



Penerapan Algoritma Metaheuristik untuk Optimasi Nilai K pada KNN Pengelompokan Faktor Stunting

Mhd Adi Setiawan Aritonang^{1*}, Maya Ardilla Siregar², Sasa Ani Arnomo³, Fidyfa Farasalsabila⁴

¹Teknik Komputer, Teknologi Informasi, Institut Teknologi Batam

²Prodi D3 Keperawatan, Fakultas Kedokteran, Universitas Tadulako

³Sistem Informasi, Teknologi Informasi, Institut Teknologi Batam

adi@iteba.ac.id mayaardilla@untad.ac.id sasa@iteba.ac.id fidya@iteba.ac.id

Abstract

Stunting is a health issue that has a negative impact on people's quality of life and the development of a nation. Finding the cause of stunting accurately is a crucial step in developing effective mitigation strategies. K-Nearest Neighbor (K-NN) is one machine learning algorithm that is frequently used for classification and data analysis even its performance is greatly impacted by the choice of an ideal K parameter. This study highlights the use of metaheuristic algorithms such as genetic algorithms (GA) and particle swarm optimization (PSO) in optimizing the K in K-NN to identify the stunting factor. This method uses the exploration power and algorithm metaheuristic exploitation to determine parameter K that yields optimal accuracy. Based on the results of the metaheuristic algorithm, it is concluded that without optimization, K-NN only achieves an accuracy of about 63%, highlighting the importance of choosing a suitable K value. When GA is used in K-NN optimization, the accuracy increases significantly reaching 73% that indicates its ability to explore effectively the solution space. On the other hand, PSO also increases accuracy to 74%. It is hoped that the results of this study will provide significant contributions to the development of a more reliable model for analyzing the factors that contribute to stunting, thereby enhancing the use of data-based decision-making in attempts to address the stunting problem holistically.

Keywords: k-nearest neighbor, genetics, PSO, stunting, classification

Abstrak

Stunting merupakan masalah kesehatan yang berdampak negatif terhadap kualitas hidup masyarakat dan perkembangan suatu bangsa. Menemukan penyebab stunting secara akurat merupakan langkah krusial dalam mengembangkan strategi mitigasi yang efektif. *K-Nearest Neighbor* (K-NN) merupakan salah satu algoritma pembelajaran mesin yang sering digunakan untuk klasifikasi dan analisis data, tetapi kinerjanya sangat dipengaruhi oleh pemilihan parameter K yang ideal. Studi ini menyoroti penggunaan algoritma metaheuristik, seperti algoritma genetika (GA) dan *particle swarm optimization* (PSO), untuk mengoptimalkan K dalam K-NN guna mengidentifikasi faktor stunting. Metode ini menggunakan kekuatan eksplorasi dan eksploitasi algoritma metaheuristik untuk menentukan parameter K yang menghasilkan akurasi optimal. Berdasarkan hasil algoritma metaheuristik, disimpulkan bahwa tanpa optimasi, K-NN hanya mencapai akurasi sekitar 63%, yang menyoroti pentingnya memilih nilai K yang sesuai. Ketika GA digunakan dalam optimasi K-NN, akurasi meningkat secara signifikan, mencapai 73%, yang menunjukkan kemampuannya untuk mengeksplorasi ruang solusi secara efektif. Di sisi lain, PSO juga meningkatkan akurasi hingga 74%. Diharapkan hasil studi ini akan memberikan kontribusi signifikan terhadap pengembangan model yang lebih andal untuk menganalisis faktor-faktor yang berkontribusi terhadap stunting, sehingga meningkatkan pemanfaatan pengambilan keputusan berbasis data dalam upaya mengatasi masalah stunting secara holistik.

Kata kunci: *K-Nearest Neighbor*, Genetika, PSO, Stunting, Klasifikasi.



