

Optimisasi Menu Balita Berdasarkan Gizi Harian Menggunakan XGBoost, Genetic Algorithm dan Particle Swarm Optimization

Evyra Rizki Safitri*, Ahmad Muklason

Fakultas Teknologi Elektro dan Informatika Cerdas, Program Studi Sistem Informasi, Institut Teknologi Sepuluh Nopember, Surabaya, Indonesia

Email: ¹*6016241001@student.its.ac.id, ²mukhlason@is.its.ac.id

Email Penulis Korespondensi: 6016241001@student.its.ac.id

Submitted: 02/06/2026; Accepted: 30/06/2026; Published: 30/06/2026

Abstrak—Perencanaan menu balita memerlukan pendekatan yang sistematis karena rekomendasi menu harus mempertimbangkan kecukupan gizi, status gizi anak, pembatasan alergi, dan kombinasi menu yang layak. Penelitian ini mengembangkan alur kerja sistem pendukung keputusan yang peka terhadap alergi dengan mengintegrasikan klasifikasi *XGBoost* bersama *Genetic Algorithm* dan *Particle Swarm Optimization* untuk optimasi menu harian balita. Pendekatan ini dipilih karena metode konvensional yang langsung menggunakan target AKG populasi cenderung belum menangkap perbedaan kebutuhan anak berdasarkan kondisi gizinya dan belum memasukkan alergi makanan sebagai pembatas dalam penyusunan menu. Gabungan *XGBoost* dan metaheuristik ini memiliki kombinasi yang mampu memetakan pola non-linier dari kondisi fisik balita secara instan dan mampu menjelajahi jutaan kombinasi bahan pangan kompleks secara efisien, yang tidak dapat diselesaikan secara komputasional oleh metode manual konvensional. Dalam alur ini, *XGBoost* digunakan untuk memprediksi kelas menu (catch-up nutrition, balanced nutrition, atau energy control) dipetakan ke target gizi personal berbasis AKG dalam bentuk vektor energi, proteion, lemak, dan karbohidrat. Vektor target ini kemudian jadi masukan utama fungsi fitness sekaligus dasar penyaringan kandidat menu sebelum proses optimasi dijalankan. Model *XGBoost* menghasilkan rata-rata akurasi 96,4% dan *weighted F1-score* 96,38% pada pengujian validasi silang, serta akurasi 87,18% pada pengujian *hold-out*. Pada enam kategori eksperimen, GA dan PSO sama-sama mampu menghasilkan menu yang mendekati target gizi dengan nilai *RDI score* umumnya berada pada kisaran 94,6%-99,7%. GA mencapai tingkat deviasi nutrisi yang lebih rendah pada skenario catch-up dan gizi seimbang, sedangkan PSO berkinerja lebih baik pada skenario kontrol energi dan secara konsisten membutuhkan waktu komputasi yang jauh lebih efisien (rata-rata 17,74 detik dibandingkan 79,78 detik pada GA). Hasil ini menunjukkan bahwa GA lebih sesuai ketika presisi nutrisi diprioritaskan, sedangkan PSO lebih sesuai untuk implementasi sistem dengan batasan waktu nyata. Kontribusi utama penelitian ini adalah terciptanya kerangka kerja komputasional yang utuh dan adaptif terhadap kondisi klinis dan keamanan alergi balita, serta penyediaan bukti empiris terkait pemilihan algoritma metaheuristik untuk sistem rekomendasi nutrisi terpersonalisasi.

Kata Kunci: Balita; Optimasi Menu; *XGBoost*; Genetic Algorithm; Particle Swarm Optimization

Abstract—Toddler menu planning requires a systematic approach, as menu recommendations must account for nutritional adequacy, the child's nutritional status, allergy restrictions, and feasible menu combinations. This study develops an allergy-aware decision-support workflow by integrating *XGBoost* as a menu-class classifier and Genetic Algorithm and Particle Swarm Optimization for daily toddler menu optimization. This approach is chosen because conventional methods that directly apply population-level dietary references values do not adequately capture individual differences in nutritional status and usually do not treat food allergy as a hard constraint during menu generation. Combined of *XGBoost* and metaheuristics have instantly map non-linear patterns of a toddler's physical condition while efficiently exploring millions of complex food combinations a task computationally unachievable by conventional manual methods. In the proposed workflow, the *XGBoost* output in the form of menu class (catch-up nutrition, balanced nutrition, or energy control) is mapped into personalized nutrient targets for energy, protein, fat, and carbohydrates. These targets become the main inputs to the fitness function and guide the allergy-safe candidate filtering step before optimization. The *XGBoost* model achieved an average accuracy of 96,4% and a weighted F1-score of 96,38% in cross-validation testing, along with an 87,18% accuracy in the hold-out test. Across six experimental categories, both GA and PSO successfully generated menus closely matching the nutritional targets, with RDI scores generally ranging from 94,6% to 99,7%. GA achieved lower nutritional deviation in the catch-up and balanced nutrition scenarios, whereas PSO performed better in energy-control scenarios and consistently required significantly less computation time (averaging 17,74 seconds compared to 79,78 seconds for GA). These findings indicate that GA is preferable when nutritional precision is prioritized, whereas PSO is more suitable for real-time, time-constrained system deployments. The main contributions of this study are the creation of an end-to-end computational framework that adapts to clinical conditions and toddler allergy safe, and the provision of empirical evidence for selecting metaheuristic algorithm for personalized nutrition recommendation systems.

Keywords: Toddler; Menu Optimization; *XGBoost*; Genetic Algorithm; Particle Swarm Optimization

1. PENDAHULUAN

Pemenuhan nutrisi pada masa balita menjadi hal penting yang menentukan pertumbuhan fisik, perkembangan kognitif, fungsi imun, dan kualitas kesehatan jangka panjang. Pada periode ini, anak membutuhkan asupan energi dan zat gizi makro yang cukup, seimbang, serta sesuai dengan kondisi status gizinya [1]. Apabila kebutuhan gizi tidak terpenuhi secara memadai, maka balita berisiko mengalami gangguan pertumbuhan dan perkembangan. Dalam konteks Indonesia, persoalan gizi balita masih menjadi isu yang signifikan, terutama karena *stunting* masih berada pada tingkat yang memerlukan perhatian serius. Artikel *toddler* yang menjadi dasar penelitian ini menegaskan bahwa prevalensi *stunting* nasional mencapai 21,5% pada tahun 2023 dan menurun menjadi 19,8% pada tahun 2024, dengan target pemerintah sebesar 14,2% pada tahun 2029 [2]. Meskipun terjadi penurunan, kondisi tersebut tetap menunjukkan

bahwa masalah gizi balita belum sepenuhnya teratasi dan memerlukan pendekatan intervensi yang lebih adaptif, terarah, dan aplikatif dalam kehidupan sehari-hari [3].

