



Metode K-Nearest Neighbor Berbasis *Forward Selection* untuk Identifikasi Status *Stunting* pada Balita

Ismi Rizqa Lina^{*1}, Sri Retnowati²

Email: ¹irizqalina@gmail.com, ²sriretnowati919@gmail.com

^{1,2}Program Studi Sains Data, Universitas Insan Cita Indonesia

Diterima: 3 November 2024 | Direvisi: 9 Desember 2024 | Disetujui: 27 Desember 2024

©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Salah satu masalah kesehatan utama yang secara signifikan memengaruhi pertumbuhan dan perkembangan anak serta potensi ekonomi di masa depan adalah *stunting* pada balita. Untuk mencegah dampak jangka panjang, identifikasi status *stunting* sejak dini perlu dilakukan sehingga intervensi gizi dan kesehatan dapat diberikan secara efektif. Penelitian ini bertujuan untuk mengidentifikasi status *stunting* pada balita menggunakan metode *K-Nearest Neighbor* (KNN). Model KNN dilatih dengan data pelatihan sebesar 80% dan diuji pada data pengujian (20%). Jarak yang digunakan dalam penelitian ini, yaitu jarak *Manhattan*. Evaluasi model menunjukkan bahwa model KNN memiliki akurasi sebesar 91,20%, presisi sebesar 85%, recall sebesar 28%, dan skor F1 sebesar 42%, yang menunjukkan efektivitas metode ini dalam mengidentifikasi status *stunting* pada balita, meskipun terdapat beberapa kekurangan. Untuk mengatasi kekurangan tersebut, model KNN dikombinasikan dengan metode *forward selection*, yang secara signifikan meningkatkan kinerja model yang mencapai akurasi, presisi, recall, dan skor F1 sebesar 100%. Kombinasi ini menunjukkan bahwa KNN dengan *forward selection* sangat efektif dan dapat menghasilkan model yang lebih akurat dan andal.

Kata kunci: *Stunting, K-Nearest Neighbor, Forward Selection, Manhattan.*

K-Nearest Neighbor Method Based on Forward Selection to Identify Stunting Status in Toddlers

Abstract

One of the primary health issues that significantly affects children's growth and development and their future economic potential is *stunting* in toddlers. To prevent long-term impacts, identification of *stunting* status needs to be done early so that nutritional and health interventions can be provided effectively. This research aims to identify the *stunting* status in toddlers using the *K-Nearest Neighbor* (K-NN) method. The dataset used includes various attributes of toddlers, such as gender, age, weight, height, weight-for-age index (W/A), z-score of weight-for-age index (W/A), weight-for-height index (W/H), z-score of weight-for-height index (W/H), height-for-age index (H/A), and z-score of height-for-age index (H/A). The data is then divided into training (80%) and testing (20%) sets. The K-NN model is trained with the training data and tested on the testing data. The initial evaluation of the model shows that the K-NN model has an accuracy of 91.20%, precision of 85%, recall of 28%, and an F1 score of 42%, indicating the effectiveness of this method in identifying the *stunting* status in toddlers, despite some shortcomings. To address these shortcomings, the K-NN model is combined with the *forward selection* method, which significantly improves the model's performance, achieving an accuracy, precision, recall, and F1 score of 100%. This combination demonstrates that K-NN with *forward selection* is highly effective and can produce a more accurate and reliable model.

Keywords: *Stunting, K-Nearest Neighbor, Forward Selection, Manhattan.*

1. PENDAHULUAN

Stunting merupakan satu masalah yang signifikan dalam kesehatan masyarakat, terutama di negara-negara berkembang termasuk Indonesia. *Stunting* merupakan gangguan pertumbuhan jangka panjang yang disebabkan oleh kekurangan nutrisi dan lingkungan yang tidak mendukung pertumbuhan optimal [1]. *Stunting* pada balita dapat memiliki konsekuensi jangka panjang yang signifikan terhadap kesehatan, perkembangan kognitif, dan produktivitas. Menurut standar WHO, prevalensi *stunting* seharusnya berada di bawah 20%. Namun pada tahun 2022, angka *stunting* pada balita di Indonesia mencapai 21,6% yang menunjukkan tingkat yang masih cukup tinggi dan perlu perhatian serius dari berbagai pihak terkait [2].

Kecamatan Karanganyar adalah salah satu wilayah di Indonesia yang menghadapi masalah *stunting* yang signifikan. Saat ini, pendataan dan penilaian *stunting* pada balita dilakukan menggunakan pendekatan antropometri, yang dilakukan secara manual dan subjektif. Oleh karena itu, diperlukan pengembangan sistem yang memadai untuk mengotomatiskan proses penentuan status *stunting* tersebut agar dapat dilakukan dengan efisien dan akurat [3].

Terdapat banyak metode *machine learning* yang efektif dan efisien untuk mengidentifikasi balita yang berisiko *stunting* dalam upaya pencegahan dan penanganan *stunting*. Salah satunya, yaitu metode algoritma *K-Nearest Neighbor* (KNN) [4]. Pemanfaatan algoritma *K-Nearest Neighbor* (KNN) untuk mengklasifikasikan suatu penyakit akan menghasilkan nilai yang cukup besar, hasil pengujian menunjukkan tingkat akurasi sebesar 90% terutama untuk jenis penyakit eksternal [5]. Selain itu, algoritma *K-Nearest Neighbor* (KNN) juga cocok digunakan dalam menganalisis dan mengklasifikasikan suatu data. Hasil penelitian [6] menunjukkan bahwa KNN ideal untuk mengkategorikan komentar di Twitter, terutama kamus kebijakan pemerintah tentang kampus merdeka.

