
Implementasi *Machine Learning* Menggunakan *Adaboost* dalam Prediksi Status Gizi Anak di Posyandu Tanjung XXIV

Annisa Maulana Majid^{1*}, Ismasari Nawangsih²

Teknik Informatika, Universitas Pelita Bangsa, Bekasi, Indonesia

*e-mail *Corresponding Author*: annisa.maulanamajid@pelitabangsa.ac.id

Abstract

Nutritional status is important for children's growth and development, as well as for measuring nutritional adequacy. Posyandu Tanjung XXIV is a facility for routinely recording children's growth and development, but it still uses manual processes to determine nutritional status so it is not yet effective. Data processing is needed to help predict children's nutritional status. Machine Learning is used for data processing and predicting data based on algorithmic patterns. Previous research related to nutritional status using Machine Learning has been carried out but resulted in a small level of accuracy in the Naïve Bayes algorithm, so accuracy needs to be increased. This research aims to implement Machine Learning using Naïve Bayes combined with the Adaboost method to increase the accuracy of the Posyandu Tanjung XXIV toddler dataset. The research uses variable data Weight by Age, Height by Age, Weight by Height. The results of the research show that the implementation of Naïve Bayes using Adaboost increases accuracy with results of 100% accuracy, an increase of 6.67% from the implementation of Naïve Bayes independently with results of 93.33%.

Keywords: *Nutritional status; Machine Learning; Naive Bayes; Adaboost*

Abstrak

Status Gizi hal yang penting bagi pertumbuhan dan perkembangan anak, serta untuk mengukur kecukupan zat gizi. Posyandu Tanjung XXIV merupakan fasilitas untuk mendata pertumbuhan dan perkembangan anak secara rutin, namun masih menggunakan proses manual untuk menentukan status gizi sehingga belum efektif. Perlu pengolahan data untuk membantu memprediksi status gizi anak. *Machine Learning* digunakan untuk pengolahan data serta memprediksi data berdasarkan pola algoritma. Penelitian sebelumnya terkait status gizi menggunakan *Machine Learning* sudah dilakukan namun menghasilkan tingkat akurasi kecil pada algoritma *Naïve Bayes*, sehingga perlu peningkatan akurasi. Penelitian ini bertujuan untuk implementasi *Machine Learning* menggunakan *Naïve Bayes* dikombinasikan dengan metode *Adaboost* untuk meningkatkan akurasi dataset balita Posyandu Tanjung XXIV. Penelitian menggunakan data variable Berat Badan menurut Umur, Tinggi Badan menurut Umur, Berat Badan menurut Tinggi Badan. Hasil dari penelitian menunjukkan implementasi *Naïve Bayes* menggunakan *Adaboost* meningkatkan akurasi dengan hasil akurasi 100%, meningkat sebesar 6,67% dari penerapan *Naïve bayes* mandiri dengan hasil 93,33%

Kata kunci: *Status Gizi; Machine Learning; Naive Bayes; Adaboost*

1. Pendahuluan

Gizi merupakan hal yang penting karena berhubungan pada kesehatan terutama pada anak bayi dibawah lima tahun atau balita yang masih rentan dengan berbagai masalah kesehatan. Gizi juga berkaitan dengan pertumbuhan dan perkembangan bagi anak sehingga perlu perhatian oleh para orang tua. Masalah gizi pada balita dapat memiliki dampak jangka pendek ataupun jangka panjang, oleh karena itu pentingnya pemberian asupan gizi seimbang untuk meningkatkan pertumbuhan dan perkembangan pada anak. Status gizi merupakan ukuran terkait kondisi tubuh yang berkaitan dengan konsumsi makanan dan zat-zat gizi dalam tubuh [1]. Status gizi merupakan hal yang penting bagi pertumbuhan dan perkembangan balita. Status gizi akan mempengaruhi kesehatan seseorang, kecukupan zat gizi bagi balita akan menentukan

apakah balita kurang gizi, optimal gizi, atau lebih gizi [2]. Anak balita membutuhkan konsumsi zat gizi dengan kuantitas dan kualitas yang cukup supaya tidak terjadi keterlambatan pertumbuhan dan perkembangan [3]. Perkembangan dan pertumbuhan bagi balita diperlukan pemantauan untuk mengetahui status gizi.

Berdasarkan dari hasil Studi Status Gizi Indonesia (SSGI) oleh Kementerian Kesehatan Republik Indonesia Tahun 2022, status gizi balita *stunting* sebesar 21,6%, status *wasting* sebesar 7,7 %, status *underweight* sebesar 17,1 % dan status *overweight* sebesar 3,5% [4]. Sehingga perlu adanya upaya untuk terus meningkatkan kesadaran pentingnya asupan gizi yang maksimal bagi balita di Indonesia. Menurut Peraturan Menteri Kesehatan Republik Indonesia Nomor 2 Tahun 2020 bahwa penilaian status gizi anak dapat dilakukan dengan cara membandingkan hasil pengukuran berat badan dan panjang/tinggi badan dengan Standar Antropometri. Standar Antropometri Anak merupakan kumpulan data tentang ukuran, proporsi, komposisi tubuh sebagai rujukan untuk menilai status gizi dan tren pertumbuhan anak.

