

Klasifikasi Status Stunting Pada Anak Bawah Lima Tahun Menggunakan Extreme Gradient Boosting

Muhamad Fikri

Universitas Muhammadiyah Ponorogo

Email: irkifdamahum@gmail.com

Alamat: Jl. Budi Utomo No.10 Ponorogo, Jawa Timur Indonesia

Korepondensi Penulis: irkifdamahum@gmail.com

Abstract. *Stunting is a condition of failure to thrive in children, in Indonesia it is still a serious problem with a fairly high prevalence. The government is trying to reduce stunting rates with various health programs, and early detection through routine measurements is very important. This research uses the Extreme Gradient Boosting (XGBoost) algorithm to classify stunting status in children under five years. This study uses a relevant dataset containing anthropometric information on children, such as gender, age, birth weight and length, current weight and length, and breastfeeding status. The research stages include dataset search, preprocessing, classification, evaluation, and implementation in a local web-based prediction program. The XGBoost algorithm was chosen because of its advantages in speed, scalability, and efficiency. After preprocessing and data sharing, the model was trained and tested, resulting in 86% accuracy, 89% precision, 95% recall, and 92% F1-score. Evaluation using the confusion matrix and classification report shows that this model is quite effective in classifying stunting status.*

Keywords: *Stunting, Classification, Machine learning, Extreme Gradient Boosting.*

Abstrak. Stunting merupakan kondisi gagal tumbuh pada anak, di Indonesia masih menjadi masalah serius dengan prevalensi yang cukup tinggi. Pemerintah berupaya menurunkan angka stunting dengan berbagai program kesehatan, dan deteksi dini melalui pengukuran rutin sangat penting. Penelitian ini menggunakan penerapan algoritma Extreme Gradient Boosting (XGBoost) untuk mengklasifikasikan status stunting pada anak di bawah lima tahun. Penelitian ini menggunakan dataset yang relevan yang berisi informasi antropometri anak-anak, seperti jenis kelamin, usia, berat dan panjang lahir, berat dan panjang badan saat ini, serta status menyusui. Tahapan penelitian meliputi pencarian dataset, preprocessing, klasifikasi, evaluasi, dan implementasi dalam program prediksi berbasis web lokal. Algoritma XGBoost dipilih karena keunggulannya dalam kecepatan, skalabilitas, dan efisiensi. Setelah melakukan preprocessing dan pembagian data, model dilatih dan diuji, menghasilkan akurasi sebesar 86%, precision 89%, recall 95%, dan F1-score 92%. Evaluasi menggunakan confusion matrix dan classification report menunjukkan bahwa model ini cukup efektif dalam mengklasifikasikan status stunting.

Kata kunci: Stunting, Klasifikasi, Machine learning, Extreme Gradient Boosting.

LATAR BELAKANG

Stunting adalah kondisi gagalnya pertumbuhan tinggi dan berat anak bawah lima tahun dibandingkan anak normal seusianya, kondisi ini disebabkan oleh berbagai faktor, seperti akses makanan bergizi yang terbatas selama masa kehamilan dan balita, pendidikan ibu tentang pola makan dan kesehatan sebelum kehamilan yang kurang memadai, asupan vitamin dan mineral yang tidak mencukupi, kehamilan remaja, dan jarak kehamilan yang terlalu dekat. Identifikasi faktor risiko stunting yang terlambat atau kurang optimal dapat memperbesar kemungkinan terjadinya masalah. Berbagai program pencegahan dan penanganan stunting terus dilakukan untuk menurunkan prevalensinya (Pahlevi et al., 2024). Tingkat stunting di Indonesia masih tinggi, mencapai 24,4% pada tahun 2021. Deteksi dini melalui pengukuran rutin di Posyandu sangat penting untuk pencegahan. Meskipun prevalensinya turun dari 24,4% menjadi 21,6%

pada 2022,nyatanya indonesia masih tergolong besar jumlah balita yang mengidap stunting(Fauzan Adzim et al., 2023). Pemerintah terus berupaya untuk menekan angka stunting balita berada di bawah 20%, mengikuti standar dari WHO,maka dari itu perlu adanya pencegahan sedini mungkin.Pemerintah juga berupaya menurunkan prevalensi stunting melalui berbagai program kesehatan. Peran orang tua, terutama ibu, sangat penting dalam memastikan asupan gizi yang baik untuk anak agar terhindar dari stunting(Adzhima et al., 2023).

