

DETEKSI STANTING PADA BALITA DENGAN MENGGUNAKAN PERBANDINGAN ALGORITMA *MACHINE LEARNING*

Novita Ranti Muntiari ^[1]; Kharis Hudaiby Hanif ^[2]; Asma ^[3]; Lily Herawati ^[4]

^[1,3,4] Politeknik Kaltara Program Studi Promosi Kesehatan

^[2] Universitas Borneo Tarakan Program Studi Teknik Komputer

Email : novitarantimuntiari@gmail.com

INFO ARTIKEL	INTISARI
Diajukan : 21 Januari 2025	Deteksi stunting pada balita adalah proses identifikasi dini untuk mendeteksi gangguan pertumbuhan yang terlihat dari tinggi badan yang berada di bawah standar usia. stunting merupakan indikator dari masalah gizi kronis yang disebabkan oleh kekurangan asupan gizi dalam jangka waktu yang lama, sering kali diperburuk oleh infeksi berulang dan kondisi sosial ekonomi yang tidak mendukung. Stunting, yang merupakan kegagalan pertumbuhan anak akibat kekurangan gizi jangka panjang, merupakan masalah kesehatan masyarakat yang rumit dengan dampak yang berlangsung dalam jangka panjang. Dalam penelitian ini, dibangun sistem yang menggunakan algoritma <i>machine learning</i> , yaitu <i>decision tree</i> , <i>SVM</i> , <i>KNN</i> , <i>random forest</i> , <i>naïve bayes</i> , <i>logistic regression</i> , untuk mengukur tingkat akurasi masing-masing algoritma. Pengujian dilakukan dengan menggunakan 30% data untuk pengujian dan 70% untuk pelatihan. Hasil pengujian menunjukkan tingkat akurasi algoritma sebagai berikut: <i>decision tree</i> mencapai akurasi 99%, <i>SVM</i> 95%, <i>logistic regression</i> 74%. <i>naïve bayes</i> 48%, <i>KNN</i> 99%, dan <i>random forest</i> 99%. Oleh karena itu, algoritma <i>decision tree</i> , <i>KNN</i> , dan <i>random forest</i> menghasilkan akurasi tertinggi, yaitu 99% yang menunjukkan bahwa algoritma ini lebih efektif untuk mendeteksi stunting pada balita.
Diterima : 03 April 2025	
Diterbitkan: 01 Juni 2025	
Kata Kunci : Deteksi Stunting, <i>Naive Bayes</i> , <i>SVM</i> , <i>KNN</i> , <i>Machine Learning</i>	

I. PENDAHULUAN

Deteksi stunting pada balita merupakan suatu proses identifikasi dini untuk mengetahui adanya gangguan pertumbuhan ditandai tinggi badan rendah untuk usia. Stunting merupakan salah satu indikator status gizi kronis akibat kekurangan gizi dalam waktu lama, seringkali diperburuk oleh faktor infeksi berulang dan kondisi sosial ekonomi yang kurang mendukung. Identifikasi stunting secara dini sangat penting untuk mencegah dampak jangka panjang seperti gangguan perkembangan kognitif, penurunan produktivitas, serta risiko penyakit tidak menular di masa dewasa (Kemenkes RI, 2021). Metode deteksi stunting dapat dilakukan melalui pengukuran antropometri menggunakan indeks TB/U sesuai standar WHO. Hal ini memerlukan perhatian dari berbagai pihak, termasuk tenaga kesehatan, keluarga, dan pemerintah, untuk bersama-sama mengurangi prevalensi stunting di masyarakat. Stunting, yaitu kondisi pertumbuhan anak yang terhambat akibat kekurangan gizi kronis, menjadi masalah kesehatan masyarakat yang kompleks dan berdampak jangka panjang (Mutammimul Ula et al., 2022). Di era data yang melimpah, *machine learning* menawarkan potensi besar untuk