Salah satu upaya untuk mencegah meningkatnya status kasus gizi buruk atau kurang gizi yaitu adanya peningkatan informasi terkait pola asuh dan pemberian zat gizi dari orang tua maupun tenaga kesehatan. Pemberian informasi dan pengecekan rutin terkait tumbuh kembang anak dapat dilakukan di Posyandu melalui tenaga kesehatan. Posyandu Tanjung XXIV (Dua Empat) merupakan salah satu fasilitas kesehatan yang rutin selama 1 bulan sekali untuk mendata anak balita serta ibu hamil namun dalam proses pendataan gizi anak masih menggunakan proses manual sehingga informasi yang didapatkan belum efektif, perlu adanya proses pengolahan data untuk membantu tenaga kesehatan dalam memprediksi status gizi anak. Oleh karena itu perlu adanya pengolahan data menggunakan teknik *Machine Learning* untuk dapat membantu tenaga kesehatan dalam memprediksi adanya status gizi yang tidak seimbang terhadap anak balita dapat ditangani sejak dini demi pertumbuhan dan perkembangan yang optimal. Metode *Machine Learning* dapat digunakan dalam bidang kesehatan salah satunya untuk memudahkan dalam memprediksi gejala masalah kesehatan sejak dini agar segera mendapatkan penanganan dengan cepat dan tepat, salah satunya prediksi terkait status gizi anak. *Machine learning* merupakan suatu algoritma yang digunakan dalam menyelesaikan dan mempermudah suatu tugas dengan belajar dari suatu pola dalam data besar untuk tujuan tertentu, seperti memprediksi suatu nilai, mengevaluasi, bereksperimen, atau mengoptimalkan suatu model [5].

Pengkajian penelitian terkait prediksi status gizi Balita telah dilakukan. Namun hasil akurasi menunjukkan perlu adanya peningkatan akurasi pada algoritma *Machine Learning Naive Bayes*. *Naive Bayes* merupakan pengklasifikasian menggunakan probabilitas menggunakan teorema Bayes [6]. Metode *Ensamble* merupakan salah satu metode yang dapat meningkatkan akurasi salah satunya yaitu *Adaboost*. *Adaboost* merupakan suatu algoritma yang digunakan untuk meningkatkan algoritma dengan model akurasi rendah untuk dapat menghasilkan model dengan akurasi tinggi [7]. Penelitian bertujuan untuk mengimplementasikan *Machine Learning* yaitu algoritma *Naive Bayes* menggunakan *Adaboost* dalam Prediksi Status Gizi Anak di Posyandu Tanjung XXIV menggunakan aplikasi *RapidMiner*. Hasil penelitian digunakan untuk mempermudah tenaga kesehatan dalam memprediksi status gizi anak balita sehingga balita dapat tercukupi gizi dan baik dalam tumbuh kembangnya.

2. Tinjauan Pustaka

Pengkajian penelitian terdahulu tentang prediksi status gizi anak balita telah dilakukan menjadi referensi bagi peneliti dalam penelitian. Referensi penelitian terdahulu sebagai berikut:

Penelitian pertama oleh Putri Handayani dkk, Tahun 2024 meneliti status gizi menggunakan data kondisi gizi anak balita di Puskesmas Kecamatan Nglegok Kabupaten Blitar menghasilkan nilai *Accuracy* sebesar 88,6% menggunakan algoritma *Random Forest* [8].

Penelitian kedua oleh Indah Pratiwi Putri, dkk Tahun 2024 tentang prediksi *stunting* pada anak menggunakan sumber data dari data *stunting* di Indonesia tahun 2022 menghasilkan tingkat akurasi sebesar 83,2% pada algoritma *Naive Bayes*, 84,8% akurasi pada algoritma *K-Nearest Neighbors* (KNN), dan 87,75% akurasi pada algoritma *Random Forest* [9].

Penelitian oleh Septi Kenia Pita Loka dan Arif Marsal Tahun 2023 membandingkan algoritma KNN dan *Naive bayes* untuk klasifikasi status gizi pada balita menggunakan data Dinas Kesehatan Kota Solok menghasilkan tingkat akurasi sebesar 96,10% pada algoritma KNN dan 90,94% pada algoritma *Naive Bayes* [10].


Berdasarkan penelitian sebelumnya yang telah dilakukan, algoritma *Naive Bayes* memiliki tingkat akurasi yang lebih kecil dari algoritma lain, maka perlu adanya peningkatan pada

algoritma *Naïve Bayes*. Penelitian ini akan mengimplementasikan algoritma *Machine Learning Naïve Bayes* dengan metode *Adaboost* untuk meningkatkan akurasi pada status gizi balita. Penelitian ini menggunakan data yang berasal dari Posyandu Tanjung XXIV menggunakan aplikasi RapidMiner 10.3.

