



Model Klasifikasi Risiko Stunting Pada Balita Menggunakan Algoritma *CatBoost Classifier*

Omar Pahlevi^{1,*}, Dewi Ayu Nur Wulandari¹, Luci Kanti Rahayu¹, Henny Leidiyana¹, Yopi Handrianto²

¹ Program Studi Sistem Informasi, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika, Jakarta, Indonesia

² Program Studi Teknologi Informasi, Fakultas Teknik dan Informatika, Universitas Bina Sarana Informatika, Jakarta, Indonesia

Email: ^{1,*}omar.opi@bsi.ac.id, ²dewi.dan@bsi.ac.id, ³luci.lkr@bsi.ac.id, ⁴henny.hnl@bsi.ac.id, ⁵yopi.yph@bsi.ac.id

Email Penulis Korespondensi: omar.opi@bsi.ac.id

Abstrak—*Stunting* merupakan masalah kesehatan yang signifikan di Indonesia, mempengaruhi pertumbuhan dan perkembangan anak balita yang dipengaruhi oleh berbagai faktor risiko kompleks, seperti gizi, lingkungan, dan akses terhadap layanan kesehatan. Proses identifikasi risiko *stunting* secara manual sering kali memerlukan waktu dan sumber daya yang besar, serta keahlian khusus dari tenaga medis. Penelitian ini bertujuan untuk mengembangkan model klasifikasi risiko *stunting* pada balita dengan menggunakan *machine learning* melalui algoritma *CatBoost Classifier*. Algoritma ini dipilih karena keunggulannya dalam menangani variabel kategorikal tanpa memerlukan proses *encoding* yang rumit, serta kemampuannya dalam mengatasi data yang tidak seimbang, yang pada akhirnya meningkatkan akurasi prediksi. Dalam studi kasus yang dilakukan, pembaruan prediksi model diilustrasikan melalui peningkatan prediksi awal sebesar 0,25 menjadi 0,27 setelah memperhitungkan koreksi residual pada iterasi pertama, dengan *learning rate* sebesar 0,1. Proses ini menunjukkan cara kerja *CatBoost* yang iteratif dalam memperbaiki prediksi model melalui pembaruan bertahap. Hasil evaluasi menunjukkan bahwa model yang dibangun mencapai akurasi sebesar 98,47% dan nilai ROC-AUC sebesar 1,00 untuk beberapa kelas, yang menandakan kemampuan tinggi dalam mengklasifikasikan risiko *stunting* dengan akurat. Temuan ini mengindikasikan bahwa algoritma *CatBoost* efektif untuk klasifikasi risiko *stunting*, mampu menangani kompleksitas data, dan diharapkan dapat memberikan kontribusi signifikan dalam mendukung upaya pencegahan *stunting* melalui deteksi dini yang lebih baik.

Kata Kunci: *CatBoost Classifier*; *Machine Learning*; Model Klasifikasi; Risiko *Stunting*; Variabel Kategorikal

Abstract—*Stunting* is a significant health issue in Indonesia, affecting the growth and development of young children and influenced by various complex risk factors such as nutrition, environment, and access to healthcare services. The manual process of identifying *stunting* risks often requires considerable time, resources, and specialized expertise from medical professionals. This study aims to develop a *stunting* risk classification model for young children using machine learning through the *CatBoost Classifier* algorithm. This algorithm was chosen for its advantages in handling categorical variables without requiring complex encoding processes and its ability to manage imbalanced data, ultimately improving prediction accuracy. In the conducted case study, the model's prediction updates were illustrated by increasing the initial prediction from 0.25 to 0.27 after accounting for residual corrections in the first iteration, with a learning rate of 0.1. This process demonstrates *CatBoost*'s iterative mechanism for improving model predictions through gradual updates. Evaluation results showed that the developed model achieved an accuracy of 98.47% and a ROC-AUC score of 1.00 for several classes, indicating a high capability in accurately classifying *stunting* risks. These findings suggest that the *CatBoost* algorithm is effective for *stunting* risk classification, capable of handling data complexity, and expected to contribute significantly to supporting *stunting* prevention efforts through improved early detection.

Keywords: *CatBoost Classifier*; *Machine Learning*; Classification Model; *Stunting Risk*; Categorical Variable

1. PENDAHULUAN

Stunting merupakan salah satu permasalahan kesehatan utama yang dihadapi Indonesia, terutama dalam hal pertumbuhan dan perkembangan anak. Berdasarkan data dari Survei Status Gizi Balita Indonesia (SSGBI) 2021, sekitar 24,4% balita di Indonesia mengalami *stunting* [1]. Angka ini masih jauh dari target yang ditetapkan oleh pemerintah Indonesia melalui Rencana Pembangunan Jangka Menengah Nasional (RPJMN) 2020-2024, yaitu menurunkan prevalensi *stunting* hingga 14% pada tahun 2024 [2]. *Stunting* bukan hanya masalah gizi buruk yang menyebabkan tubuh anak tidak tumbuh optimal, tetapi juga berpengaruh signifikan terhadap perkembangan kognitif dan kemampuan belajar anak [3]. Faktor penyebab *stunting* cukup kompleks, meliputi aspek gizi, pola asuh, sanitasi lingkungan, serta akses terhadap layanan kesehatan [4]. Kompleksitas ini menjadi tantangan dalam mengidentifikasi risiko *stunting* secara manual melalui pengukuran fisik dan wawancara, yang sering kali membutuhkan waktu dan sumber daya yang besar. Selain itu, variasi faktor risiko yang memengaruhi *stunting* sulit untuk diidentifikasi secara cepat dan tepat oleh tenaga kesehatan. Oleh karena itu, terdapat urgensi untuk mengembangkan solusi untuk mendeteksi risiko *stunting*, sehingga upaya pencegahan dapat dilakukan secara lebih tepat waktu. Salah satu solusi potensial adalah penggunaan model berbasis teknologi kecerdasan buatan, khususnya *machine learning*, yang dapat mengotomatisasi proses klasifikasi risiko *stunting* dengan lebih efisien.