mengatasi permasalahan ini. Dengan memanfaatkan algoritma *machine learning*, kita dapat menganalisis data besar dari berbagai sumber, seperti data kesehatan, sosial ekonomi, dan lingkungan, untuk mengidentifikasi faktor risiko stunting yang lebih spesifik dan kompleks. Model *machine learning* membantu memprediksi risiko stunting pada anak, memungkinkan intervensi lebih awal dan tepat. Selain itu, *machine learning* juga dapat digunakan untuk mengoptimalkan program-program intervensi stunting dengan cara mempersonalisasi pendekatan berdasarkan karakteristik individu. Penelitian (Muntiari & Hanif, 2022) menggunakan *machine learning* dengan bertujuan mengklasifikasikan jenis kanker payudara. Tujuh algoritma yang digunakan meliputi *neural network*, *decision tree*, *naïve bayes*, *KNN*, *logistic regression*, dan *random forest*, dan *SVM*. Hasilnya 95% nilai akurasi tertinggi dari setiap algoritma *machine learning*. Penelitian yang dilakukan oleh (Chazar & Erawan, 2020) bertujuan mendiagnosis kanker payudara menggunakan *SVM*. Hasil penelitian mampu menentukan sel hidup kanker bersifat ganas atau jinak. Penelitian yang dilakukan oleh (Wiratama & Aziz, 2024) bertujuan untuk

menerapkan algoritma SVM dan RF dalam memprediksi risiko stunting pada balita menggunakan data terbaru. Hasil penelitian berhasil mengklasifikasikan status gizi anak-anak dengan tingkat akurasi yang tinggi menggunakan model SVM dan Random Forest.

Perbandingan penelitian ini menggunakan perbandingan algoritma dari *machine learning* yaitu SVM, KNN, *decision tree*, *naive bayes*, *random forest* dan *logistic regresion*. Penelitian bertujuan untuk mendeteksi stunting pada balita.

Berdasarkan permasalahan penelitian menggunakan algoritma *machine learning* yaitu SVM, KNN, *decision tree*, *naive bayes*, *random forest* dan *logistic regresion* dalam mendeteksi stunting pada balita dengan membandingkan tingkat akurasi tertinggi dari masing-masing algoritma.

II. BAHAN DAN METODE

Pada Gambar 1 ditunjukkan alur penelitian meliputi tahapan pengumpulan data, pengolahan data, klasifikasi, hingga tahap evaluasi.



Gambar 1. Alur Penelitian

Pengumpulan Data

Penelitian ini menggunakan atau diperoleh dari dataset publik yaitu dari *Kaggle Stunting Toddler*. Dataset tersebut memiliki empat atribut yang dirangkum dalam Tabel 1.

Tabel 1. Atribut

Nama Atribut	Deskripsi
Jenis Kelamin	Perempuan, Laki-laki
Tinggi Badan	Tinggi
Usia	Usia (0-59 bulan)
Status Gizi	Sangat Stunting : 0, Stunting : 1, tidak stunting: 2, tinggi stunting: 3

Klasifikasi

Dalam *machine learning*, proses klasifikasi terdiri dari dua tahap utama. Data latih digunakan untuk melatih model klasifikasi, sedangkan data uji digunakan untuk menguji model (Muntiari et al., 2019). Pada penelitian ini, 70% pelatihan, 30% pengujian, seperti Gambar 2.



Gambar 2. Pembagian Data Pelatihan dan Pengujian

Machine Learning adalah cabang kecerdasan buatan yang memungkinkan komputer belajar dan mengenali pola dari data tanpa pemrograman eksplisit (Putra & Muhammad, 2024) (Muntiari et al., 2023). *Machine learning* adalah yang memungkinkan komputer belajar dari data tanpa pemrograman langsung. Dengan menggunakan algoritma khusus, sistem ini mampu mengidentifikasi pola, membuat prediksi, dan mengambil keputusan secara otonom (Nugraha et al., 2019). Algoritma *machine learning* salah satunya yaitu *naive bayes*, *random forest*, *Support Vector Machine (SVM)*, *logistic regresion* (Muntiari et al., 2021).

Algoritma *Decision tree*

Teknik sering digunakan dalam pembelajaran mesin untuk tugas klasifikasi dan regresi. Metode ini membangun sebuah model berbentuk pohon, di mana setiap cabang mewakili keputusan yang diambil berdasarkan atribut tertentu. Dengan demikian, *decision tree* memungkinkan prediksi hasil berdasarkan pola-pola yang dikenali dari data input (Prasetyo & Nugroho, 2024). *Decision tree* adalah algoritma yang menyusun data menjadi struktur pohon untuk membuat prediksi (Pattihha & Hendry, 2022).

Algoritma *Naive Bayes*

Metode klasifikasi berbasis probabilitas yang menggunakan teorema Bayes, dengan asumsi independensi antar fitur dalam data. (Gurning et al., 2024)(Ramadhani et al., 2024). *Naive bayes* menghitung kemungkinan suatu data termasuk dalam kategori tertentu berdasarkan fitur-fiturnya (Yulian Pamuji et al., 2021).