3. Metodologi

3.1 Tahapan Penelitian

Penelitian ini menggunakan *Machine Learning* dengan algoritma *Naïve Bayes* yang diimplementasikan dengan metode *Adaboost* untuk meningkatkan akurasi dalam prediksi status gizi anak balita menggunakan aplikasi Rapidminer 10.3. Berikut ini merupakan tahapan dalam penelitian:



Gambar 1. Tahapan Penelitian

Tahap pertama dalam penelitian yaitu pengumpulan data anak balita yang berasal dari data Posyandu Tanjung XXIV, kemudian dilakukan tahap data *pre-processing* untuk mengoptimalkan hasil klasifikasi model. Setelah proses *pre-processing* dilakukan maka menghasilkan *dataset* baru. *Dataset* baru akan digunakan untuk implementasi model algoritma, Selanjutnya tahap validasi dilakukan dalam penelitian untuk mengoptimalkan proses pengujian. Model yang digunakan yaitu algoritma *Machine Learning Naïve Bayes* dikombinasikan dengan metode *Adaboost* untuk meningkatkan akurasi *dataset*. Selanjutnya proses evaluasi yang menghasilkan data *accuracy*, *recall*, dan *precision*.

3.2 Pengumpulan Data

Dataset yang digunakan dalam penelitian ini merupakan data dari Posyandu Tanjung XXIV, dengan total data 120 data anak balita. Data tersebut terdiri dari 19 atribut dan 1 atribut label yaitu kategori status gizi sebagai berikut:

Tabel 1. Atribut Dataset Anak Balita Posyandu XXIV

No.	Atribut
1	NIK
2	Nama
3	Jenis Kelamin
4	Nama Orang Tua
5	Alamat
6	Tanggal Lahir
7	BB Lahir
8	TB Lahir
9	Usia Saat Ukur
10	Berat
11	Tinggi
12	Cara Ukur
13	BB/U
14	Zero Score BB/U

No.	Atribut
15	TB/U
16	Zero Score TB/U
17	BB/TB
18	Zero Score BB/TB
19	Naik Berat Badan
20	Kategori Status Gizi (Label)

Data kategori status gizi dapat dilihat pada tabel sebagai berikut:

Tabel 2. Kategori Status Gizi

Kategori Status Gizi	Jumlah
BB Tidak Naik	93
Underweigth	1
Normal	20
Stunting	2
Beresiko Gizi Lebih	2
Obesitas	1
Gizi Lebih	1
Total	120

3.3 Data Preprocessing

Penelitian ini akan dilakukan tahap data *preprocessing* untuk mengelola *dataset* agar dapat menghasilkan tingkat akurasi yang maksimal. *Pre-processing* yang dilakukan dalam penelitian ini yaitu reduksi data. Reduksi data merupakan suatu proses untuk mengurangi kompleksitas data dengan cara memilih beberapa fitur-fitur yang paling relevan [11]. Reduksi data yaitu proses memilih atribut data yang relevan dengan hal yang akan dianalisa dan menghapus atribut data yang tidak relevan [12]. Reduksi data merupakan proses mengurangi jumlah data dari kelas mayoritas [13]. Dalam Peraturan Menteri Kesehatan Republik Indonesia Nomor 2 Tahun 2020 menyatakan bahwa penilaian status gizi anak atau balita dapat diketahui dengan membandingkan hasil pengukuran berat badan dan panjang/tinggi badan dengan Standar Antropometri dengan mengacu pada parameter 4 indeks, yaitu Berat Badan menurut Umur (BB/U), Tinggi Badan menurut Umur (TB/U), Berat Badan menurut Tinggi Badan (BB/TB), dan Indeks Massa Tubuh menurut Umur (IMT/U). Oleh karena itu dalam penelitian ini akan memilih atau mereduksi atribut *dataset* yang relevan dalam memprediksi status gizi dalam *dataset* anak balita posyandu tanjung XXIV. Hasil reduksi data yang akan digunakan dalam penelitian sebagai berikut:

Tabel 3. Atribut Hasil Reduksi Data

No.	Atribut
1	Nama
2	Jenis Kelamin
3	Tanggal Lahir
4	BB Lahir
5	TB Lahir
6	Usia Saat Ukur
7	Berat
8	Tinggi
9	BB/U
10	Zero Score BB/U
11	TB/U
12	Zero Score TB/U
13	BB/TB
14	Zero Score BB/TB
15	Kategori Status Gizi (Label)

