

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1 Penelitian Yang Relevan**

Pada bagian ini, penulis melakukan kajian terhadap penelitian-penelitian terdahulu yang relevan dengan klasifikasi status gizi balita menggunakan pendekatan machine learning. Kajian ini bertujuan untuk memperoleh gambaran mengenai metode, dataset, algoritma, serta hasil yang telah dicapai oleh peneliti sebelumnya, sekaligus juga mengidentifikasi celah penelitian (research gap) yang belum terjawab secara optimal.

Penelitian Pertama, “Klasifikasi Status Gizi Balita dengan Algoritma K-Nearest Neighbor (KNN) di Puskesmas Cakranegara”. Isi penelitian ini yaitu tentang bagaimana membangun sebuah sistem berbasis komputer untuk menentukan penelitian ini status gizi balita menggunakan metode KNN dengan variabel input umur, jenis kelamin, dan berat badan. Sistem dikembangkan dengan model waterfall, menggunakan PHP dan MySQL sebagai basis implementasi. Berdasarkan hasil pengujian terhadap 134 data balita, sistem ini mampu menghasilkan tingkat akurasi sebesar 88,06%, dengan recall gizi buruk sebesar 70%, recall gizi kurang 57,89%, dan recall gizi baik 95,24%. Temuan ini membuktikan bahwa algoritma KNN cukup efektif untuk klasifikasi status gizi balita, meskipun disarankan menambahkan parameter tinggi badan untuk penelitian selanjutnya. (Yunus & Pratiwi, 2023).

Penelitian Kedua, “Aplikasi Naïve Bayes Classifier (NBC) pada Klasifikasi Status Gizi Balita Stunting dengan Pengujian K-Fold Cross Validation”. Penelitian ini dilakukan untuk mengatasi permasalahan stunting yang masih tinggi di Indonesia dengan memanfaatkan algoritma klasifikasi Naïve Bayes. Data yang digunakan berasal dari Puskesmas Padangsari, Semarang, ada sebanyak 1066 data balita, dengan variabel usia, tinggi badan, berat badan, jenis kelamin dan lingkaran lengan atas. Metode yang digunakan adalah Naïve Bayes Classifier dengan 10-Fold Cross Validation, serta pengolahan data dilakukan menggunakan GUI-R (RStudio Shiny Package). Hasil penelitian menunjukkan bahwa akurasi tertinggi tercapai pada iterasi

ke-8 dengan nilai 95,14%, sementara akurasi terendah pada iterasi ke-3 sebesar 81,73%. Secara keseluruhan, rata-rata akurasi tiap iterasi adalah 88,53%. Evaluasi performa juga menunjukkan nilai presisi kelas normal 100%, recall 97,59%, dan F1-Score 98,78%, sehingga disimpulkan bahwa Naïve Bayes cukup andal dalam mengklasifikasi status gizi balita stunting dan dapat digunakan untuk klasifikasi data baru dengan variabel serupa. (Rizqi Robbi Arisandi et al., 2022).

Penelitian Ketiga, “Pemantauan Kesehatan Balita melalui Pemanfaatan Aplikasi Becat Beleg dalam Program Pengabdian Kepada Masyarakat”. Penelitian yang dilakukan oleh Zaetun dkk. (2025) ini berfokus pada digitalisasi dan berangkat dari masalah pencatatan kesehatan ibu hamil dan balita yang masih dilakukan secara manual, sehingga rentan terhadap keterlambatan data dan sulitnya dipantau secara akurat. Kemudian mereka memperkenalkan aplikasi Becat Beleg berbasis Android yang digunakan untuk mencatat hasil pemeriksaan posyandu, seperti tinggi dan berat badan balita, sekaligus membantu mendeteksi dini risiko stunting. Melalui aplikasi Becat Beleg hasil kegiatan menunjukkan kader posyandu menjadi lebih terampil dalam menggunakan aplikasi. Program ini dilaksanakan di Lombok Barat dengan melibatkan pelatihan kader posyandu, pemeriksaan kesehatan ibu hamil (Hb dan LILA), serta pendampingan selama dua bulan. Hasilnya, kader menjadi lebih terampil menggunakan aplikasi digital, kesehatan ibu hamil dengan anemia membaik berkat edukasi dan bantuan makanan, serta proses pemantauan tumbuh kembang balita menjadi lebih sistematis. Penelitian ini menunjukkan inovasi digital dapat mendukung program percepatan penurunan stunting di masyarakat. (Anggit et al., 2025).

Penelitian Keempat, “Klasifikasi Status Gizi Balita Menggunakan Algoritma Random Forest dan Feature Selection Relief-F”. Penelitian ini menggunakan data balita dengan berbagai macam variable seperti usia, tinggi badan, berat badan, jenis kelamin, asupan gizi, serta faktor sosial ekonomi dengan sampel antara 200–500 data balita. Penelitian ini bertujuan untuk mengembangkan model klasifikasi status gizi balita dengan memanfaatkan algoritma Random Forest yang dipadukan dengan teknik pemilihan fitur Relief-F. Relief-F digunakan untuk memilih fitur yang paling relevan, sehingga model menjadi lebih efisien dan akurat. Hasil penelitian menunjukkan bahwa kombinasi Random Forest dengan Relief-F mampu

menghasilkan performa klasifikasi yang lebih baik dibandingkan metode tanpa pemilihan fitur, dengan evaluasi metrik akurasi, precision, recall, dan F1-score yang tinggi. Model ini terbukti efektif untuk klasifikasi status gizi balita menjadi gizi baik, gizi buruk, dan gizi lebih. (Mahardika & Raihanah, 2025).

Penelitian Kelima, “Pengembangan Sistem Klasifikasi Status Gizi Balita Berbasis Website Menggunakan Metode Random Forest di Posyandu Kumis Kucing”. Penelitian yang dilakukan oleh Muhammad & Nudin (2025) ini menggunakan data dari Bangladesh Demographic and Health Survey (BDHS) 2014 serta data lokal. Penelitian ini mencoba menghadirkan Solusi digital berupa suatu Sistem berbasis web yang memanfaatkan algoritma Random Forest. dikembangkan menggunakan framework Laravel dan database PostgreSQL, dengan model Random Forest yang dioptimalkan melalui RandomSearchCV serta validasi K-Fold Cross Validation. Hasil pengujian menunjukkan model memiliki akurasi yang tinggi, yakni 97,7% untuk stunting, 97,4% untuk wasting, dan 97,9% untuk underweight, setelah melalui optimasi hyperparameter dengan RandomSearchCV dan validasi K-Fold Cross Validation. Penelitian ini telah membuktikan bahwa integrasi machine learning dengan sistem berbasis web dapat membantu deteksi dini masalah gizi secara praktis dan efisien. .

Penelitian Keenam, “Implementasi Metode Naïve Bayes Classifier untuk Klasifikasi Status Gizi Stunting pada Balita”. Penelitian yang dilakukan oleh Titimeidara & Hadikurniawati (2021) ini menggunakan data balita dari Puskesmas Pandanaran, Semarang, untuk mengklasifikasikan status gizi stunting. Algoritma Naive Bayes dipilih karena sederhana dan efektif dalam menangani data berukuran besar. Dengan menerapkan algoritma Naïve Bayes, hasil pengujian menunjukkan akurasi 88% dalam klasifikasi stunting. Dengan adanya sistem ini diharapkan dapat membantu tenaga medis mendeteksi anak yang berisiko stunting lebih cepat. (Titimeidara & Hadikurniawati, 2021).

Penelitian Ketujuh, “Enhancing Nutritional Status Prediction through Attention-Based Deep Learning and Explainable AI”. Studi internasional ini memperkenalkan kerangka kerja deep learning dengan pendekatan Multi-Head Attention (MHA) dan Explainable AI (XAI) untuk meningkatkan Tingkat akurasi

sekaligus juga transparansi klasifikasi status gizi pada anak. Penelitian ini menggunakan dataset besar berjumlah 9.605 sampel, dengan variabel antropometri seperti tinggi badan, berat badan, lingkaran lengan atas, serta z-score WHO. Model CNN dengan Multi-Head Attention (CNN-MHA) menghasilkan akurasi 99,08%, sedikit lebih unggul dibandingkan LSTM-MHA yang memperoleh 98,91%. Keunggulan penelitian ini adalah penggunaan Explainable AI (XAI) dengan SHAP, sehingga klasifikasi model lebih transparan dan sesuai standar WHO. Selain itu, perangkat IoT digunakan untuk mengumpulkan data antropometri secara real-time, membuat sistem lebih praktis dan skalabel. (Santoso et al., 2025).

