

Implementasi Algoritma K-Nearest Neighbors Dengan Pendekatan Elbow Method Untuk Klasifikasi Status Ketahanan Pangan Provinsi Di Indonesia

Cinthy Agatha Sinaga¹, Anirma Kandida Ginting²

^{1,2} Universitas Katolik Santo Thomas Medan, Jl. Setia Budi No.479 F Tanjung Sari, Medan, Indonesia

ARTICLE INFORMATION

Received: Februari 02,24
Revised: March 23, 25
Available online: April 01, 27

KEYWORDS

Classification, K-Nearest Neighbors, Ketahanan Pangan Provinsi, Elbow Method

CORRESPONDENCE

Phone: +62 88708489910

E-mail: cinthyaagathaa@gmail.com

ABSTRAK

Ketahanan pangan merupakan isu strategis dalam pembangunan nasional, terutama dalam menghadapi tantangan ketimpangan distribusi pangan antarprovinsi di Indonesia. Penelitian ini bertujuan untuk mengklasifikasikan status ketahanan pangan provinsi menggunakan algoritma K-Nearest Neighbors (KNN) yang dioptimalkan melalui pendekatan Elbow Method. Data yang digunakan mencakup dua variabel utama, yaitu Indeks Ketahanan Pangan dan Prevalensi Ketidakcukupan Konsumsi Pangan dari 34 provinsi, dengan data tahun 2023 sebagai data latih dan 2024 sebagai data uji. Hasil pemodelan menunjukkan bahwa nilai k optimal adalah 3, dengan tingkat akurasi klasifikasi sebesar 91% serta precision, recall, dan f1-score yang konsisten. Temuan ini menunjukkan efektivitas KNN sebagai pendekatan machine learning yang akurat dan sistematis dalam mendukung pemetaan ketahanan pangan berbasis data di Indonesia

PENDAHULUAN

Ketahanan pangan merupakan isu krusial dalam pembangunan nasional Indonesia yang sejalan dengan komitmen pemerintah terhadap Tujuan Pembangunan Berkelanjutan (SDGs), khususnya tujuan SDGs yang ke dua yang dikenal sebagai "Tanpa Kelaparan" (Zero Hunger). Tujuannya adalah untuk mengakhiri kelaparan, mencapai ketahanan pangan dan gizi yang baik, serta mendorong pertanian yang berkelanjutan sebagai upaya utama untuk menjamin ketersediaan pangan yang cukup dan merata bagi seluruh masyarakat Indonesia (Kementerian PPN/Bappenas, 2023). Dalam konteks nasional, hal ini menjadi sangat relevan mengingat masih adanya kelompok masyarakat yang rentan terhadap kekurangan pangan dan gizi, terutama di daerah-daerah terpencil dan kurang berkembang.

Ketidakmerataan status ketahanan pangan antarprovinsi di Indonesia menjadi tantangan utama yang harus diatasi. Data Badan Pusat Statistik (2023) menunjukkan bahwa indeks ketahanan pangan di beberapa provinsi masih berada pada tingkat yang rendah, menandakan kerentanan yang tinggi terhadap krisis pangan. Perbedaan ini disebabkan oleh berbagai faktor, termasuk disparitas akses terhadap sumber daya, infrastruktur distribusi, dan ketahanan ekonomi masyarakat lokal. Oleh karena itu, klasifikasi dan pemetaan status ketahanan pangan secara akurat menjadi langkah penting untuk memahami karakteristik wilayah dan merancang intervensi yang tepat sasaran (Salasa, 2021).

Pengambilan keputusan berbasis data (data-driven policy) menjadi pendekatan yang semakin diutamakan dalam upaya meningkatkan efektivitas kebijakan ketahanan pangan di Indonesia. Pemerintah dan lembaga terkait semakin mengandalkan data komprehensif yang mengintegrasikan berbagai analisis seperti ketersediaan pangan, aksesibilitas, dan stabilitas pasokan sebagai dasar perencanaan dan evaluasi program (Kementerian Desa, 2025). Penelitian yang menerapkan metode komputasi modern, seperti klasifikasi algoritma dan pembelajaran mesin, telah menunjukkan potensi besar dalam mempercepat identifikasi daerah rawan pangan dan meningkatkan akurasi intervensi (Cadavid, Arulnathan and Pelletier, 2024).