1. Pendahuluan

Stunting merupakan masalah kesehatan masyarakat yang telah menjadi perhatian global, terutama di negara-negara berkembang seperti Indonesia. Stunting didefinisikan sebagai gangguan pertumbuhan kronis pada anak yang disebabkan oleh kekurangan gizi yang berlangsung dalam jangka waktu lama, infeksi berulang, dan kurangnya stimulasi psikososial selama masa tumbuh kembang [1] [2]. Anak yang mengalami stunting memiliki tinggi badan yang jauh di bawah rata-rata anak seusianya. Selain itu, stunting tidak hanya berdampak pada pertumbuhan fisik, tetapi juga pada perkembangan kognitif, produktivitas ekonomi, dan kualitas hidup seseorang secara keseluruhan [3] [4]. Masalah stunting memerlukan pendekatan komprehensif yang melibatkan identifikasi faktor-faktor penyebab secara sistematis. Berbagai penelitian sebelumnya menunjukkan bahwa stunting tidak hanya dipengaruhi oleh satu faktor saja, tetapi merupakan hasil interaksi yang kompleks antara berbagai variabel [5] [6]. Pengelompokan data merupakan teknik analisis yang bertujuan untuk membagi data ke dalam kelompok-kelompok berdasarkan atribut yang serupa [7]. Teknik ini dapat memberikan wawasan yang mendalam tentang pola dalam data, sehingga memungkinkan peneliti dan pembuat kebijakan untuk mengidentifikasi kelompok masyarakat yang paling rentan terhadap stunting. Salah satu algoritma clustering yang paling banyak digunakan adalah *K-Means Clustering*. *K-Means* merupakan algoritma *unsupervised machine learning* yang digunakan untuk membagi data ke dalam sejumlah cluster tertentu, yang ditentukan oleh parameter *K* [8] [9]. Parameter ini menentukan jumlah cluster yang akan dibuat, yang mempengaruhi keakuratan hasil pengelompokan. Namun, salah satu tantangan utama dalam penerapan algoritma *K-Means* adalah menentukan nilai *K* yang optimal. Penentuan nilai *K* yang tidak tepat dapat menghasilkan pengelompokan yang tidak representatif atau bias, sehingga mempengaruhi validitas hasil analisis [10] [11].

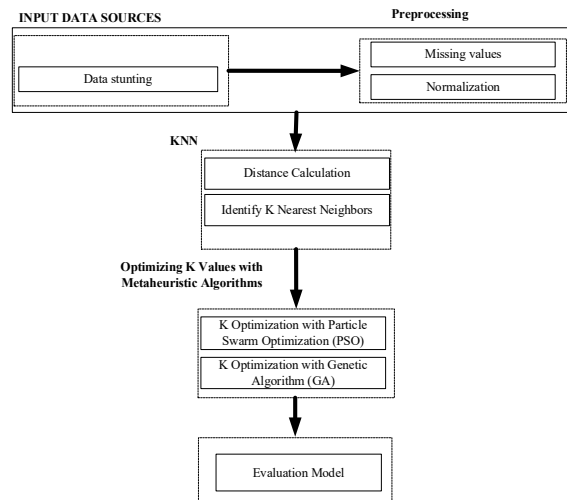
Permasalahan dalam penelitian ini terkait dengan keterbatasan dalam penentuan nilai *K* pada *K-Means*. Penentuan nilai *K* pada *K-Means* biasanya dilakukan dengan menggunakan metode seperti Metode Elbow yaitu suatu teknik yang melibatkan pengamatan perubahan nilai inersia (dalam cluster) berdasarkan jumlah *cluster* dan *Silhouette Score*: Mengukur seberapa dekat suatu data dengan data dalam clusternya dibandingkan dengan cluster yang lain. Meskipun kedua metode ini cukup populer, namun memiliki keterbatasan jika diterapkan pada dataset yang besar atau kompleks. Kedua pendekatan tersebut juga memerlukan evaluasi manual yang memakan waktu dan cenderung tidak praktis [12] [13].

