal weight</i>	<i>normal weight</i>
97	<i>stunted</i>	normal	<i>underweight</i>	<i>underweight</i>
...	...	...	...	...
91.497	normal	normal	<i>normal weight</i>	<i>risk of overweight</i>
91.504	normal	normal	<i>underweight</i>	<i>severely overweight</i>
4.222 rows				

Tabel 4.2 menyajikan label status gizi yang memiliki label berbeda antara label asli dari dataset dengan label baru yang dihasilkan dari perhitungan ulang *z-score*. Analisis perbandingan pada 91.519 baris data menunjukkan adanya ketidaksesuaian yang signifikan, di mana ditemukan total sebanyak 4.222 baris data yang berbeda. Perbedaan tersebut melibatkan 2.019 baris data dengan perubahan label *stunting* dan 2.287 baris data dengan perubahan label *underweight*, dimana sebagian baris mengalami perubahan pada kedua indikator sekaligus. Hal ini menunjukkan adanya kemungkinan perbedaan dalam kriteria penilaian status gizi antara label awal dengan label baru hasil perhitungan *z-score* WHO. Oleh karena itu, untuk memastikan model dilatih menggunakan data target yang konsisten dan dapat dipertanggungjawabkan, maka label baru digunakan sebagai variabel target dalam seluruh tahapan pemodelan selanjutnya.

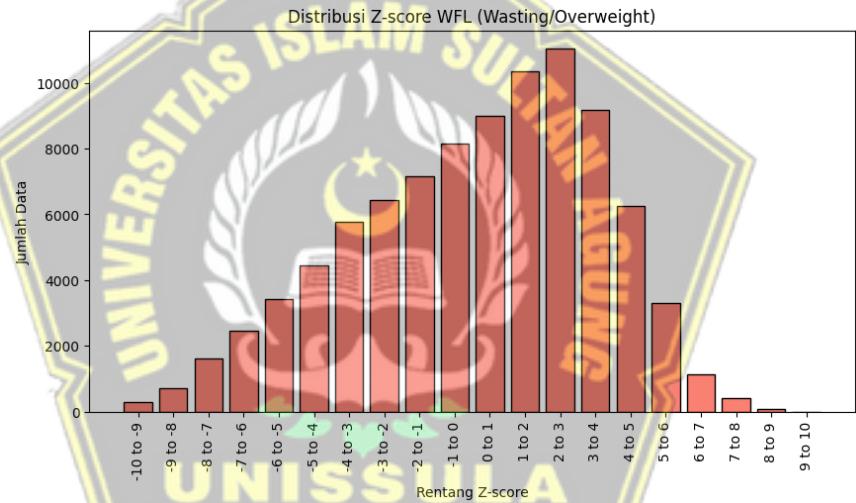
#### 4.1.3 Hasil Pra-pemrosesan Data

Tahap pra-pemrosesan data dilakukan untuk mengubah data menjadi format yang siap digunakan oleh model *machine learning*. Hasil dari setiap tahapan pra-pemrosesan yang telah dilakukan adalah sebagai berikut.

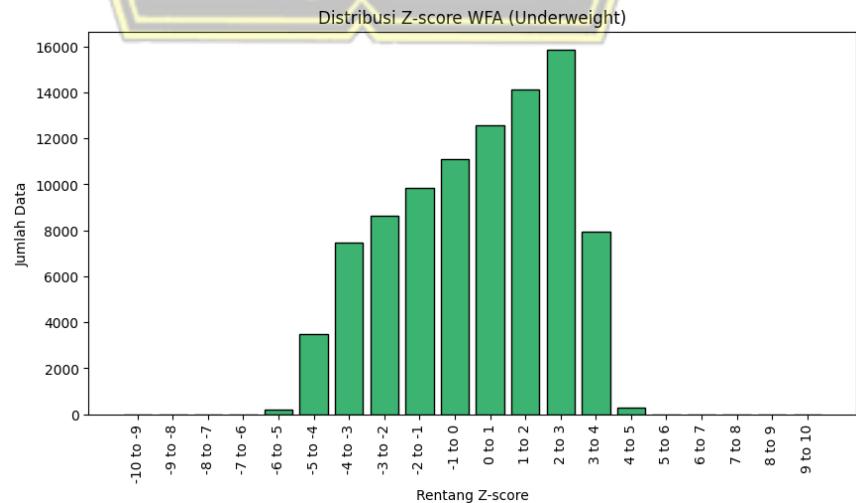
- Penanganan *Outlier z-score*: Nilai *z-score* yang diperoleh dari tahap sebelumnya kemudian disaring untuk menghapus nilai *outlier* pada masing-masing indikator. Distribusi *z-score* pada setiap indikator dijelaskan pada Gambar 4.1, Gambar 4.2, dan Gambar 4.3.



Gambar 4. 1 Distribusi Z-score Length-for-Age (Stunting)



Gambar 4. 2 Distribusi Z-score Weight-for-Length (Wasting/Overweight)



Gambar 4. 3 Distribusi Z-score Weight-for-Age (Underweight)

Gambar 4. 1, Gambar 4.2, dan Gambar 4. 3 menampilkan distribusi nilai *z-score* secara visual untuk masing-masing indikator setelah proses pelabelan data. Dari grafik-grafik tersebut terlihat bahwa data yang digunakan memiliki banyak *outlier*, terutama pada indikator *wasting/overweight* yang menunjukkan nilai *z-score* ekstrem hingga mencapai -10 SD dan +10 SD. Nilai-nilai ini sangat tidak realistik dan tidak menggambarkan kondisi anak-anak dalam kehidupan nyata. Keberadaan *outlier* yang terlalu jauh dari rentang nilai wajar dapat memengaruhi kualitas model dan hasil analisis secara keseluruhan. Oleh karena itu, penelitian ini hanya mempertahankan data dengan nilai *z-score* antara -4 SD hingga +4 SD pada semua indikator, sedangkan nilai di luar rentang tersebut dianggap sebagai *outlier* yang ekstrem dan jarang, sehingga dihapus karena berisiko tinggi mengandung kesalahan pengukuran atau pencatatan serta memiliki potensi bias pada model. Proses penyaringan data ini secara signifikan mengurangi jumlah data dengan menghapus 25.039 baris data sehingga menyisakan data final yang siap untuk pemodelan menjadi 66.480 baris.