Urgensi topik ketahanan pangan juga didorong oleh tantangan global dan nasional, seperti perubahan iklim, kenaikan harga pangan, serta masalah gizi buruk yang masih tinggi di Indonesia. Meski terdapat kemajuan dalam menurunkan angka kelaparan dan stunting, data Global Hunger Index (2023) menempatkan Indonesia pada kategori "serius" dalam masalah ketahanan pangan. Oleh karena itu, penelitian yang mengintegrasikan pendekatan analitis dan informasi teknologi ke dalam pemetaan dan mengklasifikasikan status ketahanan pangan di tingkat provinsi sangat relevan dan mendesak untuk mendukung pencapaian target SDGs 2030 (Azhar *et al.*, 2023).

Meskipun Indonesia telah mengumpulkan data ketahanan pangan yang cukup banyak, pemanfaatan data tersebut untuk analisis klasifikasi status ketahanan pangan di tingkat provinsi masih belum optimal. Data yang tersedia belum diolah secara menyeluruh dan sistematis sehingga kurang mampu memberikan gambaran yang akurat mengenai wilayah yang rentan maupun yang tahan terhadap ketahanan pangan. Pendekatan konvensional yang sering mengandalkan indikator tunggal atau penilaian subjektif menyebabkan hasil klasifikasi kurang konsisten dan kurang dapat diandalkan untuk mendukung kebijakan yang efektif (Salasa, 2021).

Untuk mengatasi tantangan ini, diperlukan metode klasifikasi yang lebih tepat dan akurat, yang mampu memproses data multidimensi secara efisien. Algoritma machine learning seperti K-Nearest Neighbors (KNN) memiliki potensi untuk mengklasifikasikan status ketahanan pangan berdasarkan fitur serupa, namun perlu disertai teknik optimasi parameter agar hasilnya maksimal.

Algoritma K-Nearest Neighbors (K-NN) merupakan metode klasifikasi yang bekerja berdasarkan konsep jarak atau kedekatan antar data. Algoritma ini mengelompokkan data uji dengan melihat label dari sejumlah tetangga terdekatnya dalam ruang fitur, sehingga sangat cocok digunakan untuk data yang sudah berlabel dan memiliki karakteristik multidimensi (Dewi and Pramita, 2019). Kelebihan K-NN terletak pada kemudahan dan kemampuannya dalam menangani data yang tidak memerlukan asumsi distribusi tertentu, sehingga sering dipilih dalam berbagai studi klasifikasi ketahanan pangan di Indonesia.

Meski demikian, salah satu kendala utama dalam penerapan KNN adalah penentuan nilai k yang optimal, yaitu jumlah tetangga terdekat yang digunakan untuk menentukan kelas data uji. Pemilihan nilai k yang kurang tepat dapat menurunkan akurasi model, karena nilai k yang terlalu kecil rentan terhadap noise, sedangkan nilai k yang terlalu besar dapat batas antar kelas (Maori and Evanita, 2023). Untuk mengatasi masalah ini, pendekatan Elbow Method dapat digunakan sebagai teknik sistematis dalam menentukan nilai k terbaik dengan mengamati perubahan error atau variansi yang signifikan saat nilai k bertambah. Pendekatan ini telah terbukti meningkatkan kinerja klasifikasi dalam konteks ketahanan pangan, sehingga memberikan hasil yang lebih andal dan objektif (Abrar, Abdullah and Sucipto, 2023).

METODE PENELITIAN

2.1. Persiapan Data

Data yang digunakan dalam penelitian ini bersumber dari portal data terbuka milik pemerintah, yakni data.go.id, yang menyediakan berbagai indikator pembangunan dari tingkat nasional hingga daerah. Fokus penelitian ini mengarah pada dua fitur utama yang menggambarkan kondisi ketahanan pangan di Indonesia, yaitu Indeks Ketahanan Pangan (IKP) dan Prevalensi Ketidakcukupan Konsumsi Pangan. Variabel kedua ini diambil dari data masing-masing provinsi di Indonesia dengan mencakup sebanyak 38 provinsi, dan tersedia untuk dua tahun terakhir, yakni 2023 dan 2024. Dalam proses analisis, data tahun 2023 dimanfaatkan sebagai data latih (training) untuk membangun model klasifikasi, sedangkan data dari tahun 2024 digunakan sebagai data uji (testing) guna mentransmisikan akurasi prediksi dari model yang dibentuk.