Sejumlah penelitian terdahulu telah mengeksplorasi klasifikasi *stunting* atau status gizi balita dengan menggunakan berbagai algoritma *machine learning*. Salah satu studi mengaplikasikan *K-Nearest Neighbor* (KNN) untuk mengklasifikasikan status gizi balita di Puskesmas Sa'dan, menggunakan data dari tahun 2017-2021, dan mencapai akurasi 91,8% [5]. Penelitian serupa juga menerapkan KNN pada data dari Posyandu Nusa Indah 4, dengan 516 data training dan 100 data testing, menghasilkan akurasi, presisi, dan recall sebesar 94,64% [6]. Pendekatan berbeda digunakan dalam studi lain yang menerapkan algoritma *Decision Tree* untuk memprediksi status gizi balita, menghasilkan akurasi 92,73% [7]. Pengembangan dari *Decision Tree*, yaitu algoritma C4.5, juga digunakan dalam penelitian lain dengan data dari Puskesmas Janji dan Puskesmas Suka Makmur, namun hanya mencapai akurasi 80% [8]. Algoritma *Random Forest* digunakan dalam penelitian di Kecamatan Ngelegok, menganalisis data antropometri dari 2.542 balita. Hasilnya menunjukkan akurasi 88,6%, presisi 88,1%, recall 88,6%, dan F1 score 88,2% [9].



Berdasarkan penelitian sebelumnya, algoritma yang digunakan memiliki keterbatasan dalam menangani data kategorikal, karena membutuhkan proses pra-pengolahan data yang rumit seperti *encoding* fitur kategori. Selain itu, algoritma- algoritma yang digunakan pada penelitian sebelumnya belum optimal dalam mengelola dataset yang tidak seimbang, yang sering kali ditemukan pada data klasifikasi *stunting*. Selain itu, potensi penggunaan algoritma *boosting* untuk menyelesaikan persoalan ini belum sepenuhnya dieksplorasi, meskipun algoritma tersebut telah terbukti mampu meningkatkan kinerja model klasifikasi pada dataset yang memiliki kompleksitas tinggi. Untuk itu, perbedaan penelitian ini dengan studi sebelumnya yaitu penggunaan algoritma *CatBoost Classifier* dalam mengklasifikasikan risiko *stunting* pada balita. *CatBoost* adalah algoritma *boosting* yang dirancang untuk menangani data dengan banyak fitur kategori tanpa memerlukan proses *encoding* yang rumit, menjadikannya efisien dalam waktu pemrosesan dan akurat dalam prediksi [10]. *CatBoost* juga memiliki keunggulan dalam menangani dataset kompleks dan tidak seimbang, serta mendukung pemrosesan paralel untuk mempercepat pelatihan model [11]. Hal ini dikarenakan *CatBoost* bekerja dengan menerapkan algoritma *boosting* berbasis gradien yang dirancang untuk secara adaptif memprioritaskan data yang sulit diklasifikasikan, sekaligus mengelola distribusi kelas yang tidak seimbang melalui teknik penyeimbangan *loss* secara otomatis. Selain itu, *CatBoost* menggunakan pemrosesan fitur kategorikal yang efisien dengan metode pengkodean berbasis statistik, yang menjaga konsistensi data selama pelatihan.

Penelitian ini bertujuan untuk mengembangkan model klasifikasi risiko *stunting* pada balita dengan menggunakan algoritma *CatBoost Classifier*. Dengan mengembangkan model klasifikasi berbasis *CatBoost*, penelitian dapat memberikan kontribusi dalam mempercepat proses deteksi dini risiko *stunting* pada balita, sehingga upaya pencegahan dan intervensi dapat dilakukan lebih tepat waktu dan lebih efektif.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Tahapan penelitian merupakan rangkaian langkah yang tersusun secara sistematis yang dilakukan oleh peneliti untuk menyelesaikan suatu studi atau eksperimen [12]. Langkah-langkah yang dilakukan dalam penelitian ini divisualisasikan pada Gambar 1.



Gambar 1. Langkah-Langkah Penelitian

a. Mengumpulkan Data

Tahap pertama adalah pengumpulan data yang akan digunakan untuk analisis. Dataset merupakan elemen penting dalam sebuah penelitian atau proyek *machine learning* karena berfungsi sebagai dasar untuk melatih, menguji, dan mengevaluasi model yang dikembangkan [13]. Dataset yang digunakan dalam penelitian ini diperoleh dari dataset publik yang berjudul "*Stunting Toddler Detection*" di Kaggle [14]. Dalam mengklasifikasikan status *stunting* pada balita, dataset ini menerapkan formula *z-score* yang mengacu pada standar *World Health Organization* (WHO). Kumpulan data mencakup 121.000 entri yang memuat berbagai parameter seperti usia, jenis kelamin, tinggi badan, serta kondisi gizi anak balita. Klasifikasi risiko *stunting* dibagi menjadi empat kategori yang berbeda: Normal (Gizi Baik) untuk anak dengan pertumbuhan sesuai standar, *Stunted* (Gizi Kurang) menunjukkan adanya *stunting*, *Severely Stunted* (Gizi Buruk) mengindikasikan kondisi *stunting* yang parah, dan Tinggi (Gizi Lebih) untuk anak dengan tinggi di atas rata-rata.