Algoritma SVM

Digunakan untuk regresi dan klasifikasi dengan cara menemukan *hyperplane* optimal yang memisahkan dua kelas data. SVM berfokus pada pemaksimalan margin antara kedua kelas dengan memilih titik-titik data terdekat. Algoritma dapat diterapkan pada masalah klasifikasi baik yang linier maupun non-linier dengan menggunakan kernel yang tepat (Haris et al., 2022). SVM merupakan metode pembelajaran mesin yang bertujuan menentukan batas keputusan optimal untuk memisahkan data ke dalam berbagai kelas (Twitter et al., 2022).

Algoritma KNN

KNN digunakan untuk tugas klasifikasi dan regresi dengan cara mengklasifikasikan data baru berdasarkan mayoritas kelas dari k tetangga terdekatnya. Nilai k yang kecil membuat model lebih sensitif terhadap data latih, sementara nilai k yang lebih besar cenderung memberikan model

yang lebih stabil. KNN bekerja dengan menghitung jarak antar data, misalnya menggunakan jarak Euclidean, tanpa membangun model eksplisit (Pangestu et al., 2023). KNN bekerja dengan prinsip bahwa data yang berdekatan dalam ruang fitur cenderung memiliki label kelas yang sama. Dengan kata lain, KNN mencari K data pelatihan terdekat dengan data baru dan mengklasifikasikan data baru berdasarkan mayoritas kelas dari K tetangga terdekat tersebut (Chamidah et al., 2020).

Algoritma Random Forest

Algoritma *mengklasifikasi* dan membangun beberapa pohon keputusan secara acak dan menggabungkan hasil prediksi dari seluruh pohon. Setiap pohon dibangun menggunakan subset acak dari data dan fitur, yang meningkatkan keragaman model dan mengurangi kemungkinan *overfitting*. Algoritma ini biasanya menghasilkan akurasi yang tinggi berkat penggabungan keputusan dari berbagai pohon (Wiratama & Aziz, 2024). *Random forest* membuat beberapa pohon keputusan secara acak dan menggabungkan prediksinya dengan voting untuk klasifikasi atau rata-rata untuk regresi (Kristanto et al., 2023).

Algoritma Logistic Regregrision

Logistic regression adalah teknik yang digunakan dalam klasifikasi, terutama untuk masalah klasifikasi dua kelas. Algoritma ini memodelkan hubungan antara variabel input dan probabilitas terjadinya suatu kejadian menggunakan fungsi logistik (sigmoid). Meskipun disebut regresi, algoritma ini sebenarnya digunakan untuk tujuan klasifikasi (Mutammimul Ula et al., 2022).

Confusion Matrix

Alat untuk mengevaluasi kinerja model klasifikasi dengan membandingkan prediksi model dan data aktual. (Hanif & Muntiari, 2024).

Evaluasi

Tabel 2. Tabel *Confusion Matrix*

		Prediction Class	
		+	-
+	TP	FN	
-	FP	TN	

Tabel 2 menampilkan *confusion matrix* untuk mengukur kinerja algoritma, termasuk *f1-measure*, *recall*, akurasi, dan presisi, yang dihitung dengan rumus-rumus tersebut. Akurasi adalah metrik umum untuk menilai kinerja algoritma, dihitung dengan membandingkan jumlah data yang diprediksi dengan benar dan total data dalam dataset.

$$Precision = \frac{TP}{TP+FP} \dots\dots\dots(1)$$

$$Recall = \frac{TP}{TP+FN} \dots\dots\dots(2)$$

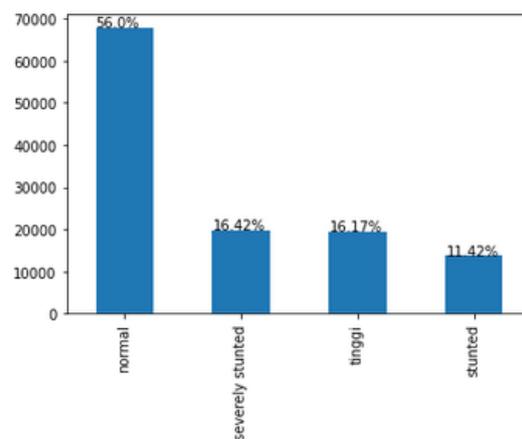
$$F - measure = \frac{2 \times precision \times recall}{precision + recall} \dots\dots\dots(3)$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \dots\dots\dots(4)$$

Formula untuk menghitung precision dapat dilihat pada persamaan (1). Sedangkan, rumus untuk menghitung recall ditunjukkan pada persamaan (2), yang berfungsi untuk mengukur seberapa tepat, persamaan (3) menunjukkan menghitung F, dan mengukur ketepatan pada persamaan (4) (Aisha et al., 2024).

