

Comparative Evaluation of Ensemble Learning Models for Prenatal Stunting Risk Assessment Based on Maternal Health Data

Nur Inaya Bahar^{1*}, Eka Qadri Nuranti^{2**}, Intan Sari Areni^{3**}

^{1,2}Program Studi Ilmu Komputer, Institut Teknologi Bacharuddin Jusuf Habibie

³Departemen Teknik Elektro, Universitas Hasanuddin

nurinayabahar.221011025@mahasiswa.ith.ac.id¹, eka.qadri@ith.ac.id², intan@unhas.ac.id³

Article Info

Article history:

Received 2026-06-04

Revised 2026-07-24

Accepted 2026-08-12

Keyword:

*Ensemble Learning,
Prenatal Stunting,
Light Gradient Boosting Machine,
Maternal Data*

ABSTRACT

Stunting remains a significant public health challenge, where interventions are often delayed as they occur postnatally. This research aims to shift the detection focus to the prenatal phase by comparing the performance of four Ensemble Learning algorithms: Random Forest, XGBoost, CatBoost, and Light Gradient Boosting Machine (LGBM). Using a maternal dataset from DPPKB Parepare City consisting of 871 respondents, the models were developed through a Stratified 5-Fold Group Cross Validation scheme to predict stunting risk based on clinical features of pregnant women. Experimental results show that LGBM is the most optimal algorithm, where the hyperparameter tuning process increased model performance to an F1-Score of 94.34% and an accuracy of 94.50%. Ablation analysis identified maternal age, height, and the age of the last child as the most dominant predictors. The best model was integrated into a web-based decision support system using cloud-based microservices architecture, featuring geospatial mapping. This study proves that the application of LGBM on prenatal maternal data can provide accurate early detection to support targeted nutritional interventions for Family Assistance Teams (TPK) in Parepare City, although its generalizability remains limited to local administrative characteristics and warrants further prospective external validation before broader deployment.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Stunting tetap menjadi tantangan kesehatan masyarakat yang sangat mendesak, baik dalam skala global maupun nasional. Berdasarkan data tahun 2022, diperkirakan terdapat 148 juta anak balita di seluruh dunia yang menderita stunting, yang merepresentasikan kegagalan pertumbuhan dan perkembangan jangka panjang akibat kekurangan gizi kronis [1]. Di Indonesia, meskipun tren prevalensi menunjukkan penurunan, angka tersebut masih berada pada level 21,5% pada tahun 2023 [2]. Angka ini masih terpaut jauh dari target ambisius pemerintah yang mematok prevalensi stunting sebesar 14% pada akhir tahun 2024 [3], [4]. Kegagalan dalam mencapai target ini bukan sekadar masalah angka statistik, melainkan menandakan adanya ancaman serius terhadap kualitas sumber daya

manusia masa depan. Dampak buruk stunting yang terjadi pada 1.000 Hari Pertama Kehidupan (HPK) bersifat ireversibel atau tidak dapat dipulihkan, yang mencakup keterlambatan perkembangan kognitif, rendahnya kemampuan belajar, serta meningkatnya kerentanan terhadap penyakit degeneratif di masa dewasa [5],[6]. Kondisi ini secara sistemik melanggengkan siklus kemiskinan antar-generasi akibat rendahnya produktivitas individu di masa depan [7], [4].

Akar permasalahan dalam penanganan stunting, khususnya di daerah seperti Kota Parepare, sering kali terletak pada pendekatan intervensi yang bersifat responsif atau ditangani setelah gejala fisik muncul. Praktik di lapangan menunjukkan bahwa intervensi gizi sering kali baru dilakukan setelah anak lahir dan terdeteksi mengalami gagal tumbuh berdasarkan indikator antropometri.

Padahal, secara patofisiologi, proses terjadinya stunting banyak dimulai sejak masa janin berada dalam kandungan (*in utero*) [8], [9], [10]. Kondisi maternal, termasuk status gizi ibu, prevalensi anemia, serta riwayat kesehatan selama kehamilan, merupakan faktor penentu utama yang sering kali terabaikan dalam sistem deteksi dini [11]. Oleh karena itu, diperlukan sebuah transformasi paradigma dari penanganan pasca-lahir menjadi deteksi risiko sejak fase prenatal. Pemanfaatan kemajuan teknologi *Machine Learning* (ML), terutama melalui metode *Ensemble Learning*, menawarkan peluang besar untuk menciptakan sistem penilaian risiko yang cerdas. Metode ini memiliki kemampuan unik untuk mengekstraksi dan menganalisis pola-pola kompleks dari variabel klinis ibu hamil yang bersifat non-linear, guna mengidentifikasi kehamilan dengan risiko stunting tinggi secara lebih presisi.


Eksplorasi terhadap efektivitas *Machine Learning* dalam klasifikasi stunting sebenarnya telah banyak dilakukan dalam penelitian sebelumnya. Studi yang dilakukan oleh [9], [12], [13] menunjukkan bahwa algoritma seperti *Random Forest* mampu mencapai akurasi sebesar 92,70%, sementara model *CatBoost* bahkan mencatatkan akurasi hingga 98,47% dalam konteks klasifikasi stunting pada balita. Namun, mayoritas penelitian tersebut masih berfokus pada klasifikasi postnatal atau data setelah anak lahir [13]. Meskipun model-model tersebut memiliki akurasi yang tinggi untuk kepentingan diagnosis, mereka tidak mampu menjawab kebutuhan mendesak akan pencegahan primer yang harus dilakukan sejak masa kehamilan. Ketergantungan pada data pasca-lahir menyebabkan peluang emas untuk melakukan intervensi gizi preventif selama masa kehamilan menjadi hilang, sehingga sistem yang ada saat ini cenderung berfungsi sebagai alat pencatatan beban penyakit daripada alat pencegahan dini.

Penelitian ini hadir untuk memitigasi keterbatasan tersebut dengan menggeser fokus deteksi dari fase postnatal ke fase prenatal menggunakan dataset maternal murni secara longitudinal. Melalui pendekatan ini, penelitian memberikan kontribusi signifikan dalam upaya pencegahan stunting langsung dari hulunya. Kontribusi studi ini dijabarkan ke dalam tiga poin utama: (1) mengevaluasi model *Ensemble Learning* mutakhir untuk penilaian risiko stunting prenatal menggunakan data administratif ibu; (2) menerapkan validasi *Stratified 5-Fold Group Cross Validation* untuk memitigasi risiko *data leakage* dalam catatan longitudinal ibu hamil; dan (3) mengintegrasikan model dengan performa terbaik ke dalam prototipe sistem pendukung keputusan (*Decision Support System*) fungsional yang dilengkapi dengan fitur visualisasi geospasial. Dengan rangkaian kontribusi tersebut, penelitian ini diharapkan mampu menjadi instrumen cerdas yang krusial dalam upaya nasional menurunkan prevalensi stunting melalui deteksi dini yang presisi sejak masa kehamilan.

II. METODE

Penelitian ini menggunakan pendekatan kuantitatif dengan data sekunder retrospektif yang bersumber dari Dinas

Pengendalian Penduduk dan Keluarga Berencana (DPPKB) Kota Parepare periode 2024-2025. Alur penelitian mencakup tahapan pengumpulan data, pra-pemrosesan, pemodelan menggunakan algoritma *Ensemble Learning*, hingga evaluasi kinerja dan implementasi sistem.