b. Pra-Pemrosesan Data

Pada tahap ini, data yang telah dikumpulkan diolah lebih lanjut untuk memastikan bahwa tidak ada data yang hilang atau duplikat yang dapat mempengaruhi hasil analisis [15]. Proses pra-pemrosesan ini mencakup beberapa langkah penting. Pertama, dilakukan pengecekan terhadap data kosong untuk memastikan bahwa tidak ada nilai yang hilang atau kosong di dalam dataset, sehingga kualitas data tetap terjaga. Kedua, dilakukan penghapusan data duplikat agar hanya data unik dan valid yang digunakan dalam analisis, menghindari bias hasil yang disebabkan oleh adanya data ganda. Ketiga, dilakukan *encoding* pada fitur kategorikal seperti 'Jenis Kelamin' dan 'Status Gizi'. Teknik label *encoding* digunakan untuk mengonversi data kategorikal ini menjadi nilai numerik sehingga algoritma pembelajaran mesin dapat memprosesnya dengan lebih efisien dan akurat. Tahapan pra-pemrosesan ini sangat penting dalam mempersiapkan data agar siap digunakan untuk pelatihan model klasifikasi.

c. Standarisasi Fitur

Setelah tahap *encoding*, dilakukan standarisasi pada data numerik seperti tinggi badan dan umur menggunakan "StandardScaler" untuk menormalkan data sehingga setiap fitur memiliki skala yang seragam. Ini penting untuk memastikan bahwa algoritma pembelajaran mesin seperti *CatBoost Classifier*, dapat bekerja lebih efektif tanpa dipengaruhi oleh perbedaan skala antar fitur.

d. Membangun Model Klasifikasi

Pada tahap ini, dilakukan implementasi algoritma *CatBoost Classifier*, yang merupakan salah satu algoritma *boosting* yang efisien dan cepat dalam menangani data kategorikal. Model ini dilatih menggunakan data latih untuk mempelajari pola-pola yang ada dalam data.

e. Mengevaluasi Model

Setelah model selesai dilatih, dilakukan evaluasi menggunakan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-Score* untuk mengukur performa model dalam mengklasifikasikan data uji. Selain itu, dihitung *ROC-AUC score* untuk mengukur kualitas prediksi probabilistik model. Visualisasi berupa *ROC curve* juga dihasilkan untuk melihat performa model dalam setiap kelas secara lebih detail. *Confusion matrix* digunakan untuk menunjukkan prediksi model dan perbandingan dengan hasil sebenarnya dalam bentuk tabel.

f. Analisis Hasil

Setelah evaluasi model dilakukan, hasil yang diperoleh dianalisis untuk memahami performa model secara keseluruhan, termasuk melihat kelas mana yang lebih sulit untuk diklasifikasikan oleh model. Hasil analisis ini kemudian digunakan untuk menyimpulkan hasil penelitian atau mengembangkan solusi yang diusulkan.

2.2 Algoritma *CatBoost Classifier*

CatBoost Classifier adalah salah satu algoritma pembelajaran mesin berbasis *boosting* yang dikembangkan untuk menangani masalah klasifikasi dan regresi [16]. *CatBoost*, singkatan dari "*Categorical Boosting*," dirancang untuk menangani data kategorikal dengan lebih efisien tanpa memerlukan pra-pemrosesan yang ekstensif seperti *one-hot encoding*, yang sering digunakan dalam algoritma lain [17]. *CatBoost* termasuk dalam keluarga algoritma *gradient boosting*, tetapi dengan beberapa perbaikan khusus yang membuatnya lebih stabil, lebih cepat, dan mampu menangani fitur kategorikal secara *native* [18].

CatBoost bekerja dengan menerapkan teknik *boosting*, yang berarti membangun model secara iteratif dan memperbaiki kesalahan prediksi model sebelumnya [19]. Pada intinya, *CatBoost* melatih banyak pohon keputusan (*decision trees*) di setiap langkah *boosting* [20]. Pada setiap iterasi, model mencoba meminimalkan kerugian (*loss*) dari model yang ada dengan mengarahkan fokus pada contoh-contoh yang sebelumnya salah diklasifikasikan. Pada setiap iterasi, *CatBoost Classifier* mencoba meminimalkan kerugian (*loss*) dengan mengarahkan fokus pada contoh-contoh yang sebelumnya salah diklasifikasikan. Algoritma ini menggunakan pendekatan *boosting*, di mana model secara bertahap dibangun dengan memperbaiki kesalahan dari model sebelumnya, sehingga meningkatkan akurasi secara progresif, khususnya dalam menghadapi data kategoris dan menangani *overfitting*.

Algoritma *boosting*, termasuk *CatBoost*, mengikuti prinsip *gradient boosting* untuk meminimalkan fungsi kerugian secara bertahap. Secara umum, untuk setiap iterasi t , model membangun pohon baru berdasarkan gradien (turunan pertama) dari fungsi kerugian terhadap prediksi sebelumnya. Misalnya, untuk model yang memprediksi $\hat{y}_i^{(t)}$ pada iterasi t , rumus pembaruan pada iterasi berikutnya dapat dinyatakan dengan persamaan (1).

$$\hat{y}_i^{(t+1)} = \hat{y}_i^{(t)} + \eta \cdot h_t(x_i) \quad (1)$$

di mana $\hat{y}_i^{(t+1)}$ merujuk pada prediksi yang diperbarui untuk contoh ke- i pada iterasi $t + 1$, η merupakan *learning rate* yang mengontrol seberapa banyak model harus mengoreksi prediksinya pada setiap iterasi, sedangkan $h_t(x_i)$ menunjukkan pohon keputusan yang dibangun pada iterasi ke- t , yang memprediksi sisa kesalahan dari model sebelumnya.