3.4 Naïve Bayes

Naïve Bayes merupakan algoritma *Machine Learning* yang dirancang sederhana untuk mendapatkan probabilitas lain dari probabilitas tertentu yang sudah ada [14]. *Naïve Bayes* adalah suatu algoritma klasifikasi *Machine Learning* yang akan menghitung keseluruhan probabilitas berdasarkan pada Teorema Bayes yang dapat dikombinasikan dengan nilai frekuensi data [15]. *Naïve Bayes* dapat menggunakan data sebagai pengalaman pada masa lalu untuk dijadikan prediksi keputusan pada masa depan [16]. Persamaan *Naïve Bayes* sebagai berikut [17]:

$$P(H|X) = \frac{P(X|H) * P(H)}{P(X)} \dots \dots \dots (1)$$

Dimana:

- H : Hipotesis data yang merupakan suatu *class* spesifik
- X : Data dengan *class*
- $P(H)$: Probabilitas hipotesis H (prior probabilitas)
- $P(X)$: Probabilitas X
- $P(H|X)$: Probabilitas hipotesis H yang berdasarkan kondisi X (potensi probabilitas)
- $P(X|H)$: Probabilitas X yang berdasarkan kondisi hipotesis H

Berikut tahapan algoritma *Naïve Bayes*:

1. Menghitung nilai peluang dengan *class* atau label yang ada pada data $P(H)$
2. Menghitung jumlah peluang dari masing-masing *class* atau label $P(X|H)$
3. Mengkalikan semua variable label pada data $P(X|H) * P(H)$
4. Menentukan *class* dari suatu kasus

3.5 Metode Adaboost

Metode *Adaboost* merupakan suatu metode yang menggabungkan beberapa aturan prediksi lemah untuk menjadi aturan prediksi yang akurat [7]. *Adaboost* merupakan singkatan dari *Adaptive Boosting*. Metode *Adaboost* akan membangun klasifikasi yang kuat dari kombinasi klasifikasi sederhana atau yang lemah. Metode ini dapat digunakan untuk meningkatkan akurasi pada metode *Machine Learning* klasifikasi. Berikut persamaan metode *Adaboost* [18]:

$$H(x) = \text{sign}(\sum_{t=1}^T \alpha_t h_t(x)) \dots \dots \dots (2)$$

Dimana:

- $h_t(x)$: keluaran dari pengklasifikasi lemah t untuk input x, pengklasifikasian lemah
- α_t : bobot yang diberikan pada pengklasifikasi, (*learning rate*)
- $H(x)$: hasil pengklasifikasian akhir yang lebih kuat

Berikut tahapan metode *Adaboost* sebagai:

1. Mempersiapkan data *training* dan data *testing*
2. Memberikan nilai pada inialisasi bobot di setiap atribut
3. Mengatur kembali bobot pada setiap fitur dengan menggunakan nilai bobot
4. Menghitung nilai hipotesis h_t dengan menggunakan nilai probabilitas
5. Menghitung kesalahan et
 - Jika $et > \frac{1}{2}$ maka menghitung nilai koefisien bobot, menghitung bobot nilai baru dan normalisasi
 - Jika $et < \frac{1}{2}$ maka menghitung klasifikasi data testing
6. Hasil akhir klasifikasi data uji dengan bobot kuat

3.6 Validasi dan Evaluasi Data

Proses validasi dalam penelitian menggunakan *K-fold cross validation*. *K-fold cross validation* membagi *dataset* menjadi data *testing* dan data *training* secara terpisah dan melakukan pengujian pada data dengan diulang sebanyak nilai K [19]. *K-fold cross validation*

merupakan proses pengujian data dengan membagi *dataset* dengan ukuran sama untuk meningkatkan model algoritma sebanyak *k* (iterasi) dan mengurangi waktu proses komputasi namun tetap memelihara hasil klasifikasi [20]. Pada penelitian ini menggunakan *K-fold cross validation* dengan nilai *k* = 10. Setelah proses pemodelan dan pengujian algoritma, selanjutnya proses evaluasi menggunakan *confusion matrix*. *Confusion matrix* merupakan suatu cara yang digunakan untuk mengevaluasi performa dari model algoritma klasifikasi [21]. *Confusion matrix* adalah suatu tabel untuk mengevaluasi data klasifikasi secara aktual dan prediktif untuk mengetahui performa pada model klasifikasi [22]. Tabel *confusion matrix* dapat dilihat sebagai berikut:

Tabel 4 *Confusion Matrix*

		Prediksi		
		Positif		Negatif
		Positif	TP (<i>True Positive</i>)	FN (<i>False Negative</i>)
Aktual	Negatif	FP (<i>False Positive</i>)	TN (<i>True Negative</i>)	

Confusion matrix akan menghasilkan nilai *accuracy*, *recall*, dan *precision* [23] *Accuracy* adalah perbandingan antara data yang diklasifikasikan secara benar dengan keseluruhan data.

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \dots\dots\dots (3)$$

Recall adalah perbandingan antara data positif yang terprediksi benar dengan total kasus yang positif secara aktual

$$Recall = \frac{TP}{TP+FN} \times 100\% \dots\dots\dots (4)$$

Precision adalah perbandingan antara data positif yang terprediksi benar dengan total prediksi yang positif.

$$Precision = \frac{TP}{TP+FP} \times 100\% \dots\dots\dots (5)$$


4. Hasil dan Pembahasan
4.1 Implementasi Algoritma

Penelitian ini dimulai dengan tahap import *dataset* anak balita pada aplikasi *RapidMiner* menggunakan fitur Read Excel. Gambar 2 adalah hasil import pada aplikasi *RapidMiner*.