Masalah *stunting* mulai dibahas oleh [7],[8], dan [9] yang dilakukan di daerah pedesaan. Kemudian, metode KNN digunakan untuk mengklasifikasikan *stunting* dengan mengklasifikasikan tingkat gizi balita di posyandu desa Bluto. Jarak yang digunakan dalam menghitung antara masing-masing objek data sampel, yaitu jarak *Euclidian* [10]. Perhitungan jarak *Euclidian* kemudian dibandingkan dengan jarak *Manhattan* dalam Klasifikasi pengeluaran perkapita di Tiga Provinsi Sulawesi dengan metode KNN. Hasilnya dinyatakan bahwa akurasi tertinggi pada $k = 9$ dimana jarak *Euclidian* sebesar 76,47% yang menunjukkan klasifikasi yaitu cukup, di sisi lain pada penelitian tersebut digunakan jarak *Manhattan* diperoleh akurasi sebesar 94,12% yang menunjukkan klasifikasi tersebut sangat baik [11].

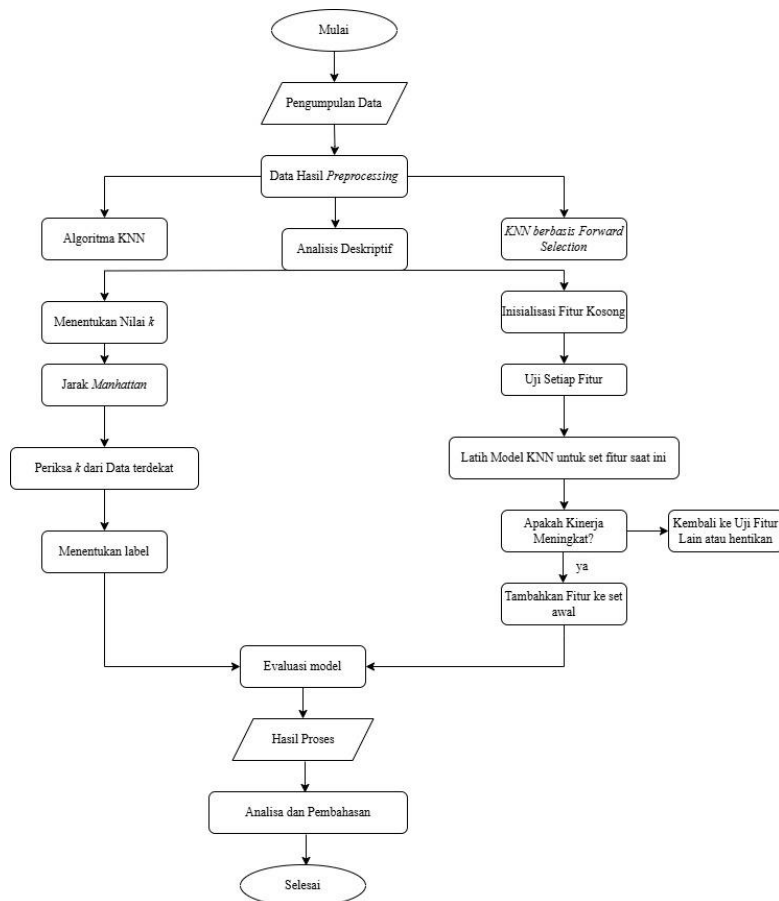
Untuk klasifikasi status gizi pada balita, algoritma KNN kemudian dibandingkan dengan *Naive Bayes Classifier* (NBC) [12] dan [13]. Hasilnya, menunjukkan bahwa algoritma KNN mempunyai nilai akurasi 96,10 % sedangkan nilai akurasi pada algoritma NBC sebesar 90,94%. Metode KNN selanjutnya dikombinasikan dengan seleksi fitur metode *backward selection* [14]. Sebaliknya, algoritma NBC dan *Forward Selection* digunakan untuk mengklasifikasikan status gizi *stunting* pada balita di Puskesmas Pandanaran Kabupaten Semarang [15]. Penelitian tersebut menunjukkan bahwa algoritma NBC menghasilkan klasifikasi status gizi *stunting* dengan akurasi sebesar 83,33%, di sisi lain akurasi dalam algoritma NBC dengan fitur *Forward Selection* sebesar 86%.

Berdasarkan latar belakang di atas, sedikit berbeda dengan penelitian [14] dan [15], penelitian ini akan melakukan klasifikasi status *stunting* menggunakan metode KNN yang berbasis *Forward Selection*. Subset fitur yang paling relevan untuk menentukan status *stunting* dipilih melalui metode *Forward Selection*. Pada penelitian ini, jarak *Manhattan* digunakan untuk menentukan k tetangga terdekat dari titik data yang ingin diprediksi [11]. Evaluasi setiap iterasi penghapusan fitur berdasarkan performa model KNN pada data pelatihan. Kemudian diterapkan algoritma KNN pada data pelatihan dengan menggunakan subset fitur yang dipilih. Optimasi parameter KNN dan proses seleksi fitur digunakan untuk meningkatkan performa model. Setelah model dinilai memadai, dapat diterapkan pada data baru untuk mengidentifikasi status *stunting* pada balita.

2. METODE PENELITIAN

Data sekunder untuk penelitian ini dikumpulkan dari puskesmas Karanganyar pada Maret 2024. Data ini memiliki delapan atribut: umur, berat badan, tinggi badan, z-score bb/u, berat badan dibandingkan dengan tinggi badan (bb/tb), z-score bb/tb, tinggi badan dibandingkan dengan umur (tb/U), dan z-score tb/u.

Data tersebut kemudian diklasifikasikan pada status *stunting* atau *tidak stunting* dengan menggunakan pendekatan berbasis *machine learning* yang lebih cepat dan akurat dibandingkan menggunakan metode konvensional. Dalam penelitian ini, metode KNN merupakan salah satu pendekatan berbasis *machine learning* yang digunakan. Proses analisis yang digunakan dalam penelitian ini ditunjukkan pada *flowchart* Gambar 1. sebagai berikut.