Gambar 1. Alur Penelitian

A. Pengumpulan dan Pelabelan Data

Pengumpulan data diawali dengan mengekstraksi data mentah dari aplikasi pendataan DPPKB Kota Parepare, yang terdiri dari set data ibu hamil (bumil) dan data anak di bawah dua tahun (baduta). Proses ini menerapkan pendekatan pelacakan kohort retrospektif untuk menghubungkan dua linimasa pengamatan yang berbeda, yaitu data prediktor maternal saat masa kehamilan (rentang tahun 2024 sebagai waktu pengamatan T_0) dengan data luaran (*outcome*) pertumbuhan anak pasca-persalinan (rentang tahun 2025 sebagai waktu pengamatan T_1). Kedua set data tersebut digabungkan menggunakan Nomor Induk Kependudukan (NIK) sebagai kunci penaut dengan teknik *VLOOKUP* untuk memastikan setiap rekam medis ibu semasa hamil (T_0) terhubung secara akurat dengan data pertumbuhan anaknya setelah lahir (T_1). Untuk menjaga etika penelitian, seluruh data identitas pribadi dianonimkan dengan mengganti NIK menjadi ID unik.

Dataset gabungan ini kemudian melalui proses pelabelan biner untuk menentukan variabel target berdasarkan kondisi riil anak pada rentang pengamatan T_1 . Label ditentukan secara objektif berdasarkan status pertumbuhan anak yang tercatat dalam sistem sesuai dengan Standar Antropometri Kementerian Kesehatan Republik Indonesia. Kategori

"Berisiko" (1) diberikan jika ibu hamil pada masa T_0 memiliki bayi yang pada masa T_1 terkonfirmasi secara klinis memiliki indikasi gangguan pertumbuhan atau status *stunting* berdasarkan indeks Tinggi Badan menurut Umur (TB/U) dengan nilai $Z\text{-score} < -2$ Standar Deviasi (SD). Kategori "Tidak Berisiko" (0) diberikan untuk ibu hamil dengan bayi yang memiliki pertumbuhan normal dengan nilai $Z\text{-score}$ TB/U ≥ -2 SD. Untuk memprediksi risiko tersebut secara prenatal, model dikembangkan menggunakan fitur prediktor maternal yang dirinci pada Tabel I. Variabel baduta (seperti Tinggi badan Lahir dan Usia Kelahiran) hanya digunakan untuk pembentukan label target dan dihapus dari dataset fitur guna mencegah *data leakage*.

TABEL I
DAFTAR FITUR PREDIKTOR MATERNAL

Kategori	Nama Fitur	Deskripsi Teknis	Tipe Data
Demografi	Usia Ibu hamil, jumlah anak kandung	Profil risiko dasar dan beban fisiologis ibu	Numerik
	Usia anak terakhir	Indikator jarak kehamilan.	Numerik
Antropometri	IMT, LILA	Indeks Massa Tubuh, Lingkar Lengan Atas	Numerik
	Berat badan (sebelum & saat ini), Tinggi badan	Status gizi fisik ibu secara longitudinal	Numerik
Klinis	Kadar hemoglobin	Indikator anemia selama kehamilan	Numerik
	TFU, Usia Kehamilan (minggu)	Pemantauan perkembangan janin <i>in utero</i>	Numerik
	Riwayat_Penyakit	Penyakit penyerta selama kehamilan	Kategorikal
Lingkungan	Kualitas_Air, Fasilitas_Jamban	Akses air layak dan fasilitas sanitasi	Kategorikal
Perilaku	Meminum tablet tambah darah	Kepatuhan konsumsi suplemen zat besi	Kategorikal
	Terpapar asap_rokok	Paparan asap rokok rutin	Kategorikal

B. Pra-Pemrosesan Data

Pra-pemrosesan data merupakan tahapan fundamental dalam siklus pengembangan *machine learning* yang bertujuan untuk mentransformasi data mentah sebanyak 2.613 rekaman (yang berasal dari 871 responden longitudinal) menjadi format yang bersih, konsisten, dan berkualitas tinggi sebelum

memasuki proses pemodelan [14], [15]. Dalam konteks penelitian ini, data maternal yang diperoleh dari sistem administratif seringkali memiliki tingkat kompleksitas dan ketidakteraturan yang tinggi. Tanpa proses pembersihan dan penyesuaian yang tepat, algoritma *machine learning* akan mengalami kesulitan dalam mengidentifikasi pola-pola penting, yang pada akhirnya dapat mengakibatkan model menjadi bias atau tidak akurat. Oleh karena itu, tahap ini bertugas untuk meminimalisir gangguan (*noise*) serta menyelaraskan struktur data agar sesuai dengan persyaratan teknis algoritma berbasis pohon yang digunakan.

a. Pembersihan data (*data cleaning*)

Pembersihan data (*data cleaning*) menjadi langkah awal yang krusial untuk menjamin integritas dataset sebelum memasuki tahapan pemodelan. Proses ini meliputi identifikasi dan penanganan data yang tidak lengkap (*missing values*) serta nilai ekstrem (*outliers*) yang kerap ditemukan pada pencatatan data kesehatan ibu hamil secara manual. Fitur numerik yang kehilangan nilai diimputasi menggunakan nilai median, yang secara metodologis dipilih karena sifatnya yang lebih kuat (*robust*) dan tidak sensitif terhadap bias pencilan dibandingkan nilai rata-rata (*mean*). Sementara itu, untuk fitur kategorikal yang tidak lengkap, imputasi dilakukan dengan menggunakan nilai modus atau nilai yang paling sering muncul guna menjaga konsistensi distribusi asli data. Selain penanganan data hilang, dilakukan pula identifikasi *outliers* menggunakan metode batas logis klinis (*clinical range validation*). Deteksi difokuskan pada nilai numerik yang berada di luar rentang logis biologis seorang ibu hamil, seperti kadar Hemoglobin (Hb) yang ekstrem atau kesalahan entri pada parameter antropometri. Nilai yang tidak logis atau bernilai negatif akibat kesalahan input manual (*human error*) dieliminasi dan disesuaikan menggunakan nilai ambang batas klinis terdekat (*winsorization*) guna mencegah gangguan (*noise*) yang dapat menyesatkan arah percabangan pohon keputusan pada model *Ensemble Learning*. Pembersihan ini sangat penting karena kualitas prediksi model sangat bergantung pada kualitas data input, sehingga dataset yang bersih akan menghasilkan performa yang andal bagi petugas kesehatan dalam menilai risiko *stunting* secara tepat sasaran.

b. Transformasi Data

Transformasi data melalui teknik *Label Encoding* untuk mengubah variabel kategorikal menjadi representasi numerik [12], [16]. Karena algoritma seperti XGBoost, LGBM, dan CatBoost bekerja berdasarkan perhitungan matematis, data dalam bentuk teks tidak dapat diproses secara langsung. Sebagai contoh, variabel riwayat penyakit yang semula bernilai "Ada" dan "Tidak Ada" ditransformasikan menjadi nilai biner 1 dan 0. Proses ini memungkinkan model untuk secara efisien membagi data berdasarkan ambang batas numerik dalam proses pembentukan pohon keputusan, sehingga memudahkan perhitungan bobot risiko pada setiap fitur maternal yang diberikan.

c. Feature Engineering & Pemetaan Manual

Feature Engineering yang melibatkan pembentukan fitur baru melalui pemetaan manual berbasis aturan (*rule-based mapping*). Tahap ini bertujuan untuk menyederhanakan informasi yang kompleks menjadi fitur yang lebih memiliki nilai klinis. Salah satu implementasi nyatanya adalah penggabungan berbagai kategori pada kolom "Sumber Air Minum" menjadi fitur baru bernama "Kualitas Air". Dengan memetakan kategori seperti PDAM atau sumur terlindungi ke dalam nilai 1 (Layak) dan kategori yang tidak memenuhi syarat kesehatan ke dalam nilai 0 (Tidak Layak), model dapat lebih fokus pada hubungan antara kelayakan sanitasi dengan risiko stunting prenatal tanpa harus terbebani oleh variasi kategori sumber air yang terlalu beragam.

Hasil akhir dan indikator keberhasilan dari seluruh rangkaian pra-pemrosesan data ini. Indikator utamanya adalah tersedianya dataset yang sudah sepenuhnya konsisten, berformat numerik, dan bebas dari anomali data dasar. Keberhasilan tahap ini dipastikan dengan melakukan pengecekan akhir terhadap distribusi data untuk memastikan tidak ada fitur yang memiliki korelasi yang tidak logis atau data yang bocor (*data leakage*). Dengan tersedianya dataset yang matang ini, proses pemodelan dan evaluasi kinerja model dapat dilakukan secara objektif, yang menjadi landasan utama bagi penelitian ini untuk menghasilkan akurasi prediksi risiko yang tinggi.