- b. Encoding Variabel: Proses encoding pada variabel kategorikal, yaitu Jenis Kelamin dan Status Gizi, berhasil mengubah semua fitur dan target menjadi format numerik, sehingga siap digunakan dalam pemodelan.
- c. Pembagian Data: Dataset final dibagi menjadi data latih dan data uji dengan proporsi 70:30. Pembagian data dilakukan secara terstratifikasi untuk memastikan proporsi setiap kelas tetap seimbang. Dari pembagian data, didapatkan data latih sebanyak 46.536 baris dan data uji sebanyak 19.944 baris. Hasil pembagian data secara rinci dijelaskan dalam tabel berikut:

Tabel 4. 3 Hasil pembagian data indikator *stunting*

Kelas	Data Training	Data Testing	Total
<i>Severely Stunted</i>	2.161	926	3.087
<i>Stunted</i>	6.075	2.604	8.679
Normal	35.679	15.291	50.970
<i>Tall</i>	2.621	1.123	3.744
Total Keseluruhan:			66.480

Tabel 4.3 menunjukkan hasil pembagian data indikator *stunting* ke dalam data latih dan data uji. Dalam tabel tersebut, terlihat bahwa kelas normal mendominasi dengan jumlah 50.970 data, diikuti oleh kelas *stunted* dengan 8.679 data, kelas *tall* dengan 3.744 data, dan kelas *severely stunted* yang memiliki jumlah paling sedikit, yaitu 3.087 data.

Tabel 4. 4 Hasil pembagian data indikator *wasting/overweight*

Kelas	Data Training	Data Testing	Total
<i>Severely Wasted</i>	3.746	1.606	5.352
<i>Wasted</i>	4.439	1.902	6.341
Normal	16.997	7.284	24.281
<i>Risk of Overweight</i>	7.221	3.095	10.316
<i>Overweight</i>	7.691	3.296	10.987
Obese	6.442	2.761	9.203
Total Keseluruhan:			66.480

Tabel 4.4 menyajikan distribusi data latih dan data uji pada indikator *wasting/overweight*. Dari tabel tersebut, kelas dengan jumlah data terbanyak adalah kelas normal dengan total 24.281 data, sedangkan kelas dengan jumlah data paling sedikit adalah *severely wasted* dengan total 5.352 data.

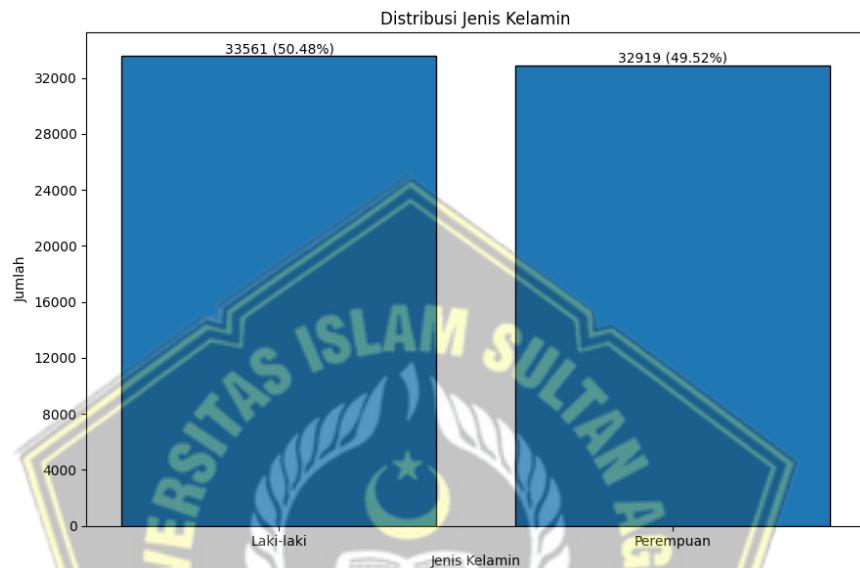
Tabel 4. 5 Hasil pembagian data indikator *underweight*

Kelas	Data Training	Data Testing	Total
<i>Severely Underweight</i>	1.675	718	2.393
<i>Underweight</i>	3.505	1.502	5.007
Normal Weight	22.311	9.562	31.873
<i>Risk of Overweight</i>	19.045	8.162	27.207
Total Keseluruhan:			66.480

Tabel 4.5 menampilkan distribusi data indikator *underweight* ke dalam data latih dan data uji. Kategori dengan jumlah terbesar dalam tabel tersebut adalah *normal weight* dengan 31.873 data, diikuti oleh kelas *risk of overweight* dengan 27.207 data, dan kelas *underweight* dengan 5.007 data. Kelas *severely underweight* memiliki jumlah paling sedikit, yaitu 2.393 data.

#### 4.1.4 Karakteristik Dataset Final

Proses persiapan data yang telah diselesaikan menghasilkan dataset final yang siap dimodelkan dengan total 66.480 baris data. Untuk memberikan gambaran yang komprehensif, karakteristik dataset disajikan melalui visualisasi dan tabel, yang mencakup distribusi jenis kelamin dan statistik deskriptif variabel kontinu.



Gambar 4. 4 Distribusi Jenis Kelamin Dataset Final

Berdasarkan Gambar 4.4, distribusi jenis kelamin pada dataset yang digunakan cukup seimbang, sehingga dapat meminimalisasi potensi bias pada model. Dari total 66.480 data, terdapat 33.561 data (50,48%) berjenis kelamin laki-laki dan 32.919 data (49,52%) berjenis kelamin perempuan.

Tabel 4. 6 Statistik Deskriptif Dataset Final

	Umur (bulan)	Panjang Badan (cm)	Berat Badan (kg)
count	66480	66480	66480
mean	12,893848	74,770159	9,778756
std	6,931854	10,392070	2,915104
min	0	45	2
25%	7	67,9	7,7
50%	13	75,7	9,8
75%	19	82,3	11,9
max	24	97,6	17,2

Tabel 4.6 menyajikan statistik deskriptif dari dataset final. Rata-rata umur anak dalam dataset adalah 12,89 bulan, panjang badan 74,77 cm, serta berat badan 9,78 kg. Nilai minimum dan maksimum untuk setiap variabel juga konsisten dengan rentang karakteristik anak usia 0–24 bulan, yang menegaskan data ini representatif untuk proses pemodelan. Standar deviasi yang cukup besar pada variabel umur (6,93), panjang badan (10,39), dan berat badan (2,92) menunjukkan adanya variasi yang wajar antar anak, yang mencerminkan beragam kondisi pertumbuhan pada rentang usia tersebut.

## 4.2 Hasil Penerapan Model

Proses optimasi *hyperparameter* telah dilakukan menggunakan *Randomized Search* untuk model *LightGBM* dan *Grid Search* untuk model *Decision Tree*, yang dikombinasikan dengan metode *5-fold cross validation*. Dengan berfokus pada metrik *recall\_macro* untuk memastikan performa yang seimbang pada kelas minoritas, kombinasi parameter terbaik yang ditemukan untuk setiap model dirangkum dalam tabel berikut.