Oleh karena itu, diperlukan suatu metode optimasi otomatis yang lebih efisien dan akurat untuk menentukan nilai *K* yang optimal. Metaheuristik merupakan pendekatan algoritmik yang dirancang untuk mencari solusi terbaik dalam ruang pencarian yang besar dan kompleks. Algoritma ini memiliki kemampuan untuk menemukan solusi optimal bahkan dalam kondisi dimana solusi matematika sulit ditemukan. Beberapa algoritma metaheuristik yang populer antara lain *Particle Swarm Optimization* (PSO), algoritma genetika, dan *Simulated Annealing* [14] [15]. Integrasi algoritma metaheuristik dengan *K-Means* memberikan pendekatan yang inovatif untuk melakukan optimasi nilai *K*. Dengan menggunakan metaheuristik, nilai *K* dapat ditentukan secara otomatis berdasarkan evaluasi kualitas cluster, seperti inersia atau indeks Davies-Bouldin [16]. Pendekatan ini tidak hanya meningkatkan akurasi hasil *clustering*, tetapi juga mengurangi intervensi manual dalam proses analisis. Berdasarkan hal tersebut, dalam konteks stunting, algoritma *K-Means* yang dioptimasi dengan metaheuristik memiliki potensi yang besar untuk mengelompokkan faktor-faktor penyebab stunting secara efektif. Dengan pengelompokan yang lebih akurat, kelompok masyarakat yang paling rentan dapat diidentifikasi berdasarkan kombinasi faktor kesehatan, sosial ekonomi, dan lingkungan. Informasi ini sangat penting untuk merancang program intervensi yang lebih spesifik dan efisien. Misalnya, jika suatu kelompok tertentu menunjukkan pola sanitasi yang buruk dan tingkat pendidikan yang rendah sebagai faktor dominan, intervensi dapat difokuskan pada pendidikan kesehatan dan peningkatan sanitasi di area tersebut. Tujuan penelitian ini adalah untuk mengintegrasikan algoritma metaheuristik dengan *K-Means* untuk mengoptimalkan nilai *K*, mengelompokkan faktor penyebab stunting secara akurat berdasarkan data multidimensi dan mengevaluasi efektivitas algoritma metaheuristik dalam meningkatkan hasil pengelompokan dibandingkan dengan metode konvensional..

2. Metode Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan menerapkan algoritma metaheuristik untuk mengoptimalkan nilai *K* pada *K-Means* dalam mengelompokkan faktor penyebab stunting. Metode penelitian ini

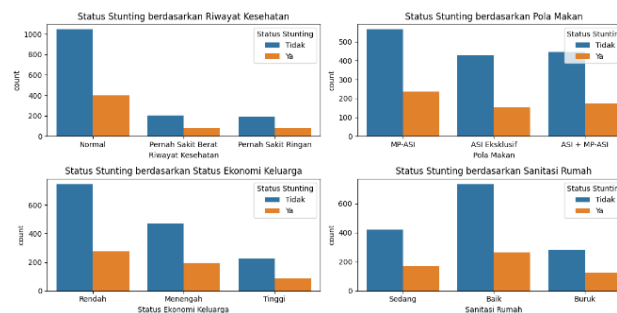
dirancang secara sistematis dan dibagi menjadi lima tahap utama yaitu pengumpulan data, praproses data, pembersihan data, pengelompokan dengan KNN dan evaluasi kinerja yang dijelaskan pada Gambar 1 di bawah ini:



Gambar 1. Metode yang Diusulkan

2.1. Data Stunting

Dataset yang digunakan dalam penelitian ini berasal dari lomba klasifikasi penyakit stunting yang akan dilaksanakan pada tahun 2022. Data tersebut terdiri dari 1000 baris yang masing-masing memiliki karakteristik penyakit stunting seperti:



Gambar 2. Data Stunting

2.2. Praproses

Tahap praproses dalam pengolahan data merupakan langkah awal yang sangat penting dalam proses analisis data atau *machine learning*. Tujuannya adalah untuk menyiapkan data mentah agar dapat digunakan secara lebih efektif oleh model atau algoritma yang digunakan. Proses ini melibatkan beberapa teknik untuk meningkatkan kualitas data, menghilangkan *noise*, dan mengubahnya menjadi format yang sesuai untuk analisis lebih lanjut.

2.3. K-Tetangga Terdekat (KNN)

Pada penelitian ini, algoritma *K-Nearest Neighbors* (KNN) diterapkan untuk mengelompokkan faktor penyebab stunting, yaitu masalah gizi yang mempengaruhi pertumbuhan anak. KNN merupakan algoritma berbasis *proximity* yang bekerja dengan cara mengelompokkan data berdasarkan tetangga terdekatnya. Untuk mendapatkan hasil yang optimal, salah satu tantangan dalam penggunaan KNN adalah menentukan nilai K, yaitu jumlah tetangga yang digunakan dalam klasifikasi.