III. HASIL DAN PEMBAHASAN

Data pengujian dalam penelitian sejumlah 120.999 balita. Berdasarkan data tersebut, 56% balita di kategorikan pertumbuhan ya normal, 16% balita dikategorikan terlambat pertumbuhan parah, 16% dikatagorikan balita dikategrikan terlambat pertumbuhan tinggi dan 11% balita mengalami terhambat pertumbuhan (*stunting*). Gambar 3 yang menunjukkan seperti apa angka ini dalam bentuk persentase.



Gambar 3. Persentase Data Awal Penelitian

Berdasarkan data uji yang diberikan di atas, klasifikasi data disusun dengan 30% dialokasikan untuk pengujian dan 70% untuk pelatihan. Pengujian dilakukan menggunakan algoritma *machine learning* yaitu SVM, KNN, *decision tree*, *naive bayes*, *random forest* dan *logistic regression*.

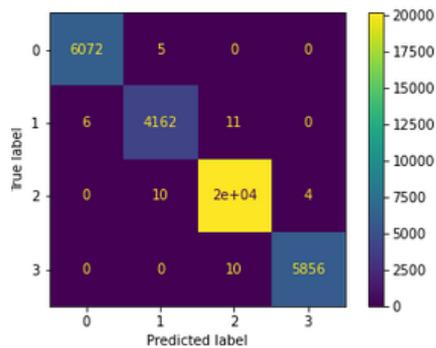
Hasil uji algoritma *decision tree* dengan hasil akurasi 99%, *precison* 100%, *recall* 100% dan *f1-core* 100% seperti Gambar 4. Gambar 4 menunjukkan hasil akurasi algoritma *decision tree*.

Akurasi model Decision Tree: 0.998732782369146
confusion_matrix Decision Tree:

	precision	recall	f1-score	support
0	1.00	1.00	1.00	6077
1	1.00	1.00	1.00	4179
2	1.00	1.00	1.00	20178
3	1.00	1.00	1.00	5866
accuracy			1.00	36300
macro avg	1.00	1.00	1.00	36300
weighted avg	1.00	1.00	1.00	36300

Gambar 4. Hasil Algoritma Decision Tree

Gambar 5 menunjukkan confusion matrix hasil uji algoritma decision tree.



Gambar 5. Algoritma Decision Tree Confusion Matrix

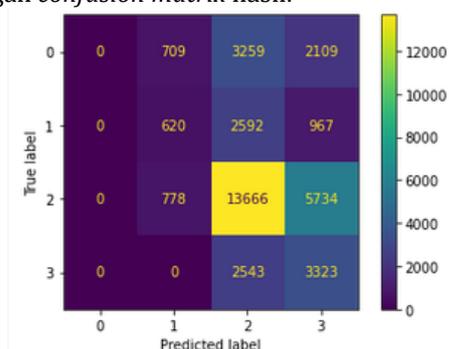
Hasil uji algoritma naive bayes akurasi 48%, precision 27%, recall 57% dan f1-core 37% seperti Gambar 6.

Akurasi model naive bayes: 0.48509641873278236

	precision	recall	f1-score	support
0	0.00	0.00	0.00	6077
1	0.29	0.15	0.20	4179
2	0.62	0.68	0.65	20178
3	0.27	0.57	0.37	5866
accuracy			0.49	36300
macro avg	0.30	0.35	0.30	36300
weighted ave	0.42	0.49	0.44	36300

Gambar 6. Hasil Algoritma Naive Bayes

Gambar 7 menunjukkan algoritma naive bayes dengan confusion matrix hasil.