Di Indonesia, penilaian kebutuhan gizi balita umumnya merujuk pada indikator antropometri dan *Angka Kecukupan Gizi* (AKG) [4]. Indikator seperti berat badan menurut tinggi badan atau berat badan menurut panjang badan dapat digunakan untuk menilai kondisi gizi, sedangkan AKG menyediakan acuan kebutuhan zat gizi harian berdasarkan umur dan jenis kelamin. Namun, acuan tersebut belum otomatis dapat diterjemahkan menjadi pilihan menu harian yang praktis. Orang tua atau pengasuh mungkin memahami bahwa anak membutuhkan pola makan bergizi seimbang, tetapi mereka masih menghadapi kesulitan saat harus memilih kombinasi bahan makanan yang sekaligus memenuhi target energi, protein, lemak, dan karbohidrat. Kesulitan ini menjadi semakin kompleks ketika anak memiliki alergi makanan tertentu, karena ruang pilihan bahan pangan menjadi lebih terbatas. Oleh karena itu, diperlukan sistem yang tidak hanya mampu menilai kondisi gizi anak, tetapi juga dapat mengubah hasil penilaian tersebut menjadi rekomendasi menu yang aman dan mendekati kebutuhan gizi personal [5].

Perkembangan penelitian pada bidang gizi dan komputasi menunjukkan bahwa masalah rekomendasi makanan dapat didekati melalui berbagai metode. Dalam upaya menyelesaikan permasalahan nutrisi melalui komputasi, berbagai pendekatan telah dikembangkan. Wulandari dan Baizal membangun sistem rekomendasi makanan menggunakan pendekatan *ontology-based food recommender system*. Sistem ini bekerja dengan membangun model representasi pengetahuan (semantik) yang memetakan relasi antara bahan makanan, kandungan gizi, dan profil pengguna, untuk kemudian merekomendasikan menu yang sesuai dengan kebutuhan kalori harian. Meskipun sistem ini mampu memberikan rekomendasi menu, pendekatan ontologi cenderung bersifat kaku dan tidak mengeksekusi optimisasi matematis untuk mencari presisi gramasi porsi. Selain itu, sistem ini menargetkan anak usia sekolah dengan target gizi yang homogen, serta belum mengintegrasikan variabel pembatas klinis seperti alergi makanan yang sangat krusial bagi balita [6].

Pada area klasifikasi status gizi, As dan Subhiyakto mengimplementasikan pemodelan *Machine Learning* untuk mendeteksi stunting pada anak. Penelitian tersebut bekerja dengan mengekstraksi data antropometri dasar seperti usia, berat badan, dan tinggi badan sebagai fitur masukan, lalu melatihnya menggunakan algoritma ansambel yang dikombinasikan dengan teknik SMOTE untuk menangani ketidakseimbangan kelas data. Sistem tersebut tidak memiliki modul preskriptif lanjutan yang mampu menerjemahkan hasil klasifikasi *stunting* tersebut menjadi rancangan intervensi berupa jadwal atau kombinasi menu makan yang dapat diterapkan langsung oleh orang tua [7].

Dari sisi optimisasi penyusunan menu, Rad dan Amiri mengembangkan pendekatan *personalized meal planning* menggunakan algoritma *Particle Swarm Optimization* (PSO). Proses kerja sistem ini adalah menginisialisasi kandidat makanan sebagai partikel yang beterbangan dalam ruang solusi multi-dimensi, kemudian mengevaluasinya melalui fungsi kebugaran (*fitness*) secara iteratif hingga partikel konvergen pada kombinasi menu yang paling mendekati target nutrisi harian pengguna. Namun, penelitian ini dikembangkan untuk populasi pengguna dewasa, di mana target kebutuhan gizinya bersifat statis. Selain itu, formulasi ruang pencariannya tidak memperhitungkan *hard constraint* terkait keamanan pangan, seperti penyaringan alergen secara absolut sebelum proses iterasi berjalan. [8].

Lebih spesifik pada komparasi algoritma diet, Kurnianingtyas dkk. membandingkan performa GA dan PSO untuk menyusun rekomendasi menu maternal (ibu hamil). Sistem ini bekerja dengan mengkodekan basis data bahan makanan ke dalam bentuk kromosom (pada GA) dan posisi partikel (pada PSO), lalu menjalankan operator evolusioner dan pergerakan swarm untuk mencari deviasi gizi paling minimal terhadap target gizi kehamilan. Meskipun studi ini memberikan wawasan mendalam terkait perbandingan efisiensi GA dan PSO, sistem ini mengasumsikan bahwa setiap ibu hamil pada usia kandungan yang sama memiliki target gizi yang persis sama. Penelitian tersebut belum mengintegrasikan model klasifikasi prediktif (*front-end classifier*) yang dapat secara dinamis mendeteksi profil medis pengguna dan mempersonalisasi target kalori secara individual sebelum diserahkan ke mesin optimisasi [9].

Berdasarkan penelitian terdahulu, terdapat kesenjangan penelitian yang mendasar. Belum ada penelitian yang menggabungkan kemampuan diagnostik algoritma *Machine Learning* dengan ketangguhan preskriptif algoritma metaheuristik dalam satu alur kerja yang berkesinambungan. Sebagian penelitian terdahulu menggunakan target nutrisi yang seragam untuk semua individu dalam kelompok umur tertentu, padahal kebutuhan menu anak dapat berbeda tergantung pada kondisi gizinya [10]. Selain itu, formulasi target gizi yang benar-benar adaptif dan terpersonalisasi secara individual bagi balita dengan penyaringan ketat terhadap alergi makanan sebagai pembatas mutlak (*hard constraint*) belum pernah dikomparasikan performanya secara langsung menggunakan GA dan PSO.