No	Kategori Status Gizi	NIK	Nama	JK	Tgl Lahir	BB Lahir	TB Lahir	Usia Saat Ukur	Berat	Tinggi	Cara Ukur	BBU	ZS BBU	TBU	ZS TBU	BBTB	ZS BBTB	Na..	Kategori
1	Normal	3216193211..	MUSA	L	Aug 11, 2019	3	50	4 Tahun - 10 Bulan - 10 Hari	15	107	Berdiri	Berat Badan Normal	-1.410	Normal	-0.450	Normal	-1.830	T	BB Tidak Naik
2	Normal	3216067008..	INAYMA DWI..	P	Aug 30, 2019	3.300	50	4 Tahun - 9 Bulan - 22 Hari	16	104	Berdiri	Berat Badan Normal	-0.750	Normal	-0.900	Normal	-0.300	T	BB Tidak Naik
3	Normal	3216191809..	ATAYA ABRIZ..	L	Sep 18, 2019	2.700	47	4 Tahun - 9 Bulan - 3 Hari	16.500	112	Berdiri	Berat Badan Normal	-0.600	Normal	0.800	Normal	-1.770	T	BB Tidak Naik
4	Normal	3216231206..	ADMADEVA A..	L	Jun 12, 2020	3.400	50	4 Tahun - 0 Bulan - 9 Hari	14	98	Berdiri	Berat Badan Normal	-1.250	Normal	-1.310	Normal	-0.700	T	BB Tidak Naik
5	Normal	3214120605..	RAFASYA FA..	L	May 6, 2020	3.200	50	4 Tahun - 5 Bulan - 15 Hari	13	99	Berdiri	Berat Badan Normal	-1.930	Normal	-1.220	Normal	-1.860	T	BB Tidak Naik
6	Normal	3216190901..	ALVIAN DON..	L	Jan 9, 2020	3.500	51	4 Tahun - 5 Bulan - 11 Hari	13.500	101	Berdiri	Berat Badan Normal	-1.900	Normal	-1.210	Normal	-1.830	T	BB Tidak Naik
7	Normal	3216190811..	MUHAMMAD ..	L	Nov 8, 2019	3.500	51	4 Tahun - 7 Bulan - 12 Hari	16	102	Berdiri	Berat Badan Normal	-0.720	Normal	-1.220	Normal	0.050	T	BB Tidak Naik
8	Normal	3216235311..	DAYYANI HAN..	P	Nov 13, 2019	3.800	51	4 Tahun - 7 Bulan - 7 Hari	16	106	Berdiri	Berat Badan Normal	-0.560	Normal	-0.190	Normal	-0.740	T	BB Tidak Naik
9	Normal	3216230305..	ARSYA FIRD..	L	May 3, 2020	2.600	49	4 Tahun - 1 Bulan - 18 Hari	13	98	Berdiri	Berat Badan Normal	-1.940	Normal	-1.460	Normal	-1.640	T	BB Tidak Naik
10	Normal	3216196207..	AISYAH SHA..	P	Jul 2, 2020	3	49	3 Tahun - 11 Bulan - 19 Hari	15	108	Berdiri	Berat Badan Normal	-0.470	Normal	1.280	Normal	-1.920	T	BB Tidak Naik
11	Normal	3216236408..	SHAFANA BU..	P	Aug 24, 2020	2.800	48	3 Tahun - 6 Bulan - 27 Hari	12.500	94	Berdiri	Berat Badan Normal	-1.720	Normal	-1.770	Normal	-0.990	T	BB Tidak Naik
12	Normal	3216192411..	MUHAMMAD ..	L	Nov 24, 2019	3.100	50	4 Tahun - 6 Bulan - 27 Hari	16	103	Berdiri	Berat Badan Normal	-0.660	Normal	-0.940	Normal	-0.170	T	BB Tidak Naik
13	Normal	3306062101..	MUHAMMAD ..	L	Mar 21, 2020	4	54	4 Tahun - 3 Bulan - 0 Hari	16	104	Berdiri	Berat Badan Normal	-0.400	Normal	-0.240	Normal	-0.390	N	Normal