Salah satu metode klasifikasi yang cukup sering digunakan adalah metode Extreme Gradient Boosting.Metode ini seringkali digunakan karena efisiensi dan skalabilitasnya untuk memecahkan beragam masalah klasifikasi ataupun regresi(LUTFIANI et al., 2023).Penerapan algoritma XGBoost dipilih karena keunggulannya dalam kecepatan, skalabilitas, dan efisiensi. Xtreme Gradient Boosting (XGBoost) dirancang untuk meningkatkan kinerja dan efisiensi dalam menangani data besar. XGBoost menggabungkan pengklasifikasi lemah menjadi model yang kuat secara, memperbaiki kesalahan sebelumnya. Algoritma Extreme Gradient Boosting (XGBoost) memakai metode unik yang menggabungkan proses boosting dengan gradient boosting untuk mencapai hasil yang 10 kali lebih cepat. XGBoost mengintegrasikan tiga jenis algoritma ensemble, yaitu classification dan regression trees atau CART(Wijaya & Prasetyo, 2021).

Algoritma XGBoost adalah metode machine learning jenis supervised learning yang menggunakan sistem tree boosting.Dalam proses machine learning XGBoost, terdapat parameter residual, yaitu selisih antara nilai prediksi atau nilai tengah dengan nilai aktual, algoritma Extreme Gradient Boosting memiliki akurasi sangat tinggi sebesar 94.9% dan nilai parameter sebesar 0.8 yang menunjukkan tingkat kategori tinggi(Syarifuddin et al., 2023). Pada penelitian ini, evaluasi dilakukan menggunakan Confusion Matrix untuk mengukur kinerja metode klasifikasi. Tujuan evaluasi adalah untuk mengetahui tingkat akurasi dari metode yang digunakan. Confusion Matrix dalam proses pengujian merepresentasikan keakuratan klasifikasi, dengan berisi informasi mengenai nilai actual dan prediksi dalam sistem klasifikasi. Confusion Matrix menghasilkan empat nilai utama: True Positive (TP), False Positive (FP), False Negative (FN), dan True Negative (TN).Dari nilai tersebut akan didapat nilai akurasi dari model yang dibuat(Aristio & Suhartana, 2023).Data juga sangat diperlukan untuk melatih dan menguji model, metode menemukan pola dalam data, yang terbagi menjadi deskripsi, estimasi, prediksi, klasifikasi, clustering, dan asosiasi. Prosesnya meliputi tiga langkah perbaikan data, penerapan algoritma, dan evaluasi hasil untuk menemukan aturan yang berharga(Muflih Ihza Rifatama et al., 2023).

Pada penelitian-penelitian sebelumnya menggunakan algoritma yang biasa digunakan untuk klasifikasi seperti random forest, decision tree, naïve bayes, metode c4.5, super vector machine, dan metode KNN. Pada penelitian ini saya mencoba menerapkan Algoritma Extreme Gradient Boosting untuk mengklasifikasi status stunting pada anak bawah lima tahun. Tujuannya untuk mengetahui bagaimana akurasi dan efektivitas algoritma XGBoost pada kasus ini dibanding dengan algoritma yang sudah pernah di terapkan. Algoritma Extreme Gradient Boosting dipilih dan digunakan oleh penulis untuk membantu dalam melakukan klasifikasi.