C. Pemodelan dan Evaluasi Kinerja

Proses pemodelan dalam penelitian ini difokuskan pada penggunaan algoritma *Ensemble Learning* yang memiliki kemampuan superior dalam menangani data kesehatan maternal yang kompleks. Empat algoritma utama yang diimplementasikan adalah:

- Random Forest (RF): Menggunakan metode *Bagging* dengan membangun sekumpulan pohon keputusan secara independen untuk meminimalisir *overfitting* melalui pemilihan fitur acak [17].
- Extreme Gradient Boosting (XGBoost): Algoritma *boosting* sekuensial yang dilengkapi regulasi L1 dan L2 untuk mengontrol kompleksitas model serta fitur *sparsity-aware split finding* untuk menangani data yang hilang [8], [17].
- Light Gradient Boosting Machine (LGBM): Menggunakan strategi pertumbuhan *leaf-wise* serta teknik GOSS dan EFB untuk mencapai kecepatan pelatihan ekstrem dan efisiensi memori yang tinggi [10], [18].
- Categorical Boosting (CatBoost): Dioptimasi khusus untuk fitur kategorikal menggunakan teknik *Ordered Boosting* guna mengatasi *prediction shift* tanpa memerlukan *One-Hot Encoding* manual [12], [14].

Setelah model dibangun, serangkaian prosedur evaluasi dilakukan untuk memastikan objektivitas dan validitas hasil prediksi, yang meliputi tahapan sebagai berikut:

a. Skema Validasi

Untuk menjamin evaluasi performa model yang objektif dan mencerminkan kemampuan generalisasi pada data riil, penelitian ini menerapkan skema validasi *Stratified 5-Fold Group Cross Validation*. Pemilihan skema ini didasarkan pada dua alasan metodologis utama yang berkaitan dengan karakteristik dataset maternal yang digunakan:

1. Pencegahan *Data Leakage* pada Catatan Longitudinal (*Group K-Fold*)

Dataset penelitian ini bersifat longitudinal, di mana terdapat total 2.613 rekaman klinis yang berasal dari 871 responden ibu hamil unik (artinya, satu individu ibu memiliki beberapa baris data kunjungan atau pemeriksaan berkala). Dalam konteks ini, definisi kelompok (*group*) yang digunakan adalah ID unik anonim (atau NIK) dari masing-masing ibu hamil. Penggunaan *Group K-Fold* memastikan secara ketat bahwa seluruh rekam medis yang berasal dari individu ibu yang sama diisolasi secara utuh ke dalam satu *fold* tertentu (baik sepenuhnya di data *training* atau sepenuhnya di data *validation*) dan tidak terpisah antar lipatan. Jika menggunakan *cross-validation* standar, rekam medis dari individu yang sama berpotensi tersebar di kedua subset data, yang memicu terjadinya kebocoran data (*data leakage*) dan menghasilkan estimasi performa model yang terlalu optimis secara semu (*overoptimistic bias*).

2. Menjaga Konsistensi Distribusi Kelas (*Stratified*)

Komponen *Stratified* diintegrasikan untuk mempertahankan proporsi kelas target (Berisiko Stunting vs. Tidak Berisiko Stunting) agar tetap representatif dan seimbang di setiap lipatan (*fold*) pengujian, sesuai dengan distribusi pada dataset asli.

Melalui skema *5-Fold*, pada setiap iterasi pengujian, model dilatih menggunakan 80% kelompok data dan divalidasi menggunakan 20% kelompok data sisanya yang tidak tumpang tindih secara berkelompok (*group-wise*). Proses ini diulang sebanyak lima kali sehingga seluruh data berkesempatan menjadi data pengujian, dan performa akhir dilaporkan berdasarkan rata-rata dari seluruh lipatan.

b. Optimasi Model (*Hyperparameter Tuning*)

Proses optimasi model dilakukan khusus pada algoritma terbaik yang terpilih untuk memaksimalkan performa prediksinya. Proses *hyperparameter tuning* ini diimplementasikan menggunakan metode Randomized Search Cross-Validation (RandomizedSearchCV) dengan total sebanyak 50 iterasi pencarian acak di atas skema validasi silang yang telah ditentukan [19]. Penggunaan *Randomized Search* dipilih karena efisiensinya dalam mengeksplorasi ruang parameter yang luas dibandingkan dengan *Grid Search* konvensional. Ruang pencarian (*search space*) parameter yang dikonfigurasi untuk model LGBM dalam penelitian ini dirinci sebagai berikut:

- `n_estimators` (Jumlah Pohon): Rentang pencarian [100, 200, 300, 500].
- `max_depth` (Kedalaman Maksimum Pohon): Rentang pencarian [-1 (tanpa batas), 10, 20, 30].
- `num_leaves` (Jumlah Maksimum Daun): Rentang pencarian [20, 31, 50, 70].
- `learning_rate` (Tingkat Pembelajaran): Rentang pencarian [0.05, 0.1, 0.2].
- `subsample` (Rasio Sampel Baris): Rentang pencarian [0.7, 0.8, 1.0].
- `colsample_bytree` (Rasio Sampel Fitur): Rentang pencarian [0.7, 0.8, 1.0].
- `min_child_samples` (Jumlah Minimum Sampel per Daun): Rentang pencarian [10, 20, 30].

c. Metrik Evaluasi

Kinerja model diukur secara kuantitatif menggunakan *Confusion Matrix* yang mencakup komponen *True Positive* (TP), *True Negative* (TN), *False Positive* (FP), dan *False Negative* (FN). Dari komponen tersebut, diturunkan enam metrik evaluasi utama [13] :

Accuracy: Proporsi prediksi benar dari keseluruhan data.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Precision: Rasio ketepatan model dalam memberikan prediksi positif.

$$Precision = \frac{TP}{TP + FP}$$

Recall: Kemampuan model menemukan seluruh data positif yang benar.

$$Recall = \frac{TP}{TP + FN}$$

F1-Score: Rata-rata harmonis antara presisi dan *recall* untuk evaluasi yang seimbang.

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall}$$

1. Area Under the ROC Curve (ROC-AUC)

Metrik ini mengukur kemampuan model dalam membedakan antara dua kelas (Berisiko vs. Sehat) pada berbagai ambang batas keputusan (*threshold*). Kurva ROC memplot antara *True Positive Rate* (Recall) dan *False Positive Rate*. Nilai AUC yang mendekati 1,0 menunjukkan bahwa model memiliki kemampuan diskriminasi yang sangat tajam dalam mengidentifikasi ibu hamil yang berisiko tanpa mencampurnya dengan kategori sehat.

2. Precision-Recall AUC (PR-AUC)

PR-AUC merupakan metrik yang lebih spesifik dalam mengevaluasi performa model pada kelas minoritas atau kelas positif (Berisiko). Metrik ini *sangat* krusial dalam penelitian

kesehatan maternal karena fokus pada hubungan antara presisi dan *recall*. Nilai PR-AUC yang tinggi menjamin bahwa model tidak hanya mampu mendeteksi banyak kasus risiko (*Recall* tinggi), tetapi juga menjaga agar prediksi tersebut memiliki tingkat kebenaran yang tinggi (*Precision* tinggi).