Penelitian Kedelapan, “An Early Prediction Model for Toddler Nutrition Based on Machine Learning from Imbalanced Data”. Penelitian ini berfokus pada klasifikasi status gizi balita menggunakan data rekam medis elektronik (EMR) dengan parameter usia, jenis kelamin, berat, dan tinggi badan. Masalah utama yang mereka hadapi adalah data tidak seimbang (imbalanced dataset), sehingga model cenderung bias ke dalam mayoritas. Sehingga diterapkan metode SMOTE (Synthetic Minority Oversampling Technique) untuk memperbaiki distribusi data agar lebih seimbang. Algoritma yang digunakan meliputi Random Forest (RF), XGBoost, dan Support Vector Machine (SVM). Hasil terbaik diperoleh dari Random Forest + SMOTE dengan akurasi 88,9%, F1-score 84,7%, precision 80%, recall 84,2%, dan ROC-AUC 93%. Hasil ini membuktikan bahwa penanganan data tidak seimbang sangat penting untuk menghasilkan klasifikasi status gizi yang lebih adil. (Miranda et al., 2024).

Penelitian Kesembilan, “Penerapan Algoritma DECISION TREE pada Klasifikasi Status Gizi Balita”. Penelitian ini berfokus dengan memanfaatkan data sekunder dari Puskesmas Janji dan Puskesmas Suka Makmur, dengan adanya 502 data balita. Dipilihnya Algoritma DECISION TREE karena kemampuannya dalam membangun model pohon keputusan yang bisa mudah dipahami, serta dapat menangani variabel numerik maupun diskrit. Dari hasil pengujian menggunakan confusion matrix dengan pembagian data 80:20, lalu diperoleh akurasi sebesar 80%. Temuan ini menunjukkan bahwa algoritma DECISION TREE dapat digunakan untuk membantu tenaga medis dalam mengklasifikasikan status gizi balita dengan lebih

cepat dan akurat, sehingga dapat mendukung intervensi dini terhadap masalah gizi (Ramadhan Nasution et al., n.d.).

Penelitian Kesepuluh, “Analisis Perbandingan Algoritma DECISION TREE dan Random Forest dalam Klasifikasi Status Gizi Balita”. Studi ini berfokus pada perbandingan dua metode populer, yaitu DECISION TREE dan Random Forest, dalam mengolah data antropometri balita. Hasil penelitian menunjukkan bahwa Random Forest unggul dengan akurasi lebih tinggi dibandingkan DECISION TREE. Random Forest dinilai lebih stabil dan mampu mengurangi risiko overfitting karena bekerja dengan menggabungkan banyak pohon keputusan. Sedangkan DECISION TREE, meski interpretasinya lebih mudah, menghasilkan akurasi yang relatif lebih rendah. Penelitian ini menegaskan bahwa pemilihan algoritma sangat mempengaruhi hasil klasifikasi dan Random Forest lebih cocok diterapkan dalam kasus status gizi balita (Ramadhan et al., 2024) .

Penelitian Kesebelas, “Classification of Stunting Status in Toddlers Using Naïve Bayes Method in the City of Madiun Based on Website”. Penelitian ini dilakukan oleh Purnomo & Rozaq (2022) dengan memanfaatkan data antropometri balita dari Dinas Kesehatan Kota Madiun. Sistem dibangun berbasis web menggunakan bahasa pemrograman Python dan framework Flask, dengan metode Naïve Bayes untuk klasifikasi status gizi berdasarkan parameter jenis kelamin, umur, berat badan, dan tinggi badan. Dari hasil pengujian menggunakan confusion matrix, diperoleh nilai akurasi sebesar 58%, precision 68%, dan recall 58%. Hasil ini menunjukkan bahwa meskipun Naïve Bayes dapat diaplikasikan dalam klasifikasi status stunting, performanya masih terbatas dibandingkan algoritma lain yang lebih kompleks. (Rozaq & Purnomo, 2022).

## 2.1.1 Tabel SOTA (State Of The Art)

Tabel 2. 1 Metrik Penelitian

| No | Nama Peneliti                                                                | Judul Penelitian                                                                                                  | Lokasi & Dataset                                                                                      | Metode                         | Fitur Utama                               | GAP                                                                                         | Keterbatasan Utama                                             |
|----|------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------|--------------------------------|-------------------------------------------|---------------------------------------------------------------------------------------------|----------------------------------------------------------------|
| 1. | Muhammad Yunus, Ni Kadek Ari Pratiwi (2023)                                  | Klasifikasi Status Gizi Balita Dengan Algoritma K-Nearest Neighbor (KNN) di Puskesmas Cakranegara                 | Nusa Tenggara Barat, Menggunakan 134 data balita dari puskesmas Cakranegara (umur, jenis kelamin, BB) | KNN                            | Usia, BB, TB, LILA                        | -Ada TB + rasio BB/TB<br>-SMOTE untuk kelas minoritas (gizi buruk 4,7%)                     | -Tanpa TB (hanya BB).                                          |
| 2. | Riza Rizqi Robbi Arisandi, Budi Warsito, Arief Rachman Hakim (2022)          | Aplikasi Naïve Bayes Classifier (NBC) pada Klasifikasi Status Gizi Balita Stunting dengan K-Fold Cross Validation | 1066 data balita dari Puskesmas Padangsari, Semarang (usia, jenis kelamin, BB, TB, LILA)              | Naïve Bayes + 10-Fold          | Usia, BB, TB, LILA                        | -3 kelas sesuai WHO (buruk/baik/lebih)<br>-Fokus pada gizi akut (BB/TB)                     | -Hanya binary (stunting saja)<br>-Tidak multikelas WHO         |
| 3. | Siti Zaetun, Yudha Anggit Jiwantoro, Ersandhi Resnhaleksmana, Suhaema (2025) | Klasifikasi Status Gizi Balita dengan KNN di Puskesmas Cakranegara                                                | Data posyandu di Lombok Barat (Hb ibu hamil, LILA, BB/TB balita)                                      | Aplikasi Android (Becat Beleq) | HB ibu, LILA, BB/TB                       | -Ada model XGBoost untuk klasifikasi otomatis<br>-Bukan hanya pencatatan, tapi deteksi dini | -Tanpa ML(hanya pencatatan)<br>-Tidak ada klasifikasi otomatis |
| 4. | Dzikri Mahardika, Afrahul Naura Raihanah (2025)                              | Klasifikasi Status Gizi Balita Menggunakan Algoritma                                                              | 200–500 data balita (usia, BB, TB, gizi, sosial ekonomi)                                              | Random Forest + Relief-F       | Usia, BB, TB, asupan gizi, sosial ekonomi | Dataset lokal spesifik: 788 data dari 12                                                    | -Dataset tidak jelas lokasinya<br>-Tidak                       |

