

Klasifikasi Stunting pada Balita menggunakan Algoritma Gradient Boosting Classifier

Daffa Maulana Azhari^{1,*}, Moch Sjamsul Hidajat¹

¹ Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Indonesia

* Correspondence: daffamaulanaa15@gmail.com

Copyright: © 2024 by the authors

Received: 14 September 2024 | Revised: 20 September 2024 | Accepted: 11 Oktober 2024 | Published: 19 Desember 2024

Abstrak

Stunting merupakan masalah kesehatan masyarakat yang signifikan, berdampak pada pertumbuhan dan perkembangan balita secara fisik dan kognitif. Di Indonesia, stunting menjadi isu utama yang disebabkan oleh kurangnya asupan gizi sejak lahir, termasuk di kota Semarang. Penelitian ini bertujuan untuk membandingkan performa algoritma *K-Nearest Neighbor* (KNN), *Naïve Bayes*, dan *Gradient Boosting Classifier* dalam mengklasifikasikan *stunting* pada balita, untuk menemukan model terbaik. Data yang digunakan adalah data kuantitatif dari posyandu, terdiri dari 1288 sampel dengan variabel diantaranya Nama, Jenis Kelamin, Usia, Tanggal Lahir, Nama Orang tua, Desa/ Kelurahan, Rt, RW, berat, tinggi, lingkaran lengan, dan *Z-score*. Setelah pengumpulan data, dilakukan proses preprocessing data untuk membersihkan dan mempersiapkan data. Data dibagi menjadi data latih dan data uji dengan rasio 80:20, 70:30, dan 60:40, yang kemudian dilatih dan diuji menggunakan ketiga algoritma tersebut. Model terbaik dievaluasi lebih lanjut dengan *K-Fold Cross Validation* untuk menilai kestabilan dan generalisasi prediksi. Evaluasi model menggunakan metrik akurasi, *precision*, *recall* dan *F1-Score*. Hasil penelitian menunjukkan bahwa Gradient Boosting Classifier memberikan performa terbaik dengan akurasi 99.92%, *precision* 99.92%, *recall* 99.92%, dan *F1-score* 99.92%. Penelitian ini menyimpulkan bahwa Gradient Boosting Classifier merupakan model yang paling optimal dalam klasifikasi stunting balita, memberikan hasil prediksi yang stabil dan akurat.

Kata kunci: *artificial intelligence; gradient boosting classifier; kesehatan; machine learning; stunting*

Abstract

Stunting is a significant public health problem, impacting the physical and cognitive growth and development of children under five. In Indonesia, stunting is a major issue caused by a lack of nutritional intake since birth, including in the city of Semarang. This study aims to compare the performance of K-Nearest Neighbor (KNN), Naïve Bayes, and Gradient Boosting Classifier algorithms in classifying stunting in toddlers, to find the best model. The data used is quantitative data from posyandu, consisting of 1288 samples with variables including Name, Gender, Age, Date of Birth, Parent's Name, Village, Rt, RW, weight, height, arm circumference, and Z-score. After data collection, a data preprocessing process is carried out to clean and prepare the data. The data was divided into training and test data with a ratio of 80:20, 70:30, and 60:40, which were then trained and tested using the three algorithms. The best model was further evaluated with K-Fold Cross Validation to assess the stability and generalizability of the predictions. Model evaluation uses accuracy, precision, recall and F1-Score metrics. The results showed that Gradient Boosting Classifier gave the best performance with 99.92% accuracy, 99.92% precision, 99.92% recall, and 99.92% F1-score. This study concludes that the Gradient Boosting Classifier is the most optimal model in the classification of stunting in toddlers, giving the best precision results.

Keywords: *artificial intelligence; gradient boost classifier; health; machine learning; stunting*



PENDAHULUAN

Stunting adalah gangguan perkembangan dan pertumbuhan anak yang diakibatkan oleh buruknya gizi sejak dini (Sari et al., 2023). *Stunting* menggambarkan keadaan seorang manusia atau balita yang mengalami gizi kronis pada masa pertumbuhannya (Titimeidara & Hadikurniawati, 2021). *Stunting* pada balita mengakibatkan penurunan tingkat kecerdasan, gangguan berbicara, dan kesulitan dalam menangkap pembelajaran (Ali et al., 2021; Rozaq & Purnomo, 2022; Titimeidara & Hadikurniawati, 2021). Untuk melakukan identifikasi *stunting* pada balita, WHO menggunakan nilai simpang (Z-Score) untuk melakukan klasifikasi status *stunting* pada balita (Siahaan et al., 2023). Pada tahun 2022, angka *stunting* menurun mencapai 21,6%, dan pemerintah mempunyai target untuk menurunkan *stunting* pada tahun 2024 sebesar 14% (Sa'adah et al., 2024). Oleh karena itu, diperlukan adanya upaya yang lebih dalam melakukan pengembangan teknologi sehingga mampu menghasilkan teknologi yang mampu melakukan klasifikasi *stunting* dini dengan akurat.