Gambar 7. Confusion Matrix Algoritma Naive Bayes

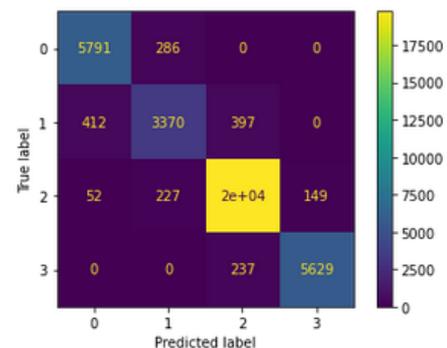
Hasil uji algoritma SVM dengan akurasi 95%, precision 97%, recall 96% dan f1-core 97% seperti Gambar 8.

Akurasi model SVM: 0.9515151515151515
confusion_matrix SVM:

	precision	recall	f1-score	support
0	0.93	0.95	0.94	6077
1	0.87	0.81	0.84	4179
2	0.97	0.98	0.97	20178
3	0.97	0.96	0.97	5866
accuracy			0.95	36300
macro avg	0.93	0.92	0.93	36300
weighted avg	0.95	0.95	0.95	36300

Gambar 8. Hasil Algoritma SVM

Gambar 9 algoritma SVM menunjukkan confusion matrix.



Gambar 9. Algoritma SVM Confusion Matrix

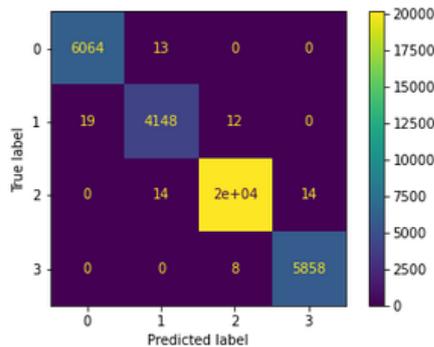
Hasil uji algoritma KNN dengan hasil akurasi 99%, precision 100%, recall 100% dan f1-core 100% seperti Gambar 10.

Akurasi model KNN: 0.9977961432506887
confusion_matrix KNN:

	precision	recall	f1-score	support
0	1.00	1.00	1.00	6077
1	0.99	0.99	0.99	4179
2	1.00	1.00	1.00	20178
3	1.00	1.00	1.00	5866
accuracy			1.00	36300
macro avg	1.00	1.00	1.00	36300
weighted avg	1.00	1.00	1.00	36300

Gambar 10. Hasil Algoritma KNN

Gambar 11 algoritma KNN menunjukkan confusion matrix.



Gambar 11. Algoritma KNN Confusion Matrix

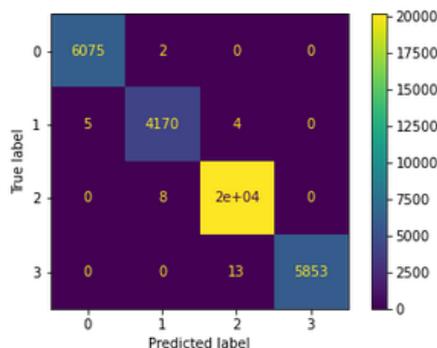
Hasil uji algoritma *random forest* dengan hasil akurasi 99%, *precision* 100%, *recall* 100% dan *f1-core* 100% seperti Gambar 12.

Akurasi model Random Forest: 0.9991184573002755
confusion_matrix Random Forest:

	precision	recall	f1-score	support
0	1.00	1.00	1.00	6077
1	1.00	1.00	1.00	4179
2	1.00	1.00	1.00	20178
3	1.00	1.00	1.00	5866
accuracy			1.00	36300
macro avg	1.00	1.00	1.00	36300
weighted avg	1.00	1.00	1.00	36300

Gambar 12 Hasil Algoritma Random Forest

Gambar 13 algoritma *random forest* menunjukkan *confusion matrix*.



Gambar 13. Confusion Matrix Algoritma random forest

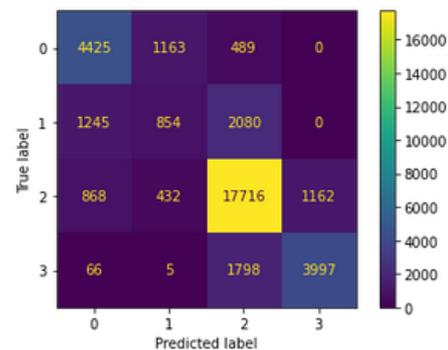
Hasil uji *logistic regression* dengan hasil akurasi 74%, *precision* 77%, *recall* 68% dan *f1-core* 73% seperti Gambar 14.

