ISSN: 2598-8565 (media cetak)
ISSN: 2620-4339 (media online)

PENGEMBANGAN SISTEM INFORMASI KLASIFIKASI KESESUAIAN KANDUNGAN GIZI MENU TERINTEGRASI DENGAN MODUL ARTIFICIAL NEURAL NETWORK

Hen Hen Lukmana✉, Muhammad Alhusaini, Luh Desi Puspareni
Universitas Siliwangi, Tasikmalaya, Indonesia
Email: henhenlukmana@unsil.ac.id

DOI: https://doi.org/10.46880/jmika.Vol10No2.pp933-946

ABSTRACT

Evaluation of meal-menu nutritional adequacy in nutrition fulfilment programs is often performed manually, making the process time-consuming, accuracy-dependent, and susceptible to recording errors. This study develops and conducts an initial validation of a web-based prototype information system for classifying menu nutritional adequacy using an Artificial Neural Network (ANN) classification module. Using a Design Science Research (DSR) approach, the prototype integrates menu data management, automatic nutrient computation, adequacy classification, and analysis-history storage within a single platform. The ANN module was trained on a reproducibly generated controlled synthetic dataset of 4,500 samples with three balanced classes (Insufficient, Adequate, and Excessive) and ten nutrient-adequacy percentage features. Evaluation covered model performance, comparison with a Decision Tree baseline, ten core functional scenarios using black-box testing, and perceived usability using the System Usability Scale (SUS). The ANN achieved 98.81% test accuracy and a 98.81% macro F1-score, whereas the Decision Tree baseline achieved 97.63% accuracy and a 97.63% macro F1-score on the same test partition. All tested core functional scenarios were valid, and the mean SUS score was 88.50, exceeding the commonly used SUS benchmark of 68. These findings support the initial feasibility of the prototype within the evaluated scope. The main contribution is the development and initial validation of an integrated prototype rather than a new classification algorithm.

Keywords: Information System, Artificial Neural Network, Nutritional Adequacy Classification, Menu Evaluation, Nutrition Fulfilment.

ABSTRAK

Evaluasi kesesuaian kandungan gizi menu pada program pemenuhan gizi masih banyak dilakukan secara manual, sehingga memerlukan waktu, ketelitian, dan berisiko menimbulkan kesalahan pencatatan. Penelitian ini mengembangkan dan melakukan validasi awal prototipe sistem informasi berbasis web untuk klasifikasi kesesuaian kandungan gizi menu dengan modul Artificial Neural Network (ANN). Dengan pendekatan Design Science Research (DSR), prototipe mengintegrasikan pengelolaan data menu, perhitungan kandungan gizi otomatis, klasifikasi kesesuaian, dan penyimpanan riwayat analisis dalam satu platform. Modul ANN dilatih menggunakan dataset sintetis terkontrol yang dapat direplikasi sebanyak 4.500 sampel dengan tiga kelas seimbang (Kurang, Sesuai, dan Berlebih) serta sepuluh fitur persentase kecukupan gizi. Evaluasi mencakup performa model, perbandingan dengan baseline Decision Tree, sepuluh skenario fungsional utama melalui pengujian black-box, dan usability menggunakan System Usability Scale (SUS). ANN mencapai test accuracy 98,81% dan macro F1-score 98,81%, sedangkan Decision Tree memperoleh accuracy 97,63% dan macro F1-score 97,63% pada partisi data testing yang sama. Seluruh skenario fungsi utama yang diuji dinyatakan valid, dan skor SUS rata-rata mencapai 88,50, lebih tinggi daripada benchmark SUS yang umum digunakan sebesar 68. Hasil ini mendukung kelayakan awal prototipe dalam ruang lingkup pengujian yang dilakukan. Kontribusi utama penelitian adalah pengembangan dan validasi awal prototipe terintegrasi, bukan pengembangan algoritma klasifikasi baru.

Kata Kunci: Sistem Informasi, Artificial Neural Network, Klasifikasi Kesesuaian Gizi, Evaluasi Menu, Pemenuhan Gizi.

PENDAHULUAN

Pemenuhan gizi yang cukup dan seimbang merupakan salah satu faktor penting dalam mendukung pertumbuhan, perkembangan, kesehatan, dan kualitas hidup masyarakat (Shams-White et al., 2023). Permasalahan gizi, khususnya pada kelompok rentan

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

seperti balita, anak usia sekolah, ibu hamil, dan ibu menyusui, masih menjadi tantangan yang memerlukan perhatian serius. Di Indonesia, stunting masih menjadi masalah gizi penting dan berkaitan dengan determinan sosial, lingkungan, pola pengasuhan, kondisi rumah tangga, serta faktor kesehatan ibu dan anak (Arief et al., 2025). Malnutrisi dan stunting pada awal kehidupan dapat berdampak terhadap pertumbuhan, perkembangan neurokognitif, capaian belajar, serta produktivitas pada tahap kehidupan berikutnya ((Suryawan et al., 2022) . Oleh karena itu, penanganan masalah gizi memerlukan intervensi yang terukur, konsisten, multisektoral, dan berbasis data (Aminah et al., 2024) .

Salah satu upaya strategis dalam mendukung pemenuhan gizi masyarakat adalah penyediaan menu makanan yang sesuai dengan kebutuhan gizi kelompok sasaran. Pola makan berkualitas menekankan kecukupan dan keseimbangan komponen pangan serta zat gizi sesuai kebutuhan kelompok sasaran (Shams-White et al., 2023) . Dalam konteks layanan pemenuhan gizi, setiap menu yang disajikan perlu dianalisis agar kandungan energi, protein, lemak, karbohidrat, serta zat gizi lainnya dapat dibandingkan dengan kebutuhan yang telah ditetapkan. Evaluasi kandungan gizi merupakan bagian penting dalam penilaian diet karena kualitas hasilnya sangat bergantung pada ketepatan identifikasi makanan, ukuran porsi, pencatatan konsumsi, dan estimasi kandungan zat gizi (Bailey, 2021) . Oleh karena itu, evaluasi kesesuaian kandungan gizi menu perlu dilakukan secara sistematis agar kualitas menu dapat dijaga secara berkelanjutan.

Namun, proses analisis kandungan gizi menu yang dilakukan secara konvensional memiliki sejumlah keterbatasan. Penilaian diet dapat melibatkan pencatatan jenis makanan, ukuran porsi, konversi satuan, dan penghitungan zat gizi, sehingga rentan terhadap kesalahan pengukuran maupun ketidakakuratan pencatatan (Bailey, 2021). Dalam pengelolaan menu, tenaga gizi atau pengelola menu perlu mengidentifikasi bahan makanan, mengonversi ukuran rumah tangga ke satuan gram, menghitung kandungan zat gizi setiap bahan, menjumlahkan nilai gizi dalam satu paket menu, kemudian membandingkannya dengan standar kebutuhan gizi. Rangkaian proses tersebut membutuhkan ketelitian dan waktu, terutama apabila jumlah menu yang dianalisis cukup banyak.

Perkembangan teknologi informasi membuka peluang untuk membuat evaluasi menu lebih cepat, konsisten, dan terdokumentasi. Kajian terkini menunjukkan bahwa aplikasi berbasis web, perangkat bergerak, serta metode berbantuan citra semakin banyak digunakan untuk mendukung dietary assessment, pengenalan makanan, estimasi porsi, dan perhitungan zat gizi (Chotwanvirat et al., 2024; Zheng et al., 2024). Sistem informasi juga dapat menyatukan input menu, perhitungan zat gizi, penyimpanan hasil, dan penelusuran riwayat. Sementara itu, machine learning memperluas fungsi sistem digital dari pencatatan menuju prediksi dan klasifikasi berbasis data (Armand et al., 2024; Kirk et al., 2022) .

Meskipun demikian, penerapan kecerdasan buatan di bidang gizi sejauh ini lebih banyak diarahkan pada dietary assessment, estimasi asupan makanan, food recognition berbasis citra, dan sistem rekomendasi makanan (Bondevik et al., 2024; Chotwanvirat et al., 2024; Phalle & Gokhale, 2025). Kebutuhan pengelola menu pada program pemenuhan gizi berbeda, yaitu sistem yang mengelola data menu sekaligus mengklasifikasikan kesesuaian kandungan gizinya ke dalam kategori Kurang, Sesuai, dan Berlebih dalam satu alur kerja. Oleh karena itu, celah yang diangkat dalam penelitian ini bukan pada pengembangan metode klasifikasi baru, melainkan pada integrasi pengelolaan data menu, perhitungan kandungan gizi, dan klasifikasi otomatis dalam satu sistem yang dapat digunakan secara praktis oleh pengelola menu.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan mengembangkan dan melakukan validasi awal prototipe sistem informasi klasifikasi kesesuaian kandungan gizi menu yang terintegrasi dengan modul Artificial Neural Network (ANN). ANN diposisikan sebagai komponen klasifikasi yang menghasilkan kategori Kurang, Sesuai, atau Berlebih berdasarkan persentase kecukupan gizi. Dengan posisi tersebut, penelitian menilai kelayakan integrasi modul klasifikasi ke dalam alur pengelolaan menu, bukan menguji kesiapan sistem untuk penggunaan operasional berskala produksi.