Pengembangan teknologi klasifikasi *stunting* dini dapat dilakukan dengan memanfaatkan teknologi berbasis *machine learning* yang dapat menjadi solusi untuk melakukan prediksi *stunting* pada balita secara dini dengan cara melakukan perbandingan algoritma *Machine learning* berdasarkan tingkat akurasi (Setianto et al., 2023; Wahyudin, 2020). Dengan melakukan perbandingan algoritma *machine learning*, dapat ditemukan model terbaik yang akurat dalam melakukan klasifikasi *stunting* dini pada balita (Darnis, 2022; Yahya, 2022). Pemanfaatan lainnya adalah data mining yang berfungsi untuk melakukan analisis mendalam terhadap data statistik pada balita dengan cara memanfaatkan teknik yang canggih mampu melakukan identifikasi pola pola yang tidak terlihat secara langsung seperti korelasi antar berat badan dengan gizi, tinggi badan dengan gizi, usia dengan gizi (Mulyanto et al., 2024). Selain itu, teknik *ensemble boosting* dalam *machine learning* dipilih karena kemampuannya untuk meningkatkan performa pengklasifikasi dengan menggabungkan beberapa model yang dilatih secara berurutan, di mana setiap model baru fokus pada kesalahan yang dibuat oleh model sebelumnya, sehingga menghasilkan prediksi yang lebih akurat, terutama dalam menghadapi data yang kompleks dan variabilitas yang tinggi (Finda & Utomo, 2024). Dengan memadukan *machine learning*, Data Mining, dan teknik *ensemble boosting*, ketiga pendekatan tersebut mampu menghasilkan model yang prediktif yang akurat dalam mengelompokkan kasus *stunting* dini pada balita (Wahyudi et al., 2021).

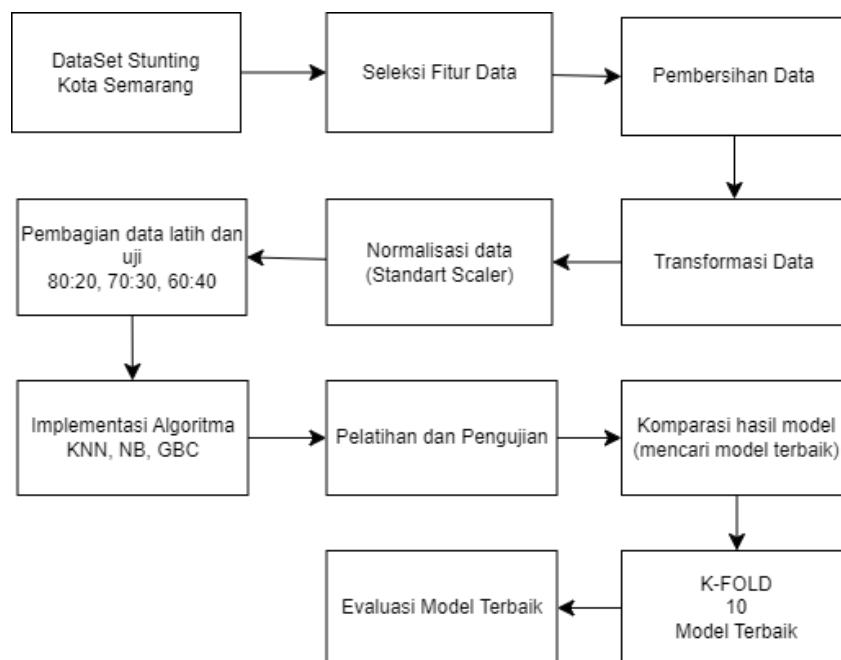
Pada penelitian klasifikasi *stunting* menggunakan Algoritma *naïve bayes* dengan seleksi fitur *forward selection*, algoritma *naïve bayes* menghasilkan tingkat akurasi sebesar 89% (Wahyudin, 2020). Sementara itu, penelitian tentang status *stunting* pada balita menggunakan algoritma *K-Nearest Neighbor* (KNN) dengan *feature selection* dan *backward elimination* yang menggunakan 457 data dengan teknik pembagian data *k-fold* bernilai 10 yang menghasilkan performa metrik akurasi sebesar 91.9%, Presisi sebesar 93,4, *recall* sebesar 71.0 dan *F1-score* sebesar 77,6 (Lonang & Normawati, 2022). Selanjutnya, algoritma *XGBoosting* menghasilkan performa dengan akurasi sebesar 86%, *precision* 89%, *recall* 95%, dan *F1-score* 92% dalam melakukan klasifikasi *stunting* yang menggunakan dataset publik penelitian Harnelia berjumlah 10000 data yang sudah dilakukan penyeimbangan kelas. (Fikri, 2024).