Fungsi *loss* (L) yang sering digunakan untuk klasifikasi biner dalam *boosting*, termasuk *CatBoost*, adalah *log loss* yang dinyatakan melalui persamaan (2).

$$L(y, \hat{y}) = -(y \log(\hat{y}) + (1 - y) \log(1 - \hat{y})) \quad (2)$$


di mana y merupakan label aktual (0 atau 1) dan \hat{y} adalah prediksi probabilitas dari model untuk kelas 1.

Pada intinya, *CatBoost* memperbarui model pada setiap iterasi berdasarkan gradien dari fungsi kerugian, serupa dengan algoritma *gradient boosting* lainnya, tetapi dengan tambahan optimasi untuk menangani data kategorikal dan meminimalkan kebiasaan urutan data.

3. HASIL DAN PEMBAHASAN

Penelitian ini mengembangkan model untuk memprediksi risiko *stunting* pada balita dengan menerapkan teknik boosting menggunakan algoritma *CatBoost Classifier*. Dataset yang digunakan dalam penelitian ini berasal dari dataset publik yaitu: "*Stunting Toddler Detection*" di Kaggle [14], yang mencakup berbagai fitur atau variabel seperti usia, jenis kelamin, tinggi badan, dan status gizi. Tahapan pertama adalah pra-pemrosesan data, yang dimulai dengan membaca dataset dari file CSV dan menampilkan informasi dasar tentang dataset, seperti melihat lima baris pertama, informasi tipe data, dimensi dataset, dan pengecekan adanya nilai null atau duplikasi data. Jika ada data duplikat, maka akan dihapus untuk memastikan keunikan data. Selanjutnya, proses *encoding* dilakukan untuk mengonversi fitur kategorikal, seperti 'Jenis Kelamin' dan 'Status Gizi', menjadi nilai numerik dengan bantuan LabelEncoder. LabelEncoder merupakan salah satu kelas dalam pustaka *scikit-learn* di Python yang digunakan untuk mengubah label kategoris (data teks) menjadi bentuk numerik (data numerik). Ini sangat berguna ketika kita bekerja dengan algoritma machine learning yang membutuhkan input data dalam bentuk numerik. Langkah ini memudahkan algoritma *CatBoost* dalam memahami data yang berbentuk kategorikal. Setelah itu, dilakukan visualisasi sebaran data yang digunakan untuk mengetahui pola-pola dari variabel-variabel yang ada pada dataset tersebut.

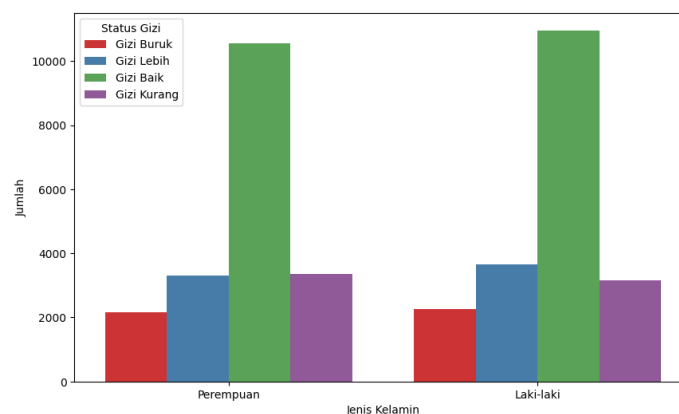
Variabel yang pertama yaitu usia, dimana variabel ini dinilai memiliki pengaruh terhadap risiko *stunting* berdasarkan status gizi pada balita. Visualisasi distribusi data usia terhadap status gizi pada dataset yang digunakan di tampilkan pada Gambar 2.



Gambar 2. Sebaran Data Variabel Usia Terhadap Status Gizi Balita

Visualisasi pada Gambar 2 menunjukkan distribusi tinggi badan terhadap umur berdasarkan status gizi pada balita. Setiap warna mewakili kategori status gizi yang berbeda: "Gizi Buruk" ditampilkan dalam warna merah, "Gizi Lebih" dalam warna biru, "Gizi Baik" dalam warna hijau, dan "Gizi Kurang" dalam warna ungu. Grafik ini memperlihatkan bahwa tinggi badan balita umumnya meningkat seiring bertambahnya usia. Namun, perbedaan status gizi menghasilkan pola tinggi badan yang berbeda. Balita dengan "Gizi Baik" dan "Gizi Lebih" cenderung memiliki tinggi badan yang lebih tinggi dibandingkan dengan balita dengan "Gizi Buruk" dan "Gizi Kurang". Visualisasi ini membantu dalam memahami hubungan antara status gizi dengan pertumbuhan tinggi badan pada berbagai usia.

Variabel selanjutnya yaitu jenis kelamin, dimana pada dataset ini perlu dilakukannya analisis sebaran data jenis kelamin terhadap status gizi pada balita. Untuk memvisualisasikan distribusi data jenis kelamin berdasarkan status gizinya disajikan pada *bar plot* pada Gambar 3.