Berdasarkan permasalahan dan kesenjangan tersebut, penelitian ini bertujuan membangun kerangka rekomendasi menu balita yang peka alergi (*allergy-aware*) dengan mengintegrasikan klasifikasi kelas menu menggunakan XGBoost dan optimisasi menu menggunakan GA serta PSO. Secara khusus, penelitian ini bertujuan memprediksi kelas menu balita menggunakan XGBoost, memetakan hasil prediksi ke target gizi personal berbasis Angka Kecukupan Gizi (AKG), menyusun kombinasi menu harian menggunakan algoritma optimisasi, lalu membandingkan performa GA dan PSO dari aspek *RDI Score*, deviasi nutrisi, dan waktu komputasi.


Berdasarkan permasalahan dan *gap* tersebut, penelitian ini bertujuan menciptakan arsitektur sistem pendukung keputusan yang utuh (*end-to-end*), di mana tebakan kelas gizi dari XGBoost secara dinamis menentukan ambang batas pencarian bagi algoritma PSO dan GA. Selain itu, penelitian ini berkontribusi dalam membuktikan secara empiris bahwa integrasi filter alergen sebagai batasan ruang pencarian dapat menjamin keamanan menu balita tanpa

mengorbankan kualitas presisi pencapaian gizi, sekaligus menghasilkan rekomendasi teknis mengenai algoritma mana yang paling siap diimplementasikan untuk kebutuhan komputasi waktu nyata (*real-time*).

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan desain berbasis sistem pendukung keputusan. Alur penelitian dimulai dari pengumpulan dan pembersihan data, dilanjutkan dengan pembentukan label kelas menu berbasis AKG, serta optimasi menu menggunakan GA dan PSO. Setelah kedua algoritma dibandingkan, algoritma yang paling sesuai dipilih sebagai basis implementasi aplikasi rekomendasi balita



Gambar 1. Alur Penelitian

2.2 Pengumpulan Data

Penggunaan dua jenis data, dataset profil balita dari Posyandu Soko yang berisi identitas anak, tanggal lahir, pengukuran berat badan dan tinggi badan, serta jenis alergi makanan. Sumber kedua adalah TKPI 2017 yang memuat komposisi pangan, referensi AKG, dan lembar indeks kategori bahan makanan [11]. Dalam implementasi, data TKPI dibaca dari tiga sheet, yaitu Komposisi Pangan per 100g BDD, AKG fix, dan Indeks. Masing-masing sheet memiliki peran yang berbeda: sheet komposisi pangan menyediakan kandungan zat gizi per 100 gram bagian yang dapat dimakan, sheet AKG fix menyediakan kebutuhan gizi berdasarkan kelompok umur, dan sheet indeks mendukung pengelompokan bahan makanan untuk optimasi menu. Karakteristik dataset dapat dilihat di Tabel 1. Karakteristik Dataset.

Tabel 1. Karakteristik Dataset

Atribut	Deskripsi
Dataset balita	242 anak
Fitur	Usia (bulan), berat badan (kg), tinggi badan (cm), BMI, dan indikator alergi makanan
Target	Kelas menu (KM = 0: Catch-Up, KM = 1: Balanced, KM = 2: Energy Control)
Basis data pangan	TKPI 2017 – 1.146 item pangan, 5 kelompok menu (makanan pokok, lauk hewani, lauk nabati, sayur, buah)
Referensi gizi	AKG Permenkes No. 28 Tahun 2019 berdasarkan kelompok umur 0–5 bulan, 6–11 bulan, 1–3 tahun, dan 4–6 tahun

Sebagaimana ditunjukkan pada Tabel 1. Karakteristik Dataset, dataset balita menyediakan data antropometri dan alergi untuk pembentukan kelas menu, sedangkan TKPI menyediakan kandidat bahan makanan dan kandungan gizinya. Struktur ini memungkinkan proses klasifikasi dan optimasi dilakukan secara terintegrasi.

2.3. Preprocessing Data

Preprocessing data balita dilakukan dalam beberapa tahap berurutan. Pertama, nilai tanggal lahir diparsing ke format *datetime* dan data dengan tanggal tidak valid dihapus. Kedua, umur dihitung dalam satuan bulan berdasarkan selisih antara tanggal lahir dan tanggal referensi/pengukuran, kemudian dibatasi hingga 60 bulan agar tetap sesuai definisi usia balita. Ketiga, berat badan dan tinggi badan dikonversi ke bentuk numerik dan hanya pengukuran yang valid pada rentang usia balita yang dipertahankan [12]. Keempat, indeks massa tubuh (BMI) dihitung dari berat badan dan tinggi

badan yang telah dibersihkan [13]. Kelima, atribut alergi dinormalisasi menjadi label huruf kecil dan ditransformasikan ke indikator biner untuk alergen umum, yaitu telur, susu, kedelai, kacang, ikan, dan udang [14].

Pada basis data TKPI, *preprocessing* meliputi standarisasi nama kolom, konversi nilai numerik yang semula terbaca sebagai nilai tanggal akibat format Excel, penggabungan data komposisi pangan dengan data indeks kategori, dan penyaringan item pangan ke dalam lima kelompok menu wajib. Hanya item dengan data energi, protein, lemak, dan karbohidrat yang lengkap yang dipertahankan agar kualitas evaluasi gizi tetap terjaga.

2.4. Pelabelan Z-score

Label status gizi dibentuk menggunakan standar pertumbuhan anak WHO 2006 melalui *library pygrowingup* yang menerapkan metode Lambda-Mu-Sigma (LMS) [15]. Tiga indeks antropometri dihitung untuk setiap data anak, yaitu berat badan menurut umur (BB/U), tinggi badan menurut umur (TB/U), dan berat badan menurut panjang/tinggi badan (BB/TB). Untuk anak di bawah 24 bulan digunakan panjang badan terlentang, sedangkan pada anak usia 24 bulan ke atas digunakan tinggi badan berdiri sesuai Permenkes No. 2 Tahun 2020 [5]. Dalam penelitian ini, indikator utama yang dipakai untuk penentuan menu adalah *z-score* BB/TB karena paling merefleksikan kondisi gizi akut yang relevan dengan intervensi diet.