Tabel 4.7 *Hyperparameter* Optimal Model *LightGBM*

Parameter	Model 1 <i>Stunting</i>	Model 2 <i>Wasting/Overweight</i>	Model 3 <i>Underweight</i>
<i>n_estimators</i>	600	800	800
<i>learning_rate</i>	0.08	0.05	0.08
<i>max_depth</i>	7	10	5
<i>num_leaves</i>	63	31	31
<i>min_child_samples</i>	200	100	200
<i>subsample</i>	0.8	0.7	0.8
<i>min_split_gain</i>	0.1	0.0	0.0
<i>reg_lambda</i>	1.0	1.0	1.0
<i>subsample_freq</i>	1	1	1

Hasil optimasi pada Tabel 4.7 menunjukkan bahwa setiap model memerlukan konfigurasi *hyperparameter* yang unik. Sebagai contoh, pada parameter *max\_depth*, Model 2 (*Wasting/Overweight*) optimal dengan kedalaman 10, sementara Model 3 (*Underweight*) optimal dengan kedalaman 5. Perbedaan ini

menegaskan bahwa setiap masalah klasifikasi memiliki karakteristik data yang spesifik, yang memerlukan penyesuaian parameter untuk mendapatkan hasil yang maksimal. Selain itu, pengaturan parameter lain seperti *learning\_rate*, *num\_leaves*, dan *subsample* juga menunjukkan perbedaan yang mendalam antara masing-masing model, yang mencerminkan strategi yang berbeda dalam menangani data dan mengoptimalkan performa model.

Tabel 4. 8 *Hyperparameter* Optimal Model *Decision Tree*

Parameter	Model 1 <i>Stunting</i>	Model 2 <i>Wasting/Overweight</i>	Model 3 <i>Underweight</i>
<i>max_depth</i>	12	12	12
<i>min_samples_leaf</i>	10	10	10
<i>min_samples_split</i>	10	10	10

Hasil optimasi pada Tabel 4.8 menunjukkan konfigurasi *hyperparameter* yang identik untuk ketiga model *Decision Tree*. Model secara konsisten menetapkan *max\_depth* pada 12, serta *min\_samples\_leaf* dan *min\_samples\_split* pada 10. Hal ini mengindikasikan bahwa algoritma *Decision Tree* memiliki respons yang stabil dan tidak memerlukan penyesuaian spesifik terhadap karakteristik data pada setiap skenario.

#### 4.3 Hasil Evaluasi Model

Hasil evaluasi model yang ditampilkan adalah evaluasi model utama, yaitu LightGBM yang digunakan untuk mengukur performa model yang telah dilatih menggunakan data latih (*training set*). Evaluasi ini dilakukan pada data uji (*testing set*) dengan jumlah 19.944 baris data yang belum pernah dilihat oleh model sebelumnya. Kinerja model disajikan dalam *Classification Report*, yang mencakup metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score* untuk setiap kelas. Selain itu, kinerja model juga divisualisasikan melalui *Confusion Matrix* sehingga pola klasifikasi yang benar maupun keliru pada masing-masing kelas dapat diamati dengan lebih rinci.

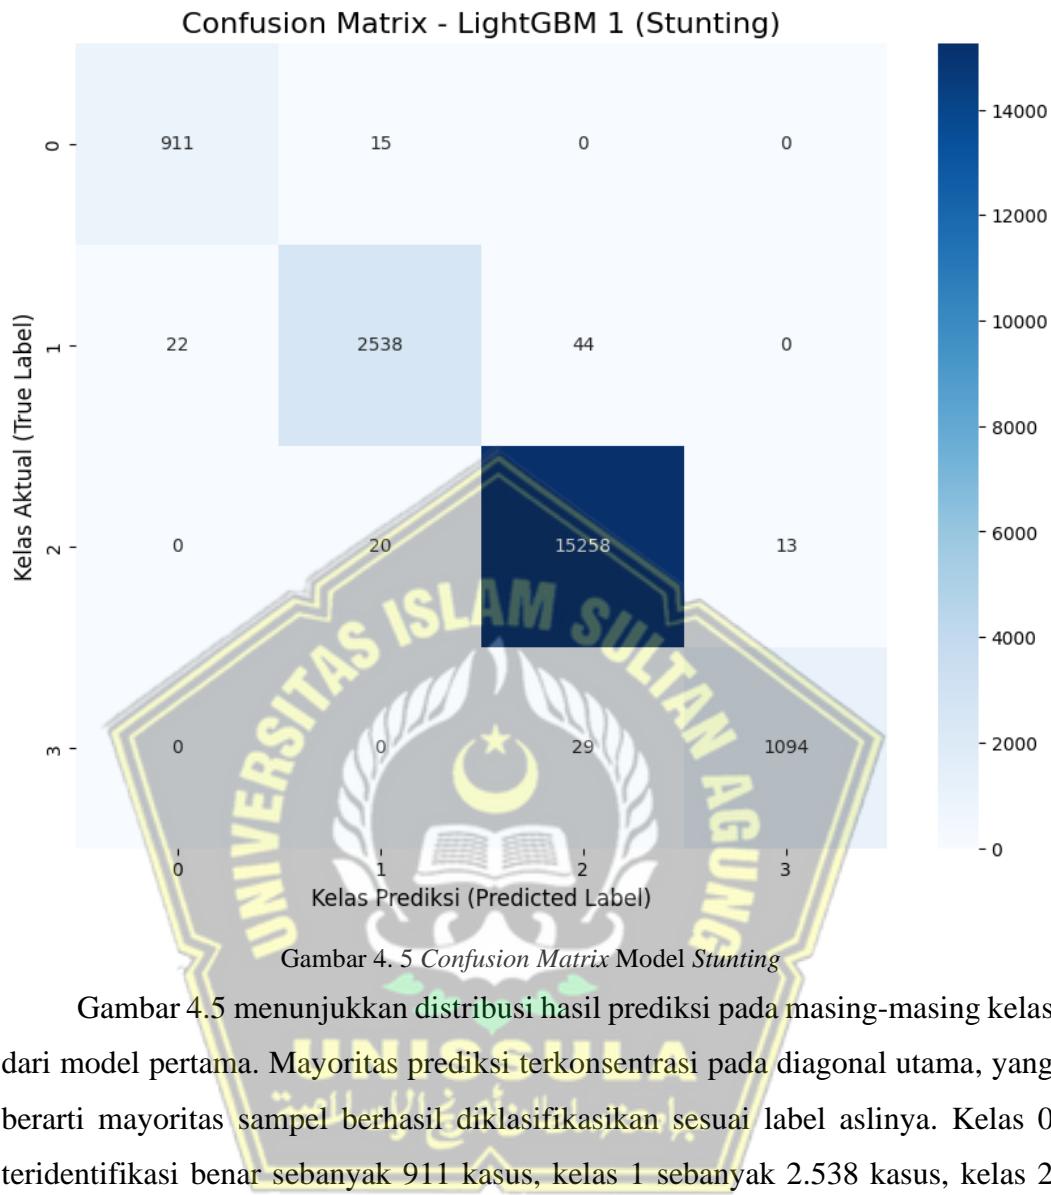
### 4.3.1 Evaluasi Kinerja Model Klasifikasi *Stunting*

Evaluasi pertama dilakukan pada model 1 yang digunakan untuk mengklasifikasikan status *stunting* pada anak. Hasil dari evaluasi ini memberikan gambaran mengenai seberapa efektif model dalam mengenali pola-pola pada data. Evaluasi kinerja model *stunting* disajikan pada tabel berikut.