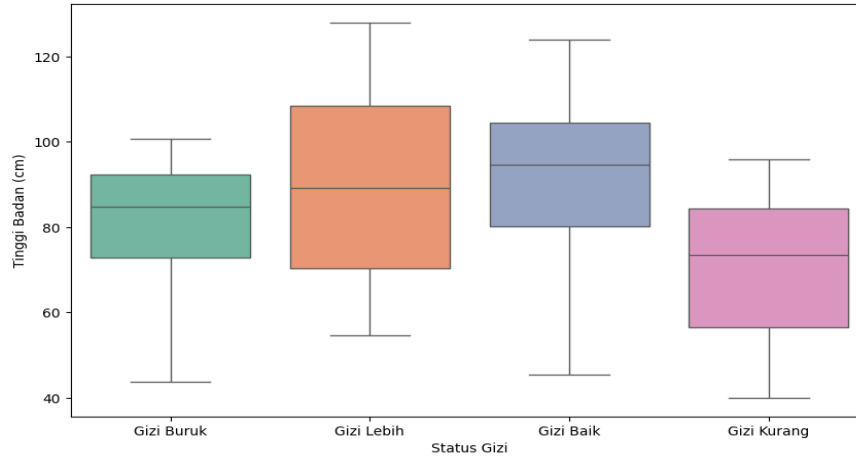


Gambar 3. Sebaran Data Variabel Jenis Kelamin Berdasarkan Status Gizi Balita



Visualisasi pada Gambar 3 memperlihatkan distribusi status gizi balita berdasarkan jenis kelamin (Perempuan dan Laki-laki). Grafik menunjukkan empat kategori status gizi: "Gizi Buruk" (merah), "Gizi Lebih" (biru), "Gizi Baik" (hijau), dan "Gizi Kurang" (ungu). Secara umum, baik pada balita perempuan maupun laki-laki, kategori "Gizi Baik" mendominasi jumlah terbanyak, disusul oleh "Gizi Lebih" dan "Gizi Kurang", sementara "Gizi Buruk" memiliki jumlah paling sedikit. Pola distribusi serupa terlihat pada kedua jenis kelamin, dengan balita perempuan dan laki-laki menunjukkan proporsi yang hampir sama dalam setiap kategori status gizi. Visualisasi ini membantu memahami perbandingan status gizi berdasarkan jenis kelamin, dengan indikasi bahwa "Gizi Baik" merupakan kategori paling dominan dalam populasi yang diamati.

Untuk visualisasi berikutnya yaitu distribusi data tinggi badan terhadap status gizi balita. Tinggi badan menjadi faktor utama dalam mengklasifikasikan bahwa balita tersebut berisiko *stunting* atau tidak. Visualisasi ini ditunjukkan melalui *box plot* pada Gambar 4.



Gambar 4. Sebaran Data Variabel Tinggi Bada Balita Berdasarkan Status Gizinya

Box plot yang ditampilkan pada Gambar 4 menunjukkan distribusi tinggi badan balita berdasarkan status gizi mereka dalam bentuk *box plot*. Setiap kategori status gizi, yaitu "Gizi Buruk," "Gizi Lebih," "Gizi Baik," dan "Gizi Kurang," memiliki distribusi tinggi badan yang berbeda. Kategori "Gizi Lebih" memiliki median dan rentang tinggi badan yang paling tinggi, menunjukkan bahwa balita dengan gizi lebih cenderung memiliki tinggi badan di atas rata-rata. "Gizi Baik" juga menunjukkan distribusi yang relatif tinggi, meskipun sedikit lebih rendah dibandingkan "Gizi Lebih." Sementara itu, kategori "Gizi Buruk" dan "Gizi Kurang" memiliki median yang lebih rendah dan rentang tinggi badan yang lebih sempit, yang menunjukkan korelasi antara kekurangan gizi dan rendahnya tinggi badan.

Proses selanjutnya yaitu menyiapkan model pelatihan untuk klasifikasi risiko *stunting* berdasarkan status gizinya menggunakan algoritma *CatBoost Classifier*. Algoritma *CatBoost* bekerja berdasarkan prinsip *gradient boosting* yang bertujuan untuk secara bertahap meminimalkan fungsi kerugian. Pada setiap iterasi t , model membangun pohon baru dengan memanfaatkan gradien (turunan pertama) dari fungsi kerugian terhadap prediksi pada iterasi sebelumnya. Untuk studi kasus pada penelitian ini memiliki subset data kecil digunakan untuk satu iterasi *CatBoost* yang ditampilkan pada Tabel 1.

Tabel 1. Studi Kasus Subset Data

Usia (bulan)	Jenis Kelamin	Tinggi Badan (cm)	Kondisi Gizi	Label Aktual
12	Laki-laki	75	Normal	Normal
24	Perempuan	80	Stunted	Stunted
18	Laki-laki	60	Severely Stunted	Severely Stunted
36	Perempuan	100	Tinggi	Tinggi

Pada Tabel 1 menunjukkan subset data kecil digunakan untuk satu iterasi. Pada iterasi pertama, model memulai dengan prediksi awal yang sama untuk semua kelas. Probabilitas awal (\hat{y}_i^0) diberikan secara seragam, misalnya $\frac{1}{4} = 0.25$ untuk keempat kelas. Fungsi *loss* yang digunakan untuk klasifikasi multi-kelas biasanya adalah *log loss*. Gradien untuk setiap contoh dan kelas dihitung sebagai turunan terhadap prediksi probabilitas ($\hat{y}_{i,c}$), berikut proses perhitungannya:

$$\hat{y}_{1,normal}^0 = -\frac{1}{0,25} = -4$$

$$\hat{y}_{1,stunted}^0 = -\frac{1}{0,25} = -4$$

$$\hat{y}_{1,severly stunted}^0 = -\frac{1}{0,25} = -4$$



$$\hat{y}_{1,tinggi}^0 = -\frac{1}{0,25} = -4$$

Langkah selanjutnya, pohon keputusan dibangun untuk memprediksi *residual* (gradien negatif). Misalnya:

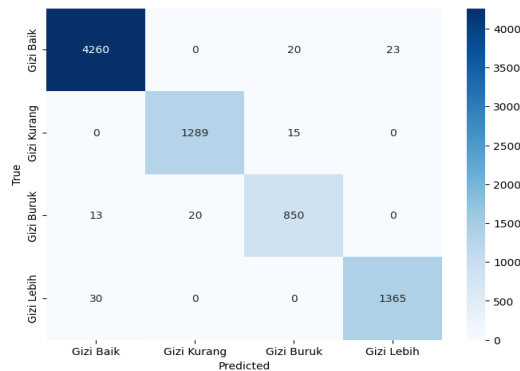
- a. Usia < 18 bulan: Kemungkinan tinggi untuk kelas *Severely Stunted*.
- b. Tinggi Badan > 90 cm: Kemungkinan tinggi untuk kelas Tinggi.