Gambar 1. Diagram alir klasifikasi stunting dengan KNN

2.1 Data Preprocessing

Sebelum suatu data dianalisis, terlebih dahulu dilakukan *preprocessing*, yang merupakan bagian penting pada proses penemuan pengetahuan ketika data yang diperoleh tidak lengkap atau tidak konsisten. Data untuk memeriksa status *stunting* balita yang digunakan harus lengkap dan konsisten, sehingga dapat dilanjutkan ke tahap berikutnya.

2.2 Pemilihan Fitur (Forward Selection)

Forward Selection adalah teknik pemilihan fitur yang digunakan untuk memilih subset terbaik dari fitur-fitur yang ada. Proses ini dimulai dengan model tanpa fitur apapun, kemudian fitur ditambahkan satu per satu berdasarkan seberapa baik mereka meningkatkan performa model. *Forward Selection* membantu dalam mengurangi dimensi data, meningkatkan akurasi model, dan mengurangi overfitting, yang sangat penting dalam analisis data medis [16]. Berikut ini adalah langkah-langkah model *Forward Feature Selection* dilakukan :

- a. Membuat model regresi untuk variabel respon Y dengan setiap variable predictor X secara individual. Model yang memiliki nilai R^2 tertinggi yang menunjukkan variabel prediktor dengan hubungan terbaik terhadap variabel respon. Misalnya model ini menghasilkan prediktor X_α , seperti yang ditunjukkan pada persamaan (1):

$$Y^\wedge = b_0 + b_\alpha X_\alpha \tag{1}$$

- b. Setelah memilih predictor pertama X_α , buat model baru yang meregresikan variabel respon Y menggunakan X_α , serta semua prediktor selain X_α dan prediktor lain. Kemudian dipilih model yang memiliki nilai R^2 tertinggi. Dalam kasus ini, model ini prediktor X_b , seperti ditunjukkan pada persamaan (2):

$$Y^\wedge = b_0 + b_\alpha X_\alpha + b_b X_b \tag{2}$$

- c. Setelah memilih predictor kedua X_b , hitung nilai F-sequensial untuk prediktor X_b yang dipilih ditunjukkan pada persamaan (3):

$$F_{seq} = R(\beta_b | \beta_0, \beta_\alpha) / MSE / db \tag{3}$$

- d. Selain itu, nilai F_{seq} untuk X_b dapat diperoleh dengan cara mengkuadratkan nilai statistik uji T dari prediktor X_b .
- e. Hitung jarak untuk menentukan tetangga terdekat berdasarkan jarak minimum ke- k menggunakan metode KNN.
- f. Kategori dari tetangga terdekat tersebut kemudian digunakan untuk memperoleh nilai prediksi, yaitu dengan menggunakan kategori mayoritas dari tetangga terdekat.

2.3 Penerapan Algoritma K-Nearest Neighbor (KNN)

Salah satu algoritma pembelajaran mesin adalah K-Nearest Neighbor (KNN), yang digunakan untuk regresi dan klasifikasi. Prinsip kerja KNN adalah mencari k tetangga terdekat dari suatu data jarak tertentu. Penelitian ini menggunakan jarak Manhattan dan menggunakan mayoritas kelas dari tetangga terdekat untuk menentukan kelas data. KNN dikenal sebagai metode yang sederhana namun efektif dalam berbagai aplikasi, termasuk pengenalan pola, klasifikasi gambar, dan identifikasi penyakit [17].

Algoritma KNN menggunakan Jarak Manhattan, metode perhitungan jarak untuk mengukur jarak antar dua titik dalam ruang multidimensi dengan menghitung jumlah nilai absolut perbedaan antara setiap koordinat. Apabila terdapat dua titik $A = (x_1, y_1, z_1, \dots)$ dan $B = (x_2, y_2, z_2, \dots)$ dalam ruang berdimensi n , maka rumus jarak d_M Manhattan ditunjukkan pada persamaan berikut ini:

$$d_M(A, B) = \sum_{i=1}^n |x_i - y_i|, \tag{4}$$

A dan B merupakan dua vektor dengan dimensi yang sama, dan n adalah jumlah dimensi ruang. Perhitungan bobot dengan jarak Manhattan ini memerlukan penjumlahan dari selisih absolut antara koordinat data x_i dan y_i dalam masing-masing dimensi. Algoritma KNN akan menggunakan hasil bobot ini untuk menghitung k tetangga terdekat dari data pengujian x_i yang didasarkan pada data pelatihan y_i . Apabila nilai bobot (jarak Manhattan) semakin kecil, maka data x_i dengan y_i semakin dekat satu sama lain dalam ruang berdimensi, di sisi lain, apabila nilai bobot besar, maka semakin jauh jarak antara keduanya. Algoritma KNN digunakan untuk melakukan perhitungan jarak Manhattan dan prediksi pada data uji, langkah berikutnya adalah evaluasi model untuk membuat perbandingan antara nilai nyata dan hasil prediksi.

2.4 Evaluasi Model klasifikasi.

Dalam penelitian ini, *confussion matrix*, digunakan sebagai metode evaluasi; tabel yang menggambarkan kinerja model klasifikasi digunakan. *Confussion Matrix* menghasilkan empat nilai yang menunjukkan hasil perhitungan evaluasi model.

Tabel 1. *Confussion matrix*

Predict	Actual	
	True	False
True	True Positif	False Negatif
False	False Positif	True Negatif

Keterangan :

True Positive (TP) = Jumlah data yang benar-benar positif kemudian diprediksi sebagai positif, yang berarti model berhasil mengklasifikasikan data positif dengan benar atau akurat.