Sebelum dilakukan pengolahan lebih lanjut, data melalui tahap pembersihan untuk menjamin kualitas dan integritas analisis. Seluruh entri yang mengandung nilai kosong, baik pada variabel IKP maupun prevalensi konsumsi pangan, dihapus dari dataset. Hal ini penting dilakukan untuk menghindari gangguan terhadap proses normalisasi dan perhitungan jarak dalam algoritma klasifikasi yang digunakan. Setelah proses ini, jumlah provinsi dengan data lengkap menyusut menjadi 34 provinsi untuk masing-masing tahun. Dataset yang telah bersih dan konsisten ini kemudian menjadi dasar dalam proses normalisasi, sebelum dilanjutkan ke tahapan klasifikasi menggunakan pendekatan K-Nearest Neighbors (KNN).

2.2. Teknik Analisis Data

Penelitian ini menerapkan pendekatan berbasis machine learning untuk melakukan klasifikasi status ketahanan pangan provinsi di Indonesia. Algoritma utama yang digunakan adalah K-Nearest Neighbors

(KNN), dengan pemilihan nilai parameter k ditentukan melalui pendekatan Elbow Method. Proses analisis dilakukan secara bertahap, dimulai dari input data, pembersihan, pembagian data latih dan uji, pemilihan nilai k , proses klasifikasi, hingga evaluasi hasil. Alur lengkap proses dapat dilihat pada diagram berikut.



Gambar 1. Teknik Analisis Data

HASIL DAN PEMBAHASAN

3.1. Pembersihan Data

Sebelum dianalisis, data terlebih dahulu dibersihkan untuk memastikan akurasi dan konsistensi. Langkah ini mencakup penghapusan entri duplikat, penanganan data kosong, dan koreksi kesalahan input. Hasil akhir berupa data terstruktur yang siap digunakan dalam tahap analisis selanjutnya.


Table 1. Data Awal Setelah Pembersihan

NO	TAHUN	PROVINSI	Kode Provinsi	IKP	Prevalensi Ketidacukupan Konsumsi Pangan (Persen)	Kerentanan Area
1	2023	ACEH	11	72,96	9,44	Tahan
2	2023	SUMATERA UTARA	12	75,97	8,6	Sangat Tahan
3	2023	SUMATERA BARAT	13	83,22	7,63	Sangat Tahan
4	2023	RIAU	14	68,68	12,33	Tahan
.....						
35	2024	ACEH	11	73,94	9,1	
36	2024	SUMATERA UTARA	12	77,49	7,54	
37	2024	SUMATERA BARAT	13	84,32	8,88	

Berdasarkan Tabel 1, data setelah dilakukan pembersihan berubah menjadi 34 entri untuk masing-masing (training dan testing). Pembersihan yang dilakukan adalah menghapus entri yang kosong untuk mempertahankan konsistensi kinerja data terhadap algoritma.

3.2. Penentuan Nilai K dengan Elbow Method

Pemilihan parameter k yang tepat dalam algoritma *K-Nearest Neighbors* (KNN) menjadi langkah penting agar model dapat menghasilkan klasifikasi yang optimal. Dalam penelitian ini, pendekatan yang digunakan untuk menentukan nilai k terbaik adalah metode Elbow, yang dikenal luas karena kemudahan dan efektivitasnya dalam memvisualisasikan titik optimal pada suatu parameter.



Gambar 2. Grafik Akurasi nilai K dengan Elbow Method

Berdasarkan Gambar 2, terlihat nilai akurasi tertinggi adalah $k=1$ sampai $k=3$. Dalam visualisasi ini $k=3$ menjadi titik kritis yang dimana menjadi penurunan akurasi setelahnya. Titik ini dikenal sebagai siku (*elbow*) dan menunjukkan bahwa jika ada penambahan jumlah tetangga maka tidak lagi meningkatkan kinerja model secara signifikan. Oleh karena itu, nilai $k=3$ dianggap sebagai nilai k terbaik dan yang paling optimal, cukup tinggi untuk menghindari overfitting namun tidak terlalu besar untuk mengurangi sesivitas model terhadap pola dalam data.