Tabel 2. Klasifikasi status gizi dan kelas menu

Rentang Z-score	Status gizi	Kelas menu
$Z < -3 \text{ SD}$	Gizi buruk	KM = 0 (Catch-Up Nutrition)
$-3 \text{ SD} \leq Z < -2 \text{ SD}$	Gizi kurang	KM = 0 (Catch-Up Nutrition)
$-2 \text{ SD} \leq Z \leq +1 \text{ SD}$	Normal	KM = 1 (Balanced)
$+1 \text{ SD} < Z \leq +2 \text{ SD}$	Berisiko gizi lebih	KM = 2 (Energy Control)
$+2 \text{ SD} < Z \leq +3 \text{ SD}$	Gizi lebih	KM = 2 (Energy Control)
$Z > +3 \text{ SD}$	Obesitas	KM = 2 (Energy Control)

Tabel 2 menunjukkan bahwa kelas menu dibentuk langsung dari indikator BB/TB. Pendekatan ini menggantikan pelabelan sederhana berbasis kuantil BMI yang kurang bermakna secara klinis. Dengan demikian, variabel target pada model *XGBoost* adalah kelas menu (KM = 0, 1, 2), bukan sekadar label gizi umum.

2.5. Klasifikasi XGBoost

XGBoost dipilih sebagai model klasifikasi karena mampu menangani interaksi fitur nonlinier dan relatif tangguh terhadap ketidakseimbangan kelas [16]. Berbeda dari pendekatan yang memberikan target AKG yang sama kepada seluruh anak pada kelompok umur tertentu, penelitian ini menggunakan *XGBoost* untuk mempelajari hubungan antara profil antropometri anak dan kelas menu, sehingga personalisasi target gizi dapat dilakukan pada level individu.

Tabel 3. Variabel XGBoost

No.	Fitur	Simbol	Keterangan
1	Usia dalam bulan	U	Bilangan bulat, rentang 0–60 bulan
2	Tinggi badan	TB	Tinggi badan aktual (cm)
3	Berat badan	BB	Berat badan aktual (kg)
4	Indeks massa tubuh	BMI	Turunan dari berat badan dan tinggi badan
5	Alergi telur	ALG_Egg	Indikator biner alergi
6	Alergi susu	ALG_Milk	Indikator biner alergi
7	Alergi kedelai	ALG_Soy	Indikator biner alergi
8	Alergi kacang	ALG_Peanut	Indikator biner alergi
9	Alergi ikan/udang	ALG_Fish, ALG_Shrimp	Indikator biner alergi
Keluaran	Kelas menu	KM	0 = Catch-Up, 1 = Balanced, 2 = Energy Control

Data latih dibagi menjadi data *training* dan *testing*. Karena distribusi kelas cenderung tidak seimbang, data *training* diseimbangkan menggunakan SMOTE sebelum pelatihan model [17]. Evaluasi *XGBoost* dilakukan dengan *stratified 5-fold cross validation* untuk memperoleh rerata akurasi dan *weighted F1-score*, kemudian diuji kembali pada data *hold-out* 20%. Metrik yang dilaporkan mencakup *accuracy*, *precision*, *recall*, *weighted F1-score*, dan *confusion matrix* per kelas.

2.6. Penyusunan Kandidat Menu

Kelas menu hasil prediksi *XGBoost* dipetakan ke vektor target gizi personal $T = [TE, TP, TL, TKh]$ yang mewakili energi, protein, lemak, dan karbohidrat. Nilai dasar diperoleh dari tabel AKG dengan menyesuaikan umur anak ke kelompok umur 0–5 bulan, 6–11 bulan, 1–3 tahun, dan 4–6 tahun. Setelah itu, target disesuaikan menurut kelas menu yang diprediksi agar menu yang dioptimasi benar-benar mengikuti kondisi gizi anak, bukan target populasi rata-rata.

Tabel 4. Target gizi menurut kelas menu

Kelas menu	Kondisi gizi	Target energi	Nutrisi
KM = 0	<i>Catch-Up Nutrition</i>	$AKG \times 1,20$	Protein $\times 1,20$; lemak dan karbohidrat = AKG
KM = 1	<i>Balanced Nutrition</i>	AKG standar	Seluruh nutrisi = AKG standar
KM = 2	<i>Energy Control</i>	$AKG \times 0,85$	Lemak $\times 0,90$; protein dan karbohidrat = AKG

Penyesuaian pada Tabel 4 menjadikan alur rekomendasi lebih adaptif. Kelas *catch-up* memperoleh peningkatan energi dan protein, sedangkan kelas *energy control* menerima target energi dan lemak yang lebih rendah. Strategi ini memastikan tahap optimasi mencari menu yang sesuai dengan kebutuhan gizi individual.

2.7. Formulasi Optimasi

Rekomendasi menu diformulasikan sebagai masalah optimasi kombinatorial [18]. Satu solusi merepresentasikan paket menu satu hari yang terdiri atas satu item dari masing-masing lima kelompok menu wajib, yaitu makanan pokok, lauk hewani, lauk nabati, sayur, dan buah, serta porsi dari setiap item. Tujuan optimasi adalah meminimalkan deviasi rata-rata berbobot antara total kandungan gizi menu terhadap target gizi personal. Bobot yang digunakan pada komponen energi, protein, lemak, dan karbohidrat berturut-turut adalah 0,40; 0,30; 0,15; dan 0,15.