Tabel 4.9 *Classification Report* Model *Stunting*

	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>	<i>Support</i>
0	0.98	0.98	0.98	926
1	0.99	0.97	0.98	2684
2	1.00	1.00	1.00	15291
3	0.99	0.97	0.98	1123
<b><i>Accuracy</i></b>			0.99	19944
<b><i>Macro avg</i></b>	0.99	0.98	0.98	19944
<b><i>Weighted avg</i></b>	0.99	0.99	0.99	19944

Tabel 4.9 menunjukkan kinerja model pada indikator *stunting* dengan performa yang sangat tinggi dan konsisten antara data latih dan data uji. Berdasarkan hasil evaluasi, algoritma LightGBM memperoleh akurasi 99%. Selisih akurasi yang sangat kecil mengindikasikan bahwa model mampu menggeneralisasi data dengan baik dan minim risiko *overfitting*. Nilai presisi, *recall*, dan *F1-score* untuk setiap kelas juga tinggi, dengan skor mayoritas di atas 0,97. Hal ini mengindikasikan bahwa model mampu mengenali setiap kategori *stunting* dengan sangat baik dan hanya menghasilkan sedikit kesalahan klasifikasi. Kinerja tertinggi terlihat pada kelas 2 (normal) yang memperoleh nilai mendekati 1,00 pada seluruh metrik. Rata-rata *macro* dan *weighted* juga mencapai 0,98-0,99 yang menegaskan konsistensi performa model pada seluruh kelas tanpa bias signifikan terhadap kelas mayoritas.



Gambar 4.5 Confusion Matrix Model Stunting

Gambar 4.5 menunjukkan distribusi hasil prediksi pada masing-masing kelas dari model pertama. Mayoritas prediksi terkonsentrasi pada diagonal utama, yang berarti mayoritas sampel berhasil diklasifikasikan sesuai label aslinya. Kelas 0 teridentifikasi benar sebanyak 911 kasus, kelas 1 sebanyak 2.538 kasus, kelas 2 sebanyak 15.258 kasus, dan kelas 3 sebanyak 1.094 kasus. Kesalahan klasifikasi hanya terjadi dalam jumlah kecil dan terjadi pada kelas yang berdekatan. Misalnya, terdapat 15 kasus dari kelas 0 (*severely stunted*) yang salah diprediksi sebagai kelas 1 (*stunted*) dan 29 kasus dari kelas 3 (*tall*) yang diprediksi sebagai kelas 2 (*normal*). Pola ini menunjukkan bahwa kesalahan terjadi pada batas label yang memiliki nilai  $z$ -score berdekatan, sehingga wajar jika model mengalami sedikit ambiguitas. Secara keseluruhan, hasil ini menegaskan bahwa model mampu mengidentifikasi status *stunting* dengan tingkat akurasi yang sangat tinggi dan memiliki ketahanan yang baik terhadap variasi data.

### 4.3.2 Evaluasi Kinerja Model Klasifikasi *Wasting/Overweight*

Evaluasi kedua dilakukan pada model 2 yang mengklasifikasikan status *wasting* dan *overweight*. Tahap ini menilai kemampuan model dalam menangani variasi kondisi gizi dengan rentang kelas yang lebih beragam. Hasil performa model pada data uji ditampilkan pada tabel di bawah.

Tabel 4. 10 *Classification Report* Model *Wasting/Overweight*

	<b>Precision</b>	<b>Recall</b>	<b>F1-score</b>	<b>Support</b>
0	0.98	0.97	0.97	1606
1	0.96	0.96	0.96	1902
2	0.99	0.99	0.99	7284
3	0.96	0.97	0.97	3095
4	0.97	0.97	0.97	3296
5	0.99	0.98	0.99	2761
<b>Accuracy</b>			0.98	19944
<b>Macro avg</b>	0.98	0.97	0.97	19944
<b>Weighted avg</b>	0.98	0.98	0.98	19944

Tabel 4.10 menampilkan *classification report* untuk model kedua dengan 6 kelas pada indikator *wasting/overweight*. Pada data uji, model memperoleh akurasi sebesar 98%. Meskipun mengalami penurunan akurasi dibandingkan data latih yaitu 99%, selisihnya yang relatif kecil menunjukkan bahwa model mampu mempertahankan kemampuan generalisasi meskipun kompleksitas kelas pada indikator ini lebih tinggi dibanding model sebelumnya. Metrik presisi, *recall*, dan *F1-score* per kelas secara konsisten menunjukkan skor yang tinggi dengan angka di atas 95%, yang mengindikasikan bahwa setiap kategori dapat dikenali dengan baik dengan kesalahan klasifikasi yang relatif rendah. Kualitas prediksi ini juga tercermin pada nilai *macro average* sebesar 0,97 dan *weighted average* sebesar 0,98, yang menunjukkan konsistensi performa model baik pada kelas mayoritas maupun kelas minoritas. Secara keseluruhan, temuan ini menegaskan bahwa LightGBM dapat mengklasifikasikan status *wasting* dan *overweight* dengan akurasi tinggi dan stabil di seluruh kelas.



Gambar 4.6 Confusion Matrix Model Wasting/Overweight

Gambar 4.6 menampilkan *Confusion Matrix* yang memvisualisasikan performa model kedua dalam memprediksi enam kategori pada indikator *wasting/overweight*. Mayoritas nilai berada pada diagonal utama, yang menunjukkan bahwa model mampu mengklasifikasikan sampel dengan akurat untuk setiap kelas. Kesalahan klasifikasi yang muncul umumnya kecil dan terjadi pada kelas yang berdekatan, seperti 38 kasus dari kelas 3 yang diprediksi sebagai kelas 4 dan 55 kasus kelas 4 yang diprediksi sebagai kelas 3. Hal ini terjadi karena nilai *z-score* antar kelas yang berdekatan. Selain itu, terdapat satu kasus kelas 5 yang diprediksi sebagai kelas 3, namun jumlahnya yang sangat kecil tidak terlalu memengaruhi konsistensi prediksi model. Hampir tidak adanya kesalahan prediksi yang melompat jauh (misalnya dari kelas 0 ke kelas 3), mengindikasikan bahwa logika model selaras dengan urutan tingkat status gizi. Secara keseluruhan, matriks ini membuktikan bahwa model memiliki akurasi yang baik sekaligus konsisten dalam membedakan keenam kategori status gizi dari indikator *wasting/overweight*.