14	Normal	3216194061..	HAURA SHA..	P	Apr 1, 2020	3.100	47	4 Tahun - 2 Bulan - 20 Hari	13.500	102	Berdiri	Berat Badan Normal	-1.500	Normal	-0.520	Normal	-1.790	T	BB Tidak Naik
15	Normal	3216231007..	UWAS AL Q..	L	Jul 10, 2020	2.700	50	3 Tahun - 11 Bulan - 11 Hari	13	97	Berdiri	Berat Badan Normal	-1.770	Normal	-1.430	Normal	-1.420	T	BB Tidak Naik
16	Normal	3216195809..	CHARUN SE..	P	Sep 18, 2020	3.500	50	3 Tahun - 9 Bulan - 2 Hari	15	99	Berdiri	Berat Badan Normal	-0.260	Normal	-0.470	Normal	0.040	N	Normal
17	Normal	3216231802..	BEN ALFARO	L	Feb 18, 2020	3	50	4 Tahun - 4 Bulan - 2 Hari	14	97	Berdiri	Berat Badan Normal	-1.520	Normal	-1.980	Normal	-0.480	T	BB Tidak Naik
18	Normal	3216194212..	NAURA ASYA..	P	Dec 2, 2020	3.700	47	3 Tahun - 6 Bulan - 18 Hari	15	98	Berdiri	Berat Badan Normal	-0.040	Normal	-0.350	Normal	0.240	N	Normal
19	Normal	3216190311..	AKBAR SUSL..	L	Nov 3, 2019	3	49	4 Tahun - 11 Bulan - 17 Hari	15.400	103	Berdiri	Berat Badan Normal	-1.020	Normal	-1.020	Normal	-0.630	T	BB Tidak Naik
20	Normal	3216192405..	BELLISSA AL..	P	May 24, 2021	2.800	48	3 Tahun - 0 Bulan - 28 Hari	14	93	Berdiri	Berat Badan Normal	-0.010	Normal	-0.700	Normal	0.490	T	BB Tidak Naik
21	Normal	3216196806..	WAFI AFIZAH..	P	Jun 28, 2020	2.400	45	3 Tahun - 11 Bulan - 23 Hari	14	97.600	Berdiri	Berat Badan Normal	-1	Normal	-1.160	Normal	-0.440	T	BB Tidak Naik
22	Normal	3229141909..	KHALID ARG..	L	Sep 19, 2020	2.800	50	3 Tahun - 9 Bulan - 1 Hari	13.400	98.300	Berdiri	Berat Badan Normal	-1.350	Normal	-0.820	Normal	-1.320	T	BB Tidak Naik
23	Normal	3175095806..	SHEZA GLU..	P	Jun 18, 2020	3.200	47	4 Tahun - 0 Bulan - 3 Hari	13.500	98.300	Berdiri	Berat Badan Normal	-1.300	Normal	-1.040	Normal	-1	T	BB Tidak Naik
24	Normal	3216230906..	FATAN	L	Jun 9, 2020	3	49	4 Tahun - 0 Bulan - 12 Hari	14.700	99.300	Berdiri	Berat Badan Normal	-0.670	Normal	-1.010	Normal	-0.380	T	BB Tidak Naik
25	Normal	3216232712..	MIRZKY DAF..	L	Dec 27, 2019	3.100	49	4 Tahun - 5 Bulan - 24 Hari	18.900	112	Berdiri	Berat Badan Normal	0.660	Normal	1.230	Normal	-0.200	T	BB Tidak Naik
26	Normal	3216232212..	ARSAKA	L	Dec 22, 2020	3.700	54	3 Tahun - 5 Bulan - 29 Hari	13	93.600	Berdiri	Berat Badan Normal	-1.340	Normal	-1.570	Normal	-0.680	T	BB Tidak Naik
27	Normal	3216235019..	ANISA NIRMA..	P	Oct 10, 2020	3.200	50	3 Tahun - 8 Bulan - 10 Hari	17.700	107	Berdiri	Berat Badan Normal	1	Normal	1.560	Normal	0.140	T	BB Tidak Naik