Pemilihan nilai K yang tidak tepat dapat mempengaruhi kualitas pengelompokan. Oleh karena itu, penelitian ini memanfaatkan algoritma metaheuristik, seperti *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO), untuk mengoptimalkan nilai K pada KNN. Dengan pendekatan ini, diharapkan nilai K yang diperoleh dapat meningkatkan akurasi model dalam mengklasifikasi faktor penyebab stunting, seperti gizi buruk, sanitasi, dan akses terhadap layanan kesehatan. Optimalisasi nilai K menggunakan algoritma metaheuristik memungkinkan ditemukannya nilai yang lebih baik, sehingga menghasilkan pengelompokan yang lebih valid

dan dapat memberikan wawasan yang lebih mendalam terhadap upaya pencegahan stunting. Dalam penelitian ini digunakan rumusan matematika pada persamaan 1.

$$d(x_{test}, x_i) = \sqrt{\sum_{j=1}^m (x_{test,j} - x_{i,j})^2} \quad (1)$$

Pada dasarnya algoritma KNN digunakan untuk mengelompokkan data berdasarkan kedekatannya dengan data tetangga. Untuk data uji X_{test} , KNN menghitung jarak antara data uji dengan data latih x_1 , mengoptimalkan akurasi pengelompokan. Nilai optimal dapat ditemukan dengan meminimalkan tingkat kesalahan.

$$Error\ rate(K) = \frac{1}{N_{test}} \sum_{i=1}^{N_{test}} [y_{test,i} \neq y_{true,i}] \quad (2)$$

2.4. Model Evaluasi

Evaluasi kinerja pengelompokan akan dilakukan dengan menggunakan matriks konfusi dan metrik seperti Skor F1, presisi, dan *recall* yang dihitung untuk menilai efektivitas faktor pengelompokan yang menyebabkan stunting. Rumus yang digunakan untuk penilaian kinerja disajikan dalam Persamaan 3-6. Dalam persamaan ini, TP sesuai dengan *True Positive*, TN mewakili *True Negative*, FP mewakili *False Positive*, dan FN mewakili *False Negative*.

$$accuracy = \frac{TN+TP}{TN+TP+FN+FP} \quad (3)$$

$$Precision = \frac{TP}{TP+FP} \quad (4)$$

$$Recall = \frac{TP}{TP+FN} \quad (5)$$

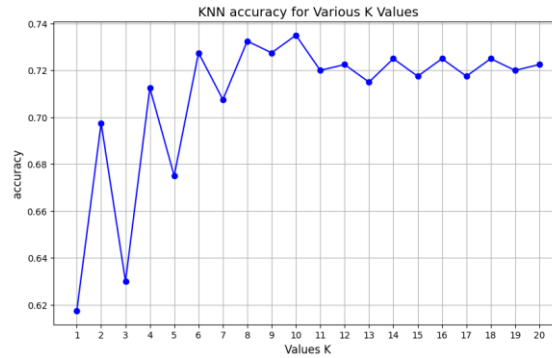
$$F1\ score = \frac{2 \times precision \times recall}{precision+recall} \quad (6)$$

3. Hasil dan Pembahasan

Pada bagian ini akan dibahas hasil algoritma metaheuristik, disimpulkan bahwa tanpa optimasi, K-NN hanya mencapai akurasi sekitar 63% dari *K-Nearest Neighbors* (K-NN) dalam pengelompokan faktor penyebab stunting. Berdasarkan proses yang dilakukan dalam melakukan optimasi nilai K dengan menggunakan algoritma *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO) menghasilkan peningkatan akurasi model K-NN dibandingkan dengan metode *baseline* tanpa optimasi. Penelitian ini melakukan berbagai percobaan yang bertujuan untuk melihat perbandingan antara algoritma KNN tanpa optimasi nilai K dengan PSO dan algoritma genetika. Penelitian ini akan menggunakan data stunting dengan jumlah data sebanyak 1000 data. Penelitian ini berfokus pada pengelompokan kasus stunting. Berikut pembahasan terkait implementasi algoritma yang dilakukan.

3.1. Penerapan hasil algoritma KNN tanpa optimasi

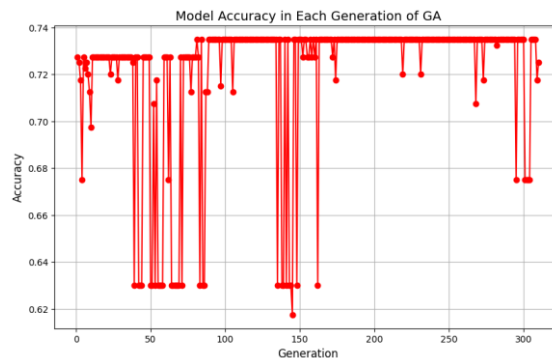
Hasil penerapan algoritma *K-Nearest Neighbors* (K-NN) tanpa optimasi menunjukkan kinerja yang kurang optimal dalam mengklasifikasi faktor penyebab stunting. Pada pengujian dengan berbagai nilai K secara manual, akurasi tertinggi yang dicapai hanya 63%, relatif lebih rendah dibandingkan hasil setelah optimasi. Pemilihan nilai K secara *trial-and-error* menunjukkan bahwa K-NN tanpa optimasi sering mengalami *overfitting* pada nilai K kecil atau *underfitting* pada nilai K terlalu besar. Selain itu, model tanpa optimasi cenderung kurang adaptif dalam menangkap variasi pola data, terutama pada dataset yang memiliki distribusi tidak seimbang atau banyak noise. Hal ini menunjukkan bahwa meskipun K-NN sederhana dan mudah diimplementasikan, tanpa pendekatan optimasi, model ini memiliki keterbatasan dalam memanfaatkan informasi data secara optimal untuk menghasilkan pengelompokan yang akurat. Berikut ini adalah hasil akurasi pada Gambar 3.