| No | Nama Peneliti                                                                                                                                                                | Judul Penelitian                                                                                                                                            | Lokasi &<br>Dataset                                                             | Metode                                                    | Fitur Utama                                           | GAP                                                                                                                                                       | Keterbatasan<br>Utama                                                                              |
|----|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------|-----------------------------------------------------------|-------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------|
|    |                                                                                                                                                                              | Random Forest<br>dan Feature<br>Selection<br>Relief-F                                                                                                       |                                                                                 |                                                           |                                                       | desa di<br>Labuapi,<br>Lombok<br>Barat                                                                                                                    | spesifik<br>NTB/Lombok                                                                             |
| 5. | Isa Iman<br>Muhammad,<br>Salamun<br>Rohman<br>Nudin<br>(2025)                                                                                                                | Pengembangan<br>Sistem<br>Klasifikasi<br>Status Gizi<br>Balita Berbasis<br>Website<br>Menggunakan<br>Metode<br>Random Forest<br>di Posyandu<br>Kumis Kucing | BDHS 2014 &<br>data local<br>Posyandu<br>Kumis Kucing<br>(BB/U, TB/U,<br>BB/TB) | Random<br>Forest +<br>Random<br>SearchC<br>V + K-<br>Fold | 3 indikator<br>(stunting/wa<br>sting/under<br>weight) | .100%<br>data lokal<br>Lombok<br>Barat<br>(bukan<br>gabungan<br>BDHS)<b<br>r> Lebih<br>relevan<br>untuk<br>karakterist<br>ik balita<br>NTB                | Dataset<br>dominan<br>Bangladesh<br>(BDHS)<br><br>Kurang<br>representatif<br>untuk populasi<br>NTB |
| 6. | Monica Yoshe<br>Titimeidara,<br>Wiwien<br>Hadikurniawa<br>ti (2021)                                                                                                          | Implementasi<br>Metode Naïve<br>Bayes Classifier<br>Untuk<br>Klasifikasi<br>Status Gizi<br>Stunting Pada<br>Balita                                          | Data Puskesmas<br>Pandanaran,<br>Semarang                                       | Naïve<br>Bayes                                            | -                                                     | Deteksi<br>lengkap<br>gizi buruk<br>dan gizi<br>lebih<br>(overweig<br>ht/obesitas<br>)                                                                    | Hanya fokus<br>stunting <br><br>Tidak deteksi<br>gizi<br>lebih/obesitas                            |
| 7. | Heru Agus<br>Santoso, Nur<br>Setiawati<br>Dewi, Su-<br>Cheng Haw<br>Arga Dwi<br>Pambudi, Sari<br>Ayu<br>Wulandari<br>Cheng Haw<br>Dian<br>Nuswantoro,<br>Arga Dwi<br>Pambudi | Enhancing<br>nutritional<br>status prediction<br>through<br>attention-based<br>deep learning<br>and explainable<br>A                                        | 9605 data (BB,<br>TB, LILA, Z-<br>score WHO, IoT<br>data)                       | CNN-<br>MHA +<br>XAI<br>(SHAP)                            | BB, TB,<br>LILA, Z-<br>score, IoT                     | .-Solusi<br>low-<br>cost**;<br>hanya<br>butuh data<br>antropome<br>tri dasar<br>(BB,<br>TB)<br><br>-Bisa jalan<br>di HP<br>kader<br>posyandu<br>tanpa IoT | -Butuh IoT<br>mahal<br><br>-Tidak<br>feasible untuk<br>posyandu<br>pedesaan                        |

| No  | Nama Peneliti                                                                                                                | Judul Penelitian                                                                                              | Lokasi & Dataset                                                        | Metode                        | Fitur Utama                                      | GAP                                                                                      | Keterbatasan Utama                                                                   |
|-----|------------------------------------------------------------------------------------------------------------------------------|---------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------|-------------------------------|--------------------------------------------------|------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------|
| 8.  | Eka Mirandaa, Mediana Aryunia, Alfi Yusrotis Zakiyyahb, Yulia Ery Kurniawatia, Albert Verasius Dian Sano, Meyske Kumbangsila | An Early Prediction Model for Toddler Nutrition (Imbalanced Data)                                             | Data EMR (usia, gender, BB, TB)                                         | RF, XGBoos t, SVM + SMOTE     | Usia, BB, TB                                     | -Dataset spesifik Lombok Barat**<br>r>-Ada prototipe Streamlit* untuk kader posyandu     | -Dataset tidak spesifik wilayah Indonesia Timur<br>-Tidak ada prototipe implementasi |
| 9.  | Yusuf Ramadhan Nasution, Armansyah, Mhd. Furqan, Toibatur Rahma Matondang                                                    | Penerapan Algoritma DECISION TREE Pada Klasifikasi Status Gizi Balita                                         | 502 data balita dari Puskesmas Janji & Suka Makmur                      | Decisio n Tree DECISI ON TREE | Gizi balita (baik/kurang)                        | -Akurasi rendah (80%)<br>>-Hanya binary                                                  | -Akurasi target >94% (hasil eksperimen Anda: 94,3%)<br>-3 kelas bukan binary         |
| 10. | Ari joko Purnomo, Abdul Rozaq                                                                                                | Classification Of Stunting Status In Toddlers Using Naïve Bayes Method In The City Of Madiun Based On Website | 673 data balita dari Dinas Kesehatan Kota Madiun (gender, umur, BB, TB) | Naïve Bayes                   | Gender, usia, BB, TB                             | -F1-Score Macro 0,972 (lebih adil untuk data imbalance )<br>-SMOTE untuk kelas minoritas | -Akurasi sangat rendah (58%) -Tidak handle imbalance                                 |
| -   | Lalu Muhammad Risgan Nazwa                                                                                                   | PENELITIAN INI                                                                                                | Lombok Barat, 788 data dari 12 desa di Labuapi                          | XGBoos t + SMOTE              | BB, TB, JK, ZS BB/U, ZS TB/U, rasio BB/TB & TB/U | Dataset lokal murni Lombok Barat Feature engineerin g rasio antropome tri +              | -                                                                                    |



| No | Nama Peneliti | Judul Penelitian | Lokasi &<br>Dataset | Metode | Fitur Utama | GAP                                                                       | Keterbatasan<br>Utama |
|----|---------------|------------------|---------------------|--------|-------------|---------------------------------------------------------------------------|-----------------------|
|    |               |                  |                     |        |             | SMOTE<br>Prototipe<br>Streamlit<br>low-cost<br>untuk<br>kader<br>posyandu |                       |

Berdasarkan hasil kajian penelitian terdahulu, penulis mengidentifikasi beberapa kesenjangan penelitian yang menjadi dasar dilakukannya penelitian ini.

1. Penulis menemukan adanya kesenjangan geografis dan kontekstual. Mayoritas penelitian menggunakan dataset dari Jawa (Jakarta, Semarang) atau gabungan BDHS yang dominan data Jawa. Belum ada penelitian komprehensif yang menggunakan dataset lokal spesifik Lombok Barat (788 data dari 12 desa di Kecamatan Labuapi) yang memiliki karakteristik populasi unik Nusa Tenggara Barat dengan prevalensi stunting historis tinggi (32,7% pada 2022).
2. Penulis mengidentifikasi kesenjangan metodologis dalam penanganan ketidakseimbangan kelas/Imbalance. Meskipun Miranda et al. (2024) telah membuktikan efektivitas SMOTE, penelitian mereka tidak mengintegrasikan feature engineering rasio antropometri (BB/TB, TB/U) yang secara klinis relevan untuk membedakan kondisi gizi akut dan kronis. Penelitian ini menggabungkan SMOTE dengan feature engineering untuk meningkatkan generalisasi model pada kelas minoritas (gizi buruk 4,7% dan gizi lebih 4,44%).
3. Penulis menemukan kesenjangan pada aspek implementasi praktis. Pendekatan dengan akurasi sangat tinggi umumnya membutuhkan infrastruktur dan biaya yang tidak sedikit. Penelitian Santoso et al. (2025) mencapai akurasi sangat tinggi (99,08%) tetapi memerlukan infrastruktur IoT mahal yang tidak feasible untuk posyandu pedesaan. Sedangkan penelitian ini mengembangkan prototipe Streamlit berbasis web yang low-cost, hanya membutuhkan data antropometri

dasar (BB,TB) tanpa IoT, sehingga dapat diimplementasikan di daerah terpencil seperti Lombok Barat.

4. Keempat, penulis mengidentifikasi kesenjangan pada pemilihan metrik evaluasi. Banyak penelitian masih mengandalkan akurasi sebagai indikator utama, padahal metrik tersebut kurang representatif pada dataset tidak seimbang. Penelitian ini secara khusus menggunakan F1-score macro sebagai metrik utama untuk memberikan evaluasi yang lebih adil terhadap seluruh kelas.

## **2.2 Landasan Teori**

Sebagai landasan penulis melakukan penelitian yang akan dilakukan maka dibahas teori yang berkaitan. Berikut ini penulis uraikan landasan teori dari karya ini.