KAJIAN TEORITIS

Stunting pada balita adalah kondisi gagal tumbuh dimana berat badan dan tingginya dibawah anak seusianya, seorang anak yang dikategorikan stunting mengalami gangguan berbicara, kecenderungan penurunan tingkat kecerdasan, dan menurunkan kemampuan belajar anak. Penyakit ini merupakan masalah serius yang sedang dihadapi dunia kesehatan. Beberapa penyebabnya beragam, mulai dari asupan gizi yang tidak memadai, lingkungan yang tidak sehat, hingga pola asuh yang kurang tepat. Kementerian kesehatan RI berusaha meningkatkan status gizi masyarakat dengan menjadikan program ini sebagai prioritas dalam pembangunan kesehatan nasional. Tujuan ini tercantum dalam sasaran utama perencanaan pembangunan jangka menengah tahun 2015 - 2019 untuk mengurangi prevalensi stunting pada balita. Upaya penanggulangan stunting membutuhkan komitmen bersama, dari pemerintah melalui program kesehatan hingga peran orang tua dalam memberikan asupan gizi dan pola asuh yang baik (Prasetya et al., 2020).

Klasifikasi merupakan metode dalam pembelajaran mesin yang digunakan untuk mengelompokkan atau mengklasifikasikan objek berdasarkan karakteristik tertentu, mirip dengan cara manusia membedakan satu benda dari benda lainnya. Klasifikasi akan membentuk analisis data yang menghasilkan model untuk menggambarkan kelas data atau memprediksi label kelas kategorikal. Klasifikasi memiliki banyak aplikasi, seperti deteksi penyakit, target penjualan, prediksi cuaca, dan diagnosis medis, klasifikasi dapat memproses dan menempatkan objek tertentu dalam kategori tertentu berdasarkan sifat objek tersebut. Klasifikasi sangat berguna dalam bidang ilmu apapun (Shafila, 2020).

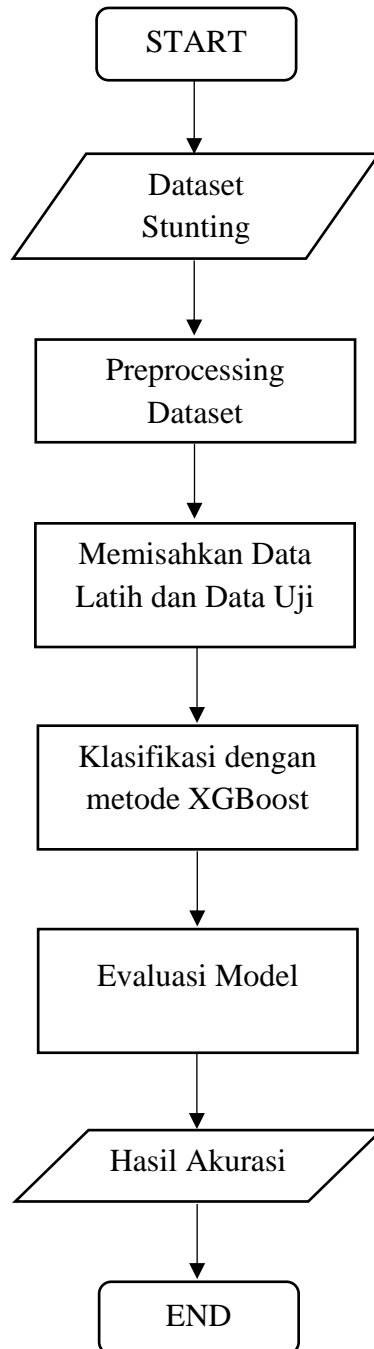
Preprocessing data merupakan langkah penting dalam analisis data dan pembelajaran mesin untuk memastikan kualitas dan keakuratan hasil analisis atau model yang dihasilkan. Sebelum data digunakan dalam analisis atau pemodelan, data perlu melalui proses persiapan yang disebut preprocessing. Proses ini penting untuk memastikan data berkualitas

dan siap untuk diolah. Preprocessing data membantu mengatasi berbagai masalah umum yang sering ditemui dalam data mentah, seperti nilai yang hilang, ketidakseimbangan skala fitur, dan variasi dalam tipe data. Dengan melakukan preprocessing, data menjadi lebih bersih, terstruktur, dan siap untuk digunakan dalam berbagai proyek analisis data atau machine learning (Gunawan et al., 2022).