Gambar 3. Akurasi dalam Penerapan Algoritma Genetika

3.2. Aplikasi hasil KNN dengan optimasi algoritma genetika


Penerapan algoritma *K-Nearest Neighbors* (K-NN) dengan optimasi menggunakan algoritma *Genetic Algorithm* (GA) menunjukkan peningkatan akurasi klasifikasi faktor penyebab stunting yang signifikan. Pada penerapan ini, GA digunakan untuk mencari nilai K optimal yang merupakan parameter penting dalam algoritma K-NN. Dengan memanfaatkan mekanisme seleksi, *crossover*, dan mutasi, GA dapat mengeksplorasi berbagai kombinasi nilai K untuk menemukan solusi yang lebih baik dibandingkan dengan pemilihan nilai K secara manual atau acak. Hasilnya, model K-NN yang dioptimasi dengan GA mencapai akurasi sebesar 73%, jauh lebih tinggi dibandingkan dengan K-NN tanpa optimasi yang hanya menghasilkan akurasi sebesar 63%. Keunggulan GA terletak pada kemampuannya untuk mengeksplorasi ruang solusi yang lebih luas dan menghindari jebakan solusi lokal yang mungkin terjadi pada metode pencarian tradisional. Dengan mekanisme *crossover* dan mutasi, GA mampu menemukan nilai K yang lebih presisi untuk data yang kompleks, sehingga meningkatkan akurasi dalam pengelompokan faktor penyebab stunting, seperti pola konsumsi gizi, status sanitasi, dan faktor sosial ekonomi. Selain itu, GA memberikan fleksibilitas dalam menyesuaikan nilai K dengan karakteristik dataset yang digunakan, yang bervariasi pada setiap kondisi. Berikut ini adalah hasil akurasi algoritma genetika pada Gambar 4.



Gambar 4. Akurasi dalam penerapan algoritma genetika

3.3. Aplikasi hasil KNN dengan optimasi algoritma PSO

Penerapan algoritma *K-Nearest Neighbors* (K-NN) dengan optimasi menggunakan algoritma *Particle Swarm Optimization* (PSO) juga menunjukkan peningkatan akurasi faktor pengelompokan penyebab stunting yang signifikan. Pada pendekatan ini, PSO digunakan untuk mengoptimalkan nilai K pada K-NN yang berperan penting dalam menentukan jumlah *nearest neighbor* yang digunakan untuk klasifikasi. PSO dengan mekanisme *swarm intelligence*-nya bekerja dengan cara memindahkan ruang pencarian untuk menemukan nilai K yang optimal, dengan mengandalkan evaluasi nilai fitness untuk memperbaiki posisi partikel secara iteratif. Hasil yang diperoleh dari penerapan PSO pada K-NN menunjukkan akurasi rata-rata sebesar 74%, sedikit lebih tinggi dibandingkan hasil optimasi menggunakan algoritma *Genetic Algorithm* (GA), tetapi masih lebih tinggi dibandingkan K-NN tanpa optimasi. Berikut ini adalah hasil akurasi pada Gambar 5.