D. Analisis Hasil dan Implementasi Sistem

Tahap akhir ini berfokus pada interpretasi hasil, pemilihan model terbaik, dan realisasi sistem fungsional. Setelah model juara terpilih, Analisis Ablasi akan diterapkan. Analisis ini bertujuan untuk "membedah" model dengan cara menghilangkan variabel input satu per satu dan mengukur penurunan kinerjanya [20], [21]. Hasilnya akan memberikan bukti kuantitatif mengenai faktor risiko maternal mana yang paling berpengaruh dalam penilaian risiko stunting menurut model tersebut [22]. Langkah berikutnya adalah implementasi teknis, di mana model terbaik yang telah divalidasi akan diintegrasikan ke dalam backend website pendataan DPPKB Kota Parepare. Capaian utama dari tahap ini adalah sebuah model penilaian risiko stunting yang tervalidasi serta sistem skrining dini yang fungsional dan siap untuk diuji coba di lapangan.

III. HASIL DAN PEMBAHASAN

Bagian ini menguraikan hasil eksperimen komparatif algoritma *Ensemble Learning* untuk deteksi risiko stunting prenatal, dimulai dari analisis karakteristik dataset hingga implementasi model dalam sistem pendukung keputusan. Pembahasan difokuskan pada interpretasi performa metrik evaluasi dan kontribusi fitur klinis maternal guna memberikan gambaran komprehensif mengenai efektivitas model yang dikembangkan.

A. Karakteristik Dataset

Dataset final yang digunakan dalam penelitian ini terdiri dari 871 responden ibu hamil unik di Kota Parepare untuk periode 2024–2025. Data ini merupakan hasil integrasi dari data maternal (ibu hamil) dan data pertumbuhan anak (*baduta*) yang telah melalui proses pembersihan dan anonimisasi identitas. Seluruh variabel yang hanya tersedia pasca-persalinan telah dihapus untuk menjamin integritas model sebagai alat skrining prenatal murni. Berdasarkan skema pelabelan retrospektif, diperoleh distribusi kelas target sebagai berikut:

TABLE II
DISTRIBUSI KELAS TARGET

Kategori Prediksi	Jumlah Kasus	Persentase
Positif (Berisiko Stunting)	407	46,7%
Negatif (Tidak Berisiko Stunting)	464	53,3%
Total	871	100,0%

Sebagaimana dirinci pada Tabel I, proporsi antara kelas positif (Berisiko Stunting) dan kelas negatif (Tidak Berisiko

Stunting) tergolong sangat seimbang dengan rasio mendekati 1:1. Karakteristik data yang demikian sangat menguntungkan bagi proses pelatihan model *machine learning* karena meminimalkan potensi bias klasifikasi terhadap kelas mayoritas. Oleh karena itu, penelitian ini secara metodologis tidak memerlukan implementasi teknik penanganan ketidakseimbangan data (seperti *Synthetic Minority Over-sampling Technique* atau SMOTE), karena algoritma *Ensemble Learning* yang diuji dapat mempelajari bobot dan batas keputusan (*decision boundaries*) dari kedua kelompok risiko secara objektif dan optimal.

B. Performa Model Baseline

Tahap pengujian awal dilakukan untuk membandingkan performa empat algoritma *Ensemble Learning* menggunakan parameter standar (*default*). Sebelum meninjau hasil eksperimen secara mendalam, penting untuk dipahami secara metodologis mengapa penelitian ini berfokus pada pendekatan *Ensemble Learning* dibandingkan dengan algoritma *baseline* konvensional tunggal seperti *Logistic Regression* atau *Decision Tree*. Model linier seperti *Logistic Regression* umumnya mengasumsikan hubungan linier antar variabel prediktor, sehingga sering kali mengalami *underfitting* dan gagal menangkap pola interaksi non-linear yang kompleks antara fitur klinis, antropometri, dan lingkungan maternal terhadap risiko stunting. Di sisi lain, sebuah *Decision Tree* tunggal sangat rentan terhadap varians yang tinggi (*overfitting*) pada dataset kesehatan yang heterogen dan longitudinal.

Kelemahan dari model-model dasar tunggal tersebut berhasil diatasi secara signifikan melalui pendekatan *Ensemble Learning* yang mengombinasikan ratusan *weak learners* (berupa *Decision Tree* dangkal) secara simultan (*bagging*) atau sekuensial (*boosting*). Proses agregasi dan koreksi kesalahan (*gradient boosting*) inilah yang mendasari tingginya capaian performa prediktif dalam penelitian ini. Evaluasi ini bertujuan untuk menentukan model dasar (*baseline*) yang paling efektif dalam mengenali pola risiko stunting dari fitur prenatal. Pengukuran dilakukan dengan teknik *5-Fold Stratified Group Cross Validation* untuk memastikan stabilitas nilai performa dan objektivitas evaluasi. Hasil evaluasi komparatif dari empat algoritma *Ensemble Learning* yang diuji dirinci pada Tabel III.

TABLE III
PERFORMA ALGORITMA

Model	Akurasi	Presisi	Recall	F1-Score	ROC-AUC	PR-AUC
Random Forest	89,02% ±0,31%	92,00% ±1,85%	83,87% ± 2,07%	87,70% ±0,44%	96,50%	96,39%
XGBoost	92,15% ±1,14%	93,36% ± 1,29 %	89,60% ± 2,21%	91,42% ±1,30 %	98,05%	97,92%
CatBoost	91,77% ±0,89%	94,16% ±1,39 %	87,88% ± 2.25 %	90,88% ±1,07 %	97,83%	97,74%
LGBM	92,50% ±0,80%	94,05% ± 1,89 %	89,68% ± 1.88 %	91,78% ±0,88 %	98,11 %	97,99%

Hasil pada Tabel III menunjukkan bahwa algoritma LGBM mendominasi seluruh metrik evaluasi. Pencantuman nilai standar deviasi ($\pm$) mengonfirmasi stabilitas model antar lipatan (*folds*), di mana LGBM mencatat variabilitas yang sangat rendah pada F1-Score ($\pm 0,88\%$). Hal ini membuktikan bahwa model memiliki reliabilitas yang tinggi dan tidak sensitif terhadap perubahan subset data responden. Kemampuan diskriminasi model dipertegas oleh nilai ROC-AUC (98,11%) dan PR-AUC (97,99%) yang hampir sempurna, menandakan bahwa LGBM sangat handal dalam memisahkan kategori berisiko dan tidak berisiko bahkan pada data yang memiliki ketidakseimbangan kelas.

Keunggulan LGBM dipicu oleh arsitektur pertumbuhan *leaf-wise* serta teknik *Gradient-based One-Side Sampling* (GOSS) dan *Exclusive Feature Bundling* (EFB) yang secara efisien menangani fitur klinis maternal yang kompleks. Algoritma ini sangat cocok diterapkan pada karakteristik data di Kota Parepare yang merupakan data administratif dengan variabilitas tinggi. Kemampuan GOSS dalam memprioritaskan data dengan gradien *error* besar memungkinkan model untuk belajar lebih dalam pada kasus-kasus risiko *stunting* yang krusial. Namun, hasil tinggi ini tetap disikapi dengan prinsip kehati-hatian klinis. Model ini diposisikan sebagai instrumen skrining pendukung (*early warning system*) bagi petugas kesehatan di Parepare untuk memprioritaskan intervensi, bukan sebagai alat diagnosis mutlak. Limitasi pada penelitian ini tetap berpijak pada kualitas data sekunder, sehingga verifikasi lapangan dan pemantauan medis secara langsung tetap menjadi prosedur utama dalam penentuan status risiko kesehatan ibu dan janin.

C. Optimasi melalui Hyperparameter Tuning


Tahap optimasi dilakukan pada model terbaik, yaitu LGBM, menggunakan metode *Randomized Search CV*. Proses ini bertujuan untuk mengeksplorasi ruang parameter guna menemukan kombinasi yang memberikan keseimbangan optimal antara bias dan varians. Tabel 2 merinci sepuluh kombinasi *hyperparameter* terbaik yang menghasilkan skor performa tertinggi selama proses validasi silang.