3.3. Pemodelan Algoritma K-Nearest Neighbors (KNN)

Setelah nilai k optimal diperoleh melalui metode *Elbow*, proses dilanjutkan dengan membangun model klasifikasi menggunakan algoritma *K-Nearest Neighbors*. Pemodelan dilakukan untuk mengukur seberapa baik algoritma tersebut mampu mengklasifikasikan status ketahanan pangan berdasarkan data uji tahun 2024.

Untuk menentukan klasifikasi pada algoritma K-Nearest Neighbors (KNN), perhitungan jarak antar data merupakan langkah utama yang harus dilakukan. Berikut disajikan rumus yang digunakan dalam proses klasifikasi KNN menggunakan metode jarak Euclidean.


$$d(x, y) = \sqrt{(x_1 - y_1)^2 + (x_2 - y_2)^2 + \dots + (x_n - y_n)^2}$$

Akurasi	: 0.91			
Precision	: 0.91			
Recall	: 0.91			
F1 Score	: 0.90			
Detail:				
	precision	recall	f1-score	support
Agak Rentan	0.00	0.00	0.00	1
Agak Tahan	0.67	1.00	0.80	2
Rentan	0.50	1.00	0.67	1
Sangat Tahan	0.95	1.00	0.98	20
Tahan	1.00	0.80	0.89	10
accuracy			0.91	34
macro avg	0.62	0.76	0.67	34
weighted avg	0.91	0.91	0.90	34

Gambar 3. Hasil Akurasi Model KNN terhadap klasifikasi data

Berdasarkan evaluasi pada Gambar 3, model *K-Nearest Neighbors* (KNN) dengan parameter $k = 3$ mampu menghasilkan tingkat akurasi sebesar 91%, yang mencerminkan kemampuan klasifikasi yang cukup

tinggi. Selain akurasi, metrik evaluasi lain seperti precision, recall, dan f1-score juga menunjukkan hasil yang konsisten, masing-masing berada pada kisaran 0.91, 0.91, dan 0.90, yang menandakan adanya keseimbangan antara ketepatan dan kelengkapan dalam prediksi. Secara umum, model memiliki kemampuan yang baik dalam mengenali pola dari kelompok data dengan representasi dominan. Namun, keterbatasan muncul saat harus memproses kelas minoritas yang jumlahnya sedikit. Situasi ini penting untuk diperhatikan, terlebih bila kelas dengan jumlah kecil tersebut berkaitan erat dengan isu-isu penting dalam kebijakan ketahanan pangan, sehingga diperlukan langkah strategis untuk menyeimbangkan data atau menggunakan pendekatan yang lebih sensitif terhadap minoritas.




Gambar 4. Visualisasi Klasifikasi Status Ketahanan Pangan Provinsi dengan KNN

Untuk memahami lebih jauh bagaimana model memetakan data dalam ruang fitur, visualisasi scatter plot pada Gambar 4 memberikan representasi spasial terhadap hasil klasifikasi. Titik-titik biru menandakan data pelatihan, sementara titik merah merepresentasikan data pengujian yang telah diprediksi oleh model. Meskipun hanya menggunakan dua fitur utama yang telah distandarisasi, plot ini cukup menggambarkan sebaran dan kedekatan antar data, yang menjadi prinsip dasar kerja algoritma KNN. Terlihat bahwa sebagian besar titik pengujian terletak berdekatan dengan kelompok pelatihan yang seragam, menunjukkan konsistensi prediksi. Namun, terdapat pula beberapa titik yang tersebar di luar pola dominan, yang dapat menjadi indikasi dari kasus prediksi kelas minoritas atau potensi kesalahan klasifikasi. Visualisasi ini memperkuat hasil evaluasi sebelumnya dan menegaskan bahwa kualitas model sangat bergantung pada distribusi data antar kelas.

3.4. Confusion Matrix

Confusion matrix berfungsi untuk memberikan gambaran rinci mengenai kinerja model klasifikasi dengan menunjukkan jumlah prediksi yang benar dan salah untuk setiap kelas. Melalui matriks ini, kita dapat menghitung metrik evaluasi seperti precision, recall, dan f1-score, serta mengidentifikasi potensi kelemahan model, seperti ketidakseimbangan prediksi antar kelas.