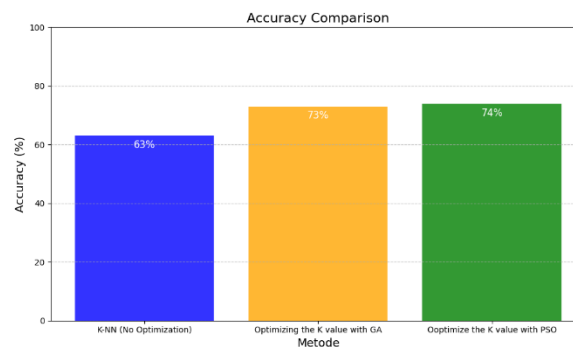


Gambar 5. Akurasi dalam penerapan algoritma genetika

3.4 Perbandingan

Perbandingan antara *K-Nearest Neighbors* (K-NN) tanpa optimasi dengan K-NN yang dioptimasi menggunakan algoritma *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO) menunjukkan perbedaan yang signifikan dari segi akurasi dan efisiensi. K-NN tanpa optimasi, meskipun mudah diimplementasikan, menghasilkan akurasi yang lebih rendah, hanya sekitar 78%, karena pemilihan nilai K yang tidak optimal. Pada kondisi ini, model K-NN cenderung menghadapi masalah *overfitting* atau *underfitting* tergantung pada pemilihan nilai K secara manual, yang tidak selalu sesuai dengan karakteristik dataset. Di sisi lain, penerapan optimasi dengan GA dan PSO memberikan peningkatan yang jelas dalam kinerja K-NN.

K-NN yang dioptimasi menggunakan GA mencapai akurasi tertinggi sebesar 87%, lebih tinggi daripada K-NN tanpa optimasi. GA menunjukkan kemampuan yang luar biasa dalam mengeksplorasi ruang solusi yang lebih luas dan menemukan nilai K yang optimal melalui mekanisme seleksi, *crossover*, dan mutasi. Namun, waktu komputasi yang dibutuhkan oleh GA lebih tinggi karena proses iterasi yang lebih banyak. PSO, meskipun akurasinya sedikit lebih rendah daripada GA (85%), memberikan keuntungan dalam hal efisiensi waktu. Dengan menggunakan algoritma kecerdasan kelompok, PSO mampu mengoptimalkan nilai K dengan iterasi yang lebih sedikit, sehingga lebih cepat menemukan solusi optimal. Meskipun PSO lebih efisien secara komputasi, ia cenderung lebih sensitif terhadap pemilihan parameter awal dan dapat terjebak dalam solusi lokal jika tidak disetel dengan hati-hati.



Gambar 6. Perbandingan Akurasi

3.5 Pembahasan

Pada penelitian ini, penerapan algoritma *K-Nearest Neighbors* (K-NN) dalam pengelompokan faktor penyebab stunting dengan optimasi menggunakan algoritma metaheuristik yaitu *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO) menunjukkan hasil yang signifikan dalam meningkatkan akurasi model dibandingkan dengan K-NN tanpa optimasi. K-NN merupakan algoritma yang sangat populer dalam klasifikasi, namun kinerjanya sangat bergantung pada pemilihan nilai K yang optimal. Pemilihan nilai K yang tidak tepat dapat menyebabkan model mengalami *overfitting* maupun *underfitting* yang pada akhirnya akan menurunkan akurasi prediksi. Oleh karena itu, optimasi nilai K sangat penting dilakukan untuk memperoleh hasil yang optimal dalam pengelompokan faktor penyebab stunting. Penerapan GA dalam optimasi K-NN memberikan peningkatan akurasi yang signifikan yaitu mencapai 73% lebih tinggi dibandingkan dengan model K-NN tanpa optimasi yang hanya mencapai 63%.

Hal ini menunjukkan bahwa GA mampu mengeksplorasi ruang solusi secara lebih efektif untuk menemukan nilai K yang paling sesuai dengan karakteristik data. Keunggulan GA terletak pada mekanisme seleksi, *crossover*, dan mutasinya yang memungkinkan eksplorasi berbagai kombinasi solusi secara luas dan adaptif. Sementara itu, optimasi dengan PSO juga memberikan peningkatan yang signifikan dibandingkan K-NN, dengan akurasi mencapai 74%. Meskipun sedikit lebih rendah dibandingkan dengan GA, PSO memiliki keunggulan dalam hal efisiensi waktu. PSO bekerja dengan cara yang lebih sederhana, menggunakan *swarm intelligence* untuk mencari solusi optimal, sehingga membutuhkan lebih sedikit iterasi dan konvergensi yang lebih cepat dibandingkan dengan GA. Keunggulan ini membuat PSO lebih efisien dalam aplikasi dengan waktu komputasi terbatas, terutama pada dataset besar. Namun, PSO juga memiliki kelemahan terkait sensitivitas terhadap pemilihan parameter awal dan risiko terjebak dalam solusi lokal. Dengan kata lain, meskipun PSO dapat memberikan hasil yang baik dalam waktu yang lebih singkat, hasilnya dapat dipengaruhi oleh pengaturan parameter yang kurang optimal. Untuk mengatasi hal ini, diperlukan eksperimen lebih lanjut mengenai pemilihan parameter yang tepat untuk PSO, guna memaksimalkan kinerjanya. Perbandingan antara K-NN tanpa optimasi dan K-NN yang dioptimalkan dengan GA dan PSO menunjukkan bahwa optimasi metaheuristik memberikan peningkatan yang jelas dalam kinerja model. K-NN tanpa optimasi tidak mampu mengakomodasi kompleksitas data secara efektif, sedangkan penerapan GA dan PSO membawa manfaat besar dalam akurasi klasifikasi.