Pohon ini memprediksi koreksi (*residual*) untuk masing-masing contoh. Prediksi diperbarui menggunakan learning rate (η). Misalnya, dengan $\eta = 0,1$ dan pohon memperkirakan koreksi $h_t(x_{i,normal}) = 0,2$, maka:

$$\hat{y}_{1,normal}^{(1)} = 0,25 + 0,1 \cdot 0,2 = 0,27$$


Prediksi diperbarui untuk semua contoh dan kelas. Dalam studi kasus yang dilakukan, pembaruan prediksi model menunjukkan bahwa prediksi awal sebesar 0,25 untuk kelas "Normal" pada contoh pertama diperbarui menjadi 0,27 setelah memperhitungkan koreksi residual yang dihasilkan pada iterasi pertama dengan *learning rate* sebesar 0,1. Melalui iterasi bertahap ini, *CatBoost* memanfaatkan gradien dari fungsi *loss* untuk meningkatkan akurasi prediksi secara sistematis.

Model prediksi dengan *CatBoost* selanjutnya diimplementasikan menggunakan dataset sebagai pelatihan dan pengujian. Dataset dipisahkan menjadi fitur (x) dan target (y) di mana fitur merupakan variabel independen, dan target adalah variabel dependen, yaitu 'Status Gizi'. Kemudian, fitur diubah menjadi bentuk standar menggunakan *StandardScaler* untuk memastikan bahwa skala setiap fitur seragam. Dataset kemudian dibagi menjadi data latih dan data uji dengan perbandingan 80:20 untuk memastikan model dapat diuji pada data yang tidak dilatih sebelumnya. Algoritma ini dilatih pada data latih untuk mempelajari pola-pola dalam dataset, dan kemudian model yang telah terlatih digunakan untuk memprediksi data uji. Hasil uji kemudian disusun kedalam *confusion matrix* yang divisualisasikan dalam bentuk *heatmap* untuk melihat perbandingan antara prediksi model dan nilai sebenarnya dari data uji. Tampilan hasil *confusion matrix* dari model yang dibangun ditunjukkan pada Gambar 5.



Gambar 5. Confusion Matrix Yang Diperoleh

Gambar 5 menunjukkan *confusion matrix*, yang berfungsi untuk membantu memahami seberapa baik model mengklasifikasikan setiap kelas serta menunjukkan jumlah kesalahan klasifikasi yang terjadi. Berdasarkan *confusion matrix* tersebut, beberapa metrik evaluasi dapat dihitung. Metrik evaluasi pertama adalah *ROC-AUC Score*, yang digunakan untuk mengukur performa model dalam memprediksi probabilitas kelas. Nilai ini diplot dalam *ROC Curve* untuk setiap kelas, yang menggambarkan kemampuan model dalam memisahkan kelas dengan melihat perbandingan antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR). *ROC (Receiver Operating Characteristic) AUC (Area Under the Curve)* adalah metrik yang mengukur kemampuan model dalam memisahkan kelas. Nilai AUC mendekati 1 menunjukkan performa yang baik, sedangkan nilai mendekati 0,5 menunjukkan model yang tidak lebih baik dari tebakan acak. Grafik *ROC Curve* tersaji pada Gambar 6.



Gambar 6. Sebaran Data Variabel



Gambar 6 merupakan visualisasi kurva ROC (*Receiver Operating Characteristic*) untuk model klasifikasi dengan beberapa kelas (*multi-class*). Kurva ROC ini menunjukkan kinerja model dalam memisahkan setiap kelas dengan melihat *trade-off* antara *True Positive Rate* (TPR) dan *False Positive Rate* (FPR). Setiap kurva berwarna (*cyan, orange, dan blue*) mewakili masing-masing kelas yang diprediksi oleh model, dengan area di bawah kurva (AUC) untuk setiap kelas mencapai nilai sempurna 1.0, menandakan bahwa model ini memiliki kemampuan yang sangat baik dalam mengklasifikasikan data secara akurat untuk setiap kelas tanpa kesalahan. Garis hitam putus-putus pada sudut 45 derajat ($y = x$) menunjukkan garis batas untuk prediksi acak; semakin jauh kurva dari garis ini, semakin baik kinerja model.

Penilaian evaluasi selanjutnya setelah diperoleh hasil *confusion matrix*, dapat digunakan untuk menghitung nilai-nilai seperti *presisi, recall, F1-Score* dan akurasi. Hasil seluruh penilaian evaluasi yang dilakukan tersaji pada Tabel 1.