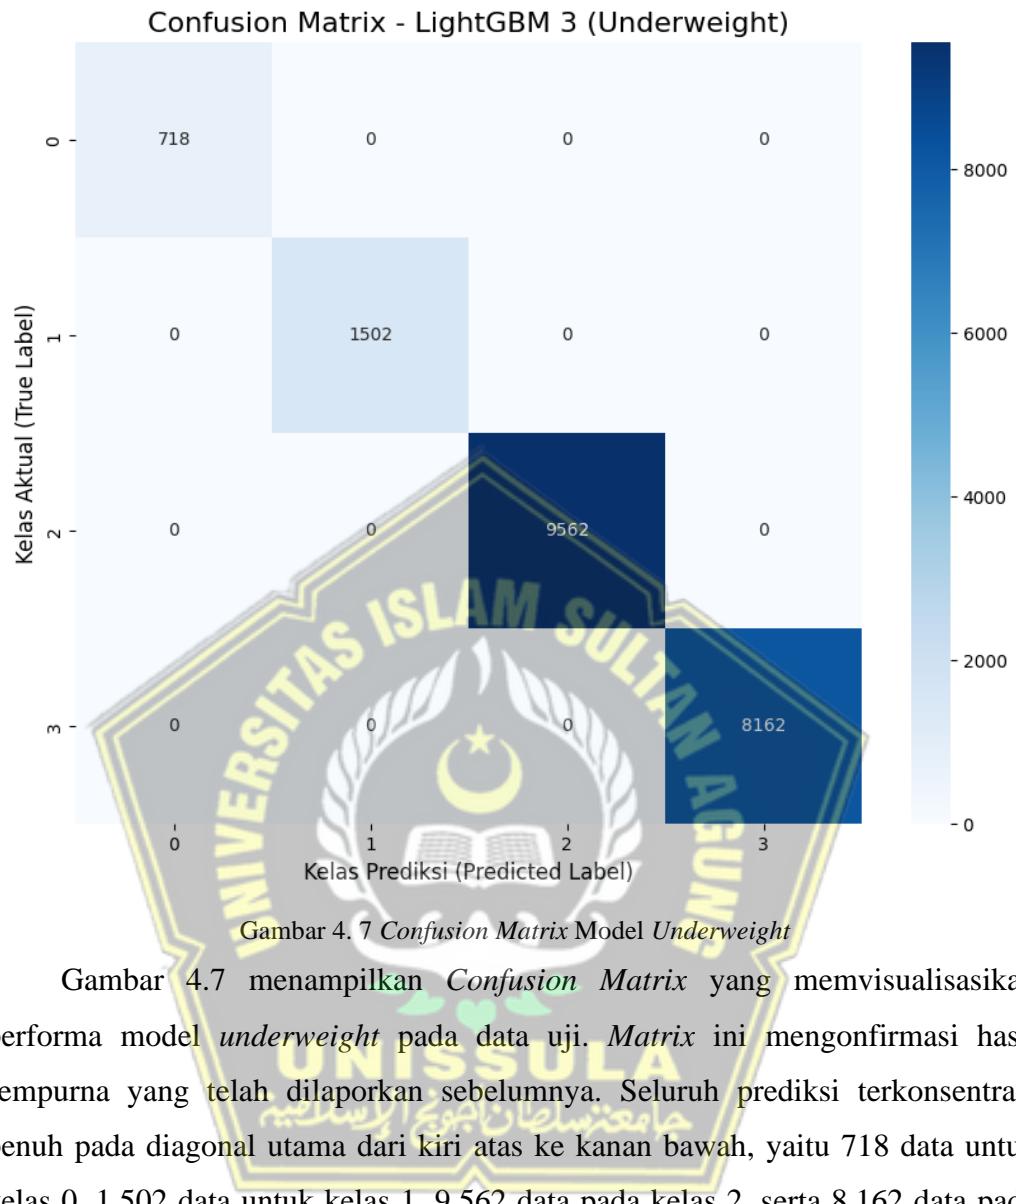
### 4.3.3 Evaluasi Kinerja Model Klasifikasi *Underweight*

Evaluasi terakhir dilakukan pada model 3 yang berfokus pada klasifikasi status *underweight*. Tahap ini bertujuan menilai kemampuan model dalam mengenali kategori berat badan rendah pada anak. Hasil performa model ditampilkan pada tabel berikut.

Tabel 4. 11 *Classification Report* Model *Underweight*

Kelas	Precision	Recall	F1-score	Support
0	1.00	1.00	1.00	718
1	1.00	1.00	1.00	1502
2	1.00	1.00	1.00	9562
3	1.00	1.00	1.00	8162
Accuracy			1.00	19944
Macro avg	1.00	1.00	1.00	19944
Weighted avg	1.00	1.00	1.00	19944

Tabel 4.11 menampilkan laporan klasifikasi model 3 yang digunakan untuk mengklasifikasikan status *underweight* pada data uji. Hasil evaluasi menunjukkan performa sempurna, ditandai dengan akurasi pengujian sebesar 100%. Selain itu, seluruh metrik evaluasi, yaitu presisi, *recall*, dan *F1-score* juga menunjukkan nilai 1.00 untuk semua kelas. Konsistensi skor sempurna ini menunjukkan bahwa model mampu mempelajari hubungan antara variabel *input* dan label target dengan sangat jelas sehingga mampu memprediksi seluruh sampel tanpa kesalahan satupun. Kondisi ini mencerminkan adanya pemisahan kelas yang sangat tegas dalam dataset *underweight*, yang memungkinkan model mengenali karakteristik masing-masing kategori secara deterministik. Dengan demikian, hasil evaluasi ini menunjukkan efektivitas LightGBM dalam mengolah data status gizi, tetapi juga menegaskan bahwa struktur dataset *underweight* mendukung performa model yang stabil dan sangat akurat.



Gambar 4. 7 Confusion Matrix Model Underweight

Gambar 4.7 menampilkan *Confusion Matrix* yang memvisualisasikan performa model *underweight* pada data uji. *Matrix* ini mengonfirmasi hasil sempurna yang telah dilaporkan sebelumnya. Seluruh prediksi terkonsentrasi penuh pada diagonal utama dari kiri atas ke kanan bawah, yaitu 718 data untuk kelas 0, 1.502 data untuk kelas 1, 9.562 data pada kelas 2, serta 8.162 data pada kelas 3, tanpa ada satupun nilai di luar diagonal. Kondisi ini menunjukkan bahwa seluruh sampel pada data uji dapat diklasifikasikan dengan tepat oleh model, sehingga akurasi yang diperoleh menjadi sempurna. Ketiadaan kesalahan prediksi menegaskan bahwa pemisahan antar kelas pada dataset *underweight* terbaca sangat jelas oleh model, sehingga setiap kategori dapat dikenali secara deterministik. Kondisi ini menunjukkan bahwa hubungan antara fitur dan label memiliki struktur yang kuat, yang memungkinkan model mencapai performa sempurna pada seluruh kelas.