3.4.1. Confusion Matrix Training



Gambar 5. Confusion Matrix Data Training

Berdasarkan Gambar 5 Berikut adalah hasil True Positive, False Positive, True Negative, dan False Negative berdasarkan matriks tersebut:

- a. True Positive (TP)

Merupakan jumlah data yang benar-benar berasal dari suatu kelas dan berhasil diklasifikasikan dengan benar oleh model.

TP untuk kelas 0 (Agak Rentan) = 3

TP untuk kelas 1 (Agak Tahan) = 2

TP untuk kelas 2 (Sangat Tahan) = 19

TP untuk kelas 3 (Tahan) = 10
- b. False Positive (FP)

Jumlah data dari kelas lain, tapi salah diklasifikasikan sebagai kelas tersebut.

FP kelas 0 = 0 (tidak ada prediksi salah ke kelas 0)

FP kelas 1 = 0

FP kelas 2 = 0

FP kelas 3 = 0
- c. False Negative (FN)

Jumlah data dari kelas tertentu, tetapi diklasifikasikan ke kelas lain.

FN kelas 0 = 0 (semua data kelas 0 diprediksi benar)

FN kelas 1 = 0

FN kelas 2 = 0

FN kelas 3 = 0
- d. True Negative (TN)

Jumlah data dari kelas lain, dan tidak diklasifikasikan sebagai kelas tersebut (klasifikasi benar terhadap kelas lain).

TN kelas 0 = 2 + 19 + 10 = 31


TN kelas 1 = 3 + 19 + 10 = 32

TN kelas 2 = 3 + 2 + 10 = 15

TN kelas 3 = 3 + 2 + 19 = 24

3.4.2. Confusion Matrix Data Testing

Hasil confusion matrix pada data testing ini memberikan gambaran sejauh mana model K-Nearest Neighbors (KNN) mampu mempertahankan performanya saat diuji dengan data yang belum pernah dilihat sebelumnya. Melalui analisis ini, kita dapat mengetahui jumlah prediksi yang benar dan salah untuk setiap kategori.



Gambar 6. Confusion Matrix Data Testing

Berdasarkan Gambar 6 Berikut adalah hasil True Positive, False Positive, True Negative, dan False Negative berdasarkan matriks tersebut:

a. True Positive (TP):

- 3 data kelas 0 diprediksi benar sebagai 0
- 2 data kelas 1 diprediksi benar sebagai 1
- 19 data kelas 2 diprediksi benar sebagai 2
- 10 data kelas 3 diprediksi benar sebagai 3

b. False Positive (FP):

Tidak terdapat FP karena tidak ada prediksi yang salah untuk kelas lain (selain diagonal semua nol)

c. False Negative (FN):

Juga tidak terdapat FN, karena tidak ada data aktual yang salah diklasifikasikan menjadi kelas lain

d. True Negative (TN):

KESIMPULAN

Penelitian ini menunjukkan bahwa penerapan algoritma K-Nearest Neighbors (KNN) dengan optimasi parameter melalui pendekatan Elbow Method dapat memberikan hasil klasifikasi yang akurat terhadap status ketahanan pangan antarprovinsi di Indonesia. Dengan menggunakan dua fitur utama yaitu Indeks Ketahanan Pangan dan Prevalensi Ketidacukupan Konsumsi Pangan, model mampu mengklasifikasikan data dengan tingkat akurasi sebesar 91%, serta menghasilkan nilai precision, recall, dan f1-score yang konsisten. Hasil ini mencerminkan potensi algoritma KNN dalam mendukung pemetaan wilayah rawan pangan berbasis data yang objektif dan sistematis.

Temuan ini juga menegaskan pentingnya pemilihan parameter yang tepat dalam model pembelajaran mesin untuk memaksimalkan performa prediksi dan meminimalkan kesalahan klasifikasi, terutama pada kelas minoritas yang sering terabaikan. Dengan demikian, pendekatan ini dapat menjadi salah satu alternatif metodologis yang efektif bagi pengambil kebijakan dalam menyusun strategi intervensi ketahanan pangan yang lebih responsif, adaptif, dan terukur. Penelitian ini juga membuka peluang untuk pengembangan model serupa dengan integrasi fitur yang lebih kompleks serta penerapan teknik balancing data guna meningkatkan sensitivitas model terhadap kelas yang kurang terwakili.