Akurasi model Logistic Regression: 0.7435812672176308
confusion_matrix Logistic Regression:

	precision	recall	f1-score	support
0	0.67	0.73	0.70	6077
1	0.35	0.20	0.26	4179
2	0.80	0.88	0.84	20178
3	0.77	0.68	0.73	5866
accuracy			0.74	36300
macro avg	0.65	0.62	0.63	36300
weighted avg	0.72	0.74	0.73	36300

Gambar 14 Hasil Algoritma Logistic Regression

Gambar 15 algoritma *logistic regression* menunjukkan *confusion matrix*.



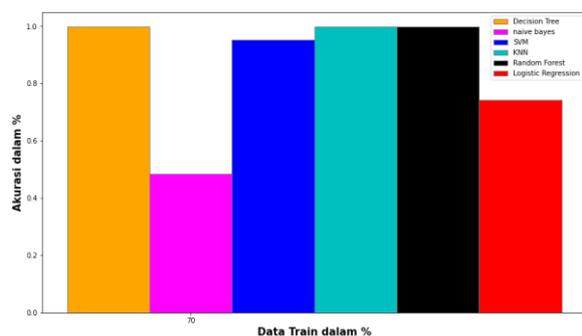
Gambar 15. Algoritma logistic regression Confusion Matrix

Pengujian yang dilakukan menggunakan enam algoritma, SVM, KNN, *decision tree*, *naive bayes*, *random forest* dan *logistic regression*, perbandingan hasil dari keenam algoritma pada Tabel 3.

Tabel 3. Perbandingan Algoritma Machine Learning

No	Algoritma	Akurasi (%)
1	Decision Tree	99
2	Naive Bayes	48
3	SVM	95
4	KNN	99
5	Random Forest	99
6	Logistic Regression	74

Berdasarkan hasil pengujian enam algoritma, diperoleh akurasi sebagai berikut: Decision Tree 99%, Naive Bayes 48%, SVM 95%, KNN 99%, Random Forest 99%, dan Logistic Regression 74%. Hasil ditunjukkan pada Gambar 16.



Gambar 16. Perbandingan Grafik Algoritma Machine Learning

Tabel 3 menunjukkan perbandingan akurasi algoritma *decision tree*, *naive bayes*, SVM, KNN, *random forest*, dan *logistic regression*. *Decision tree*, KNN, dan *random forest* memiliki akurasi tertinggi 99%, yang menunjukkan ketiganya lebih efektif untuk mendeteksi stunting pada balita.

Keefektifan algoritma *Decision Tree*, *KNN*, dan *Random Forest* dalam mendeteksi stunting pada balita didasarkan pada tingkat akurasi yang sangat tinggi, yaitu sebesar 99%. Algoritma *Decision Tree* mampu membentuk model yang jelas dan interpretatif berdasarkan pembagian data secara hierarkis, sehingga cocok untuk menangani data dengan pola yang kompleks dan non-linear. *KNN* efektif karena pendekatannya yang berbasis kedekatan antar data, sehingga dapat mengklasifikasikan data baru dengan mempertimbangkan kemiripan terhadap data sebelumnya. Sementara itu, *Random Forest* yang merupakan ensemble dari banyak pohon keputusan, mampu meningkatkan akurasi dan mengurangi risiko *overfitting* yang sering terjadi pada model tunggal. Dibandingkan dengan algoritma lain seperti *Naive Bayes* yang mengasumsikan independensi antar fitur atau *Logistic Regression* yang memiliki keterbatasan pada data non-linear, ketiga algoritma tersebut lebih mampu menangkap variasi dan kompleksitas data yang diperlukan dalam klasifikasi stunting. Algoritma *Naive Bayes* dan *Logistic Regression* menunjukkan akurasi yang relatif rendah, masing-masing sebesar 48% dan 74%, yang mengindikasikan keterbatasan dalam mengklasifikasikan data stunting secara akurat. Kelemahan utama *Naive Bayes* terletak pada asumsi dasar bahwa setiap fitur bersifat independen, padahal dalam kasus nyata seperti stunting, antar variabel (misalnya berat badan, tinggi badan, dan usia) sering kali saling berkaitan. Hal ini menyebabkan model tidak mampu menangkap hubungan kompleks antar fitur, sehingga menghasilkan prediksi yang kurang akurat. Sementara itu, *Logistic Regression* cenderung kurang efektif dalam menangani data dengan hubungan non-linear atau pola kompleks, karena model ini hanya mampu membentuk batas keputusan linier. Selain itu, *Logistic Regression* sensitif terhadap outlier dan kurang mampu menangani fitur yang saling berinteraksi tanpa dilakukan transformasi atau rekayasa fitur tambahan. Oleh karena itu, kedua algoritma ini kurang ideal digunakan untuk permasalahan klasifikasi stunting yang memiliki struktur data yang kompleks.