### **2.2.1 World Health Organization (WHO) Child Growth Standards 2006**

World Health Organization (WHO) Child Growth Standards 2006 merupakan rujukan internasional yang digunakan secara luas dalam penilaian status gizi balita berbasis parameter antropometri (Flynn et al., 2020; Tasya Aureliyana & Raden Kince Sakinah, 2022). Standar ini dikembangkan berdasarkan data pertumbuhan anak sehat dari berbagai negara yang mewakili kondisi pertumbuhan optimal, dan menggunakan Z-score (standard deviation score) sebagai indikator utama untuk mengklasifikasikan status gizi anak dibandingkan dengan populasi referensi WHO (Sandler, 2021)

Penggunaan standar WHO dalam penilaian pertumbuhan anak telah berkembang melalui sejarah panjang penelitian antropometri. (Sandler, 2021) menjelaskan bahwa evolusi antropometri sebagai sains telah membawa perubahan signifikan dalam cara kita memahami dan mengukur pertumbuhan anak, termasuk pengembangan standar dan referensi yang lebih akurat. Penggunaan standar WHO telah menjadi rekomendasi global dan diadopsi oleh berbagai negara, termasuk Indonesia melalui Peraturan Menteri Kesehatan No. 27 Tahun 2023 tentang Standar Antropometri Balita. Meskipun beberapa penelitian telah membandingkan standar WHO dengan referensi pertumbuhan nasional Indonesia, hasil menunjukkan bahwa standar WHO tetap relevan dan dapat digunakan untuk mendeteksi stunting dan wasting pada populasi anak Indonesia (Flynn et al., 2020).

Dalam konteks skrining awal di tingkat layanan primer, khususnya posyandu, WHO merekomendasikan penyederhanaan klasifikasi status gizi dari lima kategori menjadi tiga kelas operasional. Penyederhanaan ini bertujuan untuk meningkatkan kemudahan interpretasi serta efektivitas pengambilan keputusan di lapangan. Adapun klasifikasi operasional yang digunakan dalam penelitian ini adalah sebagai berikut:

#### A. Gizi Buruk (Wasting Akut)

Balita dikategorikan mengalami gizi buruk apabila memiliki nilai Z-score BB/TB  $< -2$ . Kondisi ini mencerminkan kekurangan gizi akut yang bersifat serius dan berisiko tinggi terhadap mortalitas apabila tidak ditangani secara cepat. Studi longitudinal yang dilakukan oleh WHO menunjukkan bahwa balita dengan Z-score BB/TB di bawah  $-2$  memiliki risiko kematian 3 hingga 5 kali lebih tinggi dibandingkan balita dengan status gizi normal (Ongko et al., 2023). menunjukkan bahwa gizi buruk (severe wasting) merupakan kondisi yang serius dan memerlukan intervensi segera, karena dapat menyebabkan berbagai komplikasi kesehatan yang serius apabila tidak ditangani dengan cepat dan tepat (Ongko et al., 2023). Dalam klasifikasi WHO yang lebih detail, kategori gizi buruk (wasting) dibagi menjadi dua: moderate acute malnutrition (MAM) dengan Z-score BB/TB antara  $-2$  hingga  $-1$ , dan severe acute malnutrition (SAM) dengan Z-score BB/TB  $< -1$ . Namun, untuk keperluan operasional di tingkat posyandu dengan keterbatasan sumber daya, kedua kategori ini digabungkan menjadi satu kategori 'Gizi Buruk' dengan threshold Z-score BB/TB  $< -2$  (Tasya Aureliyana & Raden Kince Sakinah, 2022).

#### B. Gizi Baik (Normal)

Kategori gizi baik ditetapkan pada rentang  $-2 \leq \text{Z-score BB/TB} \leq +2$ . Rentang ini menunjukkan bahwa pertumbuhan balita berada dalam batas normal sesuai dengan standar populasi referensi WHO, dengan risiko kesehatan yang relatif minimal.

#### C. Gizi Lebih (Overweight)

Balita dengan Z-score BB/TB  $> +2$  diklasifikasikan sebagai gizi lebih. Kondisi ini mengindikasikan berat badan berlebih relatif terhadap tinggi badan, yang dalam

jangka panjang berpotensi meningkatkan risiko obesitas masa kanak-kanak serta penyakit tidak menular pada usia dewasa (Tasya Aureliyana & Raden Kince Sakinah, 2022). Kategori gizi lebih pada balita, meskipun sering dianggap sebagai masalah kesehatan yang kurang serius dibandingkan dengan wasting atau stunting, memiliki implikasi kesehatan jangka panjang yang signifikan. Penelitian menunjukkan bahwa balita dengan overweight memiliki risiko lebih tinggi untuk mengalami obesitas pada usia sekolah dan dewasa, yang selanjutnya meningkatkan risiko penyakit tidak menular seperti diabetes tipe 2, hipertensi, dan penyakit kardiovaskular. Oleh karena itu, deteksi dini dan monitoring terhadap kategori gizi lebih juga penting dalam upaya pencegahan penyakit tidak menular sejak dini (Tasya Aureliyana & Raden Kince Sakinah, 2022)

lima kategori WHO menjadi tiga kelas operasional dilakukan dengan mempertimbangkan kondisi nyata di tingkat posyandu pedesaan. Pertimbangan tersebut meliputi:

- a. kebutuhan akan interpretasi yang sederhana oleh kader posyandu dengan latar belakang literasi kesehatan yang beragam.
- b. stabilitas statistik pada kelas minoritas yang jumlahnya sangat kecil, khususnya kategori severe wasting yang sering kali berada di bawah 1%.
- c. efisiensi alokasi sumber daya intervensi yang berfokus pada deteksi dini kasus gizi kritis, terutama wasting akut (Tasya Aureliyana & Raden Kince Sakinah, 2022)

Tabel 2. 2 Kategori Standar WHO

| Istilah Status Gizi | Definisi                                                                                                                                         | Indikator Utama (WHO)            |
|---------------------|--------------------------------------------------------------------------------------------------------------------------------------------------|----------------------------------|
| Stunting            | Kondisi gagal tumbuh pada anak balita akibat kekurangan gizi kronis yang ditandai dengan tinggi badan lebih pendek dibandingkan standar usianya. | Tinggi Badan menurut Umur (TB/U) |

|             |                                                                                                         |                                          |
|-------------|---------------------------------------------------------------------------------------------------------|------------------------------------------|
| Wasting     | Kondisi anak terlalu kurus untuk tinggi badannya, umumnya disebabkan oleh kekurangan gizi akut.         | Berat Badan menurut Tinggi Badan (BB/TB) |
| Underweight | Kondisi ketika berat badan anak berada di bawah standar berat badan untuk usianya.                      | Berat Badan menurut Umur (BB/U)          |
| Overweight  | Kondisi kelebihan gizi, di mana berat badan anak lebih tinggi dari standar tinggi badan maupun umurnya. | BB/TB atau BB/U                          |

Penelitian mengatakan bahwa malnutrisi yang di alami pada balita tidak hanya berdampak pada kesehatan fisik, namun juga perkembangan kognitif, produktivitas saat dewasa, dan kecerdasan. Kondisi ini bisa saja menciptakan siklus kemiskinan yang sulit diputus apabila tidak diatasi sejak dini (WHO, 2022; UNICEF, 2025).

### 2.2.2 Antropometri sebagai Alat Ukur Status Gizi Balita

Antropometri merupakan metode pengukuran dimensi fisik tubuh yang paling praktis, valid, dan reliabel untuk menilai status gizi balita dalam konteks pelayanan kesehatan masyarakat, terutama di wilayah dengan keterbatasan sumber daya (Sandler, 2021; Tasya Aureliyana & Raden Kince Sakinah, 2022). (Sandler, 2021) menjelaskan bahwa antropometri telah menjadi standar emas dalam penilaian status gizi anak di berbagai negara, meskipun implementasinya di lapangan menghadapi berbagai tantangan. Dalam penelitian ini, penulis menggunakan beberapa parameter antropometri utama yang direkomendasikan oleh WHO dan Kementerian Kesehatan Republik Indonesia, yaitu. Dari hasil pengukuran ini kemudian akan dibandingkan dengan standar WHO Child Growth Standards untuk menentukan kategori gizi. Contohnya, apabila nilai Z-score TB/U lebih rendah dari -2 SD, maka anak dikategorikan stunting. Namun, pencatatan manual sering kali menimbulkan masalah seperti salah ukur, salah tulis, dan kesulitan dalam interpretasi, apalagi dengan jumlah tenaga Kesehatan yang terbatas. Hal ini membuat deteksi dini kasus gizi buruk sering terlambat (Rozaq & Purnomo, 2022).