Persamaan (1) menunjukkan fungsi error optimasi, sedangkan Persamaan (2) merupakan fungsi fitness yang digunakan oleh GA dan PSO. Semakin kecil nilai error, semakin besar nilai fitness dan semakin baik solusi menu yang diperoleh.

$$Z = \sum w_n \times |Nutrien_n - T_n| / T_n, \quad n \in \{E, P, L, KH\} \quad (1)$$

$$Fitness = 1 / (1 + Z) \quad (2)$$

Tabel 5. Constraint optimasi

Jenis constraint	Interpretasi
Kelengkapan	Tepat satu item dipilih dari setiap kelompok menu agar terbentuk paket menu harian yang lengkap
Batas porsi	Porsi setiap kelompok harus berada pada rentang minimum–maksimum yang ditentukan
Validitas data	Item pangan harus memiliki data energi, protein, lemak, dan karbohidrat yang lengkap
Keamanan alergi	Item yang mengandung alergen anak dikeluarkan dari kandidat sebelum optimasi

Filtering berbasis alergi dilakukan sebelum optimasi, sehingga ruang pencarian hanya berisi item yang aman untuk dikonsumsi anak. Implementasi *constraint* ini penting karena menu yang optimal secara gizi belum tentu layak apabila mengandung bahan yang memicu alergi.

2.8. Optimasi Menu

Genetic Algorithm (GA) diterapkan sebagai metode pencarian berbasis populasi yang terinspirasi dari seleksi alam [19]. Setiap kromosom merepresentasikan menu harian dalam bentuk lima gen, di mana setiap gen memuat indeks item pangan dan porsi untuk satu kelompok menu. Implementasi GA terdiri atas lima komponen utama, yaitu inisialisasi populasi acak, seleksi menggunakan *tournament selection*, *one-point crossover*, mutasi acak pada gen, dan *elitism* untuk mempertahankan solusi terbaik [20]. Dalam penelitian ini digunakan ukuran populasi 50, maksimum 100 generasi, *crossover rate* 0,80, *mutation rate* 0,20, *elite size* 3, dan *tournament size* 4.

Particle Swarm Optimization (PSO) diterapkan dengan merepresentasikan satu menu harian sebagai partikel berdimensi 10, yaitu lima indeks item pangan dan lima ukuran porsi. Karena indeks item bersifat diskrit, posisi partikel yang semula kontinu dibulatkan dan dipotong ke batas yang valid sebelum dievaluasi. Kecepatan dan posisi partikel diperbarui menggunakan komponen inersia, pembelajaran kognitif, dan pembelajaran sosial. Parameter PSO dalam penelitian ini adalah ukuran partikel 50, maksimum 100 iterasi, *inertia weight* 0,70, serta koefisien kognitif dan sosial masing-masing 1,50.

Tabel 6. Konfigurasi Parameter GA dan PSO

Parameter	GA	PSO
Ukuran populasi/partikel	50	50
Maks. generasi/iterasi	100	100
Crossover rate	0,80	-
Mutation rate	0,20	-
Elite size	3	-
Tournament size	4	-
Inertia weight	-	0,70
Cognitive coefficient	-	1,50
Social coefficient	-	1,50
Random seed	42	42

Baik GA maupun PSO dievaluasi Tabel 6 kondisi eksperimen yang sama: basis data pangan yang sama, target gizi personal yang sama, serta jumlah evaluasi fitness yang setara. Dengan demikian, perbandingan kedua algoritma merefleksikan perbedaan mekanisme pencarian solusi, bukan perbedaan beban komputasi atau data masukan.

2.9. Evaluasi

Model *XGBoost* dievaluasi menggunakan *stratified five-fold cross validation* pada data *training* yang telah diseimbangkan dengan SMOTE, lalu diuji kembali menggunakan hold-out test 20%. Untuk perbandingan GA dan PSO, setiap algoritma dijalankan sebanyak 30 kali pada tiga skenario kelas menu ($KM = 0, 1, 2$), masing-masing pada kondisi tanpa alergi dan dengan alergi. Metrik evaluasi yang digunakan meliputi *RDI score*, *nutrient deviation*, dan *computation time*. Desain multi-skenario ini memungkinkan analisis yang lebih komprehensif terhadap perilaku algoritma pada kondisi target gizi yang berbeda.

Tabel 7. Metrik evaluasi perbandingan GA dan PSO

Metrik	Rumus ringkas	Interpretasi
<i>RDI score (%)</i>	$RDI_n = \text{Nutrien}_n / T_n \times 100$	Semakin mendekati 100%, semakin baik pemenuhan target
<i>Nutrient deviation (%)</i>	$Dev_n = \text{Nutrien}_n - T_n / T_n \times 100$	Semakin rendah, semakin dekat dengan target
<i>Computation time (s)</i>	$\bar{t} \pm s$ dari 30 run	Semakin rendah, semakin efisien

Tabel 7 menjabarkan tiga metrik evaluasi kuantitatif yang dikonfigurasi untuk menilai dan membandingkan performa Genetic Algorithm dan Particle Swarm Optimization secara komprehensif. Pada dimensi presisi gizi, metrik *RDI score* digunakan untuk melihat tingkat kepuasan pemenuhan target gizi. Dimana angka 100% merupakan titik pemenuhan ideal. *Nutrient Deviation* digunakan untuk mengukur persentase nilai galat atau simpangan absolute. Pada dimensi efisiensi komputasional, metrik *computation time* tidak diukur dari satu kali uji coba, melainkan diekstraksi dari nilai rata-rata dan standar deviasi atas 30 kali eksekusi algoritma.

3. HASIL DAN PEMBAHASAN

3.1 Kinerja Klasifikasi *XGBoost*

Tahap evaluasi pertama menilai kemampuan *XGBoost* dalam memprediksi kelas menu balita dari usia, data antropometri, dan fitur alergi. Tabel 8 memperlihatkan hasil validasi silang lima lipatan. Model memberikan skor yang tinggi dan stabil pada seluruh *fold*, dengan rerata akurasi 96,40% dan *weighted F1-score* 96,38%. Temuan ini menunjukkan bahwa fitur yang dipilih cukup informatif untuk membedakan balita yang memerlukan *catch-up nutrition*, *balanced nutrition*, maupun *energy control*.

Tabel 8. Kinerja klasifikasi *XGBoost*

Fold	Accuracy	F1-Score
1	0,9487	0,9487
2	1,0000	1,0000
3	0,8974	0,8969
4	0,9737	0,9733
5	1,0000	1,0000
Mean	0,9640	0,9638

Pada data *hold-out*, model mencapai akurasi 87,18% dan *weighted F1-score* 87,16%. Sebagian besar kesalahan klasifikasi terjadi pada kelas yang berdekatan, terutama antara *balanced nutrition* dan *energy control*, yang secara alami memiliki batas antropometri yang lebih dekat dibanding kelas *catch-up*. Secara keseluruhan, hasil ini mendukung penggunaan *XGBoost* sebagai *front-end* prediktif dalam *workflow* yang diusulkan.