Extreme Gradient Boosting atau XGBoost merupakan algoritma machine learning pembelajaran mesin yang menggabungkan decision tree dan framework Gradient Boosting dalam meningkatkan performanya. Algoritma ini merupakan pengembangan dari Gradient Boosting Machine dengan beberapa keunggulan, salah satunya adalah kemampuannya untuk mencegah overfitting. XGBoost menggunakan teknik boosting yang canggih untuk menangani data besar dan tidak linear. Algoritma ini dilengkapi dengan fitur-fitur seperti regularisasi dan pemilihan fitur optimal untuk mengatasi overfitting. Pengklasifikasi atau prediktor individual yang dihasilkan dari decision tree kemudian digabungkan untuk menghasilkan model yang kuat dan lebih akurat. Model XGBoost yang dihasilkan telah terbukti efektif dalam berbagai aplikasi machine learning, termasuk klasifikasi, regresi, dan ranking (Kharis Pratama et al., 2024).

METODE PENELITIAN

Proses-proses penelitian dilakukan dengan beberapa alur untuk memperoleh hasil yang baik dan akurat, beberapa proses penelitian digambarkan dalam bentuk flowchart dapat dilihat di gambar 1 dibawah ini.



Gambar 1. Alur Penelitian

1. Mencari Dataset

Pada tahap ini perlu ditemukan dataset yang relevan dengan penelitian yang akan dilakukan. Proses ini mencakup pencarian dataset dari berbagai sumber seperti repositori dataset publik contohnya Kaggle, NCBI, UNICEF atau Kemenkes, jurnal penelitian, atau data yang dikumpulkan secara mandiri. Pemilihan dataset harus didasarkan pada kesesuaiannya dengan tujuan penelitian, ukuran dataset, kualitas data, serta ketersediaan atribut yang dibutuhkan agar didapat hasil akurasi dan prediksi yang sesuai (Kemal Musthafa Rajabi et al., 2023). Sumber dataset dari penelitian ini didapat dari web kaggle berupa data sekunder hasil

penelitian Harnelia pada tahun 2024 yang berjudul faktor stunting, dataset berisi tentang antropometri anak bawah lima tahun yang berjumlah 10000 data.

2. Preprocessing Dataset

Data preparation atau preprocessing adalah tahap penting dalam membangun dan melatih model machine learning. Langkah ini juga membantu meningkatkan kualitas data dan mengubahnya menjadi format yang lebih mudah dipahami oleh model. Tahap ini mencakup pembersihan dan transformasi data mentah menjadi format yang sesuai untuk analisis lebih lanjut. Langkah-langkah preprocessing meliputi penanganan nilai yang hilang, perubahan tipe data, normalisasi atau standarisasi fitur, encoding data kategorikal, dan pembagian dataset menjadi subset pelatihan dan pengujian. Preprocessing yang tepat sangat penting untuk memastikan model dapat belajar dengan efektif dan menghasilkan prediksi yang akurat. Proses ini juga merupakan langkah kunci dalam penemuan pengetahuan karena data yang diperoleh sering kali tidak lengkap, memiliki noise, atau tidak konsisten (Banurea et al., 2023).