Penelitian sebelumnya (Fikri, 2024; Lonang & Normawati, 2022; Wahyudi et al., 2021) menunjukkan bahwa tingkat akurasi yang tinggi pada model *machine learning* membutuhkan penyeimbangan data serta metode seleksi fitur seperti *forward selection* dan *backward elimination*. Namun, penggunaan teknik penyeimbangan data berpotensi menghilangkan informasi aktual dalam dataset dan meningkatkan risiko *overfitting*. Sementara itu, *forward selection* dan *backward elimination* memiliki sejumlah keterbatasan, termasuk mengabaikan risiko *overfitting*, membutuhkan waktu dan komputasi yang lebih lama, menghilangkan fitur signifikan, mengabaikan fitur tersembunyi, serta meningkatkan sensitivitas terhadap *noise* (Eina et al., 2024; Maulina et al., 2024).

Pada penelitian ini, kami berfokus pada klasifikasi *stunting* pada balita, digunakan *Gradient Boosting Classifier* (GBC) karena model ini mampu menangani masalah ketidakseimbangan data melalui pendekatan *ensemble* yang menggabungkan beberapa model lemah menjadi satu model yang kuat (Prasetyo & Nugroho, 2024). Model ini juga memiliki kemampuan untuk memahami pola data pada setiap fitur yang diberikan (Ahsan et al., 2021). Model klasifikasi yang baik diharapkan memiliki nilai metrik seperti akurasi, presisi, *recall*, dan *F1-Score* yang tinggi (Yacouby & Axman, 2020). Penelitian ini bertujuan untuk membuktikan bahwa GBC mampu menghasilkan akurasi yang lebih baik dibandingkan dengan model KNN dan Naïve Bayes tanpa memerlukan *forward selection*, *backward selection*, atau penyeimbangan kelas data.

METODE

Penelitian ini adalah penelitian kuantitatif yang menggunakan data numerik untuk menganalisis dan menguji hipotesis melalui pendekatan *machine learning* untuk melakukan klasifikasi *stunting* dini pada balita. Data yang diperoleh dianalisis menggunakan algoritma *machine learning* untuk mengevaluasi performa model berdasarkan metrik seperti akurasi, *precision*, *recall*, dan *F1-score*. Gambar 1 menjelaskan alur pengerjaan yang peneliti gunakan dapat penelitian ini mulai dari dataset yang digunakan, *preprocessing data*, pembagian data latih dan data uji, algoritma yang digunakan dalam penelitian ini, pelatihan dan pengujian setiap model, melakukan komparasi setiap model, validasi model menggunakan *K-fold*, dan evaluasi model terbaik.



Gambar 1. Metode *machine learning*

Berdasarkan gambar 1, tahap awal dalam penelitian ini adalah mengumpulkan dataset. Dataset didapatkan di puskesmas Kota Semarang Timur. Pada penelitian ini data berisikan 1289 butir data yang berisikan dataset warga yang memiliki balita. Dataset terdiri dari 15 fitur diantaranya nama balita, Jenis Kelamin, Tanggal lahir, Nama Orang Tua, Desa/ kelurahan, RT, RW, Tinggi Badan, Berat Badan, Lingkarang Lengan, Z-Score Berat badan banding usia, Z-score Tinggi Badan Banding Usia, Z-Score Berat Badan dengan Tinggi badan dan status Gizi. Status gizi dalam data ini memiliki jumlah data yang berjumlah berbeda beda (data tidak seimbang). Pada penelitian ini, kami menggunakan fitur Jenis Kelamin, Usia, Tinggi badan,

Berat Badan, *Z-score* Berat badan banding usia, *Z-score* Tinggi Badan Banding Usia, *Z-Score* Berat Badan dengan Tinggi badan dan status Gizi dan status Gizi. Aspek penelitian ini tertuju pada pengelompokan status gizi pada balita yang digunakan sebagai tolak ukur apakah balita terkena *stunting* dini atau tidak. Pada bagian pembersihan data, peneliti melakukan pengecekan data yang hilang menggunakan fungsi metode missing value analysis, dan pengecekan duplikat menggunakan fungsi deduplikasi. Hasil dari pembersihan pada dataset ini tidak terdapat data yang hilang dan data yang terduplikasi.