Kontribusi penelitian ini adalah pengembangan dan validasi awal prototipe sistem informasi terintegrasi. Prototipe menghubungkan pengelolaan data menu, perhitungan kandungan gizi otomatis, sepuluh fitur persentase kecukupan, aturan kelas Kurang Sesuai Berlebih, modul ANN, dan riwayat analisis dalam satu alur kerja. Evaluasi dilakukan pada tiga tingkat, yaitu performa modul klasifikasi, fungsi utama prototipe, dan persepsi terhadap usability. Untuk memberikan konteks terhadap performa ANN, penelitian ini menggunakan Decision Tree sebagai baseline machine learning sederhana pada dataset yang sama. Dengan demikian, kebaruan penelitian bersifat integratif dan artefaktual. ANN tidak diajukan sebagai

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

algoritma baru, tetapi sebagai komponen yang divalidasi secara awal di dalam prototipe sistem.

KAJIAN LITERATUR

Kajian literatur dalam penelitian ini mencakup tiga bagian, yaitu pemanfaatan teknologi digital dalam evaluasi gizi, penerapan *machine learning* dan Artificial Neural Network di bidang gizi, serta penelitian terkait yang menjadi dasar penentuan posisi penelitian.

Teknologi Digital dalam Evaluasi Gizi

Evaluasi kandungan gizi merupakan bagian penting dari penilaian diet. Bailey (2021) menjelaskan bahwa kualitas hasil penilaian sangat dipengaruhi oleh ketepatan identifikasi makanan, ukuran porsi, pencatatan konsumsi, dan estimasi kandungan zat gizi. Dalam perkembangan terbaru, teknologi digital untuk dietary assessment banyak memanfaatkan citra makanan, perangkat bergerak, basis data gizi, dan kecerdasan buatan untuk mengurangi beban pencatatan manual serta meningkatkan konsistensi estimasi (Chotwanvirat et al., 2024; Konstantakopoulos et al., 2024; Zheng et al., 2024).

Pendekatan berbasis perangkat bergerak dan citra terus berkembang dari pengenalan makanan menuju estimasi porsi dan kandungan gizi. Tinjauan Chotwanvirat et al. (2024) dan Konstantakopoulos et al. (2024) menunjukkan bahwa pendekatan deep learning semakin dominan pada sistem dietary assessment berbasis citra, meskipun estimasi porsi dan mikronutrien masih menjadi tantangan. Whitton et al. (2024) membandingkan beberapa metode penilaian diet berbantuan teknologi terhadap asupan yang diamati secara langsung dan menunjukkan bahwa akurasi tetap dipengaruhi oleh metode serta kualitas input. Abeltino et al. (2025) juga menunjukkan bahwa aplikasi digital kini digunakan untuk diet monitoring, diet planning, pencatatan asupan, dan precision nutrition pada pengguna umum maupun profesional.

Machine Learning dan Artificial Neural Network di Bidang Gizi

Machine learning telah digunakan dalam penelitian gizi untuk klasifikasi, prediksi, analisis pola konsumsi, dan pemodelan data nutrisi. Kirk et al. (2022) mengulas pemanfaatan machine learning dalam berbagai jenis penelitian gizi, sedangkan Chaves et al. (2023) meninjau secara sistematis penerapan teknik machine learning pada penilaian asupan makanan. Tinjauan sistematis oleh Armand et al. (2024) memperlihatkan bahwa kecerdasan buatan, machine learning, dan deep learning telah diterapkan secara luas di bidang gizi.

Artificial Neural Network (ANN) merupakan salah satu metode machine learning yang mempelajari pemetaan antara sejumlah variabel masukan dan keluaran melalui penyesuaian bobot selama proses pelatihan. Kemampuan ANN merepresentasikan hubungan multivariat dan pola yang tidak harus linier membuatnya banyak digunakan pada berbagai tugas klasifikasi. Dalam penelitian gizi, ANN dan deep neural network telah digunakan untuk klasifikasi dan prediksi berbasis variabel asupan zat gizi, termasuk prediksi risiko penyakit metabolik dan diabetes(Chang et al., 2023; Kim et al., 2021) . Tinjauan yang lebih luas juga menunjukkan bahwa ANN dan pendekatan machine learning lainnya digunakan pada beragam tugas prediksi dan klasifikasi dalam penelitian gizi (Armand et al., 2024; Kirk et al., 2022) . Berdasarkan karakteristik tersebut, ANN relevan untuk diuji sebagai modul klasifikasi multikelas yang dapat diintegrasikan ke dalam sistem informasi.

Penelitian Terkait

Penelitian terdahulu menunjukkan bahwa penerapan kecerdasan buatan pada bidang gizi berkembang terutama pada dietary assessment, pengenalan makanan, estimasi asupan, dan rekomendasi. Zheng et al. (2024) melalui scoping review menemukan bahwa aplikasi AI untuk pengukuran makanan dan zat gizi menggunakan beragam sumber data, termasuk citra, sensor gerak atau suara, dan teks. Phalle & Gokhale (2025) menunjukkan bahwa perangkat dietary assessment berbantuan AI banyak diintegrasikan dengan aplikasi mobile atau web, tetapi fungsi utamanya tetap berorientasi pada pengenalan makanan, estimasi porsi atau asupan, dan pemantauan perilaku makan. Temuan tersebut konsisten dengan Shonkoff et al. (2023) , Dalakleidi et al. (2022) dan Chotwanvirat et al. (2024) yang menyoroti dominasi pendekatan berbasis citra. Pada tingkat pengembangan sistem, Wang et al. (2026) mengintegrasikan pengenalan makanan, penimbangan, dan basis data komposisi pangan untuk penilaian asupan gizi rumah sakit, sedangkan Yan et al. (2025) mengembangkan DietAI24 untuk estimasi gizi komprehensif dari citra makanan menggunakan multimodal large language models dan retrieval-augmented generation.

Pada penggunaan data zat gizi secara tabular, Kim et al. (2021) menggunakan deep neural network dan membandingkannya dengan logistic regression serta decision tree untuk memprediksi risiko overweight/obesitas, dislipidemia, hipertensi, dan

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

diabetes berdasarkan asupan gizi. Chang et al. (2023) menggunakan ANN dan sensitivity analysis untuk klasifikasi dan prediksi diabetes pada kelompok lanjut usia berdasarkan variabel asupan zat gizi. Berbeda dari penelitian tersebut, penelitian ini tidak memprediksi kondisi kesehatan individu dan tidak berfokus pada pengenalan makanan dari citra. Fokusnya adalah klasifikasi kesesuaian kandungan gizi menu terhadap target kebutuhan di dalam satu artefak sistem informasi. Perbandingan pada Tabel 1 memperjelas posisi tersebut. Kebaruan penelitian terletak pada integrasi empat unsur dalam satu alur kerja, yaitu sepuluh fitur persentase kecukupan yang dihitung dari komposisi menu, aturan kelas operasional Kurang Sesuai Berlebih yang memprioritaskan kebutuhan minimum, modul ANN sebagai komponen klasifikasi, serta pengelolaan hasil dan riwayat analisis. Karena itu, penelitian ini tidak mengklaim kebaruan pada algoritma ANN, melainkan pada integrasi klasifikasi berorientasi target kebutuhan gizi ke dalam sistem pengelolaan dan evaluasi menu.