#### 4.3.4 Perbandingan Kinerja Model LightGBM dan *Decision Tree*

Setelah mengevaluasi model *LightGBM* secara menyeluruh, dilakukan perbandingan metrik kinerja dengan model pembanding, yaitu *Decision Tree*. Perbandingan ini dilakukan dengan menggunakan versi terbaik dari masing-masing model yang telah dioptimalkan melalui proses *hyperparameter tuning* pada himpunan data uji yang sama. Tujuannya adalah untuk memperkuat justifikasi pemilihan model serta memastikan bahwa *LightGBM* merupakan metode yang unggul untuk tugas klasifikasi status gizi anak. Perbandingan antara kedua model dan ketiga indikator ditampilkan pada tabel 4.12

Tabel 4. 12 Perbandingan model *LightGBM* dengan model *Decision Tree*

Indikator	Model	Akurasi	Presisi	Recall	F1-score
<i>Stunting</i>	<i>LightGBM</i>	99.28%	0.99	0.98	0.98
	<i>Decision Tree</i>	97.72%	0.96	0.94	0.95
<i>Wasting/Overweight</i>	<i>LightGBM</i>	97.83%	0.98	0.97	0.97
	<i>Decision Tree</i>	93.21%	0.93	0.92	0.92
<i>Underweight</i>	<i>LightGBM</i>	100%	1.00	1.00	1.00
	<i>Decision Tree</i>	98.73%	0.97	0.95	0.96

Berdasarkan Tabel 4.12, hasil perbandingan menunjukkan bahwa model *LightGBM* secara konsisten mengungguli model *Decision Tree* pada seluruh indikator status gizi. Pada klasifikasi *Stunting*, *LightGBM* mencapai akurasi 99,28%, lebih tinggi dibandingkan *Decision Tree* yang akurasinya sebesar 97,72%. Keunggulan serupa juga terlihat pada indikator *Wasting/Overweight*, di mana *LightGBM* mencapai akurasi 97,83% sementara *Decision Tree* hanya mencapai 93,21%. Bahkan pada indikator *Underweight*, yang memiliki struktur data paling jelas, *LightGBM* tetap unggul dengan akurasi sempurna 100%. Perbedaan ini mengindikasikan bahwa *LightGBM* mampu mempelajari pola data secara lebih efektif dan stabil dibandingkan *Decision Tree*, sehingga menjadikannya model yang lebih sesuai untuk tugas klasifikasi status gizi anak.

#### 4.4 Analisis Penelitian

Hasil evaluasi menunjukkan bahwa model yang dikembangkan dengan algoritma *LightGBM* mampu mencapai performa yang sangat tinggi pada seluruh indikator status gizi. Kinerja ini dipengaruhi oleh dua faktor utama, yaitu karakteristik dataset serta kemampuan algoritma dalam mempelajari struktur data. Dataset yang digunakan berasal dari platform Kaggle dengan label yang dihitung secara matematis melalui rumus *z-score*, sehingga hubungan antara fitur dan target menjadi sangat jelas, minim noise, dan mudah dipelajari oleh model berbasis pohon keputusan. Kondisi tersebut membuat algoritma seperti *Decision Tree* dan terutama *LightGBM* dapat membentuk pemisahan kelas dengan efisien.

Perbandingan dengan model pembanding memperlihatkan konsistensi keunggulan *LightGBM* atas *Decision Tree*. Mekanisme *boosting* yang menggabungkan banyak pohon memungkinkan *LightGBM* menghasilkan batas keputusan yang lebih halus dan stabil, sehingga mampu menangkap variasi data yang tidak dapat dipetakan oleh satu pohon tunggal. Analisis *Confusion Matrix* memperkuat temuan tersebut, karena kesalahan prediksi yang muncul dalam indikator *Stunting* dan *Wasting/Overweight* hanya terjadi pada kelas yang berdekatan secara ordinal. Sementara itu, pada indikator *Underweight* model bahkan mencapai akurasi sempurna, mengindikasikan pola hubungan fitur-target yang sangat deterministik pada dataset tersebut.

Meskipun hasil yang diperoleh sangat baik, penting untuk menegaskan bahwa performa tersebut bersifat spesifik pada karakteristik data yang digunakan. Akurasi tinggi lebih mencerminkan struktur pola data yang teratur dan mudah dipisahkan oleh algoritma berbasis *boosting*. Dengan demikian, model *LightGBM* pada penelitian ini dapat dipandang sebagai bukti awal (*proof-of-concept*) yang menunjukkan bahwa pendekatan *boosting* mampu menangkap pola tersebut dengan sangat efektif pada kondisi data terkontrol. Konsistensi performa pada seluruh indikator juga menunjukkan bahwa model berhasil membangun representasi keputusan yang kuat dan tidak mudah terpengaruh oleh variasi minor dalam data, sehingga memberikan dasar yang meyakinkan untuk pengembangan model lanjutan pada data yang lebih kompleks atau bersifat *real-world*.

## 4.5 Hasil Implementasi Sistem

Sebagai tahap akhir penelitian, setiap model *LightGBM* yang telah divalidasi dan menunjukkan performa terbaik diimplementasikan ke dalam sebuah sistem aplikasi berbasis *website*. Implementasi ini bertujuan untuk mendemonstrasikan pemanfaatan model sebagai alat bantu skrining status gizi yang mudah diakses dan praktis digunakan. Bagian ini menyajikan hasil dari pengembangan sistem tersebut, meliputi tampilan antarmuka pengguna serta alur fungsionalitas yang mendukung proses prediksi secara menyeluruh.

### 4.5.1 Antarmuka Pengguna (User Interface)

#### Sistem Prediksi Status Gizi Baduta (0-24 Bulan)

Silakan masukkan data anak berikut:

Gambar 4. 8 Tampilan Utama Website

Gambar 4.8 merupakan tampilan utama pada aplikasi *website* yang telah dikembangkan. Halaman ini menyediakan formulir *input* yang terdiri dari empat parameter utama untuk prediksi status gizi anak, yaitu Jenis Kelamin, Umur (bulan), Panjang Badan (cm), dan Berat Badan (kg). Setiap kolom telah dilengkapi dengan nilai awal atau nilai default untuk memudahkan pengguna dalam melakukan pengisian. Pada bagian bawah, disertakan catatan mengenai prosedur standar pengukuran panjang badan bagi anak usia 0-24 bulan untuk memastikan data yang dimasukkan sesuai kaidah antropometri. Setelah seluruh data terisi, proses prediksi dapat dilakukan dengan menekan tombol “Prediksi”.