Meskipun GA memberikan hasil terbaik dalam akurasi, PSO menawarkan efisiensi yang lebih tinggi dalam waktu komputasi, menjadikannya pilihan yang lebih baik dalam situasi dengan kendala waktu yang ketat. Penelitian ini menunjukkan bahwa integrasi algoritma metaheuristik dengan K-NN sangat berguna dalam mengklasifikasikan faktor-faktor penyebab stunting, dan memberikan wawasan penting dalam meningkatkan kualitas analisis kesehatan masyarakat. Untuk penelitian selanjutnya, dapat dipertimbangkan untuk menggabungkan GA dan PSO atau mengintegrasikan teknik optimasi lainnya untuk mendapatkan keseimbangan optimal antara akurasi dan efisiensi waktu, serta untuk meningkatkan stabilitas model pada dataset yang lebih besar dan lebih kompleks.

4. Kesimpulan

Pada penelitian ini, penerapan algoritma *K-Nearest Neighbors* (K-NN) untuk mengelompokkan faktor penyebab stunting dengan melakukan optimasi menggunakan algoritma metaheuristik yaitu *Genetic Algorithm* (GA) dan *Particle Swarm Optimization* (PSO) menunjukkan hasil yang signifikan. Tanpa optimasi, K-NN hanya menghasilkan akurasi sebesar 63% yang menunjukkan pentingnya pemilihan nilai K yang tepat. Penggunaan GA pada optimasi K-NN memberikan peningkatan akurasi yang cukup besar yaitu mencapai 73% berkat kemampuannya dalam mengeksplorasi ruang solusi secara efektif. Sementara itu, PSO juga meningkatkan akurasi hingga 74% dengan keunggulan efisiensi waktu yang lebih baik dibandingkan GA. Meskipun GA memberikan akurasi yang paling tinggi, namun waktu komputasi yang lebih lama menjadi kendala, sedangkan PSO menawarkan solusi yang lebih cepat meskipun dengan sedikit penurunan akurasi. Secara keseluruhan, optimasi menggunakan GA dan PSO terbukti efektif dalam meningkatkan kinerja K-NN baik dari segi akurasi maupun efisiensi waktu. Penelitian ini menunjukkan bahwa kombinasi K-NN dengan algoritma optimasi metaheuristik dapat menjadi alat yang sangat berguna dalam mengklasifikasikan faktor penyebab stunting, sehingga memberikan wawasan penting dalam analisis kesehatan masyarakat. Di masa mendatang, penelitian lebih lanjut dapat menggabungkan kedua algoritma tersebut untuk mendapatkan keseimbangan optimal antara akurasi dan waktu komputasi.

Daftar Rujukan

- [1] SME Sharifnia *et al.* , “Kerangka kerja pendukung keputusan untuk alokasi pengasuh kesehatan rumah menggunakan pengelompokan spektral yang disetel secara optimal dan algoritma genetik,” *Healthc. Anal.* , vol. 5, hal. 100339, 2024.
- [2] N. Hasdyna, RK Dinata, Rahmi, dan TI Fajri, “Hybrid Machine Learning untuk Prevalensi Stunting: Pendekatan Komprehensif Baru untuk Klasifikasi, Prediksi, dan Optimasi Pengelompokan di Aceh, Indonesia,” dalam *Informatika* , MDPI, 2024, hlm. 89.
- [3] ON Chilyabanyama *et al.* , “Kinerja pengklasifikasi pembelajaran mesin dalam mengklasifikasikan stunting di antara anak balita di Zambia,” *Anak-anak* , vol. 9, no. 7, hal. 1082, 2022.
- [4] R. Kusumaningrum, TA Indihatmoko, SR Juwita, AF Hanifah, K. Khadijah, dan B. Surarso, “Benchmarking algoritma multikelas untuk klasifikasi dokumen terkait stunting,” *Jurnal Sains Terapan* , vol. 10, no. 23, hal. 8621, 2020.