a. Klasifikasi

Klasifikasi adalah proses pengkategorian yang digunakan untuk menentukan kelas dari data yang label kelasnya tidak diketahui. Terdapat dua tahap dalam proses klasifikasi data. Pertama adalah tahap pembelajaran (learning), yaitu proses menganalisis data pelatihan menggunakan algoritma klasifikasi. Kedua adalah tahap klasifikasi, yaitu proses memprediksi ketepatan klasifikasi menggunakan data pengujian. Proses ini mencakup pemilihan algoritma yang tepat seperti Random Forest, Decision Tree, Support Vector Machine, atau KNN, pelatihan model dengan menggunakan subset pelatihan, dan penyesuaian hyperparameter untuk meningkatkan kinerja model. Tujuan utamanya adalah menemukan model yang dapat memprediksi label kelas dengan akurasi tinggi pada data yang belum pernah dilihat sebelumnya (Lonang & Normawati, 2022). Pada tahap ini penulis menerapkan algoritma extreme gradient boosting.

b. Evaluasi

Tahap selanjutnya adalah evaluasi kinerja model klasifikasi. Evaluasi dilakukan menggunakan subset pengujian yang tidak dipakai selama pelatihan untuk memastikan model tidak mengalami overfitting. Berbagai metrik evaluasi seperti akurasi, presisi, recall, F1-score, dan AUC-ROC digunakan untuk mengukur kinerja model. Selain itu, analisis confusion matrix dapat membantu memahami kesalahan prediksi yang dibuat oleh model. Berdasarkan hasil evaluasi, mungkin diperlukan iterasi lebih lanjut pada preprocessing, pemilihan fitur, atau tuning model untuk mencapai kinerja yang optimal. Confusion matrix dipilih untuk menentukan tingkat akurasi dari model klasifikasi yang dilatih. Ada empat istilah utama yang perlu

diketahui, yaitu True Positives (TP), True Negatives (TN), False Positives (FP), dan False Negatives (FN). TP adalah jumlah data positif yang diklasifikasikan dengan benar oleh sistem, TN adalah jumlah data negatif yang diklasifikasikan dengan benar oleh sistem. FP adalah jumlah data positif yang diklasifikasikan salah oleh sistem, dan FN adalah jumlah data negatif yang diklasifikasikan salah oleh sistem (Nugraha & Irawan, 2023).

HASIL DAN PEMBAHASAN

1. Hasil Pengumpulan Dataset

Data yang dikumpulkan mencakup informasi mengenai anak-anak, disusun dalam beberapa kolom dengan atribut-atribut tertentu. Kolom pertama, "Gender," menunjukkan jenis kelamin anak yang diidentifikasi sebagai "Female" (perempuan) atau "Male" (laki-laki). Kolom "Age" mencatat usia anak dalam tahun. "Birth Weight" menunjukkan berat badan lahir anak dalam kilogram, sedangkan "Birth Length" mencatat panjang badan lahir anak dalam sentimeter. Kolom "Body Weight" mencatat berat badan anak saat ini dalam kilogram, dan "Body Length" menunjukkan panjang badan anak saat ini dalam sentimeter. Kolom "Breastfeeding" mencatat status menyusui anak, yang diidentifikasi sebagai "Yes" (iya) atau "No" (tidak). Terakhir, kolom "Stunting" mencatat status stunting anak, diidentifikasi sebagai "Yes" (iya) atau "No" (tidak). Seperti dapat dilihat pada gambar 2 dibawah ini.

	Gender	Age	Birth Weight	Birth Length	Body Weight	Body Length	Breastfeeding	Stunting
15	Female	13	2.8	49	10.5	72.2	No	Yes
16	Male	7	2.3	50	6.4	68.3	No	No
17	Male	16	2.7	50	2.9	69.0	No	Yes
18	Female	17	2.0	49	8.0	92.7	No	Yes
19	Female	13	3.1	49	7.0	65.0	No	Yes

Gambar 2. Dataset Stunting

2. Hasil Olah Data

a. Preprocessing

Tahap untuk membangun dan melatih model machine learning. Preprocessing berfungsi untuk meningkatkan kualitas data. Selain itu, preprocessing juga mengubah data ke dalam format yang lebih sederhana sehingga lebih mudah dipahami oleh model. Dataset yang bernilai kategori diubah ke dalam nilai angka. Hasil dapat dilihat digambar 3 dibawah ini.