## 4.5.2 Tampilan Hasil Prediksi

### Sistem Prediksi Status Gizi Baduta (0-24 Bulan)

Silakan masukkan data anak berikut:

Jenis Kelamin

Laki-laki

Panjang Badan (cm)

68.0

Umur (bulan)

4

Berat Badan (kg)

7.0

**Catatan:** Untuk anak usia  $\leq 24$  bulan, pengukuran dilakukan dengan posisi **terlentang**. Jika diukur dalam posisi **berdiri**, hasil pengukuran perlu ditambah 0,7 cm agar sesuai standar.

**Prediksi**

**Hasil Prediksi**

**Status Stunting**

normal

**Status Wasting / Overweight**

gizi baik

**Status Underweight**

berat badan normal

Gambar 4.9 Tampilan Hasil Klasifikasi Sistem

Gambar 4.9 menampilkan hasil klasifikasi yang muncul setelah pengguna mengisi seluruh data dan menekan tombol prediksi pada aplikasi. Sistem menampilkan hasil untuk ketiga indikator status gizi secara terpisah dan jelas pada bagian “Hasil Prediksi”, sehingga informasi masing-masing kategori dapat dibaca dengan cepat dan jelas. Tampilan ini dirancang agar pengguna memperoleh ringkasan informasi yang mudah dipahami, sehingga hasil skrining awal dapat diinterpretasikan dengan mudah tanpa adanya kesulitan. Selain memberikan kejelasan visual, bagian ini juga menunjukkan bagaimana model memproses *input* pengguna secara *real time* dan mengembalikan hasil dalam format yang informatif. Implementasi ini membuktikan bahwa model LightGBM dapat diintegrasikan dengan baik ke dalam aplikasi web yang praktis, sekaligus memenuhi tujuan penelitian untuk menghasilkan sistem pendukung skrining status gizi yang mudah diakses dan ramah pengguna.

#### 4.6 Pengujian Sistem

Pengujian sistem dilakukan untuk memastikan bahwa aplikasi prediksi status gizi berfungsi sesuai dengan tujuan pengembangannya. Metode yang digunakan adalah *Black Box Testing*, yang memfokuskan pengujian pada kesesuaian *input* dan *output* sistem tanpa memperhatikan struktur kode internalnya. Pengujian dilakukan melalui beberapa skenario untuk mengevaluasi respons sistem terhadap berbagai kondisi masukan, termasuk *input* valid, *input* tidak valid, serta kondisi batas. Pengujian ini bertujuan untuk memverifikasi bahwa seluruh komponen aplikasi, mulai dari akses halaman, formulir *input*, proses prediksi, hingga tampilan hasil dapat berjalan dengan benar dan sesuai dengan harapan. Ringkasan hasil pengujian ditampilkan pada Tabel 4.13

Tabel 4. 13 Pengujian Fungsionalitas

<i>Input</i>	Kasus Pengujian	<i>Output</i> yang Diharapkan	Hasil Aktual	Kesimpulan
Link Aplikasi	Mengakses link aplikasi	Halaman utama aplikasi tampil dengan benar	Sesuai	Berfungsi
Form Data	Memasukkan data pada setiap kolom	Semua kolom terisi sesuai dengan <i>input</i> pengguna	Sesuai	Berfungsi
Tombol “Prediksi”	Menekan tombol setelah semua form terisi data valid	Hasil prediksi muncul dengan baik	Sesuai	Berfungsi
	Menekan tombol dengan data di bawah angka minimum	Sistem menampilkan pesan <i>error</i> validasi	Sesuai	Berfungsi
	Menekan tombol dengan data di atas angka maximum	Sistem menampilkan pesan <i>error</i> validasi	Sesuai	Berfungsi

<i>Input</i>	Kasus Pengujian	<i>Output</i> yang Diharapkan	Hasil Aktual	Kesimpulan
Tombol “Prediksi”	Menekan tombol setelah menghapus nilai default pada kolom tertentu	Sistem mengembalikan nilai default pada kolom kosong	Sesuai	Berfungsi
Tampilan Hasil	Mengecek hasil klasifikasi ketiga indikator setelah prediksi berhasil	Menampilkan hasil klasifikasi ketiga indikator yang jelas dan mudah dibaca	Sesuai	Berfungsi

Tabel 4.13 menunjukkan bahwa seluruh komponen utama aplikasi berfungsi sesuai dengan yang diharapkan. Akses melalui link aplikasi berhasil menampilkan halaman utama dengan benar, menandakan bahwa sistem dapat dijalankan tanpa kendala. Formulir *input* dapat menerima data pengguna dengan baik, dan setiap kolom mampu menampilkan nilai sesuai masukan. Tombol “Prediksi” juga berfungsi dengan baik pada berbagai macam skenario pengujian, baik ketika pengguna memasukkan data valid, data melewati batas minimum atau maksimum, maupun saat terdapat kolom yang dibiarkan kosong sehingga sistem secara otomatis mengisi nilai default. Pada kondisi *input* tidak valid, sistem menampilkan pesan error validasi, sedangkan pada kolom kosong sistem mengisi nilai default sesuai desain. Selain itu, tampilan hasil klasifikasi muncul dengan jelas setelah proses prediksi berhasil dilakukan. Secara keseluruhan, seluruh skenario pengujian menunjukkan hasil yang sesuai, sehingga dapat disimpulkan bahwa aplikasi berjalan stabil dan seluruh fungsi utamanya telah beroperasi dengan baik.

## **BAB V**

### **KESIMPULAN DAN SARAN**

#### **5.1 Kesimpulan**

Penelitian ini berhasil mengembangkan dan mengevaluasi sistem klasifikasi status gizi anak di bawah dua tahun (baduta) menggunakan algoritma *Light Gradient Boosting Machine* (LightGBM), berdasarkan standar antropometri yang telah dihitung ulang menggunakan rumus *z-score* dari WHO dan diklasifikasikan sesuai Peraturan Menteri Kesehatan Republik Indonesia Nomor 2 Tahun 2020. Berdasarkan tahapan penelitian, hasil pemodelan, evaluasi, dan implementasi yang telah dilakukan, dapat ditarik beberapa kesimpulan utama:

1. Dataset awal yang berjumlah 100.000 data berhasil diproses menjadi 66.480 data final yang valid melalui tahapan pembersihan data, perhitungan ulang *z-score* dengan metode *Lambda-Mu-Sigma* (LMS), dan pelabelan ulang kategori status gizi (*stunting*, *wasting/overweight*, dan *underweight*) sesuai dengan ambang batas PMK No. 2 Tahun 2020. Proses ini menghasilkan dataset target yang lebih konsisten dan stabil untuk pemodelan.
2. Algoritma LightGBM yang diimplementasikan menghasilkan performa yang sangat tinggi pada data uji dengan akurasi 99,28% pada *stunting*, 97,83% pada *wasting/overweight*, dan 100% pada *underweight*.
3. Secara konsisten, model LightGBM mengungguli model pembanding *Decision Tree* pada seluruh indikator gizi. Hal ini menegaskan efektivitas LightGBM sebagai metode ensemble boosting dalam menangani data antropometri yang kompleks dan memastikan akurasi prediksi yang andal.
4. Implementasi model LightGBM ke dalam aplikasi web menggunakan streamlit berhasil dilakukan, dan seluruh fungsionalitas sistem telah teruji dan berjalan dengan baik dan stabil berdasarkan hasil *Black Box Testing*.