False Positive (FP) = Jumlah data yang sebenarnya negatif namun salah diprediksi sebagai positif, yang berarti model keliru mengklasifikasikan data negatif sebagai positif.

True Negative (TN) = Jumlah data yang benar-benar negatif kemudian diprediksi sebagai negative pula, yang berarti model ini berhasil mengenali data negatif secara tepat.

False Negative (FN) = Jumlah data yang sebenarnya positif namun diprediksi secara negatif, yang menunjukkan model salah dalam mengklasifikasikan data positif yang dianggap sebagai negatif.

Confussion matrix dapat digunakan untuk menghitung berbagai metrik evaluasi seperti akurasi, presisi, recall, dan skor F1. Hasil ini menunjukkan kinerja model dalam klasifikasi. Akurasi adalah proporsi prediksi yang benar (baik positif maupun negatif) dari keseluruhan prediksi yang dilakukan oleh model. Frekwensi di mana model membuat prediksi yang benar disebut akurasi. Namun, dalam kasus data yang tidak seimbang, akurasi saja mungkin tidak memberikan gambaran yang akurat tentang kinerja model. Rumus akurasi sebagai berikut.

$$Akurasi = \frac{TP + TN}{TP + TN + FP + FN}$$

Prediksi positif yang benar (TP) untuk setiap prediksi yang dianggap positif (TP + FP) disebut dengan presisi. Presisi mengukur akurasi prediksi positif dari model, yang penting dalam konteks di mana kesalahan prediksi positif (FP) harus diminimalkan.

$$Presisi = \frac{TP}{TP + FP}$$

Recall adalah pengembalian dari proposi kasus positif yang benar-benar diklasifikasikan sebagai positif oleh model (TP) dari seluruh kasus yang sebenarnya positif (TP + FN). Kemampuan model untuk menemukan semua kasus positif dapat diukur dengan pengembalian ini. Ini penting dalam situasi di mana mendeteksi semua kasus positif adalah prioritas utama.

$$Recall = \frac{TP}{TP + FN}$$

Rata-rata harmonis dari presisi dan recall merupakan F1-score. Ini adalah metrik yang berguna ketika kita ingin mempertimbangkan kedua metrik secara seimbang. F1-score memberikan gambaran tentang keseimbangan antara presisi dan recall, terutama dalam kasus data yang tidak seimbang (imbalanced data).

$$F1 - Score = 2 \times \frac{Presisi \times Recall}{Presisi + Recall}$$

Nilai F1 berkisar antara 0 dan 1; nilai 1 adalah performa yang sempurna (keseimbangan ideal antara Ketepatan dan Recall), sedangkan nilai 0 adalah performa yang sangat rendah.

Untuk meningkatkan evaluasi kinerja algoritma, dilakukan pengujian Area Under the Curve (AUC). Nilai AUC berkisar antara 0 dan 1, dan menunjukkan seberapa baik model cocok dengan data yang digunakan. Ada korelasi positif antara nilai AUC dan kemampuan variabel yang diuji untuk memprediksi kejadian tertentu. AUC-ROC adalah ukuran kinerja dalam klasifikasi biner dan sering digunakan untuk mengevaluasi model dalam hal bagaimana baiknya model membedakan antara dua kelas. Untuk memahami AUC-ROC dapat mengetahui bagaimana kurva ROC dibentuk dan bagaimana metrik TPR (True Positive Rate) berperan.

TPR, juga dikenal sebagai Sensitivity atau Recall, adalah salah satu komponen utama dalam membangun kurva ROC. TPR mengukur proporsi kasus positif yang benar-benar terdeteksi oleh model dari seluruh kasus yang sebenarnya positif.

$$TPR = \frac{TP}{TP + FN}$$

Kurva ROC adalah grafik yang menunjukkan hubungan antara TPR (sensitivity) dan FPR (False Positive Rate) pada berbagai threshold klasifikasi. False Positive Rate (FPR) adalah bagian kasus negatif yang salah dianggap positif. Rumus FPR sebagai berikut:

$$FPR = \frac{FP}{FT + FN}$$

3. HASIL DAN PEMBAHASAN

3.1 Data Preprocessing

Pembersihan data pada penelitian ini melibatkan penanganan nilai yang hilang dengan imputasi, penghapusan, dan menghapus duplikat untuk menghindari hasil yang bias, dan memperbaiki kesalahan seperti inkonsistensi, salah ketik, atau entri yang salah. Pada tahap ini, tujuan utamanya adalah membersihkan dataset agar model yang dibangun nantinya memiliki akurasi yang baik. Nilai yang hilang dalam dataset diubah menggunakan nilai rata-rata yaitu dari masing-masing atribut untuk memastikan kelengkapan data. Kemudian data dinormalisasi menggunakan StandardScaler agar seluruh fitur berada dalam skala sama, dimana hal ini penting untuk kinerja algoritma KNN.

Dari 1846 data duplikat yang dihapus, 1738 masih valid. Oleh karena itu, total 1738 daftar digunakan dalam penelitian ini. Sebelum teknik klasifikasi digunakan pada algoritma KNN, data akan dibagi menjadi dua. Model klasifikasi dibuat dengan data pelatihan, dan model pengujian digunakan untuk menguji kinerja model tersebut. Untuk evaluasi model, dataset dibagi menjadi dua bagian menggunakan rasio pembagian 8:2, yang berarti 80 persen dari dataset digunakan sebagai data pelatihan dan 20 persen sebagai data pengujian. Pada 80 persen data pelatihan, model akan belajar dari mayoritas data untuk klasifikasi, dan 20 persen data pengujian digunakan untuk menguji kinerja model pada data yang belum pernah dilihat sebelumnya.