Secara substantif, fitur antropometri menjadi penentu yang paling berpengaruh terhadap prediksi kelas menu karena ketiga fitur tersebut langsung mencerminkan proporsi tubuh dan status gizi anak. Usia membantu menempatkan pengukuran dalam konteks pertumbuhan, sedangkan indikator alergi berperan sebagai fitur pendukung personalisasi dan lebih banyak memengaruhi tahap penyaringan kandidat menu daripada pemisahan kelas gizi.


3.2 Hasil Perbandingan GA dan PSO

Perbandingan GA dan PSO dilakukan pada enam kategori eksperimen, yaitu *catch-up nutrition*, *balanced nutrition*, dan *energy control*, masing-masing pada kondisi tanpa alergi dan dengan alergi. Kedua algoritma menunjukkan kemampuan untuk menurunkan error objektif dan menghasilkan menu yang dekat dengan target gizi personal. Namun demikian, keduanya memperlihatkan *trade-off* yang berbeda pada aspek kedekatan gizi, kecepatan konvergensi, dan waktu komputasi.

Tabel 9. Hasil perbandingan GA dan PSO


Kategori eksperimen	Metode	RDI score (%)	Error Z / waktu (s)
Catch-up (tanpa alergi)	GA	95,5	0,0759 / 77,74
Catch-up (tanpa alergi)	PSO	94,6	0,0836 / 19,98
Catch-up (dengan alergi)	GA	95,6	0,0743 / 81,65
Catch-up (dengan alergi)	PSO	95,3	0,0773 / 15,90
Balanced (tanpa alergi)	GA	99,4	0,0095 / 77,69
Balanced (tanpa alergi)	PSO	98,9	0,0143 / 15,76
Balanced (dengan alergi)	GA	99,7	0,0063 / 74,09
Balanced (dengan alergi)	PSO	99,4	0,0103 / 15,49
Energy control (tanpa alergi)	GA	95,8	0,0303 / 75,68
Energy control (tanpa alergi)	PSO	96,0	0,0250 / 17,77
Energy control (dengan alergi)	GA	95,7	0,0286 / 91,80
Energy control (dengan alergi)	PSO	96,0	0,0259 / 21,54

Tabel 9 menunjukkan bahwa kedua algoritma menghasilkan *RDI score* di atas 94% pada seluruh skenario, sehingga keduanya layak digunakan untuk optimasi menu balita. Meskipun demikian, kecenderungan performanya berbeda. GA cenderung menghasilkan *RDI score* sedikit lebih tinggi dan error lebih rendah pada skenario *catch-up* dan *balanced*, sedangkan PSO lebih kompetitif pada skenario *energy control* dan secara konsisten memerlukan waktu komputasi yang jauh lebih singkat.



Gambar 2. Kurva konvergensi GA dan PSO


Kurva konvergensi pada Gambar 2. Kurva konvergensi GA dan PSO memperlihatkan bahwa PSO cenderung mencapai solusi stabil lebih cepat dibanding GA, sedangkan GA memerlukan lebih banyak generasi hingga kurva error mendatar. Pola ini konsisten dengan hasil waktu komputasi pada Gambar 3, di mana GA membutuhkan sekitar 74,09–91,80 detik per run, sedangkan PSO hanya membutuhkan 15,46–21,54 detik. Keunggulan kecepatan ini berasal dari struktur iterasi PSO yang lebih sederhana dibanding *pipeline* seleksi–*crossover*–mutasi pada GA.



Gambar 3. Perbandingan RDI score, error, dan waktu komputasi GA dan PSO

Berdasarkan Gambar 3, *Genetic Algorithm* (GA) menunjukkan *RDI Score* yang lebih tinggi dibandingkan *Particle Swarm Optimization* (PSO) pada empat dari enam skenario, yaitu dua skenario *Catch-Up Nutrition* dan dua skenario *Balanced Nutrition*. Pada kondisi *Catch-Up*, GA memperoleh 95,5% (normal) dan 95,6% (alergi), sedangkan PSO memperoleh 94,6% dan 95,3%. Pada kondisi *Balanced Nutrition*, kedua algoritma mendekati pemenuhan optimal, namun GA tetap sedikit lebih unggul dengan nilai 99,4% dan 99,7%, dibandingkan PSO sebesar 98,9% dan 99,4%. Sebaliknya, pada skenario *Energy Control*, PSO sedikit lebih baik dengan *RDI Score* 96,0% pada kondisi normal maupun alergi, sedangkan GA memperoleh 95,8% dan 95,7%. Hasil ini menunjukkan bahwa GA lebih baik dalam mencapai target gizi pada kondisi *catch-up* dan *balanced*, sedangkan PSO lebih sesuai pada target energi yang lebih terkontrol.

Hasil *nutrient deviation* pada Gambar 4 mendukung temuan tersebut. GA menghasilkan nilai *error* (*Z*) yang lebih rendah pada skenario *Catch-Up* dan *Balanced*, sedangkan PSO lebih unggul pada skenario *Energy Control*. Selain itu, penyaringan kandidat berdasarkan alergi tidak menurunkan kualitas optimasi. Pada skenario *Catch-Up*, nilai *error* justru sedikit menurun setelah filter alergi diterapkan, yang menunjukkan bahwa pembatasan kandidat dapat membuat ruang pencarian menjadi lebih terarah. Dari sisi waktu komputasi, PSO secara konsisten jauh lebih cepat dibandingkan GA. Waktu eksekusi GA berada pada rentang 74,09–91,80 detik, sedangkan PSO hanya memerlukan 15,46–21,54 detik. Dengan demikian, tidak ada satu algoritma yang unggul mutlak pada seluruh skenario. GA lebih baik dalam ketepatan pemenuhan gizi pada kondisi *Catch-Up* dan *Balanced*, sedangkan PSO lebih efisien secara komputasi dan lebih kompetitif pada kondisi *Energy Control*.