## 5.2 Saran

Berdasarkan hasil penelitian dan keterbatasan yang ditemukan, terdapat saran dari penulis yang dapat menjadi acuan pada penelitian selanjutnya adalah:

1. Penelitian selanjutnya disarankan untuk menggunakan dataset riil atau lebih beragam guna menilai performa pada kondisi dunia nyata dan meningkatkan kemampuan generalisasi.
2. Penelitian lanjutan disarankan untuk menggabungkan algoritma LightGBM dengan algoritma yang lain untuk menemukan akurasi terbaik serta mengeksplorasi pendekatan yang lebih kompleks sehingga tidak hanya terbatas pada klasifikasi.



## DAFTAR PUSTAKA

- Alfarizi, M.R.S., Al-farish, M.Z., Taufiqurrahman, M., Ardiansah, G., Elgar, M., 2023. Penggunaan Python sebagai Bahasa Pemrograman untuk Machine Learning dan Deep Learning. *Karimah Tauhid* 2, 1–6.
- Avindharin, P.D., Hikmah, A.N., Nasrianti, C.S., 2024. Hubungan Antara Berat Badan Lahir Dan Kejadian Underweight Usia 0-60 Bulan Di Kelurahan Bugel, Karawaci. *JUMAGI (Jurnal Madani Gizi Indonesia)* 1, 15–21.
- Azahra, G.S., Kartikasari, M.D., 2025. Child Stunting Classification using the LightGBM Method: A Case Study in the Rowosari District of Kendal, Central Java. *J. Math. Comput. Stat.* 8, 102–113.
- Badan Kebijakan Pembangunan Kesehatan, 2025. Survei Status Gizi Indonesia (SSGI) 2024, Badan Kebijakan Pembangunan Kesehatan, Kementerian Kesehatan RI. Jakarta.
- Badan Perencanaan Pembangunan Nasional, 2025. Rencana Pembangunan Jangka Menengah Nasional (RPJMN) 2025–2029. Jakarta.
- Bahar, M.A., Galistiani, G.F., Eliyanti, U., Mohi, A.R., 2024. Gambaran Nilai Utilitas Kesehatan Anak dengan Malnutrisi : Studi pada Kasus Stunting, Wasting, dan Underweight di Indonesia. *J. Mandala Pharmacon Indones.* 10, 610–617.
- Fitriiani, A., Pramesona, B.A., Nareswari, S., 2023. Obesitas pada Anak : Penyebab dan Konsekuensi Jangka Panjang. *Medula* 13, 104–109.
- Hanifa, Sholihin, A., Ayudya, F., 2023. Peran AI Terhadap Kinerja Industri Kreatif Di Indonesia. *J. Compr. Sci.* 2, 2159–2170.
- Hardjito, K., Sendra, E., Antono, S.D., 2024. Optimalisasi Peran Ibu dalam Mencegah Wasting pada Balita melalui Pendampingan Berbasis Komunitas. *Heal. J. Inov. Ris. Ilmu Kesehat.* 3, 115–121.
- Hidayat, F.M., Kusrini, Yaqin, A., 2024. Penerapan Algoritma Naïve Bayes Classifier Untuk Klasifikasi Status Gizi Stunting Pada Balita. *Dielektr. – J. Ilm. Kaji. Teor. dan Apl. Tek. Elektro* 11, 107–118.
- Insany, G.P., Yustiana, I., Rahmawati, S., 2023. Penerapan KNN dan ANN pada

- klasifikasi status gizi balita berdasarkan indeks antropometri. *J. CoSciTech (Computer Sci. Inf. Technol.* 4, 385–393.
- Kementerian Kesehatan Republik Indonesia, 2020. Peraturan Menteri Kesehatan Republik Indonesia Nomor 2 Tahun 2020 tentang Standar Antropometri Anak. Jakarta.
- Laily, L.A., Indarjo, S., 2023. Literature Review: Dampak Stunting terhadap Pertumbuhan dan Perkembangan Anak. *HIGEIA (Journal Public Heal. Res. Dev.* 7, 354–364.
- Latifah A, N., Fajrini, F., Romdhona, N., Herdiansyah, D., Eryansih, Suherman, 2024. Systematic Literature Review : Stunting pada Balita di Indonesia dan Faktor yang Mempengaruhinya. *Kedokt. dan Kesehat.* 20, 55–73.
- Lonang, S., Yudhana, A., Biddinika, M.K., 2023. Analisis Komparatif Kinerja Algoritma Machine Learning untuk Deteksi Stunting. *J. MEDIA Inform. BUDIDARMA* 7, 2109.
- Nisa, K., 2024. Klasifikasi Penyakit Gangguan Mental dengan Algoritma LightGBM [WWW Document]. *J. Ris. Sist. Inf. Dan Tek. Inform.* URL <https://tunasbangsa.ac.id/ejurnal/index.php/jurasik>
- Pahlevi, O., Wulandari, D.A.N., Rahayu, L.K., Leidiyana, H., Handrianto, Y., 2024. Model Klasifikasi Risiko Stunting Pada Balita Menggunakan Algoritma CatBoost Classifier 6, 414–421.
- Rizky, P.S., Hirzi, R.H., Hidayaturrohman, U., 2022. Perbandingan Metode LightGBM dan XGBoost dalam Menangani Data dengan Kelas Tidak Seimbang, *J Statistika.*
- Rufo, D.D., Debelee, T.G., Ibenthal, A., Negera, W.G., 2021. Diagnosis of Diabetes Mellitus Using Gradient Boosting Machine (LightGBM). *Diagnostics* 11, 1714.
- Setyoningsih, D., 2024. Malnutrisi pada Anak di Bawah Lima Tahun dan Pemberian Suplementasi Mikronutrien. *J. Keperawatan GSH* 13, 46–55.
- Thurstans, S., Sessions, N., Dolan, C., Sadler, K., Cichon, B., Isanaka, S., Roberfroid, D., Stobaugh, H., Webb, P., Khara, T., 2022. The relationship between wasting and stunting in young children: A systematic review. *Matern.*

Child Nutr. 18.

UNICEF, WHO, World Bank Group, 2023. Levels and trends in child malnutrition:

Key finding of the 2023 edition.

WHO, 2006. WHO Child Growth Standards, Developmental Medicine & Child

Neurology.