Pengujian pertama dilakukan menggunakan algoritma KNN tanpa melakukan seleksi fitur sebelumnya. Dataset yang digunakan terdiri dari 1738 sampel data dengan 10 atribut yang telah diubah menjadi format numerik. Atribut-atribut tersebut mencakup jenis kelamin, umur, berat badan, tinggi badan, indeks berat badan (bb/u), z-score dari indeks berat badan (bb/u), indeks berat badan terhadap tinggi badan (bb/tb), z-score dari indeks berat badan terhadap tinggi badan (bb/tb), indeks tinggi badan terhadap umur (tb/u), dan z-score dari tinggi badan terhadap umur (tb/u).

3.2 Analisis Deskriptif

Analisis Deskriptif dipakai untuk mendapatkan gambaran umum mengenai karakteristik data yang berisi informasi tentang status

gizi balita, analisis deskriptif mengungkapkan statistik ringkasan seperti rata-rata, median, standar deviasi, dan rentang nilai untuk variabel numerik seperti usia, berat, dan tinggi badan. Distribusi frekuensi dari variabel kategorikal seperti jenis kelamin dan kategori gizi (BB/U, TB/U, BB/TB) memberikan wawasan tentang sebaran data dan keseimbangan kelas. Korelasi antar variabel numerik diidentifikasi melalui matriks korelasi, yang menunjukkan hubungan signifikan antara z-score gizi dan status stunting.

Tabel 2. Deskripsi Data

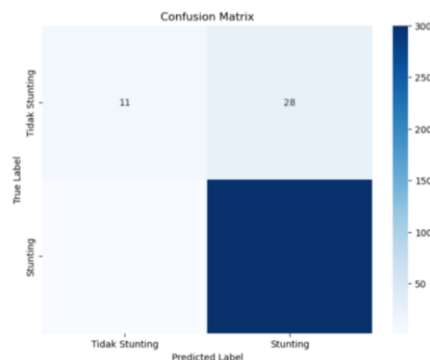
No	Variabel	Rata-Rata	Std	Min	Max
1	Usia	941.52	505.42	0	1819
2	Berat Badan	11.62	3.5	2.64	30.6
3	Tinggi Badan	86.06	13.02	47	117
4	Jenis Kelamin	0.48	0.49	0	1
5	Indeks BB/U	1.8	0.44	0	2
6	Indeks TB/U	1.86	0.39	0	2
7	Indeks BB/TB	1.01	0.36	0	2
8	ZS BB/U	-0.9	1.15	-5.38	4.44
9	ZS TB/U	-1.08	1.004	-5.39	2.55
10	ZS BB/TB	-0.42	1.18	-4.05	5.96

Tabel 2. menunjukkan bahwa Usia balita rata-rata adalah 941.52 hari dengan standar deviasi 505.42 hari, menunjukkan distribusi yang luas mulai dari 0 hingga 1819 hari. Berat badan rata-rata balita adalah 11.62 kg dengan standar deviasi 3.5 kg, dan rentang berat badan dari 2.64 kg hingga 30.6 kg. Tinggi badan balita memiliki rata-rata 86.06 cm dan standar deviasi 13.02 cm, dengan tinggi badan bervariasi antara 47 cm hingga 117 cm. Distribusi jenis kelamin hampir seimbang, dimana rata-rata 0.48 dan standar deviasi 0.49, yang mengindikasikan proporsi yang sama baik balita laki-laki dan juga perempuan.

Hasil BB/U ditunjukkan dengan rata-rata 1.8 dimana standar deviasi 0.44, sedangkan TB/U memiliki rata-rata 1.86 dan standar deviasi 0.39. BB/TB ditunjukkan dengan rata-rata 1.01 dengan standar deviasi 0.36. Z-score BB/U, TB/U, dan BB/TB memiliki rata-rata masing-masing -0.9, -1.08, dan -0.42, menunjukkan bahwa sebagian besar balita dalam dataset cenderung berada di bawah standar pertumbuhan yang diharapkan. Nilai z-score ini juga memiliki standar deviasi yang menunjukkan variasi dalam status gizi balita, dengan rentang yang cukup luas dari nilai minimum hingga maksimum yang mencakup balita dengan gizi sangat kurang hingga sangat baik.

3.3 Klasifikasi dengan Metode KNN

Model KNN dilatih menggunakan data pelatihan. Pada pengujian ini, nilai k yang digunakan untuk KNN, yaitu $k = 3$, nilai tersebut dipilih karena memberikan tingkat akurasi yang tertinggi dibandingkan dengan nilai k lainnya. Kemudian data diklasifikasikan yang selanjutnya dievaluasi dengan *Confusion matrix* berikut.



Gambar 2. Hasil *Confusion Matrix* dengan KNN

Hasil evaluasi model KNN digunakan sebagai identifikasi status *stunting* pada balita yang ditunjukkan melalui *confusion matrix* yang memberikan gambaran mengenai banyaknya prediksi benar dan salah yang dibuat oleh model. TP berjumlah 300, menunjukkan bahwa model memprediksi balita sebagai stunting dan balita tersebut benar-benar stunting. Ini berarti model mempunyai kemampuan yang sangat baik untuk mengidentifikasi balita yang benar-benar stunting, dengan jumlah prediksi benar

yang sangat tinggi. FP berjumlah 28, yang berarti model memprediksi balita sebagai stunting padahal sebenarnya tidak stunting. Jumlah ini menunjukkan bahwa ada beberapa kesalahan prediksi di mana balita yang sebenarnya sehat dikategorikan sebagai stunting oleh model.

TN berjumlah 11, yang berarti model memprediksi balita sebagai tidak stunting dan balita tersebut benar-benar tidak stunting. Ini menunjukkan bahwa model memiliki kemampuan untuk mengidentifikasi balita yang benar-benar tidak stunting, meskipun jumlahnya relatif kecil dibandingkan dengan jumlah prediksi benar untuk stunting. FN berjumlah 2, yang berarti model memprediksi balita sebagai tidak stunting padahal sebenarnya stunting. Ini menunjukkan bahwa model hanya membuat sedikit kesalahan dalam mengabaikan kasus stunting yang sebenarnya, dengan jumlah kesalahan yang sangat kecil.