Transformasi dilakukan dengan mengubah nilai string pada kolom jenis kelamin dan status gizi menjadi format numerik menggunakan LabelEncoder, serta menghapus kata "tahun" pada kolom usia untuk mengubahnya menjadi integer. Selanjutnya, normalisasi dilakukan pada kolom usia, berat badan, dan tinggi badan menggunakan StandardScaler untuk memastikan keseragaman distribusi, sementara kolom jenis kelamin tidak memerlukan normalisasi karena sifat kategorikalnya. Data dibagi dalam rasio 80:20, 70:30, dan 60:40 untuk mengevaluasi adaptasi model terhadap jumlah data latih dan pengujian. Tiga algoritma *machine learning naive bayes*, KNN, dan GBC dibandingkan, dengan penilaian performa menggunakan metrik seperti akurasi, *F1-Score*, *precision*, *recall*, dan *confusion matrix*. Model yang terbaik kemudian diuji dengan *cross-validation* untuk memastikan stabilitas dan generalisasi terhadap data yang tidak terlihat. *Cross validation* membantu dalam mengevaluasi seberapa baik model menangani variabilitas dalam dataset, serta mengurangi risiko *overfitting*.

HASIL DAN PEMBAHASAN

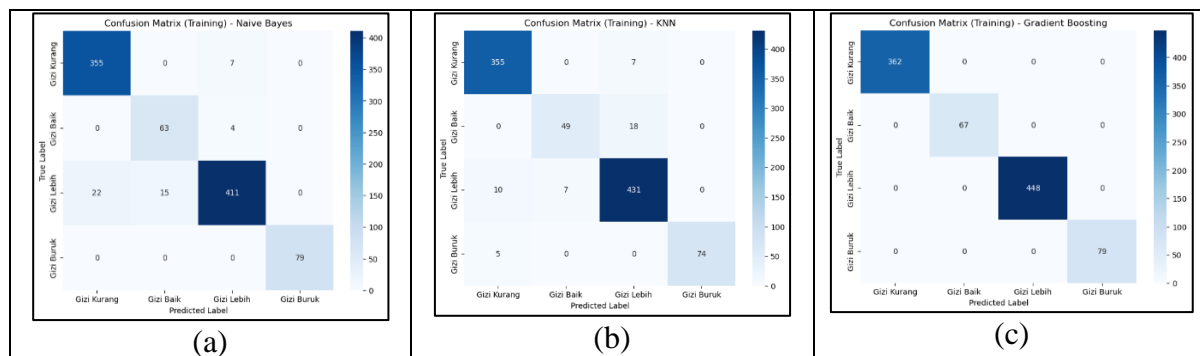
Hasil

Perbandingan hasil kinerja pelatihandari model klasifikasi *Naive Bayes* (NB), KNN, dan GBC ditabulasikan pada tabel 1 dan untuk confusion matrixnya ada pada gambar 2. Pada tabel 1 menunjukkan hasil metrik pelatihan setiap model dengan rasio 80:20, 70:30, dan 60:40. Sedangkan pada gambar 2 menunjukkan hasil *confusion matrix* model pada peforma terbaik pada pelatihan

Tabel 1. Tabel metrik pelatihan

Rasio	Model	<i>Precision Training</i>	<i>Recall Training</i>	<i>F1-Score Training</i>	<i>Accuracy Training</i>
80:20	NB	0.95	0.95	0.95	0.95
	KNN	0.95	0.95	0.95	0.95
	GBC	1.00	1.00	1.00	1.00
70:30	NB	0.95	0.94	0.94	0.95
	KNN	0.93	0.93	0.93	0.93
	GBC	1.00	1.00	1.00	1.00
60:40	NB	0.95	0.94	0.94	0.94
	KNN	0.93	0.94	0.93	0.93
	GBC	1.00	1.00	1.00	1.00


Tabel 1 menunjukkan bahwa ketiga model memiliki nilai metrik tertinggi pada rasio 80:20. Hasil metrik pelatihan pada tabel 1, ketiga model tersebut pada rasio 80:20 memiliki konsistensi yang sama. Algoritma terbaik pada pelatihan dengan rasio 80:20 ada pada algoritma GBC yang menunjukkan semua peforma metrik bernilai 1.00. *Confusion Matrix* pada gambar 2 menunjukkan algoritma GBC memiliki tingkat kesalahan prediksi kelas yang sangat kecil dibandingkan dengan algoritma NB dan KNN. Hal itu dapat divalidasi pada gambar 2c *False Positive* dan *False Negative* bernilai 0, sedangkan pada gambar 2a dan 2b menunjukkan bahwa setiap kelas masih memiliki nilai pada *false positive* dan *false negative*.