Berdasarkan hasil tuning tersebut, model LGBM mencapai performa puncak dengan *Mean Test Score* (*F1-Score*) sebesar **94,34%**. Parameter kunci yang berkontribusi pada peningkatan ini adalah pengaturan *Learning Rate* sebesar 0,2 dan jumlah pohon (*n_estimators*) sebanyak 300, yang memungkinkan model untuk belajar secara lebih mendalam tanpa terjebak dalam *overfitting*. Peningkatan performa secara keseluruhan setelah proses tuning dibandingkan dengan model *baseline* divisualisasikan dalam Gambar 2

TABLE IV
HASIL OPTIMASI HYPERPARAMETER TUNING

Num_leaves	n_estimators	min_child_samples	Max_depth	Learning_rate	colsample_bytree	mean_test_score
20	300	10	10	0,2	1,0	94,34%
50	200	20	30	0,2	1,0	93,69 %
31	200	10	-1	0,2	0,8	93,55 %
50	100	10	20	0,2	1,0	93,51 %
20	200	10	-1	0,2	0,8	93,43 %
20	500	10	-1	0,05	1,0	93,39 %
31	300	30	30	0,2	0,7	93,35 %
70	500	30	30	0,2	1,0	93,34 %
50	300	30	30	0,1	0,8	93,28 %
50	500	20	-1	0,05	0,7	93,28 %

Perbandingan Performa LightGBM
(Before vs After Tuning)



Gambar 2. Metrik Evaluasi Setelah dan Sebelum Optimasi

Gambar 2 memperlihatkan bahwa seluruh metrik evaluasi (Akurasi, Presisi, *Recall*, dan *F1-Score*) mengalami kenaikan yang konsisten. Keberhasilan optimasi ini membuktikan bahwa penyesuaian parameter eksternal secara strategis sangat krusial dalam memaksimalkan potensi algoritma.

Guna mempertegas kontribusi ilmiah dan posisi penelitian ini di antara rekam jejak studi terdahulu, dilakukan analisis

perbandingan (*benchmarking*) terhadap performa model prediktif yang dihasilkan. Mayoritas penelitian sebelumnya berfokus pada fase postnatal (setelah anak lahir) untuk memprediksi kejadian stunting menggunakan algoritma konvensional. Sebagai contoh, penelitian oleh Indra [16] menggunakan *Support Vector Machine* (SVM) untuk klasifikasi stunting balita dan mencatatkan akurasi sebesar 82,10%. Selanjutnya, Hidayat dkk. [19] menerapkan kombinasi SVM dan SMOTE pada data balita dengan capaian akurasi sebesar 86,45%.


Berbeda dengan studi-studi tersebut, penelitian ini berhasil menggeser fokus deteksi ke hulu pada fase prenatal (masa kehamilan) menggunakan pendekatan *Ensemble Learning* berbasis LGBM yang dioptimasi dengan *Randomized Search CV*. Hasil eksperimen menunjukkan bahwa model yang dikembangkan dalam penelitian ini meraih performa yang jauh lebih unggul dengan akurasi mencapai 94,50% dan *F1-Score* 94,34%. Lonjakan performa yang signifikan ini membuktikan bahwa pemanfaatan indikator maternal longitudinal yang heterogen, dikombinasikan dengan arsitektur pertumbuhan *leaf-wise* pada LGBM, memiliki kapabilitas yang jauh lebih adaptif dan presisi tinggi dalam mengeksplorasi batas keputusan komputasi pada domain risiko kesehatan prenatal dibandingkan model tunggal tradisional pada fase postnatal.

Capaian nilai *F1-Score* sebesar 94,34% dan akurasi 94,50% setelah proses *tuning* ini tergolong sangat tinggi untuk sebuah model prediksi berbasis data maternal. Namun, tingginya performa ini dipastikan merupakan representasi objektif dari kapabilitas prediktif model dan bukan akibat anomali metodologis seperti *data leakage* atau dataset yang terlalu homogen.

Pertama, dari aspek mitigasi kebocoran data (*data leakage*), penelitian ini melakukan isolasi fitur secara absolut sejak tahap pra-pemrosesan data. Fitur-fitur yang bersifat postnatal atau baru tersedia setelah bayi lahir (seperti berat dan tinggi badan lahir anak) dikeluarkan sepenuhnya dari matriks prediktor (*feature space*), dan murni hanya digunakan sebagai instrumen pembentukan label target retrospektif. Ditambah dengan penerapan *Stratified 5-Fold Group Cross Validation* berbasis ID unik ibu secara ketat, risiko kebocoran informasi antar lipatan (*inter-fold leakage*) pada data longitudinal dapat dieliminasi secara total. Dengan demikian, model terbukti melakukan inferensi murni berdasarkan indikator kehamilan maternal (*prenatal markers*).

Kedua, tingginya akurasi ini tidak dipicu oleh karakteristik data yang seragam atau terlalu homogen. Dataset sekunder dari DPPKB Kota Parepare ini mencakup 10 fitur prediktor multisektoral yang memiliki variabilitas kompleks di lapangan, meliputi aspek demografi, antropometri gizi (IMT dan LILA), kondisi klinis longitudinal (kadar hemoglobin dan TFU), hingga faktor eksternal lingkungan dan perilaku. Kombinasi fitur linear dan non-linear yang heterogen ini berhasil diekstraksi secara optimal oleh arsitektur pertumbuhan *leaf-wise* pada LightGBM. Kemampuan teknik GOSS dalam memprioritaskan sampel data dengan gradien kesalahan (*error gradients*) besar memungkinkan LGBM untuk memetakan pola risiko yang samar secara agresif tanpa mengalami *overfitting*.

Untuk melihat dampak proses optimasi terhadap kemampuan klasifikasi model secara lebih mendalam, dilakukan evaluasi menggunakan *Confusion Matrix* untuk mengidentifikasi kesalahan klasifikasi sebelum dan setelah proses *hyperparameter tuning*.



Gambar 3. Confusion Matrix

Berdasarkan Gambar 3, Hasil Confusion Matrix sebelum dan setelah di lakukan optimasi di temukan bahwa pada aspek Recall (Sensitivity) kelas berisiko, yang menjadi indikator utama keberhasilan skrining kesehatan maternal. Sebelum dilakukan *tuning*, terdapat 25 kasus *False Negative* (FN), di mana ibu yang sebenarnya berisiko gagal terdeteksi oleh

sistem. Setelah proses optimasi, jumlah FN berhasil ditekan hingga menjadi 17 kasus (penurunan sebesar 32%). Peningkatan nilai *True Positive* (TP) dari 219 menjadi 227 secara langsung meningkatkan nilai *Recall*, yang berarti model menjadi jauh lebih sensitif dan "waspada" dalam mengidentifikasi sinyal risiko *stunting* prenatal.

Penurunan nilai FN ini sangat krusial secara klinis yaitu setiap angka FN yang berkurang merepresentasikan ibu hamil berisiko yang kini dapat terjaring oleh sistem untuk mendapatkan intervensi dini. Sementara itu, penurunan *False Positive* (FP) dari 14 menjadi 10 kasus menunjukkan bahwa model juga semakin presisi, sehingga mengurangi beban kerja petugas lapangan dari peringatan palsu yang tidak perlu. Analisis terhadap sisa 17 kasus FN yang belum terdeteksi menunjukkan bahwa data tersebut memiliki profil fitur klinis yang sangat mendekati ambang batas normal (*borderline cases*), sehingga menciptakan ambiguitas pada proses percabangan pohon keputusan LGBM. Namun secara keseluruhan, pergeseran angka dari FN ke TP ini mengonfirmasi bahwa *hyperparameter tuning* berhasil mengoptimasi model untuk lebih mengutamakan keselamatan maternal melalui penguatan deteksi pada kelompok berisiko tinggi di Kota Parepare.


Tingginya performa prediktif model setelah proses *tuning* tetap menuntut adanya diskusi mendalam dari aspek etika implementasi kecerdasan buatan (*AI Ethics*) pada domain klinis maternal. Dalam konteks penentuan kebijakan kesehatan masyarakat, kesalahan prediksi biner pada *Confusion Matrix* membawa konsekuensi etis dan logistik yang berbeda nyata. Kasus *False Negative* (FN) di mana ibu hamil yang secara aktual berisiko tinggi namun salah diprediksi sebagai kategori normal oleh model memiliki risiko etis tertinggi karena hilangnya peluang emas (*golden opportunity*) bagi janin untuk mendapatkan intervensi gizi preventif di masa kehamilan, yang secara jangka panjang berpotensi melanggengkan kejadian *stunting* fisik pasca-persalinan.