Setelah model dilatih, prediksi dilakukan pada data uji dan mengevaluasi kinerjanya menggunakan metrik akurasi, precision, recall, dan F1-score. Berikut hasil nilai akurasi, precision, recall, dan F1-score.

	precision	recall	f1-score	support
0	0.85	0.28	0.42	39
1	0.91	0.99	0.95	302
accuracy			0.91	341
macro avg	0.88	0.64	0.69	341
weighted avg	0.91	0.91	0.89	341

Gambar 3. Hasil akurasi, precision, recall, dan F1-score menggunakan KNN

Hasil evaluasi model KNN menunjukkan berbagai metrik untuk memahami kinerja model dalam mengidentifikasi status stunting pada balita. *Precision* untuk kelas 0 (tidak stunting) adalah 0.85, yang berarti 85% dari balita yang diprediksi tidak stunting oleh model memang benar tidak stunting. *Precision* untuk kelas 1 (stunting) adalah 0.91, menunjukkan bahwa 91% dari balita yang diprediksi stunting oleh model memang benar stunting. Namun, *recall* untuk kelas 0 hanya 0.28, yang berarti hanya 28% dari balita yang benar-benar tidak stunting terdeteksi oleh model. Sebaliknya, *recall* untuk kelas 1 adalah 0.99, menunjukkan bahwa 99% dari balita yang benar-benar stunting berhasil diidentifikasi oleh model.

F1-Score untuk kelas 0 adalah 0.42, yang menunjukkan keseimbangan antara *precision* dan *recall* yang rendah, menandakan bahwa model kurang baik dalam mendeteksi balita yang tidak stunting. Di sisi lain, F1-Score untuk kelas 1 adalah 0.95, yang menunjukkan keseimbangan antara *precision* dan *recall* yang sangat baik, menandakan bahwa model sangat efektif dalam mendeteksi balita yang stunting. Akurasi keseluruhan model yaitu 0.91, yang berarti model mampu memprediksi yang benar sebanyak 91% dari seluruh data.

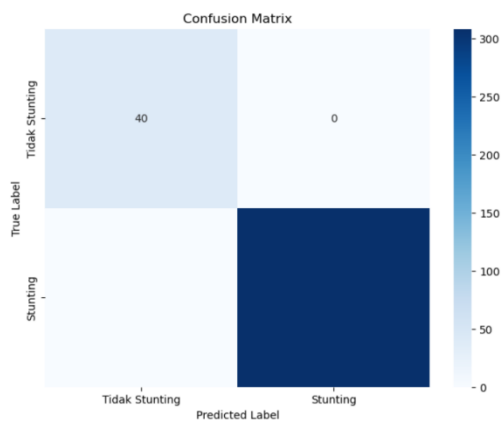
Rata-rata makro menunjukkan *precision* sebesar 0.88, *recall* sebesar 0.64, dan F1-Score sebesar 0.69, yang menunjukkan bahwa model cenderung lebih baik dalam mendeteksi kelas mayoritas (stunting) dibandingkan kelas minoritas (tidak stunting). Rata-rata tertimbang memberikan gambaran yang lebih realistis mengenai kinerja model dengan *precision* sebesar 0.91, *recall* sebesar 0.91, sementara F1-Score yaitu sebesar 0.89, dengan lebih menekankan pada kelas yang lebih sering muncul (stunting).

Model KNN memberikan hasil yang cukup memuaskan dengan akurasi yang tinggi. Namun, *precision* dan *recall* masih bisa ditingkatkan, yaitu

- Keseimbangan data antara kelas stunting dan tidak stunting dapat mempengaruhi kinerja model. Jika data tidak seimbang, model mungkin lebih cenderung memprediksi kelas mayoritas.
- Pemilihan nilai *k* (jumlah tetangga terdekat) sangat mempengaruhi kinerja model. Nilai *k* yang optimal dapat ditemukan melalui proses *cross validation*.
- Meskipun semua fitur digunakan dalam model ini, pemilihan fitur yang lebih relevan dapat meningkatkan kinerja model. Teknik seperti *Forward Selection* dapat membantu dalam pemilihan fitur. Sehingga digunakan Teknik seperti *Forward Selection* pada klasifikasi berikutnya.

3.4 Klasifikasi dengan Metode KNN berbasis *Forward Selection*

Teknik *Forward Selection* digunakan dalam memilih fitur-fitur yang paling relevan dengan menggunakan metode *incremental*. Fitur-fitur ditambahkan satu per satu berdasarkan peningkatan kinerja model. Setelah model dilatih, prediksi dilakukan pada data uji dan mengevaluasi kinerjanya menggunakan metrik akurasi, *precision*, *recall*, dan F1-score. Hasil evaluasi model menunjukkan metrik sebagai berikut:



Gambar 4. Hasil *Confusion Matrix* dengan KNN berbasis *Forward Selection*

Hasil evaluasi model KNN berbasis *Forward Selection* untuk mengidentifikasi status stunting pada balita ditunjukkan melalui *confusion matrix* yang memberikan gambaran mengenai banyaknya prediksi benar dan salah yang dibuat dengan model. True Positive (TP) berjumlah 308, menunjukkan bahwa model memprediksi balita sebagai stunting dan balita tersebut benar-benar stunting. Ini berarti model mempunyai kemampuan yang sangat baik untuk menentukan balita yang benar-benar stunting, dengan jumlah prediksi benar yang sangat tinggi dan tidak ada kesalahan untuk kategori ini. False Positive (FP) berjumlah 0, yang berarti model memprediksi balita sebagai stunting padahal sebenarnya tidak stunting. Jumlah nol ini menunjukkan bahwa model tidak membuat kesalahan dalam mengkategorikan balita yang tidak stunting sebagai stunting, mengindikasikan tingkat keakuratan yang sangat tinggi.