Gambar 2. Hasil Import *Dataset*

Setelah import *dataset*, kemudian dilanjutkan pada tahap data *preprocessing* dengan reduksi data menggunakan fitur *Select Attributes*. Selanjutnya pada tahap validasi dan evaluasi ditambahkan fitur *Cross Validation*. Berikut gambar implementasi fitur pada *RapidMiner*.




Gambar 3. Tahap Validasi

Pengujian pertama pada penelitian ini dengan penambahan fitur algoritma *Naïve Bayes*, *Apply Model* dan *Performance* di dalam fitur *Cross Validation*, sebagai berikut:




Gambar 4. Implementasi Algoritma *Naïve Bayes*

Penelitian kedua penambahan fitur metode *Adaboost* di dalam *Cross Validation* seperti berikut:



Gambar 5. Penerapan metode *Adaboost*

Didalam fitur *Adaboost* ditambahkan fitur Read Excel, Select Attributes, dan algoritma *Naïve Bayes* didalamnya untuk dikombinasikan.



Gambar 6. Implementasi *Naïve Bayes* dengan *Adaboost*

4.2 Pembahasan

Penelitian dilakukan sebanyak 2 kali dengan menguji *dataset* anak balita menggunakan model algoritma *Naive Bayes* dan mengoptimalkan model algoritma *Naive Bayes* menggunakan metode *Adaboost*. Pengujian akan menghasilkan nilai *accuracy*, *recall*, dan *precision*. Berikut merupakan tabel dari hasil pengujian yang telah dilakukan:

Tabel 5. Hasil Penelitian

	<i>Accuracy</i>	<i>Recall</i>	<i>Precision</i>
Naive Bayes	93,33%	99,12%	94,12%
Naive Bayes + Adaboost	100%	100%	100%

Berdasarkan dari pengujian yang dilakukan dalam penelitian mendapatkan hasil yaitu peningkatan nilai *accuracy*, *recall*, dan *precision*. Peningkatan terjadi pada algoritma *Naïve Bayes* yang diimplementasikan dengan Metode *Adaboost*. Berikut hasil perbedaan penelitian ini dengan penelitian sebelumnya.

Tabel 6. Hasil Perbandingan akurasi

Penelitian	Akurasi
Penelitian ini	100%
Indah Pratiwi Putri, dkk	83.2%
Septi Kenia Pita Loka dan Arif Marsal	90,94%

Pengujian mendapatkan hasil terbaik dengan *accuracy* sebesar 100% jika dikombinasikan antara Algoritma *Naïve Bayes* dengan *Adaboost* daripada menggunakan model klasifikasi mandiri dengan *accuracy* sebesar 93,33%.

5. Simpulan

Penelitian ini mendapatkan hasil terbaik dengan mengimplementasikan algoritma *Naïve Bayes* dengan metode *Adaboost* untuk memprediksi status gizi anak di Posyandu Tanjung XXIV. Hasil nilai akurasi sebesar 100%, hasil tersebut meningkat sebesar 6,67% dari pada menggunakan algoritma klasifikasi secara mandiri tanpa dikombinasikan. Penelitian ini dapat digunakan untuk mempermudah tenaga medis dalam memprediksi status gizi Anak balita sehingga apabila terdapat masalah terkait gizi dapat segera ditangani.

Penelitian yang akan datang dapat dilakukan dengan mengimplementasikan algoritma *Naïve Bayes* dengan metode Ensemble lainnya. Hasil dari penelitian selanjutnya dapat diimplementasikan ke dalam bentuk aplikasi sistem pengambilan keputusan untuk memprediksi

status gizi anak secara dini agar anak yang memiliki kekurangan gizi mendapatkan penanganan dengan cepat.