Tabel 1. Perbandingan Penelitian Terdahulu dan Posisi Penelitian

Penelitian	Pendekatan/Fitur dan Posisi terhadap Penelitian Ini
Zheng et al. (2024), Phalle & Gokhale (2025)	Tinjauan AI untuk dietary assessment dominan pada citra, sensor, estimasi asupan, dan aplikasi mobile/web. Belum berfokus pada klasifikasi kesesuaian menu terhadap target kebutuhan dalam alur pengelolaan menu.
Wang et al. (2026)	Sistem AI rumah sakit yang mengintegrasikan pengenalan makanan, penimbangan, dan basis data komposisi pangan untuk penilaian asupan. Fokus pada monitoring konsumsi dan verifikasi diet terapeutik, bukan klasifikasi kesesuaian menu terhadap target program.
Yan et al. (2025)	DietAI24 menggabungkan multimodal large language models dan retrieval-augmented generation untuk estimasi kandungan gizi dari citra makanan. Fokus pada estimasi komprehensif zat gizi dari makanan nyata, bukan pengelolaan menu dan klasifikasi Kurang-Sesuai-Berlebih.
Kim et al. (2021)	DNN dengan variabel asupan gizi untuk memprediksi risiko kondisi metabolik dibandingkan dengan logistic regression dan decision tree. Output berupa risiko kesehatan individu, bukan kelas kesesuaian menu.
(2023Chang et al. (2023)	ANN dengan variabel asupan zat gizi dan sensitivity analysis untuk klasifikasi/prediksi diabetes pada lanjut usia. Fokus pada prediksi kondisi kesehatan individu.
Penelitian ini	10 fitur persentase kecukupan + aturan Kurang, Sesuai, Berlebih + ANN yang terintegrasi dengan pengelolaan menu, perhitungan gizi, hasil, dan riwayat analisi; performa ANN dibandingkan dengan Decision Tree sebagai baseline, kemudian artefak dievaluasi pada level fungsi dan usability.

METODE PENELITIAN

Penelitian ini menggunakan Design Science Research (DSR) karena berfokus pada pengembangan dan evaluasi artefak berupa prototipe sistem informasi terintegrasi. Literatur DSR terkini menempatkan pengembangan artefak, kontribusi desain, dan evaluasi sebagai elemen penting dalam penelitian sistem informasi berbasis solusi (Brendel et al., 2022; Carter et al., 2022) . Struktur metode mengikuti enam fase DSR, yaitu identifikasi masalah, penetapan tujuan solusi, desain dan pengembangan artefak, demonstrasi, evaluasi, serta komunikasi hasil. Tahapan teknis pengolahan data dan pengembangan ANN ditempatkan pada fase desain dan pengembangan, sedangkan pengujian model, fungsi sistem, dan persepsi terhadap usability ditempatkan pada fase evaluasi prototipe.

Identifikasi Masalah dan Analisis Kebutuhan

Tahap analisis kebutuhan didasarkan pada studi dokumen dan kajian literatur terhadap alur evaluasi kandungan gizi menu, pedoman Program Makan Bergizi Gratis (MBG), Angka Kecukupan Gizi (AKG), dan Tabel Komposisi Pangan Indonesia (TKPI)((B. G. N. R. Indonesia, 2025; K. K. R. Indonesia, 2019, 2020). Kajian tersebut digunakan untuk menurunkan kebutuhan fungsional dan nonfungsional sistem. Kebutuhan fungsional meliputi pengelolaan data menu, input bahan makanan, perhitungan energi, protein, lemak, karbohidrat, serat, kalsium, besi, natrium, seng, dan vitamin C, proses klasifikasi kesesuaian kandungan gizi, serta penyimpanan riwayat hasil analisis. Sementara itu, kebutuhan nonfungsional mencakup kemudahan penggunaan, kecepatan proses analisis, konsistensi hasil, dan keterbacaan informasi yang ditampilkan kepada pengguna.

Penetapan Tujuan Solusi

Berdasarkan kebutuhan tersebut, tujuan solusi ditetapkan untuk menghasilkan prototipe yang mampu mengelola data menu dan bahan pangan, menghitung sepuluh komponen zat gizi beserta persentase kecukupannya, mengklasifikasikan kesesuaian menu ke dalam kelas Kurang, Sesuai, atau Berlebih menggunakan modul ANN, serta menyimpan hasil analisis agar dapat ditelusuri kembali. Keberhasilan prototipe dievaluasi pada tiga tingkat, yaitu performa modul klasifikasi, keterpenuhan fungsi utama sistem, dan persepsi terhadap usability.

Desain dan Pengembangan Artefak

Akuisisi dan Validasi Dataset

Dataset yang digunakan merupakan dataset sintetis terkontrol yang dibangkitkan berdasarkan

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

acuan kebutuhan gizi pada Program Makan Bergizi Gratis (MBG). Data sintetis dipilih untuk membentuk lingkungan eksperimen awal yang terkontrol dan dapat direplikasi, sehingga aturan kelas dapat diterapkan secara konsisten, setiap kelas dapat memperoleh jumlah sampel yang seimbang, dan integrasi modul klasifikasi dapat dievaluasi sebelum pengujian dengan data menu riil. Dataset terdiri atas 4.500 sampel dengan tiga kelas target, yaitu Kurang, Sesuai, dan Berlebih, masing-masing sebanyak 1.500 sampel. Distribusi seimbang tersebut merupakan desain eksperimen dan tidak dimaksudkan untuk merepresentasikan prevalensi nyata kategori kesesuaian gizi pada Satuan Pelayanan Pemenuhan Gizi (SPPG). Validasi internal dataset dilakukan secara deterministik dengan memeriksa kesesuaian setiap sampel terhadap aturan kelas yang ditetapkan, disertai pemeriksaan struktur, tipe data, missing value, dan duplikasi. Validasi ini menilai konsistensi logis dataset, bukan validitas empiris atau klinis terhadap distribusi menu di lapangan. Konsekuensinya, penggunaan data sintetis meningkatkan kontrol dan reprodusibilitas eksperimen, tetapi membatasi validitas eksternal dan generalisasi hasil hingga dilakukan validasi menggunakan data menu riil.

Proses pembangkitan dataset dilakukan secara deterministik dengan random seed 42. Untuk setiap sampel, sepuluh fitur persentase kecukupan gizi dibangkitkan menggunakan truncated normal distribution. Nilai dasar setiap fitur menggunakan parameter $\mu = 95$ dan $\sigma = 7$ dengan batas 80%–110%. Pada kelas Kurang, satu dari sepuluh fitur dipilih secara acak dengan peluang yang sama kemudian nilainya diganti menggunakan distribusi $\mu = 50$ dan $\sigma = 8$ dengan batas 40% hingga kurang dari 80%. Pada kelas Sesuai, seluruh fitur dipertahankan pada distribusi dasar 80%–110%. Pada kelas Berlebih, satu fitur dipilih secara acak kemudian diganti menggunakan distribusi $\mu = 140$ dan $\sigma = 10$ dengan batas lebih dari 110% hingga 175%. Prosedur ini menghasilkan tepat 1.500 sampel pada setiap kelas tanpa pelabelan ulang pascapembangkitan. Target kebutuhan gizi yang menjadi dasar interpretasi persentase kecukupan mengacu pada pedoman MBG dan AKG (Badan Gizi Nasional Republik Indonesia, 2025; Kementerian Kesehatan Republik Indonesia, 2019). Parameter μ dan σ ditetapkan sebagai parameter simulasi untuk menghasilkan variasi sintetis yang terkontrol di dalam dan di luar batas operasional kelas. Nilai parameter tersebut tidak dimaksudkan sebagai estimasi distribusi klinis atau populasi, melainkan untuk memastikan variasi nilai yang memadai pada setiap kelas sambil mempertahankan konsistensi aturan <80%, 80%–110%, dan >110%.

Tiga kelas target yang digunakan dalam penelitian ini terdiri atas Kurang, Sesuai, dan Berlebih. Kelas target ditentukan terlebih dahulu sebelum proses pembangkitan data sintetis. Selanjutnya, nilai sepuluh fitur persentase kecukupan gizi dibangkitkan secara terkontrol agar memenuhi karakteristik kelas yang telah ditentukan.

Karakteristik setiap kelas ditetapkan menggunakan aturan gabungan bertingkat berdasarkan persentase kecukupan gizi. Sampel kelas Kurang memiliki setidaknya satu zat gizi dengan persentase kecukupan kurang dari 80%. Sampel kelas Sesuai memiliki seluruh persentase kecukupan gizi pada rentang 80% sampai 110%. Sementara itu, sampel kelas Berlebih tidak memiliki zat gizi dengan persentase kecukupan kurang dari 80%, tetapi memiliki setidaknya satu zat gizi dengan persentase kecukupan lebih dari 110%.

Rentang 80%–110% digunakan sebagai batas operasional dalam penentuan tingkat kecukupan gizi terhadap Angka Kecukupan Gizi (AKG). Pendekatan serupa telah digunakan dalam penelitian penilaian asupan gizi dengan mengategorikan tingkat kecukupan menjadi kurang apabila berada di bawah 80% AKG, cukup pada rentang 80%–110% AKG, dan lebih apabila melebihi 110% AKG (Nahdah et al., 2022; Yugharyanti et al., 2024). Dalam penelitian ini, rentang tersebut diadaptasi sebagai dasar operasional pembentukan kelas Kurang, Sesuai, dan Berlebih pada dataset sintetis. Batas tersebut digunakan secara konsisten untuk membentuk aturan klasifikasi dalam eksperimen dan tidak dimaksudkan sebagai batas klinis universal untuk seluruh kondisi dan kelompok individu.