Gambar 2. Confusion Matrix (a) 80:20 NB (b) 80:20 KNN (c) 80:20 GBC

Tabel 2. Tabel metrik pengujian

Rasio	Model	Precision Testing	Recall Testing	F1-Score Testing	Accuracy Testing
80:20	NB	0.96	0.95	0.96	0.95
	KNN	0.90	0.91	0.90	0.91
	GBC	1.00	1.00	1.00	1.00
70:30	NB	0.96	0.96	0.96	0.96
	KNN	0.91	0.91	0.91	0.91
	GBC	1.00	1.00	1.00	1.00
60:40	NB	0.96	0.96	0.96	0.96
	KNN	0.93	0.94	0.93	0.94
	GBC	1.00	1.00	1.00	1.00



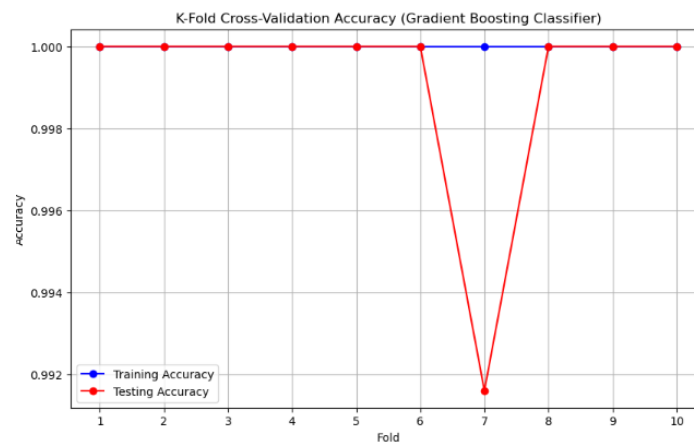
Gambar 3. Confusion matrix (a) 60:40 NB (b) 60:20 KNN (c) 60:40 GBC

Tabel 2 menunjukkan adanya perubahan performa pada setiap model yang ada. Performa tertinggi ke tiga model ada pada rasio 60:40. Pada hasil pengujian model klasifikasi, model GBC masih menunjukkan kekonsistennya dalam melakukan prediksi data pengujian. Hal itu dilihat pada tabel 2 yang menunjukkan performanya berada pada angka 1.0. Pada gambar 3c menunjukkan hal yang sama seperti gambar 2c, bahwa model GBC memiliki nilai *False Postive* dan *False negative* bernilai 0 yang mengartikan bahwa model GBC mampu memprediksi data yang tak pernah dilihat dipelajari dengan benar dan akurat.

Terbukti bahwa model terbaik ada pada model GBC, dilanjutkan melakukan pengecekan konsisten model dari GBC. Peneliti melakukan *cross validation* pada algoritma GBC. Hasil dari setiap metrik dan tiap foldnya ditabulasikan pada tabel 3 dan akurasi setiap *fold* divisualisasikan menggunakan *line chart* pada gambar 4.

Tabel 3. Tabel Metrik Pengujian

<i>Fold</i>	<i>Train Accuracy</i>	<i>Test Accuracy</i>	<i>Train Precision</i>	<i>Test Precision</i>	<i>Train Recall</i>	<i>Test Recall</i>	<i>Train f1-score</i>	<i>Test f1-score</i>
1	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
2	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
3	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
4	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
5	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
6	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
7	1.0	0.992	1.0	0.992	1.0	0.992	1.0	0.992
8	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
9	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
10	1.0	1.0	1.0	1.0	1.0	1.0	1.0	1.0
<i>Average Training Accuracy (Gradient Boosting Classifier)</i>								1.000
<i>Average Testing Accuracy (Gradient Boosting Classifier)</i>								0.9992
<i>Average Training Precision</i>								1.000
<i>Average Testing Precision</i>								0.9992
<i>Average Training Recall</i>								1.000
<i>Average Testing Recall</i>								0.9992
<i>Average Training F1 Score</i>								1.000
<i>Average Testing F1 Score</i>								0.9992
<i>Average Training Accuracy (Gradient Boosting Classifier)</i>								1.000


Gambar 4. BarChart perbandingan metrik

Hasil dari tabel 3 menunjukkan bahwa model GBC mempunyai kinerja yang hampir sempurna dalam 10 *fold cross-validation*. Pada hasil dari data pelatihan, semua metrik menunjukkan angka 1.0. Pada sisi pelatihan memiliki rata-rata yang hampir sempurna yaitu di angka 0.9992. Hal itu disebabkan dikarenakan pada *fold* ke-7 terdapat sedikit penurunan performa dari model. Pada gambar 4 juga menunjukkan bahwa garis biru (garis akurasi pelatihan) model konsisten di 1.00, sedangkan pada garis merah (garis akurasi pengujian) menunjukkan performa pada *fold*-7. Hasil dari *cross validation* ini menunjukkan bahwa model GBC mempertahankan konsistensi performanya yang akurat

Tabel 4. Hasil perbandingan model terbaik

Model	Accuracy	F1-score	Recall	Precision
NB	96%	96%	96%	96%
KNN	93%	94%	93%	94%
GBC	99.92%	99.92%	99.92%	99.92%