Di sisi lain, kasus *False Positive* (FP) di mana ibu hamil ber kondisi sehat namun salah diklasifikasikan sebagai berisiko oleh model membawa dilema etika berupa potensi pemborosan alokasi anggaran intervensi gizi spesifik dari pemerintah serta risiko psikologis berupa kecemasan berlebih (*unnecessary anxiety*) bagi ibu hamil dan keluarganya. Oleh karena itu, keberhasilan optimasi model dalam menekan angka FN sebesar 32% dan FP sebesar 28% dalam penelitian ini bukan sekadar pencapaian metrik komputasi, melainkan sebuah bentuk pertanggungjawaban etis sistem cerdas untuk meminimalkan dampak buruk maldiagnosis komputasional di lapangan sebelum sistem diimplementasikan secara luas.

D. Analisis Ablasi

Tahap Tahap akhir dalam analisis hasil adalah pelaksanaan Analisis Ablasi yang bertujuan untuk membedah tingkat kontribusi fungsional dari setiap variabel prediktor terhadap kinerja model LGBM. Untuk memperkuat interpretasi model sesuai prinsip *Explainable AI* (XAI), proses ini tidak hanya

mengandalkan fitur penting bawaan pohon (*feature importance*), melainkan dilakukan dengan menguji dampak penghapusan fitur secara sistematis menggunakan skema latih-ulang berbasis *Stratified 5-Fold Group Cross Validation* dan mengamati penurunan nilai *F1-Score* dari skor puncak sebesar 94,34%. Dampak dari penghapusan variabel-variabel tersebut divisualisasikan dalam Gambar 4.



Gambar 4. Analisis Ablasi

Berdasarkan Gambar 4, Usia Ibu Hamil teridentifikasi sebagai prediktor paling dominan dengan penurunan *F1-Score* paling signifikan, yakni sebesar 3,07%. Secara medis, usia ibu menentukan kualitas sel telur dan fungsi plasenta yang bersifat fundamental sejak awal kehamilan. Usia kehamilan yang terlalu muda (< 20 tahun) atau terlalu tua (> 35 tahun) secara biologis berkaitan erat dengan ketidakmatangan atau degradasi sistem vaskular uterus, yang menghambat transfer nutrisi optimal ke janin sehingga memicu *intrauterine growth restriction* (IUGR) sebagai cikal bakal stunting [9]. Di posisi berikutnya, variabel Tinggi Badan (penurunan 2,98%), Usia Anak Terakhir (2,82%), dan Berat Badan Sebelum Hamil (2,23%) menjadi fitur penyokong utama yang merepresentasikan status gizi kronis serta riwayat reproduksi ibu jauh sebelum masa kehamilan dimulai. Tinggi badan ibu yang pendek (< 145 cm) mencerminkan masalah gizi masa lalu (*intergenerational cycle of malnutrition*) yang membatasi kapasitas rongga panggul dan volume uterus [12]. Selain itu, variabel Usia Anak Terakhir yang merepresentasikan jarak kehamilan terlalu dekat (< 24 bulan) memicu terjadinya *maternal depletion syndrome*, suatu kondisi di mana cadangan zat gizi mikro (seperti zat besi dan kalsium) pada tubuh ibu belum pulih sepenuhnya dari proses laktasi dan persalinan sebelumnya [11]. Model LGBM mengenali bahwa kondisi-kondisi tersebut memiliki kecenderungan lebih tinggi untuk memicu hambatan pertumbuhan janin terlepas dari intervensi gizi selama kehamilan berjalan.

Meskipun variabel statis menjadi penentu utama, variabel longitudinal seperti Kadar Hemoglobin dan LILA bertindak sebagai fitur pemantau dinamis yang menyempurnakan penilaian risiko model. Kemampuan model dalam menangkap perubahan data dinamis ini membuktikan bahwa sistem berfungsi sebagai instrumen pemantauan kesehatan yang responsif dan tidak hanya melakukan klasifikasi statis. Hal ini memberikan peluang bagi tenaga kesehatan untuk melihat

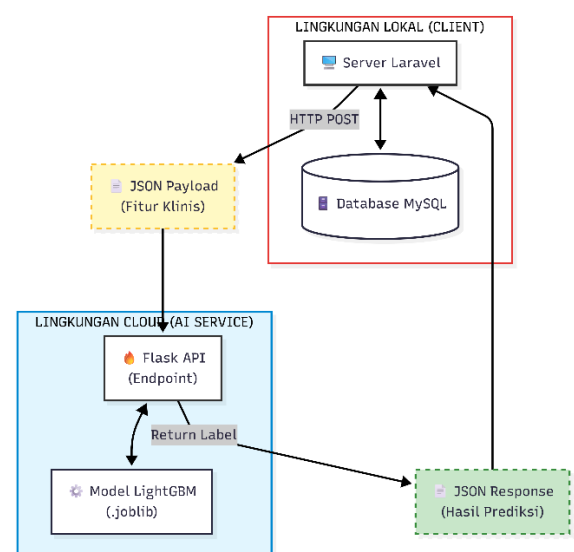
efektivitas intervensi gizi, jika indikator kesehatan ibu membaik dan risiko menurun pada trimester berikutnya, hal tersebut menjadi indikator keberhasilan penanganan prenatal dalam mencegah potensi stunting.

E. Implementasi Sistem

Bagian ini menguraikan transformasi model LGBM yang telah dioptimasi ke dalam prototipe sistem cerdas berbasis web untuk membantu tenaga kesehatan dalam deteksi dini risiko stunting secara *real-time*.

a. Arsitektur Integrasi Model (*Model Deployment*)

Model LightGBM (LGBM) yang telah dioptimasi diintegrasikan ke dalam sistem menggunakan arsitektur *Cloud-Based Microservices* yang memisahkan unit penyimpanan data dengan unit pemrosesan kecerdasan buatan guna menjaga stabilitas performa sistem, seperti yang ditunjukkan pada Gambar 5. Pada sisi *client* (Lingkungan Lokal), server utama berbasis Laravel bertugas mengelola logika bisnis dan terhubung secara langsung dengan Database MySQL untuk menyimpan rekam medis maternal responden secara permanen. Sementara itu, pada sisi *AI Service* (Lingkungan Cloud), model LGBM dideploy pada server khusus di Hugging Face Spaces dalam format binari *.joblib* dengan menggunakan *framework* Flask/Python yang dikonfigurasi sebagai *endpoint* RESTful API. Mekanisme pertukaran data dilakukan secara asinkronus di mana server Laravel mengemas fitur-fitur klinis maternal ke dalam JSON Payload dan mengirimkannya menggunakan metode HTTP POST menuju *endpoint* Flask. Setelah mesin inferensi di *cloud* selesai memproses data tersebut, hasilnya dikembalikan ke server lokal dalam format JSON Response berupa label prediksi biner (0 atau 1) secara *real-time*. Penerapan arsitektur ini menjamin efisiensi komputasi karena beban kalkulasi algoritma *Ensemble Learning* sepenuhnya diisolasi di lingkungan *cloud*, sehingga server lokal instansi terkait tidak terbebani dan aplikasi tetap berjalan dengan responsif.



Gambar 5. Arsitektur Integrasi

b. Fungsionalitas Antarmuka dan Visualisasi


Sistem dikembangkan untuk memproses data klinis maternal secara terstruktur dan menyajikan hasil analisis risiko secara dinamis. Pemrosesan data mencakup variabel statis (demografi dan antropometri awal) serta variabel dinamis yang diperbarui secara berkala pada tiap trimester. Setiap kali terjadi pembaruan data kunjungan klinis baru (seperti Kadar Hemoglobin, TFU, dan Berat Badan), sistem akan memicu proses inferensi ulang secara otomatis melalui API endpoint. Mekanisme ini memungkinkan pemantauan tren kesehatan ibu hamil secara longitudinal guna mendeteksi fluktuasi risiko selama masa kehamilan.