Aturan klasifikasi diterapkan secara hierarkis dengan memprioritaskan pemenuhan kebutuhan minimal. Dengan demikian, apabila suatu sampel memiliki setidaknya satu zat gizi dengan persentase kecukupan di bawah 80%, sampel tetap dikategorikan sebagai Kurang meskipun terdapat zat gizi lain dengan persentase kecukupan di atas 110%. Pendekatan ini digunakan untuk mencegah sampel dikategorikan sebagai Sesuai atau Berlebih ketika masih terdapat komponen zat gizi yang belum memenuhi batas kecukupan minimum.

Setelah proses pembangkitan data, label kategorikal pada setiap sampel dikonversi ke bentuk numerik, yaitu Kurang = 0, Sesuai = 1, dan Berlebih = 2, agar dapat digunakan dalam proses pelatihan dan klasifikasi oleh modul ANN. Pengkodean numerik

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

tersebut hanya mengubah representasi label dan tidak menunjukkan hubungan ordinal antarkelas.

Preprocessing dan Pembagian Data

Preprocessing data dilakukan untuk menyiapkan dataset agar dapat digunakan dalam pelatihan modul ANN. Tahap ini meliputi pemeriksaan struktur data, konversi fitur ke bentuk numerik, pengecekan missing value dan data duplikat, serta pemeriksaan konsistensi tipe data. Model menggunakan sepuluh fitur masukan berupa persentase kecukupan gizi, yaitu persentase energi, protein, lemak, karbohidrat, serat, kalsium, besi, natrium, seng, dan vitamin C. Setiap fitur dihitung sebagai rasio kandungan zat gizi menu terhadap target kebutuhan gizi dikalikan seratus persen.

Dataset selanjutnya dibagi secara stratified dengan random state 42 agar distribusi kelas tetap seimbang dan proses dapat direplikasi. Tahap pertama memisahkan 70% data sebagai data training dan 30% sebagai data sementara. Data sementara kemudian dibagi sama besar menjadi data validation dan data testing, sehingga proporsi akhir menjadi 70% training, 15% validation, dan 15% testing. Masing-masing data validation dan data testing berjumlah 675 sampel atau 225 sampel per kelas. Untuk ANN, seluruh fitur distandardisasi menggunakan StandardScaler dengan parameter rata-rata dan standar deviasi yang hanya dihitung dari data training, kemudian diterapkan pada data validation dan data testing untuk mencegah data leakage.

Perancangan Modul Artificial Neural Network

ANN dipilih sebagai modul klasifikasi pada tahap proof-of-concept karena mampu mempelajari pemetaan multivariat, termasuk hubungan yang tidak harus linier, serta menghasilkan probabilitas untuk klasifikasi multikelas. Pemilihan ini konsisten dengan penggunaan neural network pada penelitian gizi untuk klasifikasi dan prediksi berbasis variabel asupan zat gizi (Chang et al., 2023; Kim et al., 2021) , serta dengan tinjauan penerapan machine learning dan artificial intelligence dalam penelitian gizi (Armand et al., 2024; Kirk et al., 2022). Untuk mengontekstualisasikan performa ANN, Decision Tree dipilih sebagai baseline karena merupakan metode klasifikasi nonparametrik yang lebih sederhana dan juga digunakan sebagai pembanding pada penelitian prediksi berbasis asupan gizi (Kim et al., 2021). Perbandingan ini dimaksudkan sebagai evaluasi relatif pada dataset dan partisi yang sama, bukan sebagai klaim superioritas algoritma secara universal.

Arsitektur ANN menggunakan sepuluh neuron pada input layer yang merepresentasikan persentase kecukupan energi, protein, lemak, karbohidrat, serat, kalsium, besi, natrium, seng, dan vitamin C. Dua hidden layer masing-masing terdiri atas 32 dan 16 neuron dengan aktivasi ReLU serta dropout 0,20 dan 0,10. Output layer terdiri atas tiga neuron dengan aktivasi softmax untuk menghasilkan probabilitas kelas Kurang, Sesuai, dan Berlebih. Konfigurasi ini digunakan sebagai arsitektur ringan untuk kebutuhan klasifikasi multikelas dan integrasi ke dalam prototipe sistem.

Pelatihan Model

Model dilatih menggunakan optimizer Adam dengan learning rate 0,001, sparse categorical cross-entropy, batch size 32, dan maksimum 200 epoch. Data validation digunakan untuk memantau proses pelatihan. ModelCheckpoint, EarlyStopping dengan patience 20 epoch, dan ReduceLROnPlateau diterapkan untuk mengendalikan proses optimasi, sedangkan random seed 42 digunakan untuk mendukung keterulangan eksperimen.

Baseline Decision Tree

Decision Tree digunakan sebagai baseline dengan sepuluh fitur masukan serta partisi data training dan testing yang sama dengan ANN. Model dikonfigurasi menggunakan criterion Gini, splitter best, tanpa pembatasan max_depth, min_samples_split = 2, min_samples_leaf = 1, dan random state 42. Hyperparameter tuning tidak dilakukan agar Decision Tree tetap berfungsi sebagai baseline sederhana. Karena Decision Tree melakukan pemisahan berdasarkan ambang pada setiap fitur, standardisasi tidak diperlukan. Model dilatih menggunakan 3.150 data training dan dievaluasi pada 675 data testing yang sama dengan ANN, data validation tidak digunakan untuk memilih parameter baseline.

Implementasi Sistem Informasi

Modul ANN yang telah dievaluasi kemudian diintegrasikan ke dalam sistem informasi klasifikasi kesesuaian kandungan gizi menu. Sistem memiliki beberapa modul utama, yaitu modul input data menu, modul pengelolaan bahan makanan, modul perhitungan kandungan gizi, modul klasifikasi berbasis ANN, modul hasil analisis, dan modul riwayat analisis.

Lingkungan Implementasi Prototipe

Prototipe diimplementasikan sebagai aplikasi berbasis web menggunakan PHP, HTML, CSS, dan JavaScript. Pengembangan dan pengujian dilakukan

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

pada laptop dengan Intel Core i7-1360P, RAM 16 GB LPDDR5, grafis terintegrasi Intel Iris Xe, penyimpanan NVMe 1 TB, dan Fedora Linux 40. Lingkungan tersebut digunakan untuk pengembangan serta validasi awal fungsi dan integrasi prototipe. Penelitian belum melakukan deployment pada lingkungan produksi maupun pengujian lintas browser/perangkat secara terkontrol.

Demonstrasi Prototipe

Tahap demonstrasi dilakukan dengan menjalankan alur analisis menu pada prototipe yang telah mengintegrasikan modul perhitungan gizi dan ANN. Demonstrasi menunjukkan bagaimana data bahan pangan diproses menjadi kandungan gizi, diubah menjadi persentase kecukupan, distandardisasi menggunakan parameter dari data training, kemudian diklasifikasikan dan disimpan sebagai hasil analisis.

Pengguna memasukkan data menu dan bahan makanan sebagai dasar perhitungan kandungan gizi. Informasi kandungan energi dan zat gizi bahan pangan mengacu pada Tabel Komposisi Pangan Indonesia (TKPI) dari Kementerian Kesehatan Republik Indonesia (2020). Apabila bahan pangan masih menggunakan berat mentah, berat bagian yang dapat dimakan dihitung berdasarkan persentase Bagian yang Dapat Dimakan (BDD) menggunakan Persamaan (1).

$$W_{\text{bdd}} = (W_{\text{mentah}} \times \text{BDD}) / 100 \quad (1)$$

Dengan W_bdd adalah berat bahan yang dapat dimakan (gram), W_mentah adalah berat bahan mentah (gram), dan BDD adalah persentase bagian bahan yang dapat dimakan.