#### 1) Berat Badan (BB)

Berat badan merupakan indikator yang sangat sensitif terhadap perubahan status gizi jangka pendek. Penurunan berat badan relatif terhadap tinggi badan (BB/TB) menjadi indikator utama dalam mendeteksi wasting akut.

2) Tinggi Badan (TB)

Tinggi badan mencerminkan pertumbuhan linear balita yang dipengaruhi oleh asupan gizi jangka panjang serta kondisi kesehatan lingkungan. Tinggi badan yang rendah relatif terhadap usia (TB/U) mengindikasikan stunting, yaitu gangguan pertumbuhan kronis.

3) Z-score BB/U (Berat Badan terhadap Usia)

Indikator ini digunakan untuk menilai status gizi relatif terhadap usia dan sensitif dalam mendeteksi kondisi underweight.

4) Z-score TB/U (Tinggi Badan terhadap Usia)

Z-score TB/U digunakan untuk mengidentifikasi stunting sebagai manifestasi kekurangan gizi kronis.

5) Z-score BB/TB (Berat Badan terhadap Tinggi Badan) merupakan indikator antropometri kritis yang digunakan untuk mengidentifikasi kondisi gizi akut pada balita.

Parameter ini merupakan indikator paling kritis dalam mendeteksi wasting akut (Gizi Buruk) dan menjadi fokus utama dalam penelitian ini sesuai dengan standar WHO. Ketiga indikator antropometri (BB/U, TB/U, dan BB/TB) memberikan informasi yang berbeda tentang status gizi anak. BB/U mencerminkan status gizi keseluruhan dan sensitif terhadap perubahan gizi jangka pendek maupun jangka panjang. TB/U mencerminkan pertumbuhan linear dan merupakan indikator yang lebih spesifik untuk kekurangan gizi kronis (stunting). BB/TB merupakan indikator yang paling sensitif terhadap kekurangan gizi akut (wasting) dan dapat berubah dengan cepat dalam waktu singkat. Dalam penelitian ini, fokus utama adalah pada indikator BB/TB karena relevansinya dengan deteksi dini wasting akut, yang merupakan kondisi gizi yang paling mendesak dan memerlukan intervensi segera (Tasya Aureliyana & Raden Kince Sakinah, 2022).

Pengukuran antropometri yang akurat memerlukan prosedur yang terstandar dan peralatan yang tepat. Untuk pengukuran berat badan, digunakan timbangan digital dengan akurasi  $\pm 0,1$  kg, sedangkan untuk pengukuran tinggi badan (pada anak  $\geq 2$  tahun) digunakan microtoise atau stadiometer dengan akurasi  $\pm 0,1$  cm. Untuk anak berusia  $< 2$  tahun, pengukuran panjang badan (recumbent length) dilakukan menggunakan infantometer dengan akurasi yang sama (Lensoni et al., 2023). Kesalahan dalam pengukuran antropometri dapat menyebabkan misklasifikasi status gizi dan kehilangan kesempatan untuk intervensi yang tepat waktu. Oleh karena itu, pelatihan kader posyandu dalam teknik pengukuran antropometri yang benar merupakan komponen penting dalam sistem deteksi dini stunting (Lensoni et al., 2023; Rosnah et al., 2023).

Meskipun antropometri merupakan metode yang praktis dan valid, implementasinya di lapangan menghadapi berbagai tantangan. Ghani et al. (2025) menunjukkan bahwa pencatatan dan analisis data pertumbuhan balita di posyandu masih dilakukan secara manual, sehingga kesalahan dalam interpretasi data dapat terjadi. (Fitrah Ningtyas, 2023) menunjukkan bahwa penggunaan Z-Score dapat meningkatkan pemahaman orang tua dan tenaga kesehatan dalam menilai status gizi balita secara akurat. Tantangan lain termasuk keterbatasan peralatan pengukuran yang berkualitas, ketidakkonsistenan dalam teknik pengukuran antar kader, dan kesulitan dalam melakukan follow-up pada anak yang tidak hadir di posyandu. Oleh karena itu, pengembangan sistem berbasis teknologi yang dapat membantu kader dalam interpretasi data antropometri menjadi penting untuk meningkatkan akurasi deteksi dini.

Pelaksanaan pengukuran antropometri di Indonesia mengacu pada Peraturan Menteri Kesehatan No. 27 Tahun 2023 tentang Standar Antropometri Balita, yang menetapkan kurva pertumbuhan WHO 2006 sebagai acuan nasional. Di Kabupaten Lombok Barat, pengukuran antropometri dilakukan secara rutin melalui posyandu dengan cakupan pelayanan mencapai 89,7% balita usia 0–59 bulan, sehingga data yang digunakan dalam penelitian ini mencerminkan kondisi riil di lapangan. Cakupan pelayanan antropometri sebesar 89,7% di Kabupaten Lombok Barat menunjukkan tingkat partisipasi yang tinggi dari masyarakat dalam program posyandu. Namun, cakupan ini juga mengindikasikan bahwa masih terdapat 10,3%

balita yang tidak tercakup dalam pengukuran rutin, yang dapat menyebabkan terlewatnya kasus-kasus gizi buruk pada kelompok ini (Lensoni et al., 2023). Selain itu, kualitas data antropometri yang dikumpulkan melalui posyandu dapat bervariasi tergantung pada keahlian kader, ketersediaan peralatan, dan konsistensi dalam penerapan prosedur pengukuran. Oleh karena itu, data yang digunakan dalam penelitian ini telah melalui proses validasi dan cleaning untuk memastikan kualitas dan kelengkapannya (Rosnah et al., 2023).

### **2.2.3 Ketidakseimbangan Kelas pada Data Gizi Balita di Indonesia**

Data status gizi balita di Indonesia secara konsisten menunjukkan fenomena ketidakseimbangan kelas (class imbalance), di mana kategori gizi normal mendominasi secara signifikan dibandingkan kategori gizi bermasalah. Berdasarkan Riskesdas 2023, distribusi status gizi balita secara nasional terdiri atas 82,1% gizi baik, 10,2% gizi kurang, 2,6% gizi buruk, dan 5,1% gizi lebih (Tasya Aureliyana & Raden Kince Sakinah, 2022). Kondisi serupa juga ditemukan pada tingkat daerah. Di Kabupaten Lombok Barat, prevalensi stunting pada tahun 2022 tercatat sebesar 32,7%, dengan distribusi status gizi balita terdiri atas 90,86% gizi baik, 4,70% gizi buruk, dan 4,44% gizi lebih (Tasya Aureliyana & Raden Kince Sakinah, 2022).

Fenomena class imbalance dalam data gizi balita dapat dijelaskan melalui konsep imbalance ratio, yaitu perbandingan antara jumlah sampel kelas mayoritas dan kelas minoritas. Dalam konteks data Lombok Barat, imbalance ratio antara kelas gizi baik dan gizi buruk adalah 90,86% : 4,70% atau sekitar 19:1, yang menunjukkan tingkat ketidakseimbangan yang sangat tinggi (Tasya Aureliyana & Raden Kince Sakinah, 2022). Tingkat ketidakseimbangan ini dapat mempengaruhi proses pembelajaran model machine learning, di mana model cenderung untuk mengoptimalkan performa pada kelas mayoritas dengan mengorbankan performa pada kelas minoritas (Tasya Aureliyana & Raden Kince Sakinah, 2022). Ketidakseimbangan kelas ini mencerminkan realitas epidemiologis, namun sekaligus menimbulkan tantangan metodologis yang signifikan dalam pengembangan model klasifikasi berbasis machine learning.



Tanpa penanganan khusus, model prediktif cenderung menerapkan lazy strategy, yaitu memklasifikasi seluruh data sebagai kelas mayoritas (gizi baik). Strategi ini memang menghasilkan nilai akurasi tinggi secara semu, namun gagal mendeteksi kasus kritis gizi buruk yang justru menjadi fokus utama intervensi kesehatan. Selain itu, penggunaan metrik akurasi semata menjadi menyesatkan karena tidak mencerminkan kemampuan model dalam mengenali kelas minoritas (Tasya Aureliyana & Raden Kince Sakinah, 2022).