Gambar 6. Formulir Input

Hasil klasifikasi model disajikan dalam bentuk label "Berisiko" atau "Tidak Berisiko" pada daftar ibu hamil. Untuk mempermudah pengambilan keputusan oleh instansi terkait seperti DPPKB Kota Parepare, sistem mengintegrasikan hasil penilaian risiko dengan fitur pemetaan geografis (*Geospatial Mapping*).

No	NIK	Nama	Rekomendasi	Status	Aksi
1	72457900101000	Ibu Nurul Sakila	Berisiko	Tidak Berisiko	
2	724568912569000	Ibu Nurul Sah	Ujung	Berisiko	
3	820383810209999	Ibu Nurul Saif	Ujung	Tidak Berisiko	
4	820383810209999	Ibu Nurul Saif	Berisiko	Tidak Berisiko	
5	820383810209999	Ibu Nurul Saif	Ujung	Berisiko	
6	820383810209999	Ibu Nurul Saif	Berisiko	Tidak Berisiko	
7	223340772222222	Ibu Nurul Saif	Ujung	Tidak Berisiko	
8	223340772222222	Ibu Nurul Saif	Berisiko	Tidak Berisiko	
9	223340772222222	Ibu Nurul Saif	Berisiko	Berisiko	
10	888282828282828	Ibu Nurul Saif	Berisiko	Berisiko	

Gambar 7. Hasil Prediksi



Gambar 8. Visualisasi peta persebaran

Sistem secara otomatis memetakan titik koordinat tempat tinggal ibu hamil yang teridentifikasi masuk dalam kategori

risiko tinggi secara real-time. Visualisasi spasial ini berfungsi untuk mengidentifikasi kluster wilayah dengan konsentrasi risiko stunting tinggi, sehingga pihak pengelola kesehatan dapat melakukan alokasi sumber daya, intervensi gizi, dan pendampingan lapangan secara lebih efektif, tepat sasaran, dan responsif. Secara praktis, ketika sistem memberikan label "Berisiko" pada seorang ibu hamil, hasil prediksi tersebut langsung ditransformasikan menjadi rekomendasi tindakan klinis terstruktur bagi Tim Pendamping Keluarga (TPK) Kota Parepare melalui tiga jalur intervensi hulu.

Ibu hamil dengan status risiko tinggi akan langsung diprioritaskan untuk masuk ke dalam program intervensi spesifik gizi tinggi, seperti pemberian makanan tambahan berbasis pangan lokal secara berkelanjutan serta pengawasan ketat terhadap konsumsi tablet tambah darah guna menekan prevalensi anemia prenatal. Selain itu, status risiko ini memicu TPK untuk melakukan pendampingan dan edukasi intensif melalui kunjungan rumah (home visit) secara lebih berkala guna memantau indikator longitudinal seperti lingkaran lengan atas dan kepatuhan perilaku hidup sehat. Apabila parameter klinis dinamis seperti tinggi fundus uteri atau kadar hemoglobin menunjukkan tren yang terus memburuk selama trimester berjalan, sistem ini mempermudah TPK dalam mempercepat rujukan ke fasilitas kesehatan primer atau puskesmas setempat. Dengan demikian, visualisasi geospasial pada sistem ini tidak hanya berfungsi sebagai peta sebaran statis, melainkan bertindak sebagai instrumen triase digital fungsional yang memandu TPK dalam mengoptimalkan keterbatasan anggaran dan personel untuk melakukan intervensi gizi langsung pada kluster wilayah yang paling membutuhkan.

c. Karakteristik Desain dan Analisis Efisiensi Sistem

Fokus utama pada fase implementasi awal ini adalah memastikan stabilitas fungsionalitas sistem melalui konfigurasi arsitektur *cloud-based microservices* yang dirancang spesifik untuk menjamin efisiensi komputasi dan responsivitas layanan. Oleh karena itu, pengujian beban (*load testing*) multipengguna secara masif dijadwalkan pada tahap pengembangan berikutnya seiring dengan perluasan skala operasional sistem di lingkungan produksi. Desain sistem menerapkan prinsip pemisahan beban kerja (*decoupling technique*), di mana server lokal berbasis Laravel murni mengelola logika bisnis dan basis data, sedangkan proses kalkulasi model *Ensemble Learning* diisolasi penuh pada *endpoint* RESTful API Hugging Face Spaces. Melalui mekanisme pertukaran data asinkronus menggunakan *JSON payload*, server lokal terbebas dari beban komputasi penelusuran pohon keputusan LightGBM yang kompleks. Karakteristik *decoupling* ini secara teoretis menjamin skalabilitas horizontal dan reliabilitas sistem, sehingga mencegah terjadinya penurunan performa aplikasi (*latency*) pada sisi pengguna lokal saat petugas lapangan melakukan input data secara simultan.

Selain itu, efisiensi pada modul *geospatial mapping* sebaran risiko stunting dioptimalkan melalui pendekatan *client-side*

rendering menggunakan framework Vue.js. Data spasial koordinat wilayah di Kota Parepare ditransmisikan dalam struktur format GeoJSON yang sangat ringan. Dengan demikian, visualisasi peta persebaran risiko stunting pada antarmuka pengguna dapat dirender secara instan tanpa memicu beban memori (*memory overhead*) pada server utama. Evaluasi performa sistem secara kuantitatif—mencakup pengukuran waktu respons (*response time*), tingkat konkurensi, dan reliabilitas jaringan di lingkungan produksi—akan dijadwalkan sebagai bagian dari rencana studi prospektif jangka panjang bersama pihak DPPKB Kota Parepare.

IV. KESIMPULAN

Penelitian ini berhasil mengembangkan model penilaian risiko *stunting* prenatal dengan memanfaatkan algoritma *Ensemble Learning* berbasis data maternal longitudinal. Hasil analisis komparatif menunjukkan bahwa algoritma *Light Gradient Boosting Machine* (LGBM) memberikan performa paling unggul dibandingkan dengan *Random Forest*, *XGBoost*, dan *CatBoost*. Setelah dilakukan optimasi melalui *hyperparameter tuning*, model LGBM mencapai performa optimal dengan skor *F1-Score* sebesar 94,34% serta menunjukkan stabilitas yang baik pada pengujian data lokal. Melalui analisis ablasi, ditemukan bahwa variabel usia ibu hamil, tinggi badan, dan riwayat kesehatan (jarak kelahiran/usia anak terakhir) merupakan prediktor paling signifikan dalam mengidentifikasi risiko *stunting* sejak masa kehamilan. Secara praktis, model terbaik telah diintegrasikan ke dalam infrastruktur digital DPPKB Kota Parepare melalui arsitektur *cloud-based microservices*. Sistem ini berfungsi sebagai instrumen pendukung keputusan (*Decision Support System*) yang menyajikan visualisasi data geospasial dan pemantauan tren kesehatan maternal secara *real-time*. Meskipun menunjukkan hasil yang menjanjikan pada dataset Kota Parepare, efektivitas model ini tetap memiliki limitasi pada ketergantungan kualitas data sekunder serta karakteristik administratif lokal.