Berdasarkan berat bagian yang dapat dimakan tersebut, sistem menghitung kandungan zat gizi setiap bahan pangan dan menjumlahkannya untuk memperoleh total kandungan gizi menu. Kandungan gizi yang dihitung meliputi energi, protein, lemak, karbohidrat, serat, kalsium, besi, natrium, seng, dan vitamin C. Total kandungan setiap zat gizi kemudian dibandingkan dengan target kebutuhan gizi kelompok sasaran untuk memperoleh persentase kecukupan. Sebelum diberikan kepada modul ANN, sepuluh fitur persentase kecukupan tersebut distandardisasi menggunakan parameter StandardScaler yang diperoleh hanya dari data training pada tahap preprocessing. Pada tahap inferensi, scaler tidak dihitung ulang, parameter rata-rata dan standar deviasi dari data training digunakan kembali agar skala masukan konsisten dengan proses pelatihan. Sepuluh fitur hasil standardisasi kemudian digunakan sebagai masukan modul ANN untuk menghasilkan kategori kesesuaian menu, yaitu Kurang, Sesuai, atau Berlebih. Hasil klasifikasi beserta rincian perhitungan kandungan gizi selanjutnya disimpan dalam sistem agar dapat ditelusuri kembali.

Evaluasi Artefak

Evaluasi Performa Model dan Baseline

Evaluasi performa ANN dan Decision Tree dilakukan pada data testing yang sama dan tidak digunakan dalam proses pelatihan. Metrik yang dibandingkan meliputi accuracy, precision, recall, macro F1-score, balanced accuracy, dan confusion matrix. Test loss hanya dilaporkan untuk ANN karena bukan metrik yang dihasilkan oleh Decision Tree. Perbandingan dilakukan secara deskriptif untuk menilai posisi performa ANN terhadap baseline sederhana pada kondisi eksperimen yang sama.

Pengujian Fungsional Sistem

Pengujian fungsional menggunakan black-box testing pada sepuluh fungsi utama prototipe, meliputi login, pengelolaan sasaran, pengaturan target gizi, penambahan bahan pangan, perhitungan BDD dan kandungan gizi, persentase kecukupan, klasifikasi ANN, detail hasil, penyimpanan analisis, dan riwayat analisis. Setiap skenario dinilai berdasarkan kesesuaian keluaran aktual dan keluaran yang diharapkan pada alur penggunaan normal. Pengujian input tidak valid, nilai batas antarmuka, keamanan aplikasi, beban akses, serta kompatibilitas lintas perangkat belum dievaluasi secara empiris pada tahap ini; karena itu, hasil black-box diperlakukan sebagai validasi fungsi inti prototipe, bukan sertifikasi keandalan sistem produksi.

Evaluasi Usability

Usability sistem dievaluasi menggunakan System Usability Scale (SUS), yaitu instrumen sepuluh item dengan skala Likert 1-5 yang banyak digunakan untuk menilai persepsi usability pada aplikasi digital. Pengujian melibatkan 15 responden. Skor SUS dihitung menggunakan prosedur standar, kemudian diinterpretasikan terhadap benchmark 68 yang didukung oleh meta-analisis penggunaan SUS pada aplikasi kesehatan digital (Hyzy et al., 2022). Dengan pendekatan ini, interpretasi difokuskan pada posisi skor prototipe terhadap benchmark terkini, bukan pada kategori grade yang bersumber dari referensi yang lebih lama.

Komunikasi Hasil

Tahap komunikasi dilakukan dengan menyajikan rancangan artefak, prosedur pengembangan, hasil evaluasi, keterbatasan, dan

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

ISSN: 2598-8565 (media cetak)
ISSN: 2620-4339 (media online)

implikasi penelitian secara sistematis pada bagian hasil dan pembahasan. Komunikasi hasil difokuskan pada kontribusi pengembangan dan validasi awal prototipe, tanpa mengklaim keunggulan algoritma ANN di luar bukti yang dihasilkan pada penelitian ini.

HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil berdasarkan keluaran utama tahapan Design Science Research (DSR), yaitu desain dan pengembangan artefak, demonstrasi prototipe, serta evaluasi artefak. Fase identifikasi masalah dan penetapan tujuan solusi telah dijelaskan pada bagian metode sebagai dasar pembentukan kebutuhan sistem dan kriteria evaluasi.

Hasil Desain dan Pengembangan Artefak

Akuisisi dan Validasi Dataset

Pembangkitan menghasilkan 4.500 sampel dengan distribusi seimbang, masing-masing 1.500 sampel pada kelas Kurang, Sesuai, dan Berlebih. Pemeriksaan menunjukkan tidak terdapat missing value maupun duplikasi, dan validasi rule-based memastikan 100% sampel konsisten dengan aturan kelas yang telah ditetapkan. Distribusi seimbang merupakan desain eksperimen untuk mengevaluasi modul, bukan representasi prevalensi kategori menu pada SPPG.

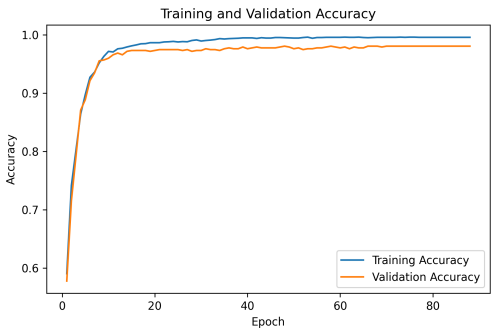
Karena fitur sintetis dibangkitkan agar memenuhi karakteristik kelas yang telah ditentukan, terdapat keterkaitan struktural yang kuat antara fitur dan label. Kondisi ini meningkatkan konsistensi internal eksperimen, tetapi membatasi validitas eksternal. Oleh sebab itu, performa ANN pada penelitian ini diinterpretasikan sebagai kemampuan mereproduksi pola klasifikasi yang dirancang di dalam prototipe, bukan sebagai bukti penemuan pola gizi baru atau generalisasi pada menu riil.

Preprocessing dan Pembagian Data

Setelah pemeriksaan kualitas data, dataset dibagi secara stratified menjadi 70% training, 15% validation, dan 15% testing dengan random state 42. Data testing berjumlah 675 sampel atau 225 sampel per kelas. StandardScaler dipasang hanya pada data training dan parameternya diterapkan pada validation serta testing untuk mencegah data leakage.

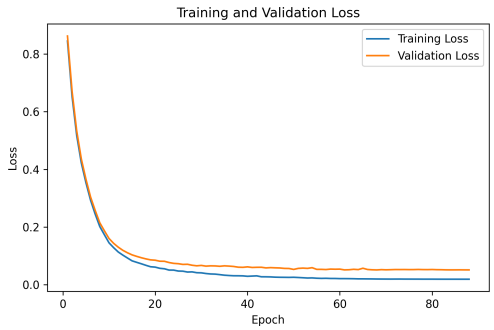
Pelatihan Model

Proses pelatihan ANN dilakukan menggunakan konfigurasi yang telah ditetapkan pada tahap perancangan dan pelatihan model. *EarlyStopping* menghentikan proses pelatihan pada *epoch* ke-88, sedangkan model terbaik berdasarkan *validation loss* terendah diperoleh pada *epoch* ke-68. Pada *epoch* terbaik tersebut, *training accuracy* mencapai 99,59% dan *validation accuracy* mencapai 98,07%. Perkembangan *accuracy* selama proses pelatihan ditunjukkan pada Gambar 1. Kedua kurva meningkat tajam pada *epoch* awal dan kemudian relatif stabil, sehingga menunjukkan proses pembelajaran yang telah mencapai kondisi konvergen tanpa indikasi *overfitting* yang kuat.



Gambar 1. Kurva *training* dan *validation accuracy* model ANN

Perubahan nilai *loss* ditunjukkan pada Gambar 2. *Training loss* dan *validation loss* menurun tajam pada *epoch* awal dan kemudian melandai. Pada *epoch* terbaik ke-68, training *loss* mencapai 0,0201 dan *validation loss* mencapai 0,0516. Setelah titik tersebut, perubahan *validation loss* relatif kecil hingga proses dihentikan pada *epoch* ke-88. Pola tersebut menunjukkan bahwa proses optimasi telah mencapai konvergensi dengan kemampuan generalisasi yang relatif stabil.