Untuk mengatasi keterbatasan akurasi sebagai metrik evaluasi pada data yang tidak seimbang, berbagai metrik alternatif telah dikembangkan. Metrik-metrik ini termasuk:

- a) Precision dan Recall, yang memberikan informasi tentang kemampuan model dalam mendeteksi kasus positif (gizi buruk) dengan benar,
- b) F1-Score, yang merupakan harmonic mean dari Precision dan Recall,
- c) Area Under the Receiver Operating Characteristic Curve (AUC-ROC), yang mengukur kemampuan model dalam membedakan antara kelas positif dan negatif pada berbagai threshold.
- d) Sensitivity dan Specificity, yang penting dalam konteks klinis untuk mengevaluasi kemampuan model dalam mendeteksi true positives dan true negatives (Aureliyana & Sakinah, 2022). Dalam penelitian ini, evaluasi model akan menggunakan kombinasi dari metrik-metrik ini untuk memberikan gambaran yang komprehensif tentang performa model (Aureliyana & Sakinah, 2022).

Risiko klinis akibat kesalahan klasifikasi, khususnya false negative pada kasus gizi buruk, sangat serius karena dapat menyebabkan keterlambatan intervensi yang berdampak pada peningkatan risiko mortalitas balita (Aureliyana & Sakinah, 2022). Dalam konteks deteksi dini gizi buruk, false negative (klasifikasi gizi baik padahal sebenarnya gizi buruk) memiliki implikasi klinis yang jauh lebih serius dibandingkan dengan false positive (klasifikasi gizi buruk padahal sebenarnya gizi baik). False negative dapat menyebabkan keterlambatan dalam memberikan intervensi gizi yang kritis, yang pada gilirannya dapat meningkatkan risiko komplikasi kesehatan dan mortalitas pada balita (Aureliyana & Sakinah, 2022). Sebaliknya, false positive mungkin hanya menghasilkan intervensi gizi tambahan

yang tidak merugikan, atau bahkan bermanfaat dalam konteks pencegahan (Aureliyana & Sakinah, 2022). Oleh karena itu, dalam pengembangan model klasifikasi untuk deteksi dini gizi buruk, prioritas harus diberikan pada minimalisasi false negative rate, bahkan jika hal ini mengakibatkan peningkatan false positive rate (Aureliyana & Sakinah, 2022).

Penelitian oleh (Anggit et al., 2025) pada sistem Becat Beleg di Lombok Barat menunjukkan bahwa 37,2% kasus wasting akut tidak terdeteksi melalui pemantauan manual posyandu, terutama akibat keterbatasan kemampuan kader dalam menginterpretasikan nilai Z-score. Temuan ini menegaskan urgensi pengembangan sistem deteksi dini berbasis kecerdasan buatan yang mampu mengatasi permasalahan class imbalance secara efektif (Aureliyana & Sakinah, 2022). Berbagai teknik telah dikembangkan untuk mengatasi masalah class imbalance dalam machine learning. Teknik-teknik ini dapat dikategorikan menjadi tiga kelompok utama:

- a) Teknik resampling, yang meliputi undersampling (mengurangi jumlah sampel kelas mayoritas) dan oversampling (menambah jumlah sampel kelas minoritas).
- b) Teknik cost-sensitive learning, yang memberikan bobot yang lebih tinggi pada kesalahan klasifikasi pada kelas minoritas.
- c) Teknik ensemble methods, yang menggabungkan beberapa model untuk meningkatkan performa pada kelas minoritas (Aureliyana & Sakinah, 2022). Dalam penelitian ini, penanganan class imbalance akan dilakukan melalui kombinasi teknik cost-sensitive learning dan ensemble methods, khususnya dengan menggunakan algoritma XGBoost yang memiliki parameter untuk menangani class imbalance (Aureliyana & Sakinah, 2022).

Penelitian sebelumnya tentang penanganan class imbalance dalam konteks kesehatan telah menunjukkan hasil yang menjanjikan. Dalam bidang medical imaging, penggunaan teknik oversampling dan cost-sensitive learning telah terbukti meningkatkan deteksi penyakit langka dengan sensitivity yang tinggi (Aureliyana & Sakinah, 2022). Dalam konteks klasifikasi status gizi, penelitian oleh Sakti et al. (2023) menunjukkan bahwa penggunaan ensemble methods dapat meningkatkan recall pada kelas minoritas (gizi buruk) hingga 85% sambil mempertahankan precision yang tinggi (Aureliyana &

Sakinah, 2022). Temuan-temuan ini memberikan dasar yang kuat untuk menggunakan teknik serupa dalam penelitian ini (Aureliyana & Sakinah, 2022).

#### **2.2.4 Synthetic Minority Oversampling Technique (SMOTE) untuk Penanganan Class Imbalance**

Synthetic Minority Oversampling Technique (SMOTE) merupakan salah satu metode yang paling banyak digunakan untuk mengatasi permasalahan ketidakseimbangan kelas (class imbalance) dalam data klasifikasi. Teknik ini bekerja dengan menghasilkan sampel sintetis pada kelas minoritas melalui proses interpolasi linier antar data tetangga terdekat (k-nearest neighbors) di dalam ruang fitur, sehingga distribusi data antar kelas menjadi lebih seimbang (Tariq et al., 2023; Wang et al., 2021).

Secara matematis, pembentukan sampel sintetis pada SMOTE sebagai berikut:

$$x_{\text{new}} = x_i + \delta \cdot (x_{zi} - x_i) \quad (2.1)$$

dengan:

$x_i$  = sampel minoritas asli

$x_{zi}$  = salah satu tetangga terdekat dari  $x_i$

$\delta$  = bilangan acak dalam rentang  $[0, 1]$

$x_{\text{new}}$  = sampel sintetis yang dihasilkan

Rumus di atas menunjukkan bahwa sampel baru dibuat pada garis yang menghubungkan dua data minoritas

Perbandingan sistematis antara berbagai metode oversampling menunjukkan keunggulan SMOTE dalam berbagai konteks. melakukan evaluasi terhadap metode oversampling yang berbeda (OVER, SMOTE, dan ROSE) pada dataset soil liquefaction menggunakan SVM, Random Forest, dan Naïve Bayes. Hasil penelitian menunjukkan bahwa SMOTE lebih efektif dibandingkan simple oversampling (OVER) dan ROSE dalam meningkatkan performa klasifikasi pada dataset yang tidak seimbang (DEMİR & ŞAHİN, 2022).

Penerapan SMOTE dalam konteks klasifikasi medis telah menunjukkan hasil yang signifikan ini menunjukkan bahwa penggunaan SMOTE pada Random Forest dan XGBoost dapat meningkatkan performa model dalam mengklasifikasikan gambar Chest X-Ray untuk deteksi tuberkulosis, dengan meningkatkan jumlah sampel kelas minoritas (TB positif). Hasil penelitian menunjukkan bahwa XGBoost dengan SMOTE mencapai akurasi 94.33%, lebih tinggi dibandingkan tanpa SMOTE (Fadhlullah & Wahyono, 2024).

Meskipun SMOTE efektif dalam mengatasi class imbalance, algoritma ini memiliki keterbatasan tertentu, ini menunjukkan bahwa SMOTE dapat menghasilkan sampel sintetis secara acak untuk meningkatkan tingkat keseimbangan, namun aplikasinya dipengaruhi oleh masalah marginalisasi dan kebutaan dalam pemilihan parameter. Penelitian ini mengusulkan peningkatan SMOTE berdasarkan distribusi Normal untuk mengatasi keterbatasan tersebut, sehingga sampel sintetis yang dihasilkan lebih dekat dengan pusat data minoritas (Wang et al., 2021)

Kombinasi SMOTE dengan algoritma klasifikasi yang kuat juga telah menunjukkan hasil yang sangat baik (Michael Lauw et al., 2023) menunjukkan bahwa penggunaan SMOTE untuk menyeimbangkan data dikombinasikan dengan Random Forest untuk klasifikasi dapat mencapai akurasi 94.1% dalam klasifikasi kanker paru, dengan peningkatan sensitivity sebesar 39% dibandingkan tanpa SMOTE (Michael Lauw et al., 2023)

Kombinasi feature extraction dan data sampling merupakan pendekatan yang efektif untuk mengatasi class imbalance pada dataset berdimensi tinggi menunjukkan bahwa penggunaan PCA untuk feature extraction dikombinasikan dengan data sampling dapat meningkatkan performa ensemble classifiers (Random Forest, CatBoost, LightGBM, dan XGBoost) dalam klasifikasi fraud detection (Salekshahrezaee et al., 2023).