	Age	Birth Weight	Birth Length	Body Weight	Body Length	Breastfeeding	Stunting
15	13	2.8	49	10.5	72.2	0	1
16	7	2.3	50	6.4	68.3	0	0
17	16	2.7	50	2.9	69.0	0	1
18	17	2.0	49	8.0	92.7	0	1
19	13	3.1	49	7.0	65.0	0	1

Gambar 3. Data Preprocessing

b. Data Splitting

Tahap ini dilakukan untuk membagi dataset menjadi set pelatihan (training set) dan set pengujian (testing set). Tujuannya adalah untuk memastikan bahwa model bekerja dengan baik pada data yang tidak terlihat selama pelatihan model, mencegah model yang terlalu fit ke data pelatihan saja dan memberikan gambaran akurat ketika model bekerja pada data nyata. Hasil dari tahap ini dapat dilihat pada gambar 4 dibawah ini.

Training set:

	Gender	Age	Birth Weight	Birth Length	Body Weight	Body Length	Breastfeeding	Stunting
4	Female	13	3.1	49	7.0	65.0	0	1
2	Male	16	2.7	50	2.9	69.0	0	1
0	Female	13	2.8	49	10.5	72.2	0	1
3	Female	17	2.0	49	8.0	92.7	0	1

Testing set:

	Gender	Age	Birth Weight	Birth Length	Body Weight	Body Length	Breastfeeding	Stunting
1	Male	7	2.3	50	6.4	68.3	0	0

Ukuran set pelatihan : 4

Ukuran set pengujian : 1

Gambar 4. Data Splitting

3. Hasil Klasifikasi Extreme Gradient Boosting

Tahap klasifikasi dengan Algoritma Extreme Gradient Boosting memberikan nilai Feature Importance untuk setiap fitur. Nilainya sangat baik untuk memberikan pengaruh yang lebih besar terhadap hasil prediksi. Untuk nilai akurasi model dalam memprediksi hasil klasifikasi juga sangat baik dengan nilai sebesar 85%. Model ini memprediksi data dengan metode klasifikasi biner untuk pemetaan label No bernilai 0 dan label Yes bernilai 1. Hasil klasifikasi dapat dilihat pada gambar 5 dibawah ini.

```

classifier = XGBClassifier(use_label_encoder=False, eval_metric='logloss',
                          max_depth=5, n_estimators=100, learning_rate=0.1)
classifier.fit(X_train_scaled, y_train)
print('Feature Importances:', classifier.feature_importances_)
y_pred = classifier.predict(X_test_scaled)
print('Accuracy:', np.mean(y_pred == y_test))
print('Label mapping:', dict(zip(label_encoder.classes_,
                                label_encoder.transform(label_encoder.classes_))))

```

```

Feature Importances: [0.04961878 0.09598999 0.7395924 0.06327819 0.05152065]
Accuracy: 0.8565259117082533
Label mapping: {'No': 0, 'Yes': 1}

```

Gambar 5. Klasifikasi Extreme Gradient Boosting

4. Hasil Evaluasi

Tahap evaluasi model klasifikasi ini menggunakan classification report untuk mendapatkan nilai precision, recall dan f1 score dari model klasifikasi yang dibuat, setelah dijalankan didapat hasil sebagai berikut :

- Accuracy bernilai 0.86 yang berarti proporsi prediksi yang benar dari keseluruhan prediksi model memiliki akurasi sebesar 86%.
- Precision bernilai 0.89 yang berarti proporsi prediksi "Yes" yang benar dari semua prediksi "Yes". Dalam hal ini, 89% dari prediksi "Yes" model benar.
- Recall bernilai 0.95 yang berarti proporsi data "Yes" yang benar-benar diidentifikasi oleh model. Dalam hal ini, model hanya mengidentifikasi 95% dari data "Yes" yang sebenarnya ada.
- F1-Score bernilai 0.92 yang berarti metrik yang menggabungkan precision dan recall untuk memberikan evaluasi kinerja model secara keseluruhan. Dalam hal ini, nilai F1-score model tergolong tinggi. Lebih jelasnya dapat dilihat pada gambar 6 dibawah ini.

```
print("\nClassification Report:\n", class_report)
```