Hasil pada tabel 4 menunjukkan hasil performa metrik GBC yang dilakukan dengan metode *K-fold* untuk menguji validasi model GBC yang dibandingkan dengan model terbaik NB dan KNN pada penelitian ini. Algoritma GBC menunjukkan performa yang unggul dengan nilai akurasi, *f1-score*, *recall*, dan *precision* mencapai angka 99.92% lebih tinggi dari model NB dan KNN. Dengan tingginya nilai metrik tersebut menunjukkan kinerja model yang sangat akurat oleh model GBC dalam mengidentifikasi kelas target dengan benar. Walaupun model NB dan KNN memberikan nilai akurasi masing masing 96% dan 93%, penerapan algoritma GBC menunjukkan peningkatan yang signifikan pada setiap metrik evaluasi, sehingga dapat mendeteksi *stunting* dini pada balita dengan akurat dan minim kesalahan.

Pembahasan

Model GBC adalah model yang paling konsisten dari antara kedua algoritma lainnya. Keseluruhan metrik evaluasi model GBC menghasilkan nilai 1.00 pada pelatihan dan pengujianya, sementara untuk model NB mendapatkan hasil maksimalnya pada pelatihan di rasio 80:20 dengan nilai *precision*, *recall*, *f1-score*, dan *accuracy* berkisar antara 0.94 hingga 0.95. Meskipun terdapat sedikit penurunan pada rasio 70:30 dan 60:40, khususnya pada nilai *recall* dan *f1-score* yang turun menjadi 0.94, akurasi model NB tetap konsisten di angka 0.95. Hal ini menunjukkan bahwa model NB memiliki kemampuan yang baik dalam menjaga performa prediksi meskipun rasio data pelatihan berubah. Sementara itu, performa KNN menunjukkan penurunan seiring dengan menurunnya rasio data pelatihan. Pada rasio 80:20, KNN berhasil memperoleh nilai *precision*, *recall*, *f1-score*, dan akurasi sebesar 0.95, namun pada rasio 70:30 dan 60:40, semua metrik turun menjadi 0.93. Dari model GBC, NB, dan KNN menunjukkan model GBC adalah model terbaik, GBC menjadi model terbaik disebabkan karena keunggulan GBC diatributkan pada kemampuannya untuk menangani kompleksitas data terutama dengan *n_estimator* sebanyak 100, *learning rate* 0.1 dan *max_depth* 3 yang membuat GBC menemukan keseimbangan antara *overfitting* dan *underfitting*.

Algoritma GBC memiliki keunggulan dari algoritma lainnya yaitu dapat mengatasi interaksi antar fitur dan dapat mengurangi bias yang kemungkinan muncul pada model KNN dan NB. Algoritma NB dan KNN tidak dapat mencapai akurasi yang tinggi disebabkan karena algoritma NB mengasumsikan probabilitas dan independensi antar fitur yang diberikan, sedangkan KNN hanya mengandalkan jarak antar data. Hal lainnya yang membuat GBC unggul adalah GBC mampu membangun model yang lebih kompleks dengan menggabungkan prediksi dari banyak pohon keputusan yang telah peneliti buat sehingga GBC mampu mengenali dan mempelajari pola yang lebih rumit.

Konsistensi GBC ini diuji lagi dalam *cross-validation* yang ditujukan di tabel 3 yang menunjukkan bahwa model GBC dengan *k-fold* 10 pada pelatihan menunjukkan nilai sempurna untuk setiap metrik, pada data pengujian mengalami sedikit penurunan menjadi 99.92%. Hal itu diperkuat lagi pada gambar line chart 4 yang menunjukkan bahwa akurasi setiap *fold* pada pelatihan mengalami konsistensi yang kuat di angka 1.00 dan mengalami sedikit penurunan pada pengujian di *fold* 7. Penelitian ini menunjukkan bahwa model GBC tidak perlu menggunakan metode seleksi fitur *forward selection* dan *backward elimination* serta penyeimbangan kelas pada dataset untuk menghasilkan performa algoritma *machine learning* yang akurat dan minim kesalahan dalam klasifikasi *stunting* pada balita. Karena resiko dari

Penggunaan seleksi fitur *forward selection* dan *backward elimination* serta penyeimbangan kelas pada dataset.

Model GBC menunjukkan potensi sebagai solusi yang lebih akurat dalam klasifikasi *stunting* dini pada balita, dengan hasil akurasi mencapai 99,92%. Hasil ini dapat dibandingkan dengan penelitian (Wahyudin, 2020) yang melibatkan model NB dengan seleksi fitur *forward selection*, menghasilkan akurasi sebesar 89%, model KNN (Lonang & Normawati, 2022) dengan seleksi fitur *backward elimination* yang mencapai akurasi 91,9%, serta algoritma *XGBoosting* (Fikri, 2024) yang memperoleh akurasi sebesar 86%. Perbandingan ini menunjukkan keunggulan signifikan dari model GBC dalam hal memprediksi status *stunting* pada balita. Penelitian ini menunjukkan bahwa pengembangan model algoritma *machine learning* akurasi tinggi dapat memberikan kontribusi signifikan dalam upaya pencegahan *stunting*, memungkinkan deteksi dan intervensi yang lebih awal pada balita yang berisiko dengan lebih akurat dan tepat.