IV. KESIMPULAN

Pengujian menggunakan 30% data testing dan 70% data training dengan enam algoritma: *decision tree*, *naive bayes*, *SVM*, *KNN*, *random forest*, dan *logistic regression*. Hasil pengujian menunjukkan akurasi algoritma sebagai berikut: *decision tree* 99%, *naive bayes* 48%, *SVM* 95%, *KNN* 99%, *random forest* 99%, dan *logistic regression* 74%. Oleh karena itu,

algoritma *decision tree*, *KNN*, dan *random forest* dengan akurasi 99% lebih efektif untuk mendeteksi stunting pada balita. Algoritma *decision tree*, *KNN*, dan *random forest* dapat diimplementasikan dalam sistem deteksi stunting untuk membantu tenaga kesehatan dalam mengidentifikasi balita yang berisiko

V. UCAPAN TERIMA KASIH

Terima kasih atas dukungan dana penelitian yang diberikan oleh Politeknik Kaltara melalui LPPM.

VI. REFERENSI

- Aisha, P., Fathurahman, M., & Prangga, S. (2024). Implementasi Metode Neighbor Weighted K-Nearest Neighbor Pada Pengklasifikasian Status Gizi Balita Di Wilayah Kerja Puskesmas Wonorejo Kota Samarinda. *VARIANCE: Journal of Statistics and Its Applications*, 6(1), 11-20. <https://doi.org/10.30598/variancevol6iss1page11-20>
- Chamidah, N., Santoni, M. M., & Matondang, N. (2020). Pengaruh Oversampling pada Klasifikasi Hipertensi dengan Algoritma Naive Bayes, Decision Tree, dan Artificial Neural Network (ANN). *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 4(4), 635-641.
- Chazar, C., & Erawan, B. (2020). Machine Learning Diagnosis Kanker Payudara Menggunakan Algoritma Support Vector Machine. *INFORMASI (Jurnal Informatika Dan Sistem Informasi)*, 12(1), 67-80. <https://doi.org/10.37424/informasi.v12i1.48>
- Gurning, U. R., Octavia, S. F., Andriyani, D. R., Nurainun, N., & Permana, I. (2024). Prediksi Risiko Stunting pada Keluarga Menggunakan Naive Bayes Classifier dan Chi-Square. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, 4(1), 172-180. <https://doi.org/10.57152/malcom.v4i1.1074>
- Hanif, K. H., & Muntiari, N. R. (2024). Penerapan Algoritma Decision Tree, Svm, Naive Bayes Dalam Deteksi Stunting Pada Balita. *METHOMIKA Jurnal Manajemen Informatika Dan Komputerisasi Akuntansi*, 8(1), 105-109. <https://doi.org/10.46880/jmika.vol8no1.pp105-109>
- Haris, M. S., Khudori, A. N., & Kusuma, W. T. (2022). Perbandingan Metode Supervised Machine Learning untuk Prediksi Prevalensi Stunting di Provinsi Jawa Timur. *Jurnal Teknologi*