Classification Report:				
	precision	recall	f1-score	support
0	0.74	0.51	0.60	418
1	0.89	0.95	0.92	1669
accuracy			0.86	2087
macro avg	0.81	0.73	0.76	2087
weighted avg	0.86	0.86	0.85	2087

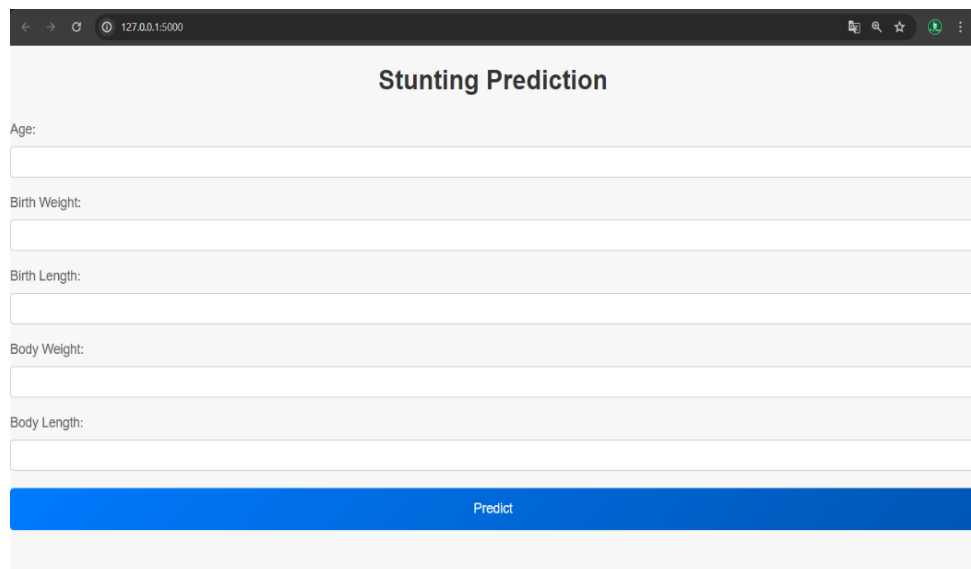
Gambar 6. Classification Report

5. Implementasi Dalam Program

Pada tahap implementasi ini penulis membuat program prediksi berbasis web lokal dengan cara mengexport model diatas ke dalam bentuk pickle, kemudian model diload dengan kode flask berbahasa python yang terhubung ke form html untuk user menginputkan data. Berikut tampilan web lokalnya :

a. Halaman Input Data

Pada halaman ini User dapat melakukan prediksi dengan menginputkan angka-angka data antropometri meliputi age, birth weight, birt length, body weight dan body length dari anak balita yang akan di prediksi statusnya, apakah termasuk kedalam stunting atau normal.



The screenshot shows a web browser window with the URL 127.0.0.1:5000. The page title is "Stunting Prediction". The form contains five input fields: "Age:", "Birth Weight:", "Birth Length:", "Body Weight:", and "Body Length:". Below the input fields is a blue button labeled "Predict".

Gambar 7. Halaman Input Data

b. Halaman Prediksi

Pada halaman ini hasil input data prediksi akan ditampilkan oleh sistem, apabila skor di bawah 1.0 maka anak dikategorikan stunting jika skor lebih dari 1.0 maka anak tersebut dikategorikan normal.



The screenshot shows a web browser window with the URL 127.0.0.1:5000/predict. The page title is "Stunting Prediction Result". The content displays the prediction result: "The prediction result is: **Stunting**" and "The prediction score is: **0.7470249**". There is a blue link labeled "Back to Home".