### **2.2.5 XGBoost untuk Klasifikasi Multi-Kelas**

XGBoost (eXtreme Gradient Boosting) merupakan algoritma ensemble learning berbasis gradient boosting yang dikembangkan oleh Chen & Guestrin (2016) dan dikenal memiliki performa tinggi pada berbagai permasalahan klasifikasi, termasuk pada dataset dengan ketidakseimbangan kelas. Keunggulan XGBoost menjadikannya kandidat yang kuat untuk diterapkan dalam klasifikasi status gizi balita yang memiliki distribusi kelas tidak seimbang. Perbandingan langsung antara berbagai algoritma ensemble dan teknik sampling menunjukkan efektivitas kombinasi SMOTE dengan Gradient Boosted Tree (Leuwol et al., 2023). menunjukkan bahwa penggunaan SMOTE dan Random Under Sampling dengan Gradient Boosted Tree, SVM, dan Random Forest dapat meningkatkan deteksi fraud pada dataset yang tidak seimbang. Hasil penelitian menunjukkan bahwa Gradient Boosted Tree (XGBoost) mencapai AUC yang lebih tinggi dibandingkan algoritma lain ketika dikombinasikan dengan SMOTE (Salomo Leuwol et al., 2023).

Kombinasi feature extraction dan data sampling dengan ensemble classifiers menunjukkan performa yang superior menunjukkan bahwa penggunaan PCA untuk feature extraction dikombinasikan dengan data sampling dapat meningkatkan performa XGBoost dalam klasifikasi fraud detection. Hasil penelitian menunjukkan bahwa XGBoost merupakan salah satu ensemble classifiers yang paling efektif dalam menangani data berdimensi tinggi yang tidak seimbang (Salekshahrezaee et al., 2023).

Penerapan XGBoost dalam konteks klasifikasi medis dengan class imbalance telah menunjukkan hasil yang signifikan. menunjukkan bahwa XGBoost dengan SMOTE mencapai akurasi 94.33% dalam klasifikasi tuberkulosis dari gambar Chest X-Ray, lebih tinggi dibandingkan Random Forest (Fadhlullah & Wahyono, 2024).

### **2.2.6 Validasi Model dengan 5-Fold Cross Validation**

Untuk memastikan bahwa performa model tidak bergantung pada satu pembagian data tertentu, penulis menerapkan metode validasi stratified k-fold cross-validation. Teknik ini membagi data training menjadi k subset (fold) yang

saling eksklusif dengan pendekatan stratifikasi, sehingga proporsi kelas pada setiap fold tetap terjaga (Jia, 2024; Toleva et al., 2025). Stratified k-fold cross-validation sangat penting ketika menangani data yang tidak seimbang menunjukkan bahwa stratified k-fold cross-validation lebih sesuai untuk kasus class imbalance dibandingkan k-fold biasa, karena memastikan bahwa setiap fold memiliki proporsi kelas yang sama dengan dataset keseluruhan. Hal ini sangat relevan untuk penelitian ini mengingat data status gizi balita menunjukkan ketidakseimbangan kelas yang signifikan.

Nilai standar deviasi yang rendah (kurang dari 0,05) pada F1-Score Macro menunjukkan bahwa model memiliki stabilitas yang baik terhadap variasi data. Sebaliknya, model dengan standar deviasi di atas 0,10 dianggap tidak stabil dan berisiko untuk diimplementasikan di lapangan karena performanya sangat bergantung pada konfigurasi data tertentu (Jia, 2024).


Pengembangan lebih lanjut dari stratified k-fold cross-validation adalah repeated stratified k-fold cross-validation (Cho et al., 2025; Guo et al., 2022) menunjukkan bahwa repeated stratified k-fold cross-validation dapat meningkatkan keandalan evaluasi model dengan mengulangi proses stratifikasi berkali-kali menunjukkan bahwa repeated stratified k-fold cross-validation dapat meningkatkan keandalan evaluasi model dalam klasifikasi smoking status pada pasien COPD dengan class imbalance (Cho et al., 2025).

Cross-validation memiliki dampak signifikan pada performa model machine learning dalam aplikasi medis (Kaliappan et al., 2023) menunjukkan bahwa pemilihan cross-validation strategy yang tepat dapat meningkatkan keandalan evaluasi model dalam deteksi dini intrauterine fetal demise. Hal ini menunjukkan bahwa cross-validation bukan hanya metode evaluasi, tetapi juga mempengaruhi hasil akhir dari model machine learning.

Penelitian (Miranda et al., 2024) menunjukkan bahwa penerapan 5-fold cross-validation mampu meningkatkan keandalan evaluasi model klasifikasi status gizi dari 76,3% menjadi 89,7% dibandingkan pendekatan single train-test split, terutama pada dataset dengan ketidakseimbangan kelas ekstrem ( $>1:20$ ). Oleh karena itu, metode ini dinilai tepat untuk digunakan dalam penelitian ini.


### 2.2.7 Machine Learning

Machine Learning merupakan bagian dari bidang ilmu yang di mana mempelajari bagaimana computer dapat meningkatkan performansinya secara otomatis melalui pengalaman. Bidang ini berkembang pesat di persimpangan ilmu komputer, statistika, dan kecerdasan buatan. Dalam perkembangannya, dan machine learning dibagi menjadi empat paradigma utama yaitu supervised learning, unsupervised learning, dan reinforcement learning.



Gambar 2. 1 Kategori Machine Learning

Supervised learning biasanya digunakan untuk belajar dari data berlabel seperti klasifikasi spam atau diagnosis medis, unsupervised learning digunakan untuk menemukan pola pada data tidak berlabel seperti clustering atau topic modeling, dan reinforcement learning berfokus pada pembelajaran melalui interaksi dengan lingkungan melalui reward dan penalti. Penerapan deep learning, yang menggunakan jaringan saraf dalam untuk memproses data bervolume besar, telah mencapai kemajuan signifikan. Ini memungkinkan peningkatan akurasi dalam bidang pengenalan suara, bahasa alami, dan visi komputer. Tantangan teoretis seperti kompleksitas sampel, kompleksitas komputasi, dan masalah privasi dan keadilan masih menjadi perhatian utama, meskipun telah banyak digunakan dalam bidang sains, industri, dan layanan publik. (Horvitz & Mulligan, 2015).




Gambar 2. 2 Klasifikasi Algoritma Supervised Learning (Pandey et al., 2008)





### 2.2.8 Flowchart


Flowchart atau sering disebut dengan diagram alir merupakan suatu jenis diagram yang merepresentasikan algoritma atau langkah-langkah instruksi yang berurutan dalam sistem. seorang analis sistem menggunakan flowchart sebagai bukti dokumentasi untuk menjelaskan gambaran logis sebuah sistem yang akan dibangun kepada programmer. Dengan begitu, flowchart dapat membantu untuk memberikan solusi terhadap masalah yang bisa saja terjadi dalam membangun sistem. Pada dasarnya, flowchart digambarkan dengan menggunakan simbol-simbol. Setiap simbol mewakili suatu proses tertentu. Sedangkan untuk menghubungkan satu proses ke proses selanjutnya digambarkan dengan menggunakan garis penghubung (Rosaly et al., n.d.)