Gambar 4. Deviasi nutrient per kategori eksperimen GA dan PSO

Gambar 4 menunjukkan bahwa perbedaan performa kedua algoritma tidak seragam pada seluruh skenario. Pada skenario *catch-up* dan *balanced*, GA menghasilkan deviasi yang lebih rendah, yang menunjukkan kemampuan eksplorasi kombinasi pangan yang lebih menyeluruh ketika target gizi relatif tinggi atau standar. Sebaliknya, pada skenario *energy control*, PSO menghasilkan error akhir yang lebih rendah. Hal ini mengindikasikan bahwa mekanisme pembaruan posisi dan kecepatan pada PSO lebih efektif untuk ruang solusi yang lebih sempit akibat target energi yang diturunkan.

Selain itu, hasil pada skenario alergi menunjukkan bahwa proses penyaringan alergen tidak menghalangi algoritma menemukan menu yang layak. Walaupun ruang pencarian menjadi lebih sempit setelah item alergen dikeluarkan, baik GA maupun PSO tetap mampu menghasilkan menu dengan kedekatan gizi yang baik. Temuan ini menegaskan bahwa *constraint* alergi bukan hanya syarat keamanan, tetapi juga dapat bertindak sebagai regularisasi yang membuat ruang pencarian lebih terfokus.

3.3 Pembahasan

Hasil penelitian menunjukkan bahwa *workflow* yang diusulkan berhasil menggabungkan tahap prediksi dan optimasi ke dalam satu proses rekomendasi yang koheren. *XGBoost* berperan sebagai *front-end classifier* yang mengubah profil anak menjadi strategi menu, sedangkan GA dan PSO mencari kombinasi pangan yang memenuhi target gizi hasil strategi tersebut. Arsitektur ini lebih adaptif dibanding pendekatan yang langsung mengoptimasi menu menggunakan target gizi tetap, karena rekomendasi dihasilkan dari kondisi gizi anak yang spesifik [21].

Penambahan *filtering* berbasis alergi meningkatkan realisme praktis sistem. Dalam konteks perencanaan menu, sebuah menu tidak dapat dianggap optimal apabila masih mengandung bahan yang tidak aman bagi anak. Dengan mengeluarkan item alergen dari kandidat sebelum optimasi, *workflow* ini memastikan bahwa menu yang dihasilkan tidak hanya relevan secara gizi, tetapi juga aman untuk dikonsumsi. Pengurangan kandidat akibat alergi juga membuktikan bahwa alergi bukan variabel minor; ia secara langsung mengubah ruang pencarian dan memengaruhi perilaku optimizer.

Perbandingan GA dan PSO memperlihatkan bahwa pemilihan algoritma bergantung pada objektif performa yang diprioritaskan. GA lebih unggul dalam ketelitian pencapaian target gizi pada skenario *catch-up* dan *balanced*, sedangkan PSO lebih unggul dalam waktu komputasi dan lebih kompetitif pada skenario *energy control*. Perbedaan ini sejalan dengan mekanisme pencarian kedua algoritma. GA menyempurnakan solusi melalui seleksi, *crossover*, mutasi, dan *elitism*, sementara PSO memperbarui posisi partikel melalui komponen inersia, pembelajaran kognitif, dan pembelajaran sosial, sehingga lebih cepat bergerak ke wilayah solusi yang baik.

Dari perspektif implementasi aplikasi, hasil penelitian memberikan dasar yang jelas dalam memilih *optimizer*. Walaupun GA menawarkan presisi gizi yang sedikit lebih tinggi pada beberapa skenario, PSO memberikan *trade-off* yang lebih sesuai untuk sistem rekomendasi yang memerlukan respons cepat. Oleh karena itu, PSO lebih layak digunakan pada tahap implementasi aplikasi, sedangkan GA dapat diposisikan sebagai pembanding atau opsi alternatif ketika fokus utama adalah ketepatan pencapaian target gizi.

4. KESIMPULAN

Penelitian ini mengembangkan kerangka sistem pendukung keputusan rekomendasi menu balita yang peka terhadap alergi dan terpersonalisasi secara individual telah berhasil dicapai secara komprehensif. Melalui integrasi algoritma, klasifikasi XGBoost terbukti sangat bagus sebagai mesin prediktif (akurasi 96,40% pada validasi silang) untuk memetakan profil balita menjadi target gizi personal berbasis AKG. Pada tahap optimasi, baik GA maupun PSO terbukti mampu menghasilkan menu harian yang terdiri atas makanan pokok, lauk hewani, lauk nabati, sayur, dan buah yang mendekati target gizi personal. Proses *filtering* alergi berhasil meningkatkan keamanan rekomendasi dengan mengecualikan bahan yang tidak aman tanpa menghilangkan kemampuan sistem untuk menemukan solusi yang layak. Hasil perbandingan menunjukkan bahwa GA cenderung memberikan deviasi gizi yang lebih rendah pada skenario *catch-up* dan *balanced*, sedangkan PSO lebih cepat secara komputasi dan lebih unggul pada skenario *energy control*. Dengan demikian, kontribusi penelitian ini terletak pada penyediaan kerangka rekomendasi menu balita yang menghubungkan identifikasi kondisi gizi, personalisasi target nutrisi, pembatasan alergi, dan optimasi menu ke dalam satu sistem yang adaptif, dan aplikatif. Lalu pada penyajian evaluasi komparatif GA dan PSO yang memberikan dasar empiris bagi pemilihan optimizer untuk implementasi aplikasi, dimana PSO paling sesuai untuk kebutuhan sistem yang memerlukan respons cepat.