Tabel 2. Hasil Evaluasi

Nama Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Accuracy</i>	<i>ROC-AUC</i>
Gizi Baik	99.00	99.00	99.00		
Gizi Kurang	98.47	98.85	98.66	98.47	1.00
Gizi Buruk	96.05	96.26	96.15		
Gizi Lebih	98.34	97.85	98.10		

Tabel 2 menunjukkan hasil evaluasi model klasifikasi risiko *stunting* menggunakan algoritma *CatBoost Classifier*, yang memperlihatkan performa sangat baik berdasarkan metrik evaluasi seperti *Precision, Recall, F1-Score, Accuracy*, dan *ROC-AUC* untuk setiap kategori status gizi. Kategori Gizi Baik memiliki hasil *Precision, Recall*, dan *F1-Score* yang sempurna, yakni 99%, menunjukkan bahwa model mampu mendeteksi anak-anak dengan gizi baik hampir tanpa kesalahan. Kelas Gizi Kurang, Gizi Buruk, dan Gizi Lebih juga menunjukkan kinerja yang sangat tinggi, dengan nilai *Precision, Recall*, dan *F1-Score* yang hampir sempurna, berkisar antara 96% hingga 98%.

Akurasi keseluruhan model mencapai 98.47%, yang mengindikasikan bahwa model ini sangat andal dalam memprediksi kategori status gizi secara umum. Selain itu, nilai *ROC-AUC* yang mencapai 1.00 untuk semua kelas menunjukkan bahwa model mampu membedakan kategori dengan sangat baik tanpa kesalahan dalam area di bawah kurva ROC. Ini menunjukkan kemampuan *CatBoost* yang unggul dalam menangani data yang mungkin memiliki distribusi tidak seimbang, serta pengoptimalan performa yang maksimal pada dataset yang digunakan. *CatBoost* secara khusus sangat efektif untuk data kategorikal, dan dalam penelitian ini, fitur seperti jenis kelamin dan status gizi mungkin memainkan peran besar dalam meningkatkan kinerja model. Selain itu, kemampuan *CatBoost* untuk secara otomatis menangani *missing values* dan kecepatan dalam *training*, membuatnya menjadi pilihan yang tepat untuk kasus klasifikasi seperti ini. Hasil evaluasi ini menunjukkan bahwa *CatBoost* dapat memberikan model klasifikasi yang akurat, cepat, dan mampu menangani kompleksitas data yang tinggi dalam konteks prediksi risiko *stunting* pada balita.

Namun, meskipun hasilnya sangat tinggi, model perlu ditingkatkan dalam menangani data baru yang memiliki pola atau distribusi berbeda dari dataset pelatihan, yang dapat menyebabkan *overfitting*. Untuk itu, perlu meningkatkan dengan memperbanyak variasi data melalui augmentasi data atau menggunakan *cross-validation* yang lebih ketat untuk memastikan generalisasi yang lebih baik pada data di luar dataset pelatihan. Selain itu, penggunaan tuning parameter pada model *CatBoost* dapat membantu meningkatkan akurasi dan efisiensi model.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model klasifikasi risiko *stunting* pada balita menggunakan algoritma *CatBoost Classifier* dengan fitur tinggi badan, umur, dan jenis kelamin. Dalam studi kasus yang dilakukan, pembaruan prediksi model menunjukkan bahwa prediksi awal sebesar 0,25 pada contoh pertama diperbarui menjadi 0,27 setelah memperhitungkan koreksi residual yang dihasilkan pada iterasi pertama dengan *learning rate* sebesar 0,1. Proses ini mencerminkan cara kerja *CatBoost*, yang secara iteratif memperbaiki prediksi model melalui pembaruan bertahap, sehingga secara keseluruhan meningkatkan akurasi klasifikasi. Model yang dihasilkan menunjukkan kinerja yang sangat baik, dengan akurasi keseluruhan sebesar 98.47% serta nilai *ROC-AUC* mencapai 1.00 untuk beberapa kelas, yang menunjukkan kemampuan model dalam membedakan setiap kategori status gizi dengan baik. Hal ini menandakan bahwa *CatBoost* mampu menangani dataset yang bervariasi dengan performa yang stabil dan akurat, menjadikannya pilihan yang sesuai untuk klasifikasi masalah *stunting*. Algoritma *CatBoost Classifier* memiliki keunggulan dalam menangani variabel kategorikal dan mampu mengatasi data yang tidak seimbang dengan meningkatkan akurasi prediksi. Namun, penelitian ini memiliki keterbatasan, yaitu model sangat bergantung pada kualitas dan distribusi dataset pelatihan. Ketidaksiharian pola atau distribusi data baru dengan data pelatihan juga dapat meningkatkan risiko *overfitting* atau menurunkan kinerja model. Untuk penelitian selanjutnya, perlu dilakukan upaya untuk mengatasi tantangan dalam menangani data baru yang mungkin memiliki pola atau distribusi berbeda dari dataset pelatihan, karena hal ini berisiko menyebabkan *overfitting*. Salah satu cara untuk mengatasi masalah ini adalah dengan meningkatkan variasi data melalui teknik augmentasi data atau menerapkan *cross-validation* yang lebih ketat guna memastikan model dapat melakukan generalisasi dengan baik pada data di luar dataset pelatihan. Selain itu, tuning parameter pada model *CatBoost* juga dapat membantu meningkatkan akurasi dan efisiensi model lebih lanjut.