Konsistensi performa GBC diuji lebih lanjut menggunakan *cross-validation*, sebagaimana ditunjukkan pada tabel 3. Hasil menunjukkan bahwa model GBC dengan *10-fold cross-validation* pada data pelatihan mencapai nilai sempurna untuk setiap metrik evaluasi, sedangkan pada data pengujian terjadi sedikit penurunan akurasi menjadi 99,92%. Hal ini diperkuat dengan visualisasi pada gambar 4, yang menunjukkan bahwa akurasi setiap lipatan (*fold*) pada data pelatihan konsisten di angka 1,00, dengan sedikit penurunan pada lipatan ke-7 pada data pengujian.

Hasil penelitian ini mengindikasikan bahwa model GBC tidak memerlukan metode seleksi fitur seperti *forward selection* atau *backward elimination* maupun penyeimbangan kelas dalam dataset untuk mencapai performa algoritma *machine learning* yang akurat dan minim kesalahan pada klasifikasi *stunting* balita. Metode seleksi fitur dan penyeimbangan kelas justru berisiko mengurangi kualitas dataset dan mengganggu hasil prediksi.

Keunggulan model GBC juga terlihat dalam perbandingan dengan hasil penelitian lain. Model ini mencapai akurasi sebesar 99,92%, jauh lebih tinggi dibandingkan model NB yang menggunakan seleksi fitur *forward selection* dengan akurasi 89% (Wahyudin, 2020), model KNN yang menggunakan seleksi fitur *backward elimination* dengan akurasi 91,9% (Lonang & Normawati, 2022), serta algoritma *XGBoosting* dengan akurasi 86% (Fikri, 2024). Perbandingan ini menunjukkan keunggulan signifikan GBC dalam memprediksi status *stunting* pada balita. Penelitian ini berkontribusi pada pengembangan model algoritma *machine learning* dengan akurasi tinggi yang dapat mendukung upaya pencegahan *stunting* secara lebih efektif. Model seperti GBC memungkinkan deteksi dini dan intervensi yang lebih akurat terhadap balita yang berisiko, sehingga dapat membantu mengurangi prevalensi *stunting* secara signifikan.

SIMPULAN

GBC terbukti sebagai algoritma terbaik dalam klasifikasi *stunting* pada balita dibandingkan dengan NB dan KNN. GBC menunjukkan kinerja yang unggul dengan nilai *precision*, *recall*, *f1-score*, dan *accuracy* hampir sempurna, di mana hasil pelatihan mencapai 1.00, dan pengujian sebesar 0.9992 pada semua rasio data. Dari penelitian ini, GBC menunjukkan keunggullannya pada kemampuan untuk menangani ketidakseimbangan data serta Memahami pola yang kompleks tanpa memerlukan seleksi fitur seperti *forward selection* maupun *backward selection*. Pengembangan teknologi deteksi *stunting* dapat menggunakan algoritma GBC untuk meningkatkan akurasi pada deteksi *stunting* dini yang memiliki tingkat kesalahan prediksi yang rendah.