REFERENCES

- [1] D. L. Putnick *et al.*, “Displacement of peer play by screen time : associations with toddler development,” *Pediatr. Res.*, vol. 93, no. May, 2022, doi: 10.1038/s41390-022-02261-y.
- [2] A. T. Mulyani, M. A. Khairinisa, and A. Khatib, “Understanding Stunting : Impact , Causes , and Strategy to Accelerate Stunting Reduction — A Narrative Review,” *Nutrients*, vol. 17, no. 9, p. 1493, 2025, doi: 10.3390/nu17091493.
- [3] T. Vaivada, N. Akseer, S. Akseer, A. Somaskandan, M. Stefopoulos, and Z. A. Bhutta, “Stunting in childhood : an overview of global burden , trends , determinants , and drivers of decline,” *Am. J. Clin. Nutr.*, vol. 112, pp. 777S–791S, 2020, doi: 10.1093/ajcn/nqaa159.
- [4] H. P. Sari, L. Permatasari, W. Ayu, and K. Putri, “Perbedaan Keragaman Pangan, Pola Asuh Makan, dan Asupan Zat Gizi Makro pada Balita dari Ibu Bekerja dan Ibu Tidak Bekerja,” no. 60, pp. 2–3, 2021, doi: 10.20473/amnt.v5i3.2021.
- [5] N. I. Firdausi, “Peraturan Menteri Kesehatan Republik Indonesia Nomor 2 Tahun 2020 Tentang Standar Antropometri Anak,” *Kaos GL Derg.*, vol. 8, no. 75, pp. 147–154, 2020.
- [6] D. A. Wulandari and Z. K. A. Baizal, “Ontology-Based Food Recommender System for Nutrition in School-Age,” vol. 7, no. 4, pp. 2425–2433, 2023.
- [7] M. As and E. R. Subhiyakto, “Performance Comparison of Random Forest , SVM , and XGBoost Algorithms with SMOTE for Stunting Prediction,” *J. Appl. Informatics Comput.*, vol. 9, no. 4, pp. 1163–1169, 2025, doi: 10.30871/jaic.v9i4.9701.
- [8] D. Bhargava, N. Tyagi, and A. Bhargava, “Optimizing Nutrient Combinations by Differential Evolution Algorithm : A Computational Approach to Dietary Planning,” *2024 4th Int. Conf. Technol. Adv. Comput. Sci.*, pp. 755–760, 2024, doi: 10.1109/ICTACS62700.2024.10840745.
- [9] D. Kurnianingtyas, N. Daud, and L. Muflikhah, “Comparison Genetics Algorithm and Particle Swarm Optimization in Dietary Recommendations for Maternal Nutritional Fulfillment,” *SITEKIN J. Sains, Teknol. dan Ind.*, vol. 21, no. 2, pp. 216–227, 2024, doi: 10.24014/sitekin.v21i2.28937.
- [10] U. M. Umoren, B. A. Ojokoh, and O. S. Ijarotimi, “Addressing Malnutrition in School-Aged Children with a Diet Recommender System,” *Int. J. Innov. Sci. Res. Technol.*, vol. 7, no. 9, pp. 1704–1719, 2022, [Online]. Available: <https://ijisrt.com/assets/upload/files/IJISRT22SEP1018.pdf>
- [11] M. Pratama and I. Riyadi, “Identifikasi Nilai Gizi Makro Lemang Berdasarkan Tabel Komposisi Pangan Indonesia (TKPI) dan Analisis Proksimat,” *J. Teknol. Pangan dan Gizi*, vol. 23, pp. 89–95, 2024, doi: 10.33508/jtpg.v23i2.4885.
- [12] G. Salloum and J. Tekli, “Automated and personalized meal plan generation and relevance scoring using a multi-factor adaptation of the transportation problem,” *Soft Comput.*, vol. 26, no. 5, pp. 2561–2585, 2022, doi: 10.1007/s00500-021-



- 06400-1.
- [13] Y. Chibber, D. Betala, and S. S., “Diet Recommendation System Using Machine Learning,” pp. 1125–1130, 2023, doi: 10.13052/rp-9788770040723.216.
 - [14] S. Abhari, K. B. Lankarani, L. Azadbakht, and S. R. N. Kalhori, “Designing and Evaluating a Nutrition Recommender System for Improving Food Security in a Developing Country,” *Acad. Med. Sci. I.R. Iran*, vol. 26, no. 11, pp. 629–641, 2023, doi: 10.34172/aim.2023.93.
 - [15] M. K. Ayele, G. A. Baye, and S. H. Yesuf, “Predicting stunting status among under five children in ethiopia using ensemblmachine learning algorithms,” *Sci. ReportsRep*, vol. 15, p, pp. 1–11, 2025, doi: 10.1038/s41598-025-03206-1.
 - [16] B. Rao, M. Rashid, and G. Hasan, “Machine Learning in Predicting Child Malnutrition: A Meta-Analysis of Demographic and Health Surveys Data,” *Int. J. Environ. Res. Public Heal.*, vol. 22, no. 3, pp. 1–15, 2025, doi: 10.3390/ijerph22030449.
 - [17] M. Imani and A. Beikmohammadi, “Comprehensive Analysis of Random Forest and XGBoost Performance with SMOTE , ADASYN , and GNUS Under Varying Imbalance Levels,” *Technologies*, vol. 13, no. 88, pp. 1–40, 2025, doi: 10.3390/technologies13030088.
 - [18] E. Arteaga-cabrera, C. Ramírez-márquez, E. Sánchez-ramírez, J. G. Segovia-hernández, O. Osorio-mora, and J. A. Gómez-salazar, “Advancing Optimization Strategies in the Food Industry: From Traditional Approaches to Multi-Objective and Technology-Integrated Solutions,” *Appl. Sci.*, vol. 15, no. 7, pp. 1–31, 2025, doi: 10.3390/app15073846.
 - [19] P. Aivaliotis-apostolopoulos and D. L. Id, “Swarming genetic algorithm : A nested fully coupled hybrid of genetic algorithm and particle swarm optimization,” *PLoS One*, pp. 1–24, 2022, doi: 10.1371/journal.pone.0275094.
 - [20] S. N. Langazane and A. K. Saha, “Effects of Particle Swarm Optimization and Genetic Algorithm Control Parameters on Overcurrent Relay Selectivity and Speed,” *IEEE Access*, vol. 10, pp. 4550–4567, 2022, doi: 10.1109/ACCESS.2022.3140679.
 - [21] I. Papastratis, D. Konstantinidis, P. Daras, and K. Dimitropoulos, “OPEN AI nutrition recommendation using a deep generative model and ChatGPT,” *Sci. Rep.*, pp. 1–18, 2024, doi: 10.1038/s41598-024-65438-x.