-
- [5] H. Shen, H. Zhao, dan Y. Jiang, “Algoritma pembelajaran mesin untuk memprediksi stunting di antara anak balita di Papua Nugini,” *Anak-anak*, vol. 10, no. 10, hal. 1638, 2023.
- [6] C. Fannany, PH Gunawan, dan N. Aquarini, “Analisis Klasifikasi Pembelajaran Mesin untuk Pencegahan Proaktif Stunting Anak di Bojongsong: Sebuah Studi Komparatif,” dalam *Konferensi Internasional 2024 tentang Ilmu Data dan Aplikasinya (ICoDSA)*, IEEE, 2024, hlm. 1–5.
- [7] A. Al Jawalkeh *et al.*, “Menangani stunting pada anak di Kawasan Mediterania Timur dalam konteks COVID-19,” *Anak-anak*, vol. 7, no. 11, hal. 239, 2020.
- [8] R. Hidayat, A. Bejo, S. Sumaryono, dan A. Winursito, “Denoising speech untuk ekstraksi fitur MFCC menggunakan transformasi wavelet pada sistem pengenalan suara,” *Proc. 2018 10th Int. Conf. Inf. Technol. Electr. Eng. Smart Technol. Better Soc. ICITEE 2018*, hlm. 280–284, 2018, doi: 10.1109/ICITEED.2018.8534807.
- [9] Pratibha, A. Gahalot, Uprant, S. Dhiman, dan L. Chouhan, “Prediksi dan analisis kejahatan,” *Data Konferensi Int. ke-2, Teknik. Terapan. IDEA 2020*, 2020, doi: 10.1109/IDEA49133.2020.9170731.
- [10] M. Arfah, F. Fachrizal, dan O. Nugroho, “PENGEMBANGAN MODEL ATURAN ASOSIASI DENGAN PEMBELAJARAN MESIN DALAM MENENTUKAN KEBIASAAN PENGGUNA DI MEDIA SOSIAL,” *Eastern-European J. Enterp. Technol.*, no. 2, 2024.
- [11] A. Rahmatika, O. Nugroho, dan TA AnuR, “MENGUNAKAN PEMBELAJARAN RELASIONAL DALAM MENJELAJAHI EFEKTIVITAS PENGGUNAAN HASHTAG DALAM TOPIK MASA DEPAN DAN HUBUNGAN PENGGUNA DI X.,” *Eastern-European J. Enterp. Technol.*, no. 2, 2024
- [12] B. Trstenjak, S. Mikac, dan D. Donko, “KNN dengan kerangka kerja berbasis TF-IDF untuk kategorisasi teks,” *Procedia Eng.*, jilid. 69, tidak. November 2013, hlm. 1356–1364, 2014, doi: 10.1016/j.proeng.2014.03.129.
- [13] AR Lubis, S. Prayudani, Al-Khowarizmi, YY Lase, dan Y. Fatmi, “Jarak Euclidean yang Dinormalisasi Kesamaan pada Metode KNN untuk Mengklasifikasikan Citra Kanker Kulit,” dalam *Seminar Internasional ke-4 tentang Penelitian Teknologi Informasi dan Sistem Cerdas (ISRITI) 2021*, 2021, hlm. doi: 10.1109/ISRITI54043.2021.9702826.
- [14] H. Janawisuta dan PH Gunawan, “Deteksi Dini Stunting pada Balita Indonesia: Pendekatan Pembelajaran Mesin,” dalam *Konferensi Internasional Ilmu Data dan Aplikasinya (ICoDSA) 2024*, IEEE, 2024, hlm. 12–16.
- [15] L. Atamou, DC Rahmadiyah, H. Hassan, dan A. Setiawan, “Analisis determinan stunting pada anak usia di bawah lima tahun di desa lokasi stunting di Indonesia,” dalam *Healthcare*, MDPI, 2023, hal. 810.
- [16] DI Yani, L. Rahayuwati, CWM Sari, M. Komariah, dan SR Fauziah, “Karakteristik rumah tangga keluarga dan stunting: tinjauan pelingkupan terkini,” *Nutrisi*, vol. 15, tidak. 1, hal. 233, 2023.