Gambar 2. Kurva *training* dan *validation loss* model ANN

Hasil Demonstrasi Prototipe

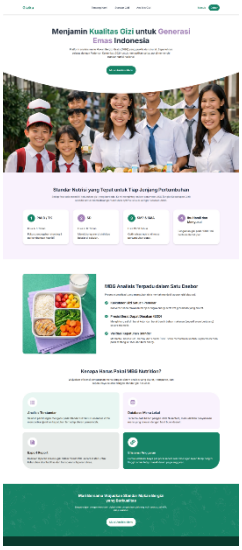
Implementasi Antarmuka Sistem

Antarmuka sistem disusun untuk membentuk alur penggunaan yang berurutan, mulai dari pengenalan fungsi sistem, pengisian parameter dan komposisi menu, hingga penyajian hasil analisis. Halaman utama

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

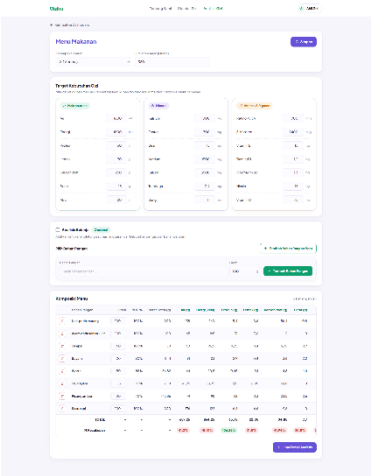
ISSN: 2598-8565 (media cetak)
ISSN: 2620-4339 (media online)

pada Gambar 3 menampilkan tujuan sistem, kelompok sasaran, dan akses menuju fitur analisis gizi, sehingga membantu pengguna memahami ruang lingkup sistem sebelum melakukan analisis menu.



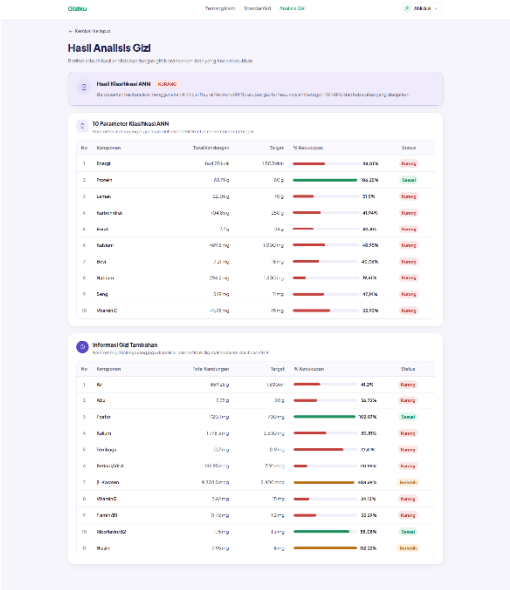
Gambar 3. Antarmuka Halaman Utama

Pada halaman analisis gizi (Gambar 4), pengguna dapat menentukan kelompok sasaran dan jumlah penerima, menyesuaikan target makronutrien, mineral, dan vitamin, serta memasukkan bahan pangan beserta beratnya. Sistem menghitung komposisi menu dan persentase kecukupan secara langsung, sehingga pengguna dapat mengidentifikasi zat gizi yang masih kurang atau telah berlebih sebelum menyimpan hasil analisis.



Gambar 4. Antarmuka Input Target Kebutuhan Gizi dan Komposisi Menu

Hasil pengolahan ditampilkan pada Gambar 5 dalam tiga kelompok, yaitu makronutrien, mineral, serta vitamin dan pigmen. Setiap komponen menyajikan total kandungan, target kecukupan, dan status hasil perbandingan. Penyajian yang terstruktur ini mendukung penelusuran hasil klasifikasi dan membantu pengguna mengenali komponen gizi yang memerlukan penyesuaian.



Gambar 5. Antarmuka Hasil Analisis Kandungan Gizi Menu

Hasil Evaluasi Artefak

Evaluasi Performa ANN dan Baseline Decision Tree

Evaluasi performa dilakukan menggunakan 675 data testing yang tidak digunakan pada proses pelatihan maupun validasi, dengan distribusi kelas seimbang (masing-masing 225 data pada kelas Kurang, Sesuai, dan Berlebih). Hasil pada Tabel 2 menunjukkan bahwa ANN memperoleh test accuracy 98,81%, macro precision 98,82%, macro recall 98,81%, macro F1-score 98,81%, dan balanced accuracy 98,81%. Pada partisi data testing yang sama, Decision Tree memperoleh accuracy 97,63%, macro precision 97,65%, macro recall 97,63%, macro F1-score 97,63%, dan balanced accuracy 97,63%. Dengan demikian, ANN memiliki keunggulan deskriptif sebesar 1,18 poin persentase pada accuracy dan macro F1-score dibandingkan baseline Decision Tree.

Tabel 2. Perbandingan Performa ANN dan Decision Tree

Metrik	ANN	Decision Tree
Test Loss	0,0339	-
Test Accuracy	98,81%	97,63%
Macro Precision	98,82%	97,65%
Macro Recall	98,81%	97,63%

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

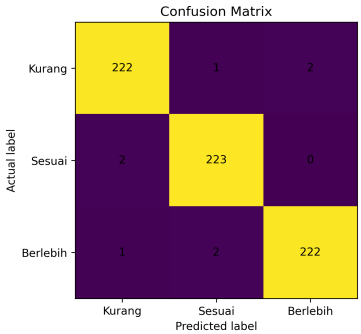
ISSN: 2598-8565 (media cetak)
ISSN: 2620-4339 (media online)

Metrik	ANN	Decision Tree
Macro F1-score	98,81%	97,63%
Balanced Accuracy	98,81%	97,63%

Analisis per kelas pada ANN menunjukkan bahwa kelas Kurang memperoleh precision 98,67%, recall 98,67%, dan F1-score 98,67%. Kelas Sesuai memperoleh precision 98,67%, recall 99,11%, dan F1-score 98,89%, sedangkan kelas Berlebih memperoleh precision 99,11%, recall 98,67%, dan F1-score 98,89%.

Confusion matrix pada Gambar 6 menunjukkan 667 dari 675 data uji diklasifikasikan dengan benar, sedangkan delapan kesalahan tersebar pada ketiga kelas. Kesalahan terutama muncul pada kombinasi fitur yang berdekatan dengan batas operasional 80% dan 110%.

Pada Decision Tree, 659 dari 675 data testing diklasifikasikan dengan benar dan 16 data mengalami salah klasifikasi. Confusion matrix menunjukkan bahwa 216 dari 225 data kelas Kurang, 222 dari 225 data kelas Sesuai, dan 221 dari 225 data kelas Berlebih diprediksi dengan benar. Untuk kelas Kurang, precision, recall, dan F1-score masing-masing sebesar 98,63%, 96,00%, dan 97,30%. Kelas Sesuai memperoleh 96,52%, 98,67%, dan 97,58%, sedangkan kelas Berlebih memperoleh 97,79%, 98,22%, dan 98,00%. Hasil ini menunjukkan bahwa baseline juga memiliki performa tinggi, tetapi menghasilkan delapan kesalahan lebih banyak daripada ANN pada data testing yang sama.



Gambar 6. *Confusion matrix* hasil pengujian model ANN

Pengujian Fungsional Black-Box

Pengujian black-box dilakukan untuk memverifikasi kesesuaian keluaran sistem terhadap masukan pada sepuluh skenario fungsi utama tanpa meninjau struktur kode program. Setiap skenario dijalankan pada sistem yang telah diimplementasikan, kemudian hasil aktual dibandingkan dengan hasil yang diharapkan. Rincian hasil pengujian disajikan pada Tabel 3

Tabel 3. Hasil Pengujian Black-Box Sistem

No	Skenario	Input/Aksi	Hasil yang Diharapkan	Hasil Aktual	Status
1	*Login* pengguna	Masukkan kredensial valid, lalu pilih Masuk.	Sistem memverifikasi akun dan membuka *dashboard* ahli gizi.	*Dashboard* ahli gizi terbuka.	Valid
2	Data kelompok sasaran	Pilih kelompok sasaran dan masukkan jumlah penerima.	Data sasaran diterima dan digunakan pada proses analisis.	Data sasaran tampil dan tersimpan.	Valid
3	Target kebutuhan gizi	Ubah nilai target makronutrien, mineral, dan vitamin.	Nilai target diperbarui dan menjadi acuan perhitungan.	Nilai target berhasil diperbarui.	Valid
4	Penambahan bahan pangan	Cari bahan pangan, isi berat, lalu tambahkan ke menu.	Bahan pangan muncul pada tabel komposisi menu.	Bahan pangan tampil pada tabel.	Valid
5	Perhitungan BDD dan zat gizi	Masukkan berat bahan dan persentase BDD.	Sistem menghitung berat dapat dimakan dan kandungan gizi.	Hasil perhitungan ditampilkan.	Valid
6	Persentase kukupa	Tambahkan beberapa bahan penyusun menu.	Sistem menghitung total gizi dan persentase kecukupan.	Total dan persentase tampil.	Valid
7	Klasifikasi ANN	Jalankan analisis terhadap data menu yang telah diisi.	Sistem memproses data dan menampilkan kategori hasil model.	Kategori hasil model ditampilkan.	Valid
8	Detail hasil analisis	Pilih tombol Lihat Detail Analisis.	Sistem menampilkan kandungan, target, dan status setiap zat gizi.	Tabel detail analisis terbuka.	Valid

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

No	Skenario	Input/Aksi	Hasil yang Diharapkan	Hasil Aktual	Status
9	Penyimpanan analisis	Pilih Simpan setelah analisis selesai.	Data menu dan hasil analisis tersimpan pada sistem.	Data analisis berhasil disimpan.	Valid
10	Riwayat analisis	Buka halaman riwayat hasil analisis.	Sistem menampilkan kembali analisis yang telah disimpan.	Riwayat analisis dapat diakses.	Valid

Seluruh 10 skenario fungsi utama memperoleh status valid. Persentase 100% tersebut hanya berlaku pada skenario black-box yang diuji dengan alur penggunaan normal dan tidak dapat ditafsirkan sebagai bukti keandalan menyeluruh. Masukan tidak valid, nilai batas pada antarmuka, keamanan, beban akses, dan kompatibilitas lintas perangkat belum diuji secara empiris. Karena itu, temuan ini mendukung fungsi inti pada tahap prototipe, sedangkan kesiapan operasional memerlukan rangkaian pengujian nonfungsional dan negatif yang lebih luas.