REFERENSI

- [1] D. A. I. C. Dewi and D. A. K. Pramita, "Analisis Perbandingan Metode Elbow dan Silhouette pada Algoritma Clustering K-Medoids dalam Pengelompokan Produksi Kerajinan Bali," *Matrix J. Manaj. Teknol. dan Inform.*, vol. 9, no. 3, pp. 102–109, 2019, doi: 10.31940/matrix.v9i3.1662.

- [2] T. Siswanto, S. Sari, and S. Teruri, “Integrasi Artificial Intelligence Pada Aplikasi ERP: Systematic Literature Review,” vol. 10, no. July 2024, pp. 1–13, 2025.
- [3] A. Fajar, A. Fauzi, and A. Faqih, “Optimization of the K-Nearest Neighbors (KNN) Algorithm in Imbalanced Dataset Classification Using the SMOTE Technique,” vol. 4, no. 2, 2025.
- [4] E. I. R. Rhofita, “Optimalisasi Sumber Daya Pertanian Indonesia untuk Mendukung Program Ketahanan Pangan dan Energi Nasional,” *J. Ketahanan Nas.*, vol. 28, no. 1, p. 82, 2022, doi: 10.22146/jkn.71642.
- [5] A. L. Azhar, S. Sulyanto, N. Chamidah, E. Ana, and D. Amelia, “Pemodelan Indeks Ketahanan Pangan di Indonesia Berdasarkan Pendekatan Regresi Logistik Ordinal Data Panel Efek Acak,” *J. Ketahanan Nas.*, vol. 29, no. 2, p. 166, 2023, doi: 10.22146/jkn.86511.
- [6] F. Istighfarizky, N. A. Sanjaya ER, I. M. Widiartha, L. G. Astuti, I. G. N. A. C. Putra, and I. K. G. Suhartana, “Klasifikasi Jurnal menggunakan Metode KNN dengan Mengimplementasikan Perbandingan Seleksi Fitur,” *JELIKU (Jurnal Elektron. Ilmu Komput. Udayana)*, vol. 11, no. 1, p. 167, 2022, doi: 10.24843/jlk.2022.v11.i01.p18.
- [7] N. A. Maori and E. Evanita, “Metode Elbow dalam Optimasi Jumlah Cluster pada K-Means Clustering,” *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 14, no. 2, pp. 277–288, 2023, doi: 10.24176/simet.v14i2.9630.
- [8] I. N. Abrar, A. Abdullah, and S. Sucipto, “Klasifikasi Penyakit Liver Menggunakan Metode Elbow Untuk Menentukan K Optimal pada Algoritma K-Nearest Neighbor (K-NN),” *J. Sisfokom (Sistem Inf. dan Komputer)*, vol. 12, no. 2, pp. 218–228, 2023.
- [9] M. N. Gunawan, T. Farhanah, S. U. Masruroh, A. M. Jundulloh, N. Z. Raushanfikar, and R. N. S. Amriza, “Accuracy of K-Nearest Neighbors Algorithm Classification For Archiving Research Publications,” *MATRIK J. Manajemen, Tek. Inform. dan Rekayasa Komput.*, vol. 23, no. 3, pp. 593–602, 2024, doi: 10.30812/matrik.v23i3.3915.
- [10] A. R. Salasa, “Paradigma dan Dimensi Strategi Ketahanan Pangan Indonesia,” *Jejaring Adm. Publik*, vol. 13, no. 1, pp. 35–48, 2021, doi: 10.20473/jap.v13i1.29357.
- [11] A. A. Amer, S. D. Ravana, and R. A. A. Habeeb, “Effective k-nearest neighbor models for data classification enhancement,” *J. Big Data*, vol. 12, no. 1, 2025, doi: 10.1186/s40537-025-01137-2.
- [12] bappeda.jogjapro., “Mengakhiri Kelaparan,” *Jogja Dataku*, pp. 20–33, 2020.
- [13] L. Cadavid, V. Arulnathan, and N. Pelletier, “Food Security and Food Sovereignty: A Review of Commonly Used Indicators and Consideration of Environmental Sustainability Aspects,” *Sustain.*, vol. 16, no. 24, 2024, doi: 10.3390/su162411034.