Tabel 2. 3 Tabel flowchart(Rosaly et al., n.d.)

| No | Simbol                                                                              | Nama     | Keterangan                                                |
|----|-------------------------------------------------------------------------------------|----------|-----------------------------------------------------------|
| 1. |  | Terminal | Simbol yang mengartikan awal dan akhirnya sebuah program. |



| No | Simbol                                                                              | Nama              | Keterangan                                                                                    |
|----|-------------------------------------------------------------------------------------|-------------------|-----------------------------------------------------------------------------------------------|
| 2. |    | Input atau Output | Simbol yang menunjukkan proses input atau output.                                             |
| 3. |    | Proses            | Simbol yang mengartikan proses yang berjalan di dalam sebuah komputer.                        |
| 4. |    | Decision          | Simbol yang menghasilkan kemungkinan dua jawaban yaitu YA/TIDAK pada kondisi tertentu.        |
| 5. |   | Display           | Simbol yang membentuk keluaran pada sebuah layar monitor.                                     |
| 6. |  | Alur Proses       | Simbol untuk menunjukkan alur proses sebuah objek.                                            |
| 7. |  | Connector         | Simbol untuk menunjukkan hubungan antar objek dengan objek lainnya pada halaman yang sama.    |
| 8. |  | Offline Connector | Simbol untuk menunjukkan hubungan antar objek dengan objek lainnya pada halaman yang berbeda. |
| 9. |  | Document          | Simbol yang mencetak dokumen.                                                                 |

| No  | Simbol                                                                            | Nama         | Keterangan                                                                    |
|-----|-----------------------------------------------------------------------------------|--------------|-------------------------------------------------------------------------------|
| 10. |  | Disk Storage | Simbol yang menunjukkan input atau output yang disimpan ke dalam sebuah disk. |

### 2.2.9 XGBoost

XGBoost (Extreme Gradient Boosting) adalah salah satu algoritma ensemble learning yang dikembangkan melalui metode gradient boosting decision tree (GBDT). Dengan algoritma ini dapat membangun model klasifikasi secara bertahap (additive model), yang di mana setiap pohon keputusan baru yang dibangun bertujuan untuk memperbaiki kesalahan dari pohon-pohon sebelumnya. Keunggulan utama XGBoost adalah kemampuannya dalam melakukan regularisasi (L1 dan L2) untuk mengurangi overfitting, dan juga efisiensi komputasi karena dapat mendukung pemrosesan paralel. XGBoost juga dilengkapi dengan teknik shrinkage (learning rate), subsampling, dan column sampling untuk meningkatkan generalisasi model, sehingga sering digunakan pada berbagai kompetisi data mining maupun aplikasi dunia nyata (Chen & Guestrin, 2016).

Dalam penelitian terbaru, XGBoost sudah terbukti unggul dibandingkan algoritma lain seperti Random Forest dan Logistic Regression terutama dalam akurasi dan kemampuan menangani data berimbalance. Studi yang dilakukan oleh (Imani, Beikmohammadi & Arabnia, 2025) menunjukkan bahwa kombinasi dari XGBoost dengan metode oversampling seperti SMOTE dan ADASYN mampu meningkatkan performa klasifikasi pada dataset dengan distribusi kelas yang tidak seimbang. Hasil ini telah menegaskan bahwa XGBoost tidak hanya unggul dalam hal efisiensi, namun juga fleksibel dalam menangani permasalahan data yang kompleks. (Imani et al., 2025).

Selain itu, dengan menerapkan XGBoost di bidang Kesehatan juga telah menunjukkan hasil yang signifikan. Misalnya, penelitian oleh Dalal et al., (2022) mengembangkan hybrid XGBoost model dengan hyperparameter tuning untuk klasifikasi penyakit hati, dan hasilnya menunjukkan peningkatan akurasi yang lebih tinggi dibandingkan algoritma pembandingan. Hal ini membuktikan bahwa penyesuaian parameter seperti max\_depth, eta,

subsample, dan colsample\_bytree dapat memberikan pengaruh besar terhadap performa model. (Dalal et al., 2022).

Fungsi tujuannya (objective function) didefinisikan sebagai:

$$L(\phi) = \sum_{i=1}^n l(y_i, y'_i) + \sum_{k=1}^K \Omega(f_k) \quad (2.2)$$

di mana  $l$  adalah fungsi loss,  $\Omega$  adalah fungsi regularisasi, dan  $f_k$  adalah pohon keputusan ke- $k$ .

Penelitian terkini menunjukkan bahwa kombinasi XGBoost dengan teknik oversampling seperti SMOTE mampu meningkatkan performa klasifikasi pada dataset dengan distribusi kelas tidak seimbang (Imani et al., 2025) Dalam konteks kesehatan, XGBoost telah terbukti unggul dalam klasifikasi penyakit hati dengan akurasi >95% setelah hyperparameter tuning (Dalal et al., 2022)

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (2.3)$$

Keterangan:

1.  $x$  = data uji
2.  $y$  = data latih
3.  $n$  = jumlah fitur
4.  $x_i, y_i$  = nilai fitur ke- $i$

#### 2.2.10 Prevalensi

Prevalensi adalah ukuran epidemiologi yang menunjukkan proporsi individu dalam suatu populasi yang mengalami suatu kondisi atau penyakit tertentu pada waktu tertentu. Dengan kata lain, prevalensi menggambarkan seberapa banyak kasus yang ada (baik kasus lama maupun baru) dibandingkan dengan total populasi yang diamati.

Menurut World Health Organization (WHO), prevalensi adalah jumlah total kasus suatu penyakit dalam populasi pada periode atau titik waktu tertentu, dibagi dengan jumlah total populasi yang berisiko pada waktu tersebut.

$$\text{Prevalensi}(\%) = \left( \frac{\text{Jumlah Kasus Gizi Buruk}}{\text{Total Data Valid per Desa}} \right) \times 100\% \quad (2.4)$$

Keterangan:


1. Jumlah Kasus Gizi Buruk: Balita dengan ZS BB/TB < -2 setelah filtering.
2. Total Data Valid: Data yang memenuhi kriteria WHO 2006 (BB 5–30 kg, TB 60–130 cm, Umur 24–59 bulan, ZS BB/TB  $\pm 5$ ).
3. Prevalensi (%): Persentase balita dengan status gizi buruk dalam populasi desa tersebut.

### **2.2.11 Metode Eksperimen Komputasional**

Eksperimen komputasional dalam ilmu komputer merupakan pendekatan penelitian yang memanfaatkan komputasi untuk melakukan eksperimen yang terkontrol dan dapat diulang dalam menganalisis sistem yang kompleks secara kuantitatif. Melalui pendekatan ini, peneliti dapat menguji berbagai konfigurasi model, parameter, dan skenario pengolahan data secara sistematis untuk mengevaluasi performa metode yang digunakan. Dalam penelitian ini, eksperimen komputasional dilakukan dengan menerapkan algoritma machine learning pada dataset antropometri balita untuk membangun model prediksi status gizi. Proses eksperimen meliputi tahap prapemrosesan data, pembagian data pelatihan dan pengujian, pelatihan model, serta evaluasi performa menggunakan metrik klasifikasi. Pendekatan ini memungkinkan analisis yang objektif dan terukur terhadap kemampuan model dalam mendeteksi status gizi balita secara lebih akurat. (Mao & Wang, 2012)

## 2.3 Kerangka Pemikiran

Berikut adalah kerangka pemikiran yang disusun untuk menggambarkan langkah-langkah proses analisis data dari awal hingga akhir, dengan tujuan untuk mendapatkan kesimpulan dari data yang sedang dianalisis.



Gambar 2. 3 Kerangka Pemikiran

Kerangka pemikiran penelitian ini mengintegrasikan teori klinis WHO dengan metodologi machine learning untuk menghasilkan sistem deteksi dini status gizi balita yang valid secara klinis dan stabil secara statistik. Gambar 2.4 mengilustrasikan alur logis dari input data hingga dampak sosial.

Untuk memastikan validitas dan reliabilitas hasil penelitian, diterapkan kerangka pengujian komprehensif berdasarkan teori evaluasi model machine learning:

Validasi dengan 5-Fold Cross-Validation

Cross-validation merupakan teknik resampling yang mengatasi keterbatasan single train-test split dengan menguji model pada 5 konfigurasi data berbeda (Kohavi, 1995). Protokol implementasi:

1. Stratified K-Fold ( $k=5$ ) untuk menjaga proporsi kelas
2. SMOTE hanya pada training set setiap fold untuk mencegah data leakage
3. Evaluasi pada validation set asli tanpa SMOTE
4. Hasil akhir = Rata-rata  $\pm$  Standar Deviasi dari 5 fold