Evaluasi Usability

Pengujian usability menggunakan SUS melibatkan 15 responden yang merupakan mahasiswa gizi. Identitas responden dianonimkan menggunakan kode R1–R15. Perhitungan berdasarkan respons terhadap sepuluh butir SUS menghasilkan jumlah skor 1.327,5 dan rata-rata 88,50. Rincian hasil disajikan pada Tabel 4.

Tabel 4. Hasil Skor System Usability Scale (SUS)

No	Kode Responden	Skor SUS
1	R1	92,5
2	R2	95,0
3	R3	85,0
4	R4	82,5
5	R5	82,5
6	R6	75,0
7	R7	92,5
8	R8	87,5
9	R9	85,0
10	R10	97,5
11	R11	90,0
12	R12	87,5
13	R13	92,5
14	R14	92,5
15	R15	90,0
	Rata-rata	**88,50**

Skor SUS berada pada rentang 75,00-97,50 dengan median 90,00 dan simpangan baku 5,81. Rata-rata 88,50 berada 20,50 poin di atas benchmark SUS 68 yang dilaporkan layak digunakan untuk mengevaluasi aplikasi kesehatan digital (Hyzy et al., 2022). Hasil tersebut menunjukkan persepsi usability yang tinggi pada kelompok responden yang diuji. Namun, skor ini merepresentasikan persepsi terhadap penggunaan prototipe dan tidak menggantikan ukuran efektivitas tugas atau kesiapan operasional.

Responden berasal dari mahasiswa gizi, sehingga hasil SUS belum mewakili seluruh pengguna sasaran seperti tenaga gizi SPPG.

Pembahasan

Accuracy dan macro F1-score yang tinggi perlu dibaca dalam konteks dataset sintetis yang dibentuk dengan aturan kelas eksplisit. Berbeda dengan Kim et al. (2021) dan Chang et al. (2023), yang menggunakan data populasi untuk memprediksi kondisi kesehatan dari variabel asupan gizi, penelitian ini memvalidasi konsistensi modul klasifikasi di dalam artefak sistem. Karena tugas, data, dan target keluaran berbeda, perbandingan angka performa secara langsung tidak tepat. Nilai hasil penelitian ini terutama menunjukkan bahwa modul dapat diintegrasikan dan mereproduksi aturan kelas secara konsisten pada skenario eksperimen yang dirancang.

Pembandingan dengan Decision Tree memperkuat interpretasi performa model. ANN memperoleh accuracy dan macro F1-score 98,81%, sedangkan Decision Tree mencapai 97,63% pada kedua metrik tersebut, dengan selisih 1,18 poin persentase pada data testing yang sama. Temuan ini menunjukkan bahwa ANN sedikit lebih baik daripada baseline sederhana dalam eksperimen terkontrol ini, sedangkan Decision Tree tetap mampu mereproduksi sebagian besar pola label dengan performa tinggi. Karena dataset masih sintetis dan perbandingan hanya melibatkan satu baseline, selisih tersebut diperlakukan sebagai perbandingan deskriptif, bukan bukti superioritas ANN secara umum. Validasi dengan data menu riil dan baseline tambahan masih diperlukan untuk menilai kestabilan manfaat ANN pada kondisi yang lebih representatif.

Pada tingkat artefak, hasil demonstrasi menunjukkan bahwa modul klasifikasi tidak berdiri sendiri, tetapi menjadi bagian dari alur pengelolaan

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

menu: pengguna memasukkan komposisi menu, sistem menghitung persentase kecukupan, modul ANN menghasilkan kategori, dan hasil analisis dapat disimpan untuk penelusuran. Posisi ini berbeda dari Wang et al. (2026) yang berfokus pada pengenalan makanan dan penilaian asupan di lingkungan rumah sakit, serta Yan et al. (2025) yang menitikberatkan estimasi kandungan gizi dari citra menggunakan model multimodal. Dengan demikian, kontribusi penelitian ini lebih tepat dipahami sebagai pengembangan dan validasi awal prototipe sistem terintegrasi, bukan inovasi algoritma klasifikasi.

Secara keseluruhan, kombinasi performa ANN yang sedikit lebih tinggi daripada Decision Tree, keberhasilan fungsi utama, dan persepsi usability memberikan bukti awal bahwa artefak layak dilanjutkan ke tahap validasi eksternal. Namun, karena data pelatihan masih sintetis, responden usability belum berasal dari pengguna akhir SPPG, dan pengujian nonfungsional belum dilakukan secara empiris, hasil penelitian belum mendukung klaim kesiapan operasional. Tahap berikutnya perlu memprioritaskan penggunaan data menu riil, pembandingan dengan baseline tambahan, pelibatan pengguna sasaran, serta pengujian input tidak valid, nilai batas, keamanan, beban akses, dan kompatibilitas perangkat.

KESIMPULAN

Penelitian ini menghasilkan dan melakukan validasi awal prototipe sistem informasi terintegrasi untuk klasifikasi kesesuaian kandungan gizi menu. Modul ANN memperoleh test accuracy, macro F1-score, dan balanced accuracy masing-masing 98,81%. Pada partisi data testing yang sama, Decision Tree sebagai baseline memperoleh accuracy 97,63%, macro F1-score 97,63%, dan balanced accuracy 97,63%, sehingga ANN lebih tinggi 1,18 poin persentase pada ketiga metrik tersebut. Sepuluh skenario fungsi utama yang diuji dinyatakan valid, sedangkan skor SUS rata-rata mencapai 88,50, lebih tinggi daripada benchmark 68. Dibandingkan penelitian terdahulu yang terutama berfokus pada pengenalan makanan, estimasi asupan, rekomendasi, atau prediksi kondisi kesehatan individu, kontribusi penelitian ini terletak pada integrasi klasifikasi berorientasi target kebutuhan gizi dengan pengelolaan menu, perhitungan kandungan gizi, dan riwayat analisis dalam satu prototipe. Kontribusi tersebut bersifat integratif dan artefaktual, bukan inovasi algoritma ANN.

Validasi pada penelitian ini masih berada pada tahap prototipe. Dataset bersifat sintetis dan validasi eksternal menggunakan menu riil belum dilakukan, sehingga generalisasi hasil masih terbatas. Pengembangan selanjutnya perlu menggunakan data menu riil, menambah baseline seperti logistic regression atau support vector machine, melakukan negative/boundary testing, security testing, load testing, dan compatibility testing, serta melibatkan tenaga gizi SPPG sebagai pengguna akhir.