Daftar Referensi

- [1] L. A. Budiman *et al.*, "Analisis Status Gizi Menggunakan Pengukuran Indeks Massa Tubuh Dan Beban Kerja Pada Tenaga Kesehatan," *Nutrizone*, vol. 01, no. 1, pp. 6–15, 2021.
- [2] L. Khulafa'ur Rosidah and S. Harsiwi, "Hubungan Status Gizi Dengan Perkembangan Balita Usia 1-3 Tahun (Di Posyandu Jaan Desa Jaan Kecamatan Gondang Kabupaten Nganjuk)," *J. Kebidanan*, vol. 6, no. 1, pp. 24–37, 2019, doi: 10.35890/jkdh.v6i1.48.
- [3] Ramadhani, Ramadhanu, and Taufik Hidayat, "Metode Machine Learning untuk Klasifikasi Data Gizi Balita dengan Algoritma Naïve Bayes, KNN dan Decision Tree," *J. SIMETRIS*, vol. 15, no. 1, pp. 57–68, 2024.
- [4] Kemenkes, "Buku Saku Hasil Survey Status Gizi Indonesia (SSGI) Tahun 2022," *Kemenkes*, pp. 1–154, 2022.
- [5] O. Ennaji, L. Vergütz, and A. El Allali, "Machine learning in nutrient management: A review," *Artif. Intell. Agric.*, vol. 9, pp. 1–11, 2023, doi: 10.1016/j.aiia.2023.06.001.
- [6] A. V. D. Sano, A. A. Stefanus, E. D. Madyatmadja, H. Nindito, A. Purnomo, and C. P. M. Sianipar, "Proposing a visualized comparative review analysis model on tourism domain using Naïve Bayes classifier," *Procedia Comput. Sci.*, vol. 227, pp. 482–489, 2023, doi: 10.1016/j.procs.2023.10.549.
- [7] C. Karima and W. Anggraeni, "Performance Analysis of the Ada-Boost Algorithm For Classification of Hypertension Risk With Clinical Imbalanced Dataset," *Procedia Comput. Sci.*, vol. 234, pp. 645–653, 2024, doi: 10.1016/j.procs.2024.03.050.
- [8] P. Handayani and A. C. Fauzan, "Machine Learning Klasifikasi Status Gizi Balita Menggunakan Algoritma Random Forest," vol. 4, no. 6, pp. 3064–3072, 2024, doi: 10.30865/klik.v4i6.1909.
- [9] I. P. Putri, T. Terttiaavini, and N. Arminarahmah, "Analisis Perbandingan Algoritma Machine Learning untuk Prediksi Stunting pada Anak," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 1, pp. 257–265, 2024, doi: 10.57152/malcom.v4i1.1078.
- [10] S. K. P. Loka and A. Marsal, "Perbandingan Algoritma K-Nearest Neighbor dan Naïve Bayes Classifier untuk Klasifikasi Status Gizi Pada Balita," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 1, pp. 8–14, 2023, doi: 10.57152/malcom.v3i1.474.
- [11] A. Amalia, A. Irma Purnamasari, and I. Ali, "Implementasi Algoritma C4.5 Dan Naïve Bayes Dalam Pengambilan Keputusan Untuk Program Indonesia Pintar (Pip) Di Sekolah Dasar Negeri 04 Majalangu," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 2, pp. 1889–1896, 2024, doi: 10.36040/jati.v8i2.8311.
- [12] F. Prasetyo and H. Hasugian, "Analisis Pola Pembelian Produk Makanan Menggunakan Algoritma Fp-Growth Untuk Strategi Penjualan," *IDEALIS Indones. J. Inf. Syst.*, vol. 7, no. 1, pp. 11–20, 2024, doi: 10.36080/idealisis.v7i1.3085.
- [13] S. Mawaddah, W. J. Pranoto, and F. Faldi, "Optimasi Algoritma C4.5 Menggunakan Metode Adaboost Classification Pada Klasifikasi Nilai Mahasiswa Studi Kasus: Universitas Muhammadiyah Kalimantan Timur," *J. Sains Komput. dan Teknol. Inf.*, vol. 6, no. 1, pp. 83–89, 2023, doi: 10.33084/jsakti.v6i1.5458.
- [14] A. S. Biyantoro and B. Prasetyo, "Penerapan Decision Tree untuk Klasifikasi Status Kesehatan dengan Perbandingan KNN dan Naive Bayes," *Indones. J. Inform. Res. Softw. Eng.*, vol. 4, no. 1, pp. 47–55, 2024.
- [15] Syahril Dwi Prasetyo, Shofa Shofiah Hilabi, and Fitri Nurapriani, "Analisis Sentimen Relokasi Ibukota Nusantara Menggunakan Algoritma Naïve Bayes dan KNN," *J. KomtekInfo*, vol. 10, pp. 1–7, 2023, doi: 10.35134/komtekinfo.v10i1.330.
- [16] F. Sholekhah, A. D. Putri, R. Rahmadden, and L. Efrizoni, "Perbandingan Algoritma Naïve Bayes dan K-Nearest Neighbors untuk Klasifikasi Metabolik Sindrom," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 4, no. 2, pp. 507–514, 2024, doi: 10.57152/malcom.v4i2.1249.
- [17] A. Putri *et al.*, "Komparasi Algoritma K-NN, Naive Bayes dan SVM untuk Prediksi Kelulusan Mahasiswa Tingkat Akhir," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 1, pp. 20–26, 2023, doi: 10.57152/malcom.v3i1.610.
- [18] R. T. Febianto, D. Suranti, and R. T. Alinse, "Penerapan Algoritma Adaboost Dalam Mengetahui Pola Pengguna Kb Di Puskesmas Tanjung Harapan," *J. Sci. Soc. Res.*, vol.

- 4307, no. 1, pp. 145–155, 2024, [Online]. Available: <http://jurnal.goretanpena.com/index.php/JSSR>
- [19] J. Jamaludin, C. Rozikin, and A. S. Y. Irawan, "Klasifikasi Jenis Buah Mangga dengan Metode Backpropagation," *Techné J. Ilm. Elektrotek.*, vol. 20, no. 1, pp. 1–12, 2021, doi: 10.31358/techne.v20i1.231.
- [20] Taofik Safrudin, G. Tri Pranoto, and W. Hadikristanto, "Optimasi Algoritma K- Nearest Neighbor Berbasis Particle Swarm Optimization Untuk Meningkatkan Kebutuhan Barang," *Bull. Inf. Technol.*, vol. 4, no. 3, pp. 281–286, 2023, doi: 10.47065/bit.v4i3.724.
- [21] R. Gusdiana, I. Alfian, and C. Juliane, "Implementation of Text Processing for Sentiment Analysis of Tax Payment Interest After the 'Rubicon' Phenomenon," *J. Tek. Inform.*, vol. 4, no. 5, pp. 1157–1164, 2023, doi: 10.52436/1.jutif.2023.4.5.1014.
- [22] D. Musfiroh, U. Khaira, P. E. P. Utomo, and T. Suratno, "Analisis Sentimen terhadap Perkuliahan Daring di Indonesia dari Twitter Dataset Menggunakan InSet Lexicon," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 1, no. 1, pp. 24–33, 2021, doi: 10.57152/malcom.v1i1.20.
- [23] R. Hidayat, M. Fikry, F. Yanto, and E. P. Cynthia, "Penerapan Naïve Bayes Classifier dalam Klasifikasi Sentimen Publik di Twitter terhadap Puan Maharani," vol. 6, pp. 93–101, 2024.