True Negative (TN) berjumlah 40, yang berarti model memprediksi balita sebagai tidak stunting dan balita tersebut benar-benar tidak stunting. Hal ini terlihat bahwa model mempunyai kemampuan yang sangat baik dalam mengidentifikasi balita yang benar-benar tidak stunting, tanpa kesalahan untuk kategori ini. False Negative (FN) berjumlah 0, yang berarti model memprediksi balita sebagai tidak stunting padahal sebenarnya stunting. Jumlah nol ini menunjukkan bahwa model tidak membuat kesalahan dalam mengabaikan kasus stunting yang sebenarnya, mengindikasikan tingkat keakuratan yang sempurna.


Dengan demikian, terlihat bahwa model KNN yang dikombinasikan dengan *Forward Selection* mampu memberikan kinerja yang baik dalam mengidentifikasi status stunting balita. Hasil evaluasi model K-Nearest Neighbor (KNN) menunjukkan performa yang sangat baik dalam mengidentifikasi status stunting balita dengan metrik yang sempurna.

Akurasi: 100.00%					
	precision	recall	f1-score	support	
0	1.00	1.00	1.00	40	
1	1.00	1.00	1.00	308	
accuracy			1.00	348	
macro avg	1.00	1.00	1.00	348	
weighted avg	1.00	1.00	1.00	348	

Gambar 5. Hasil akurasi, precision, recall, dan F1-score menggunakan KNN berbasis *Forward Selection*

Precision untuk kelas 0 (tidak stunting) adalah 1.00, yang berarti 100% dari balita yang diprediksi tidak stunting oleh model memang benar tidak stunting. *Recall* juga mencapai 1.00, menunjukkan bahwa model berhasil mendeteksi 100% dari semua balita yang benar-benar tidak stunting. *F1-Score* untuk kelas ini juga sempurna di angka 1.00, menunjukkan keseimbangan yang sempurna yaitu *precision* dan *recall*. Untuk kelas 1 (stunting), *precision* juga mencapai 1.00, yang menunjukkan bahwa 100% dari balita yang diprediksi stunting oleh model memang benar stunting. *Recall* untuk kelas ini adalah 1.00, menunjukkan bahwa model berhasil mendeteksi 100% dari semua balita yang benar-benar stunting. *F1-Score* untuk kelas ini juga sempurna di angka 1.00. Akurasi keseluruhan model yaitu 1.00, yang berarti model mampu memprediksi yang benar sebanyak 100% dari seluruh data yang diuji. Rata-rata makro menunjukkan *precision*, *recall*, dan *F1-Score* masing-masing dengan nilai 1.00, yang berarti performa model seimbang dan sempurna untuk kedua kelas, tanpa memandang ukuran dari masing-masing kelas. Rata-rata tertimbang juga menunjukkan *precision*, *recall*, dan *F1-Score* yaitu masing-masing sebesar 1.00, memberikan gambaran yang lebih realistis mengenai kinerja model dengan mempertimbangkan ukuran dari setiap kelas. Kesimpulannya, model KNN memiliki performa yang sempurna dalam mengidentifikasi status stunting pada balita. Semua metrik evaluasi mencapai nilai 1.00 untuk kedua kelas, baik kelas tidak stunting maupun stunting, menunjukkan bahwa model KNN dapat memprediksi status

stunting dengan tingkat keakuratan yang sangat tinggi dan tanpa kesalahan. Model ini sangat efektif dan andal untuk digunakan dalam pengambilan keputusan medis dan kebijakan kesehatan terkait stunting pada balita.



Gambar 6. Kurva AUC- ROC

Berdasarkan dari hasil tingkat akurasi dan nilai AUC-ROC yang diperoleh pada Gambar 6, penelitian ini tidak menunjukkan tanda-tanda overfitting. Hal ini dikarenakan tidak terdapat perbedaan signifikan antara tingkat akurasi dan nilai AUC-ROC pada data pelatihan dan data pengujian. Nilai AUC-ROC sebesar 1.00 menunjukkan bahwa model KNN berbasis forward selection mampu membedakan dengan sempurna baik balita yang mengalami stunting dan juga yang tidak stunting pada semua threshold yang diuji. Keberhasilan model ini dalam mencapai nilai AUC yang sangat tinggi tanpa adanya selisih signifikan antara data pelatihan dan data pengujian mengindikasikan bahwa model yang dibentuk tidak hanya berfungsi baik pada data pelatihan tetapi juga dapat diterapkan secara efektif pada data yang belum terlihat. Dengan demikian, model yang telah dikembangkan merupakan model yang baik dan dapat diandalkan untuk identifikasi status stunting pada balita, tanpa risiko *overfitting*.

4. KESIMPULAN

Berdasarkan dari hasil dan pembahasan yang telah disajikan, evaluasi model KNN menunjukkan akurasi 91,20%, precision 85%, recall 28%, dan F1 score 42%. Hasil ini mengindikasikan efektivitas metode KNN dalam mengidentifikasi status stunting pada balita. Untuk mengatasi kekurangan tersebut, model KNN kemudian dikombinasikan dengan metode forward selection, yang secara signifikan meningkatkan kinerja model hingga mencapai akurasi, *precision*, *recall*, dan F1 score sebesar 100%. Hal ini menunjukkan bahwa kombinasi KNN dengan *forward selection* sangat efektif dan dapat menghasilkan model yang lebih akurat dan andal. Secara keseluruhan, metode KNN ini, terutama ketika dikombinasikan dengan forward selection, dapat digunakan sebagai alat bantu yang kuat dalam pengambilan keputusan medis dan kebijakan kesehatan untuk mengatasi masalah stunting pada anak-anak.