REFERENSI

- Ahsan, M. M., Mahmud, M. A., Saha, P., Gupta, K. D., & Siddique, Z. (2021). Effect of data scaling methods on machine learning algorithms and model performance. *Technologies*, 9(3), 52. <https://doi.org/10.3390/technologies9030052>
- Ali, I., Kurnia, D. A., Pratama, M. A., & Ma'ruf, F. A. (2021). Klasifikasi status stunting balita di desa Slangit menggunakan metode K-Nearest Neighbor. *KOPERTIP Science Journal of Information Management and Computer*, 5(1), 35–39. <https://doi.org/10.51211/itbi.v5i1.1431>
- Darnis, S. (2022). Penyebab dan risiko stunting: Implikasi terhadap pendidikan anak usia dini. *Nusantara Journal of Pendidikan Indonesia*, 2(2), 343–356. <https://doi.org/10.14421/njpi.2022.v2i2-8>
- Eina, M. F., Chrisnanto, Y. H., & Melina, M. (2024). Klasifikasi telemarketing menggunakan Naïve Bayes classification dan wrapper sequential feature selection. *INTECOMS Journal of Information Technology and Computer Science*, 7(4), 1189–1198. <https://doi.org/10.31539/intecom.v7i4.10846>
- Fikri, M. (2024). Klasifikasi status stunting pada anak bawah lima tahun menggunakan extreme gradient boosting. *Merkurius Journal of Information Systems and Information Technology Research*, 2(4), 173–184. <https://doi.org/10.61132/mercurius.v2i4.159>
- Finda, S. M., & Utomo, D. W. (2024). Klasifikasi stunting balita menggunakan metode ensemble learning dan random forest. *Infotekmesin*, 15(2), 287–295.
- Lonang, S., & Normawati, D. (2022). Klasifikasi status stunting pada balita menggunakan K-Nearest Neighbor dengan feature selection backward elimination. *Journal of Media Informasi Budidarma*, 6(1), 49–56. <https://doi.org/10.30865/mib.v6i1.3312>
- Maulina, M., Wijaya, M. Y., & Fitriyati, N. (2024). Perbandingan metode backward dan forward pada seleksi mixed-effects model: Analisis fragile state index Asia Tenggara. *Jurnal Lebesgue Ilmiah Pendidikan Matematika dan Statistika*, 5(1), 62–74. <https://doi.org/10.46306/lb.v5i1.495>
- Mulyanto, Y., Idifitriani, F., & Wati, A. (2024). Klasifikasi data mining untuk penentuan stunting pada balita menggunakan metode Naïve Bayes. *Jurnal Mnemonik*, 7(2), 129–135. <https://doi.org/10.36040/mnemonic.v7i2.8849>
- Prasetyo, E., & Nugroho, K. (2024). Optimasi klasifikasi data stunting melalui ensemble learning pada label multiclass dengan imbalance data. *Techno Com*, 23(2), 1-10.
- Rozaq, A., & Purnomo, A. J. (2022). Classification of stunting status in toddlers using Naive Bayes method in the city of Madiun based on website. *Jurnal Techno Nusa Mandiri*, 19(2), 69–76. <https://doi.org/10.33480/techno.v19i2.3337>
- Sa'adah, A., Astuti, F. W., Masithah, M. D., Ovikariani, Kirana, D. A., Exma, S., Amalia, D. A., & Putriana, M. A. (2024). Pencegahan stunting di Posyandu RW 010 Kelurahan Krobokan Kota Semarang. *Jurnal Pengabdian IKIFA*, 3(1), 16–21.
- Sari, D., Ningsih, A. D., & Azzahra, A. (2023). Pencegahan stunting pada anak usia dini serta dampaknya pada faktor pendidikan dan ekonomi. *Jurnal Pengabdian kepada Masyarakat Nusantara*, 4(3), 2679–2678.
- Setianto, W., Ilyas, A., Setiawan, T. A., Budijanto, H. A., & Binabar, S. W. (2023). Klasifikasi stunting dengan KNN di kota Pekalongan berbasis sistem informasi geografis. *Jurnal Ilmiah Intech Information Technology Journal UMUS*, 5(2), 170–178.
- Siahaan, M. F., Rahmatika, A., & Nadhiroh, S. R. (2023). Tinjauan literatur: Intervensi suplemen makanan untuk meningkatkan Z-Skor PB/U pada balita stunting. *Amerta Nutrition*, 7(1), 154–160. <https://doi.org/10.20473/amnt.v7i1.2023.154-160>
- Titimeidara, M. Y., & Hadikurniawati, W. (2021). Implementasi metode Naïve Bayes classifier untuk klasifikasi status gizi stunting pada balita. *Jurnal Ilmiah Informatika*, 9(1), 54–59. <https://doi.org/10.33884/jif.v9i01.3741>

- Wahyudi, R., Orisa, M., & Vendyansyah, N. (2021). Penerapan algoritma K-Nearest Neighbors pada klasifikasi penentuan gizi balita (Studi kasus di Posyandu desa Bluto). *JATI Journal of Mahasiswa Teknik Informatika*, 5(2), 750–757. <https://doi.org/10.36040/jati.v5i2.3738>
- Wahyudin, W. C. (2020). Klasifikasi stunting balita menggunakan Naïve Bayes dengan seleksi fitur forward selection. *Jurnal Ilmu Komputer dan Matematika*, 1(1), 71–74. <https://ejr.umku.ac.id/index.php/jikoma/article/view/1220>
- Yacouby, R., & Axman, D. (2020). Probabilistic extension of precision, recall, and F1 score for more thorough evaluation of classification models. *Proceedings of the First Workshop on Evaluation and Comparison of NLP Systems*, 1(1), 79–91. <https://doi.org/10.18653/v1/2020.eval4nlp-1.9>
- Yahya, M. (2022). Algoritma K-Means untuk klasifikasi provinsi di Indonesia berdasarkan paket pelayanan stunting. *Panrita Journal of Science, Technology and Arts*, 1(2), 41–46.