- Informasi Dan Ilmu Komputer*, 9(7), 1571.
<https://doi.org/10.25126/jtiik.2022976744>
- Kemendes RI. (2021). Hasil Studi Status Gizi Indonesia (SSGI) Tingkat Nasional, Provinsi, dan Kabupaten/Kota Tahun 2021. *Kementrian Kesehatan Republik Indonesia*.
<https://doi.org/10.36805/bi.v2i1.301>
- Kristanto, F., Winarno, W. W., & Nasiri, A. (2023). Perbandingan Algoritme Naïve Bayes dan Decision Tree Pada Analisis Sentimen Data Komentar Siswa Pada Aplikasi Digital Teacher Assessment. *Jurnal Ilmiah Teknik Informatika Dan Sistem Informais*, 538-548.
- Muntiari, N. R., Fadlil, A., Studi, P., Teknik, M., Dahlan, U. A., Studi, P., Elektro, T., Dahlan, U. A., & Soepomo, J. P. (2019). *Penentuan Kriteria Penginapan Menggunakan Metode Analytic Hierarchy Process*. 9, 62-69.
- Muntiari, N. R., & Hanif, K. H. (2022). Klasifikasi Penyakit Kanker Payudara Menggunakan Perbandingan Algoritma Machine Learning. *Jurnal Ilmu Komputer Dan Teknologi*, 3(1), 1-6. <https://doi.org/10.35960/ikomti.v3i1.766>
- Muntiari, N. R., Hanif, K. H., & Nisa, I. C. (2021). *Perbandingan Algoritma Regresi Logistik , Support Vector Machine , dan Gradient Boosting Pada Analisis Sentimen Data Komentar Siswa*. 2(1), 1-7.
- Muntiari, N. R., Nisa, K., Sandi A, A. S., Ashari, I. A., Hanif, K. H., & Dwinanto, R. W. (2023). Comparison of random forest algorithm, support vector machine, and k-nearest neighbor for diabetes disease classification. *AIP Conference Proceedings*, 2706, 1-8. <https://doi.org/10.1063/5.0120218>
- Mutammimul Ula, Ananda Faridhatul Ulva, Mauliza, Muhammad Abdullah Ali, & Yumna Rilasmi Said. (2022). Application of Machine Learning in Predicting Children'S Nutritional Status With Multiple Linear Regression Models. *Multica Science and Technology (Mst) Journal*, 2(2), 124-130. <https://doi.org/10.47002/mst.v2i2.363>
- Nugraha, F. S., Shidiq, M. J., & Rahayu, S. (2019). Analisis Algoritma Klasifikasi Neural Network Untuk Diagnosis Penyakit Kanker Payudara. *Jurnal Pilar Nusa Mandiri*, 15(2), 149-156. <https://doi.org/10.33480/pilar.v15i2.601>
- Pangestu, H. G., Sinaga, R. Y., Ulya, F. Z., Athiyah, U., Muhammad, A. W., & Alameka, F. (2023). Analisis Efisiensi Metode K-Nearest Neighbor dan Forward Chaining Untuk Prediksi Stunting Pada Balita. *Informatika Mulawarman : Jurnal Ilmiah Ilmu Komputer*, 18(2), 78. <https://doi.org/10.30872/jim.v18i2.10169>
- Pattihha, F. S., & Hendry. (2022). Perbandingan Metode K-NN, Naïve Bayes, Decision Tree untuk Analisis Sentimen Tweet Twitter Terkait Opini Terhadap PT PAL Indonesia. *Jurnal Riset Komputer*, 9(2), 2407-389. <https://doi.org/10.30865/jurikom.v9i2.4016>
- Prasetyo, E., & Nugroho, K. (2024). Optimasi Klasifikasi Data Stunting Melalui Ensemble Learning pada Label Multiclass dengan Imbalance Data. *Techno.Com*, 23(1), 1-10. <https://doi.org/10.62411/tc.v23i1.9779>
- Putra, B., & Muhammad, A. H. (2024). Prediksi Prevalensi Stunting di Indonesia dengan Ordinary Least Square (OLS). *G-Tech: Jurnal Teknologi Terapan*, 8(3), 1890-1900. <https://doi.org/10.33379/gtech.v8i3.4623>
- Ramadhani, Ramadhanu, & Taufik Hidayat. (2024). Metode Machine Learning untuk Klasifikasi Data Gizi Balita dengan Algoritma Naïve Bayes, KNN dan Decision Tree. *Jurnal SIMETRIS*, 15(1), 57-68.
- Twitter, C.- Di, Raharjo, R. A., Sunarya, I. M. G., Gede, D., & Divayana, H. (2022). *Perbandingan Metode Naive Bayes Classifier Dan Support Vector Machine Pada Kasus Analisis Sentimen Terhadap Data Vaksin*. 15(2), 456-464.
- Wiratama, Y., & Aziz, R. Z. A. (2024). *Perbandingan Prediksi Penyakit Stunting Balita Menggunakan Algoritma Support Vektor Machine dan Random Forest*. 6(2). <https://doi.org/10.47065/bits.v6i2.5543>
- Yulian Pamuji, F., Puspaning Ramadhan, V., & Artikel, R. (2021). Jurnal Teknologi dan Manajemen Informatika Komparasi Algoritma Random Forest dan Decision Tree untuk Memprediksi Keberhasilan Immunotherapy Info Artikel Abstrak. *Jurnal Teknologi Dan Manajemen Informatika*, 7(1), 46-50. <http://http://jurnal.unmer.ac.id/index.php/jtmi>