DAFTAR PUSTAKA

- [1] R. I. Kemenkes, "Pedoman Gizi Seimbang, Direktorat Jenderal Bina Gizi dan KIA," 2014, *Jakarta, hal.*
- [2] S. Salsabila, S. Martha, and W. Andani, "KOMPARASI ALGORITMA K-NEAREST NEIGHBOR DENGAN EUCLIDEAN DISTANCE DAN MANHATTAN DISTANCE UNTUK KLASIFIKASI STUNTING BALITA (Studi Kasus: Puskesmas Kelurahan Parit Mayor)," *Bimaster Bul. Ilm. Mat. Stat. dan Ter.*, vol. 13, no. 2.
- [3] K. M. Rajabi, W. Witanti, and R. Yuniarti, "Penerapan Algoritma K-Nearest Neighbor (KNN) Dengan Fitur Relief-F Dalam Penentuan Status Stunting," *Innov. J. Soc. Sci. Res.*, vol. 3, no. 4, pp. 3555–3568, 2023.
- [4] S. Lonang, A. Yudhana, and M. K. Biddinika, "Analisis Komparatif Kinerja Algoritma Machine Learning untuk Deteksi Stunting," *J. MEDIA Inform. BUDIDARMA*, vol. 7, no. 4, pp. 2109–2117, 2023.
- [5] Rangga Gelar Guntara, "Aplikasi Pendeteksi Penyakit Telinga Berbasis Android menggunakan API Clarifai dan K-Nearest Neighbor," *J. CoSciTech (Computer Sci. Inf. Technol.)*, vol. 3, no. 2, pp. 81–90, 2022, doi: 10.37859/coscitech.v3i2.3862.
- [6] R. Gunawan, R. Septiadi, F. Apri Wenando, H. Mukhtar, and Syahril, "K-Nearest Neighbor (KNN) untuk Menganalisis Sentimen terhadap Kebijakan Merdeka Belajar Kampus Merdeka pada Komentar Twitter," *J. CoSciTech (Computer Sci. Inf. Technol.)*, vol. 3, no. 2, pp. 152–158, 2022, doi: 10.37859/coscitech.v3i2.3841.
- [7] T. Prasetya, I. Ali, C. L. Rohmat, and O. Nurdianan, "Klasifikasi Status Stunting Balita Di Desa Slangit Menggunakan Metode K-Nearest Neighbor," *INFORMATICS Educ. Prof. J. Informatics*, vol. 5, no. 1, pp. 93–104, 2020.
- [8] O. S. Bachri and R. M. H. Bhakti, "Penentuan Status Stunting pada Anak dengan Menggunakan Algoritma KNN," *J. Ilm. Intech Inf. Technol. J. UMUS*, vol. 3, no. 02, pp. 130–137, 2021.
- [9] P. Apriyani, A. R. Dikananda, and I. Ali, "Penerapan Algoritma K-Means dalam Klusterisasi Kasus Stunting Balita Desa Tegalwangi," *Hello World J. Ilmu Komput.*, vol. 2, no. 1, pp. 20–33, 2023.
- [10] R. Wahyudi, M. Orisa, and N. Vendyansyah, "Penerapan Algoritma K-Nearest Neighbors Pada Klasifikasi Penentuan Gizi Balita (Studi Kasus Di Posyandu Desa Bluto)," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 5, no. 2, pp. 750–757, 2021.
- [11] I. R. Lina and D. C. Wati, "Klasifikasi Pengeluaran per Kapita di Tiga Provinsi Sulawesi menggunakan K-Nearest Neighbor," *J Stat. J. Ilm. Teor. dan Apl. Stat.*, vol. 16, no. 1, pp. 395–406, 2023.
- [12] S. K. P. Loka and A. Marsal, "Perbandingan Algoritma K-Nearest Neighbor dan Na{"i}ve Bayes Classifier untuk Klasifikasi Status Gizi Pada Balita: Comparison Algorithm of K-Nearest Neighbor and Na{"i}ve Bayes Classifier for Classifying Nutritional Status in Toddlers," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 3, no. 1, pp. 8–14, 2023.
- [13] D. S. Dwiyantri and M. A. Saptari, "PERANCANGAN SISTEM INFORMASI STATUS GIZI BALITA (STUNTING) di UPTD PUSKESMAS

- MUARA SATU dan MUARA DUA MENGGUNAKAN METODE NAÏVE BAYES CLASSIFICATION dan K-NEAREST NEIGHBOR BERBASIS WEB,” *Sisfo J. Ilm. Sist. Inf.*, vol. 7, no. 2, pp. 75–81, 2023.
- [14] S. Lonang and D. Normawati, “Klasifikasi Status Stunting Pada Balita Menggunakan K-Nearest Neighbor Dengan Feature Selection Backward Elimination,” *J. Media Inform. Budidarma*, vol. 6, no. 1, pp. 49–56, 2022.
- [15] J. Zeniarja, K. Widia, and R. R. Sani, “Penerapan algoritma Naive Bayes dan forward selection dalam pengklasifikasian status gizi stunting pada Puskesmas Pandanaran Semarang,” *JOINS (Journal Inf. Syst.*, vol. 5, no. 1, pp. 1–9, 2020.
- [16] I. Guyon and A. Elisseeff, “An introduction to variable and feature selection,” *J. Mach. Learn. Res.*, vol. 3, no. Mar, pp. 1157–1182, 2003.
- [17] T. Cover and P. Hart, “Nearest neighbor pattern classification,” *IEEE Trans. Inf. theory*, vol. 13, no. 1, pp. 21–27, 1967.