DAFTAR PUSTAKA

Abeltino, A., Riente, A., Bianchetti, G., Serantoni, C., De Spirito, M., Capezzone, S., Esposito, R., & Maulucci, G. (2025). Digital applications for diet monitoring, planning, and precision nutrition for citizens and professionals: A state of the art. *Nutrition Reviews*, *83*(2), e574–e601. https://doi.org/10.1093/nutrit/nuae035

Aminah, S., Mahmudiono, T., & Nadhiroh, S. R. (2024). Policy, intervention, and management in addressing stunting in children: A systematic review. *African Journal of Reproductive Health*, *28*(10), 348–357. https://doi.org/10.29063/ajrh2024/v28i10s.37

Arief, Y. S., Yunita, F. C., Efendi, F., Murti, F. A. K., Pradipta, R. O., & McKenna, L. (2025). Social and environmental determinants of childhood stunting in Indonesia: National cross-sectional study. *JMIR Pediatrics and Parenting*, *8*, e68918. https://doi.org/10.2196/68918

Armand, T. P. T., Nfor, K. A., Kim, J.-I., & Kim, H.-C. (2024). Applications of artificial intelligence, machine learning, and deep learning in nutrition: A systematic review. *Nutrients*, *16*(7), 1073. https://doi.org/10.3390/nu16071073

Bailey, R. L. (2021a). Overview of dietary assessment methods for measuring intakes of foods, beverages, and dietary supplements in research studies. *Current Opinion in Biotechnology*, *70*, 91–96. https://doi.org/10.1016/j.copbio.2021.02.007

Bailey, R. L. (2021b). Overview of dietary assessment methods for measuring intakes of foods, beverages, and dietary supplements in research studies. *Current Opinion in Biotechnology*, *70*, 91–96. https://doi.org/10.1016/j.copbio.2021.02.007

Bondevik, J. N., Bennin, K. E., Babur, Ö., & Ersch, C. (2024). A systematic review on food recommender systems. *Expert Systems with Applications*, *238*, 122166. https://doi.org/10.1016/j.eswa.2023.122166

Brendel, A. B., Lembcke, T.-B., & Kolbe, L. M. (2022). Towards an integrative view on Design Science Research genres, strategies, and pivotal concepts in Information Systems Research. *ACM SIGMIS Database: The DATABASE for Advances in Information Systems*, *53*(4), 9–23. https://doi.org/10.1145/3571823.3571826

Carter, L. D., Yoon, V., & Liu, D. (2022). Analyzing e-government design science artifacts: A

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

systematic literature review. *International Journal of Information Management*, *62*, 102430. https://doi.org/10.1016/j.ijinfomgt.2021.102430

Chang, K., Yoo, S., & Lee, S. (2023). Classification and prediction of the effects of nutritional intake on diabetes mellitus using artificial neural network sensitivity analysis: 7th Korea National Health and Nutrition Examination Survey. *Nutrition Research and Practice*, *17*(6), 1255–1266. https://doi.org/10.4162/nrp.2023.17.6.1255

Chaves, L. O., Domingos, A. L. G., Fernandes, D. L., Cerqueira, F. R., Siqueira-Batista, R., & Bressan, J. (2023). Applicability of machine learning techniques in food intake assessment: A systematic review. *Critical Reviews in Food Science and Nutrition*, *63*(7), 902–919. https://doi.org/10.1080/10408398.2021.1956425

Chotwanvirat, P., Prachansuwan, A., Sridonpai, P., & Kriengsinyos, W. (2024). Advancements in using AI for dietary assessment based on food images: Scoping review. *Journal of Medical Internet Research*, *26*, e51432. https://doi.org/10.2196/51432

Dalakleidi, K. V, Papadelli, M., Kapolos, I., & Papadimitriou, K. (2022). Applying image-based food-recognition systems on dietary assessment: A systematic review. *Advances in Nutrition*, *13*(6), 2590–2619. https://doi.org/10.1093/advances/nmac078

Hyzy, M., Bond, R., Mulvenna, M., Bai, L., Dix, A., Leigh, S., & Hunt, S. (2022). System Usability Scale Benchmarking for Digital Health Apps: Meta-analysis. *JMIR mHealth and uHealth*, *10*(8), e37290. https://doi.org/10.2196/37290

Indonesia, B. G. N. R. (2025). *Petunjuk teknis tata kelola penyelenggaraan Program Makan Bergizi Gratis*. Badan Gizi Nasional Republik Indonesia.

Indonesia, K. K. R. (2019). *Peraturan Menteri Kesehatan Republik Indonesia Nomor 28 Tahun 2019 tentang Angka Kecukupan Gizi yang Dianjurkan untuk Masyarakat Indonesia*. Kementerian Kesehatan Republik Indonesia.

Indonesia, K. K. R. (2020). *Tabel Komposisi Pangan Indonesia (Revisi Cetakan 1)*. Kementerian Kesehatan Republik Indonesia. https://repository.kemkes.go.id/book/668

Kim, H., Lim, D. H., & Kim, Y. (2021). Classification and prediction on the effects of nutritional intake on overweight/obesity, dyslipidemia, hypertension and type 2 diabetes mellitus using deep learning model: 4-7th Korea National Health and Nutrition Examination Survey. *International Journal of Environmental Research and Public Health*, *18*(11), 5597. https://doi.org/10.3390/ijerph18115597

Kirk, D., Kok, E., Tufano, M., Tekinerdogan, B., Feskens, E. J. M., & Camps, G. (2022). Machine learning in nutrition research. *Advances in Nutrition*, *13*(6), 2573–2589. https://doi.org/10.1093/advances/nmac103

Konstantakopoulos, F. S., Georga, E. I., & Fotiadis, D. I. (2024). A review of image-based food recognition and volume estimation artificial intelligence systems. *IEEE Reviews in Biomedical Engineering*, *17*, 136–152. https://doi.org/10.1109/RBME.2023.3283149

Nahdah, R. A., Safitri, D. E., & Fitria, F. (2022). Asupan lemak, serat, kalsium dan kualitas tidur kaitannya dengan siklus menstruasi pada remaja putri. *Journal of Nutrition College*, *11*(2), 163–170. https://doi.org/10.14710/jnc.v11i2.33212

Phalle, A., & Gokhale, D. (2025). Navigating next-gen nutrition care using artificial intelligence-assisted dietary assessment tools-a scoping review of potential applications. *Frontiers in Nutrition*, *12*, 1518466. https://doi.org/10.3389/fnut.2025.1518466

Shams-White, M. M., Pannucci, T. E., Lerman, J. L., Herrick, K. A., Zimmer, M., Meyers Mathieu, K., Stoody, E. E., & Reedy, J. (2023). Healthy Eating Index-2020: Review and update process to reflect the Dietary Guidelines for Americans, 2020-2025. *Journal of the Academy of Nutrition and Dietetics*, *123*(9), 1280–1288. https://doi.org/10.1016/j.jand.2023.05.015

Shonkoff, E., Cara, K. C., Pei, X., Chung, M., Kamath, S., Panetta, K., & Hennessy, E. (2023). AI-based digital image dietary assessment methods compared to humans and ground truth: A systematic review. *Annals of Medicine*, *55*(2), 2273497. https://doi.org/10.1080/07853890.2023.2273497

Suryawan, A., Jalaludin, M. Y., Poh, B. K., Sanusi, R., Tan, V. M. H., Geurts, J. M., & Muhardi, L. (2022). Malnutrition in early life and its neurodevelopmental and cognitive consequences: A scoping review. *Nutrition Research Reviews*, *35*(1), 136–149. https://doi.org/10.1017/S0954422421000159

Wang, B., Nong, C., Zhang, J., Lv, J., Zhao, S., Li, L., & Liu, P. (2026). Development of an intelligent food nutrition recognition and nutrient intake assessment system in hospital settings. *Frontiers in Nutrition*, *13*, 1637034. https://doi.org/10.3389/fnut.2026.1637034

Whitton, C., Collins, C. E., Mullan, B. A., Rollo, M. E., Dhaliwal, S. S., Norman, R., Boushey, C. J., Delp, E. J., Zhu, F., McCaffrey, T. A., Kirkpatrick, S. I., Pollard, C. M., Healy, J. D., Hassan, A., Garg, S., Atyeo, P., Mukhtar, S. A., & Kerr, D. A. (2024). Accuracy of energy and nutrient intake estimation versus observed intake using 4 technology-assisted dietary assessment methods: A randomized crossover feeding study. *The American Journal of Clinical Nutrition*, *120*(1), 196–210. https://doi.org/10.1016/j.ajcnut.2024.04.030

Yan, R., Luo, H., Lu, J., Liu, D., Posluszny, H., Dhaliwal, M. P., MacLeod, J., Qin, Y., Yang,

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.

ISSN: 2598-8565 (media cetak)
ISSN: 2620-4339 (media online)

C., Hartman, T. J., & Hu, X. (2025). DietAI24 as a framework for comprehensive nutrition estimation using multimodal large language models. *Communications Medicine*, *5*(1), 458. https://doi.org/10.1038/s43856-025-01159-0

Yugharyanti, T. P., Fatimah, S., & Rahfiludin, M. Z. (2024). Alasan pemilihan makanan, akses pembelian makanan, dan kualitas diet pada mahasiswa. *Journal of Nutrition College*, *13*(1), 17–28. https://doi.org/10.14710/jnc.v13i1.39516

Zheng, J., Wang, J., Shen, J., & An, R. (2024). Artificial intelligence applications to measure food and nutrient intakes: Scoping review. *Journal of Medical Internet Research*, *26*, e54557. https://doi.org/10.2196/54557

This work is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.