Sebagai rencana jangka panjang untuk mengatasi keterbatasan generalisasi tersebut, penelitian selanjutnya akan difokuskan pada dua agenda validasi utama sebelum model diimplementasikan secara luas. Pertama, melakukan validasi eksternal (*external validation*) dengan menguji arsitektur model *LightGBM* yang telah dilatih menggunakan dataset maternal dari wilayah administrasi lain di Sulawesi Selatan yang memiliki variabilitas sosial-ekonomi berbeda. Kedua, menginisiasi studi prospektif (*prospective cohort study*) secara riil di lapangan melalui integrasi sistem pendukung keputusan yang telah dibangun bersama Tim Pendamping Keluarga (TPK) Kota Parepare. Langkah prospektif ini bertujuan untuk melacak dan memverifikasi akurasi prediksi model pada kelompok ibu hamil baru secara *real-time* hingga periode persalinan selesai. Melalui kombinasi validasi eksternal dan studi prospektif ini, keandalan (*robustness*) serta nilai guna klinis model sebagai instrumen pencegahan *stunting* prenatal dari hulu dapat dibuktikan secara empiris

dan menyeluruh. Penelitian ini membuktikan bahwa integrasi *machine learning* pada fase prenatal dapat menjadi solusi strategis dalam upaya deteksi dini, namun tetap harus diposisikan sebagai alat bantu skrining yang mendampingi verifikasi klinis tenaga kesehatan di lapangan.

DAFTAR PUSTAKA

- [1] World Health Organization, "Malnutrisi," World Health Organization. Accessed: May 15, 2026. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/malnutrition>
- [2] A. Heryati, D. Marcelina, and H. Romli, "Optimization of Stunting Risk Prediction Using a Hybrid Genetic-Machine Learning Model," *J. Artif. Intell. Softw. Eng.*, vol. 5, no. 2, pp. 807–815, 2025, doi: 10.30811/jaise.v5i2.6988.
- [3] K. S. R. I. Negara, "Buka Rakornas Stunting, Wapres Ungkap Keberhasilan Pemerintah Turunkan Prevalensi Lima Tahun Terakhir," Kementerian Sekretariat Negara Republik Indonesia. Accessed: May 16, 2026. [Online]. Available: https://www.setneg.go.id/Baca/Index/Buka_Rakornas_Stunting_Wapres_Ungkap_Keberhasilan_Pemerintah_Turunkan_Prevalensi_Lima_Tahun_Terakhir
- [4] K. R. Syukrina, Erika, and O. Hasanah, "Faktor-faktor yang Menyebabkan Stunting pada Balita: Sebuah Studi Literatur," *J. Med. Utama*, vol. 5, no. 02 Januari, pp. 3854–3867, 2024.
- [5] A. N. Sartika, M. Khoirunnisa, E. Meiyetrisani, E. Ermayani, I. L. Pramesthi, and A. J. Nur Ananda, "Prenatal and postnatal determinants of stunting at age 0–11 months: A cross-sectional study in Indonesia," *PLoS One*, vol. 16, no. 7 July, pp. 1–14, 2021, doi: 10.1371/journal.pone.0254662.
- [6] P. L. Rosida, M. Nurmalarani, and D. Krismawati, "Implementasi Decision Tree untuk Prediksi Kelahiran Bayi Prematur Decision Tree Implementation for Premature Birth Prediction," vol. 14, pp. 178–186, 2024.
- [7] U. R. Gurning, S. F. Octavia, and D. R. Andriyani, "Prediction of Stunting Risk In Families Using Naïve Bayes Classifier and Chi-Square Prediksi Risiko Stunting pada Keluarga Menggunakan Naïve Bayes Classifier dan Chi-Square," vol. 4, no. January, pp. 172–180, 2024.
- [8] D. M. Puspita, K. I. Santoso, A. Triyono, E. Supriyadi, and S. Agus, "Algoritma Random Forest , Decision Tree dan XGboost Untuk Klasifikasi Stunting Pada Balita," vol. 23, no. 1, pp. 67–76, 2025.
- [9] R. Ratnasari, A. J. Wahidin, and T. H. Andika, "Deteksi Dini Stunting Pada Anak Berdasarkan Indikator Antropometri dengan Menggunakan Algoritma Machine Learning," *J. Algoritma*, vol. 21, no. 2, pp. 378–387, 2024, doi: 10.33364/algoritma/v.21-2.2122.
- [10] G. S. Azahra and M. D. Kartikasari, "Child Stunting Classification using the LightGBM Method: A Case Study in the Rowosari District of Kendal , Central Java," vol. 8, no. 1, pp. 102–113, 2025.
- [11] L. Fitriani, S. Wahyuni, and . N., "Penyuluhan Upaya Pencegahan Stunting Sejak Masa Kehamilan," *J. Abdimas ITEKES Bali*, vol. 2, no. 2, pp. 84–88, 2023, doi: 10.37294/jai.v2i2.454.
- [12] O. Pahlevi, D. Ayu, L. K. Rahayu, H. Leidiyana, and Y. Handrianto, "Model Klasifikasi Risiko Stunting Pada Balita Menggunakan Algoritma CatBoost Classifier," *Bull. Comput. Sci. Res.*, vol. 6, no. 4, pp. 414–421, 2024, doi: 10.47065/bulletincsr.v4i6.373.
- [13] W. Richard, P. Thangata, B. Mkwandawire, and N. Amoah, "Human Nutrition & Metabolism Advancing predictive analytics in child malnutrition : Machine , ensemble and deep learning models with balanced class distribution for early detection of stunting and wasting," *Hum. Nutr. Metab.*, vol. 42, no. August, p. 200340, 2025, doi: 10.1016/j.hnm.2025.200340.
- [14] O. Pahlevi, D. Ayu, N. Wulandari, L. K. Rahayu, H. Leidiyana, and Y. Handrianto, "BULLETIN OF COMPUTER SCIENCE RESEARCH Model Klasifikasi Risiko Stunting Pada Balita Menggunakan Algoritma CatBoost Classifier," vol. 6, no. 4, pp. 414–421, 2024, doi: 10.47065/bulletincsr.v4i6.373.

- [15] M. S. Haris, A. N. Khudori, and W. T. Kusuma, "Perbandingan Metode Supervised Machine Learning untuk Prediksi Prevalensi Stunting di Provinsi Jawa Timur," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 9, no. 7, p. 1571, 2022, doi: 10.25126/jtiik.2022976744.
- [16] R. Romlah, S. Faisal, R. Rahmat, and J. Indra, "Prediksi Risiko Angka Stunting Pada Balita Menggunakan Algoritma Support Vector Machine," *J. Inform. Teknol. dan Sains*, vol. 7, no. 2, pp. 837–842, 2025, doi: 10.51401/jinteks.v7i2.5749.
- [17] M. A. Rayadin, M. Musaruddin, and R. A. Saputra, "Implementasi Ensemble Learning Metode XGBoost dan Random Forest untuk Prediksi Waktu Penggantian Baterai Aki," vol. 5, no. 2, pp. 111–119, 2024.
- [18] V. I. Ivanoti, M. H. P, G. Triyono, D. P. Utami, U. B. Luhur, and I. Technology, "Decision Support System For Predicting Employee Leave Using The Light Gradient Boosting Machine (Lightgbm) And K-Means," vol. 4, no. 3, pp. 657–667, 2023.
- [19] T. Hidayat, I. Sembiring, H. D. Purnomo, and A. Iriani, "Prediksi Prevalensi Stunting Balita dengan Pendekatan Algoritma Support Vector Machine dan Synthetic Minority Oversampling Technique (SMOTE)," *J. Pekommas*, vol. 10, no. 1, pp. 9–16, 2025, doi: 10.56873/jpkm.v9i1.5389.
- [20] R. Meyes, M. Lu, C. W. de Puiseau, and T. Meisen, "Ablation Studies in Artificial Neural Networks," pp. 1–19, 2019.
- [21] E. Sugianti, A. Buanasita, H. Hidayanti, and B. D. Putri, "Analisis faktor ibu terhadap kejadian stunting pada balita usia 24-59 bulan di perkotaan Maternal factor analysis on stunting incidence among children aged 24-59 months in urban areas Abstrak Pendahuluan Metode," vol. 8, no. 1, pp. 30–42, 2023.
- [22] L. M. Cendani and A. Wibowo, "Perbandingan Metode Ensemble Learning pada Klasifikasi Penyakit Diabetes," vol. 13, no. 1, pp. 33–44, 2022.