REFERENCES

- [1] S. N. Tarmizi, "Prevalensi Stunting di Indonesia Turun ke 21,6% dari 24,4%," *sehatnegeriku.kemkes.go.id*, 2023. <https://sehatnegeriku.kemkes.go.id/baca/rilis-media/20230125/3142280/prevalensi-stunting-di-indonesia-turun-ke-216-dari-244/>
- [2] N. Novrizaldi, "Pemerintah Optimis Target Penurunan Stunting 14 Persen Tercapai di 2024," *Kemenko PMK*, 2023. <https://www.kemendiknas.go.id/pemerintah-optimis-target-penurunan-stunting-14-persen-tercapai-di-2024>
- [3] A. N. Rohim, D. A. F. Mursali, S. H. Ashilah, and F. Fidrayani, "Hubungan Status Gizi terhadap Perkembangan Kognitif Anak Usia Dini Aisyah," *Madani J. Ilm. Multidisiplin*, vol. 2, no. 6, pp. 234–243, 2024.
- [4] S. Sadariah, M. Rifai, M. I. Nur, and M. Musfirah, "Analisis Faktor Yang Mempengaruhi Kejadian Stunting Pada Balita Usia 6-59 Bulan," *J. Ilm. Kesehat. Sandi Husada*, vol. 12, no. 2, pp. 317–323, 2023, doi: 10.35816/jiskh.v12i2.1075.
- [5] M. L. Dambe, S. Y. Padang, and M. S. Adha, "Evaluasi K-Nearest Neighbour Untuk Klasifikasi Status Gizi Balita," *INFINITY*, vol. 3, no. 1, pp. 33–40, 2023, doi: 10.34148/infinity.v9i1.xxx.
- [6] F. M. Sarimole, F. B. Pasaribu, Y. Akbar, and A. Z. Hidayat, "Penerapan Algoritma K-Nearest Neighbor Untuk Klasifikasi Status Gizi Balita Di Posyandu Nusa Indah 4," *J. Tek.*, vol. 18, no. 2, pp. 489–500, 1978.
- [7] D. N. A. Kurniawan and M. Maryam, "Implementasi Metode Decision Tree pada Sistem Prediksi Status Gizi Balita," *J. Sains Komput. Inform.*, vol. 7, no. 2, pp. 731–739, 2023.
- [8] Y. R. Nasution, A. Armansyah, M. Furqan, and T. R. Matondang, "Penerapan Algoritma C4.5 Pada Klasifikasi Status Gizi Balita," *J. FASILKOM*, vol. 14, no. 1, pp. 216–225, 2024.
- [9] P. Handayani, A. C. Fauzan, and H. Harliana, "Machine Learning Klasifikasi Status Gizi Balita Menggunakan Algoritma Random Forest," *KLIK Kaji. Ilm. Inform. dan Komput.*, vol. 4, no. 6, pp. 3064–3072, 2024, doi: 10.30865/klik.v4i6.1909.
- [10] T. Swetha, R. R. T. Sajitha, V. B. J. Sravani, and B. Praveen, "Forecasting Online Shoppers Purchase Intentions with CatBoost Classifier," in *International Conference on Distributed Computing and Optimization Techniques (ICDCOT)*, 2024, pp. 1–6. doi: 10.1109/ICDCOT61034.2024.10515309.
- [11] V. N. Ogar, S. Hussain, and K. A. A. Gamage, "Transmission Line Fault Classification of Multi-Dataset Using CatBoost Classifier," *Signals*, vol. 3, no. 3, pp. 468–482, 2022, doi: 10.3390/signals3030027.
- [12] R. I. Borman, F. Rossi, Y. Jusman, A. A. A. Rahni, S. D. Putra, and A. Herdiansah, "Identification of Herbal Leaf Types Based on Their Image Using First Order Feature Extraction and Multiclass SVM Algorithm," in *International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, 2021, pp. 12–17.
- [13] R. I. Borman, F. Rossi, D. Alamsyah, R. Nuraini, and Y. Jusman, "Classification of Medicinal Wild Plants Using Radial Basis Function Neural Network with Least Mean Square," in *International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, 2022.
- [14] R. P. Pradana, "Stunting Toddler Detection," *Kaggle*, 2024. <https://www.kaggle.com/datasets/rendiputra/stunting-balita-detection-121k-rows/>
- [15] R. I. Borman and M. Wati, "Penerapan Data Maining Dalam Klasifikasi Data Anggota Kopdit Sejahtera Bandarlampung Dengan Algoritma Naïve Bayes," *J. Ilm. Fak. Ilmu Komput.*, vol. 9, no. 1, pp. 25–34, 2020.
- [16] M. T. Syamkalla, S. Khomsah, Y. Setiya, and R. Nur, "Implementasi Algoritma Catboost dan Shapley Additive Explanations (SHAP) Dalam Memprediksi Popularitas Game Indie Pada Platform Steam," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 11, no. 4, pp. 771–776, 2024, doi: 10.25126/jtiik.1148503.
- [17] A. F. Istianto, A. I. Hadiana, and F. R. Umbara, "Prediksi Curah Hujan Menggunakan Metode Categorical Boosting (Catboost)," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 7, no. 4, pp. 2930–2937, 2023.
- [18] A. F. L. Ptr, M. M. Siregar, and I. Daniel, "Analysis of Gradient Boosting, XGBoost, and CatBoost on Mobile Phone Classification," *J. Comput. Networks, Archit. High Perform. Comput.*, vol. 6, no. 2, pp. 661–670, 2024.
- [19] D. Hao, Y. Xiaoqi, and Q. Taoyu, "Hybrid Machine Learning Models Based on CATBoost Classifier for Assessing Students' Academic Performance," *Int. J. Adv. Comput. Sci. Appl.*, vol. 15, no. 7, pp. 94–106, 2024.
- [20] P. Singh, T. Hasija, and K. R. Ramkumar, "Leveraging ML with XGBoost, CatBoost and LGBBoost Classifiers to Optimize Water Quality Assessment and Prediction," in *International Conference on Information Technology, Electronics and Intelligent Communication Systems (ICITEICS)*, 2024, pp. 1–6. doi: 10.1109/ICITEICS61368.2024.10625322.