Gambar 8. Halaman Prediksi

KESIMPULAN

Kesimpulan penelitian ini menfokuskan hasil dari penggunaan algoritma Extreme Gradient Boosting untuk mengklasifikasi status stunting pada anak bawah lima tahun. Implementasi model ini dalam bentuk program berbasis web memungkinkan user untuk melakukan prediksi status stunting anak dengan mudah melalui input data antropometri. Hasil prediksi ditampilkan dengan jelas, membantu dalam identifikasi dini dan pengambilan tindakan yang tepat. Secara keseluruhan, penelitian ini menunjukkan bahwa algoritma XGBoost dapat digunakan secara efektif untuk mengklasifikasikan status stunting pada anak-anak, menawarkan solusi yang cepat dan akurat dalam mendeteksi dan menangani masalah stunting.

DAFTAR REFERENSI

- Adzhima, F., Budianita, E., Nazir, A., & Syafria, F. (2023). Klasifikasi Status Stunting Balita Dengan Metode Support Vector Machine Berbasis Web. *INOVTEK Polbeng - Seri Informatika*, 8(2). <https://doi.org/10.35314/isi.v8i2.3641>
- Aristio, M. L., & Suhartana, Dr. Ir. I. K. G. (2023). Klasifikasi Musik Berdasarkan Genre dengan Metode eXtreme Gradient Boosting. *JELIKU (Jurnal Elektronik Ilmu Komputer Udayana)*, 12(1). <https://doi.org/10.24843/jlk.2023.v12.i01.p13>
- Banurea, M., Betaria Hutagaol, D., & Sihombing, O. (2023). Klasifikasi Penyakit Stunting Dengan Menggunakan Algoritma Support Vector Machine Dan Random Forest. *Jurnal TEKINKOM*, 6(2).
- Fauzan Adzim, Budianita, E., Nazir, A., & Syafria, F. (2023). Klasifikasi Status Stunting Balita Menggunakan Metode C4.5 Berbasis Web. *ZONAsi: Jurnal Sistem Informasi*, 5(3). <https://doi.org/10.31849/zn.v5i3.15828>
- Kemal Musthafa Rajabi, Witanti, W., & Rezki Yuniarti. (2023). Penerapan Algoritma K-Nearest Neighbor (KNN) Dengan Fitur Relief-F Dalam Penentuan Status Stunting. *INNOVATIVE: Journal Of Social Science Research*, 3(1).
- Kharis Pratama, A., Ashaury, H., & Rakhmat Umbara, F. (2024). Klasifikasi Data Gempa Bumi Di Pulau Jawa Menggunakan Algoritma Extreme Gradient Boosting. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(4). <https://doi.org/10.36040/jati.v7i4.7296>
- LUTFIANI, S., Saragih, T. H., Abadi, F., Faisal, M. R., & Kartini, D. (2023). Perbandingan Metode Extreme Gradient Boosting Dan Metode Decision Tree Untuk Klasifikasi Genre Musik. *Jurnal Informatika Polinema*, 9(4). <https://doi.org/10.33795/jip.v9i4.1319>
- Nugraha, A. C., & Irawan, M. I. (2023). Komparasi Deteksi Kecurangan Pada Data Klaim Asuransi Pelayanan Kesehatan Menggunakan Metode Support Vector Machine (SVM) Dan Extreme Gradient Boosting (XGBoost). *Jurnal Sains Dan Seni ITS*, 12(1). <https://doi.org/10.12962/j23373520.v12i1.107032>

Pahlevi, O., Amrin, A., & Handrianto, Y. (2024). Optimasi Algoritma Naïve Bayes Berbasis Particle Swarm Optimization Untuk Klasifikasi Status Stunting. *Computer Science (CO-SCIENCE)*, 4(1). <https://doi.org/10.31294/coscience.v4i1.2963>