

YOLOV11-BASED FOOD MENU SEGMENTATION MODEL FOR DAILY PREDICTION IN MBG PROGRAM

MODEL SEGMENTASI MENU MAKANAN BERBASIS YOLOV11 UNTUK PREDIKSI HARIAN PROGRAM MBG

Fauzi Niko Allianzah¹, Arie Qur'ania^{2‡}, and Siska
Andriani^{3‡}

^{1,2,3}Department of Computer Science, Universitas Pakuan, Indonesia

[‡]corresponding author: 065122110@student.unpak.ac.id

Copyright © 2026 Fauzi Niko Allianzah, Arie Qur'ania, and Siska Andriani. This is an open-access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Abstract

An integrated model combining YOLOv11 instance segmentation and Gated Recurrent Unit (GRU) was developed to support automated food menu detection and daily nutritional prediction for the Free Nutritious Meal Program (MBG) in Indonesia. A dataset of 1,556 images across 39 food categories, collected via camera, was annotated and partitioned 70:20:10 into training (1,084), validation (310), and test (154) sets. YOLOv11s-seg, trained for 50 epochs with early stopping, achieved mAP@50 of 0.9766, precision 0.9688, recall 0.9775, and F1-score 0.9730. A two-layer GRU (96 hidden units, dropout 0.25) was trained on 208 augmented sequences (7-day sliding window) derived from 87 real nutritional records across 3 SPPG locations (December 2025–May 2026), yielding MAE of 45.85 kcal and RMSE of 60.90 kcal for large-portion energy (80:20 split). Both models were integrated into a web-based application enabling automated menu identification, nutritional estimation, GRU-based menu recommendation, and AKG compliance analysis.

Keywords: Food Segmentation, Gated Recurrent Unit, Makan Bergizi Gratis, Nutritional Prediction, YOLOv11.

Abstrak

Model terintegrasi berbasis YOLOv11 dan *Gated Recurrent Unit* (GRU) dikembangkan untuk mendukung deteksi menu makanan secara otomatis dan prediksi gizi harian pada Program Makan Bergizi Gratis (MBG) di Indonesia. Dataset sebanyak 1.556 citra dari 39 jenis makanan MBG dikumpulkan menggunakan kamera iPhone 11, dianotasi instance

segmentation, dan dibagi 70:20:10 menjadi data latih (1.084), validasi (310), dan uji (154). Model YOLOv11s-seg dilatih 50 *epoch* dengan *early stopping* menghasilkan mAP@50 sebesar 0,9766, *precision* 0,9688, *recall* 0,9775, dan *F1-score* 0,9730. Model GRU dua lapisan (96 unit tersembunyi, *dropout* 0,25) dilatih pada 208 urutan teraugmentasi (*sliding window* 7 hari) dari 87 record data gizi nyata 3 SPPG (Desember 2025–Mei 2026), menghasilkan MAE 45,85 kkal dan RMSE 60,90 kkal untuk energi porsi besar (80:20). Kedua model diintegrasikan ke dalam aplikasi berbasis web yang menyatukan identifikasi menu otomatis, estimasi kandungan gizi, rekomendasi menu berbasis GRU, dan analisis kecukupan AKG.

Kata Kunci: *Gated Recurrent Unit*, Makan Bergizi Gratis, Prediksi Gizi, Segmentasi Makanan, YOLOv11.

1. Pendahuluan

Model Segmentasi Menu Makanan Berbasis YOLOv11 untuk Prediksi Harian pada Program Makan Bergizi Gratis (MBG). Program MBG merupakan kebijakan strategis pemerintah Indonesia yang menyediakan makanan bergizi bagi siswa usia sekolah sebagai investasi jangka panjang dalam bidang kesehatan dan pendidikan nasional. Pada tataran operasional, program ini memerlukan sistem yang mampu mengidentifikasi jenis menu makanan secara otomatis, mengestimasi kandungan gizi, serta memprediksi kebutuhan nutrisi harian berdasarkan pola konsumsi historis. Dalam bidang nutrisi, aplikasi teknologi ini mencakup penilaian diet otomatis, rekomendasi nutrisi yang dipersonalisasi, serta analisis pola konsumsi makanan yang sebelumnya dilakukan secara manual dan memakan waktu dengan hasil yang lebih efisien dan akurat. Studi sistematis oleh Armand *et al.* (2024) menunjukkan bahwa penerapan AI dalam analisis gizi mampu meningkatkan efisiensi dan akurasi penilaian diet secara signifikan.


Beberapa penelitian sebelumnya menunjukkan bahwa penerapan deep learning dalam bidang nutrisi dan pengolahan citra makanan memberikan hasil yang menjanjikan. Armand *et al.* (2024) menjelaskan bahwa teknologi AI mampu meningkatkan efisiensi dan akurasi dalam analisis asupan makanan dibandingkan metode konvensional. O'Hara *et al.* (2024) juga menyatakan bahwa sistem digital dalam pemantauan gizi dapat meningkatkan kualitas evaluasi dan pengambilan keputusan berbasis data. Dalam bidang *computer vision*, algoritma *You Only Look Once* (YOLO) telah banyak digunakan untuk deteksi dan segmentasi objek secara *real-time* dengan tingkat akurasi tinggi, termasuk dalam identifikasi jenis makanan (Utami *et al.*, 2023). Penerapan YOLOv11 secara khusus untuk deteksi makanan pada piring saji di lingkungan kantin juga telah didemonstrasikan oleh Ferreira *et al.* (2025), yang menunjukkan

kemampuan model tersebut dalam mendeteksi sisa makanan secara otomatis dengan akurasi tinggi pada konteks pelayanan makanan institusional. Sementara itu, dalam permasalahan prediksi deret waktu, algoritma *Gated Recurrent Unit* (GRU) terbukti mampu memodelkan pola temporal secara efektif dengan kompleksitas komputasi yang lebih rendah dibandingkan LSTM, namun tetap menghasilkan performa prediksi yang baik (Meriani & Rahmatulloh, 2024).

Meskipun demikian, penelitian-penelitian tersebut umumnya berfokus pada pengenalan makanan secara umum tanpa mempertimbangkan konteks spesifik distribusi makan bergizi harian dan standar AKG yang ditetapkan dalam Program MBG. Belum terdapat penelitian yang secara eksplisit mengintegrasikan YOLOv11 dan GRU dalam satu pipeline untuk mendukung operasional SPPG di Program MBG. Berdasarkan permasalahan dan hasil penelitian sebelumnya, model terintegrasi berbasis algoritma YOLOv11 dan GRU diusulkan untuk mendukung segmentasi menu makanan berbasis citra dan prediksi kebutuhan nutrisi harian dalam Program Makan Bergizi Gratis (MBG). Integrasi kedua metode ini diharapkan mampu menghasilkan sistem yang dapat mengidentifikasi jenis makanan secara otomatis, menghitung estimasi kandungan gizi, serta memprediksi kebutuhan nutrisi berdasarkan pola historis konsumsi. Dengan pendekatan tersebut, proses perencanaan dan evaluasi gizi dapat dilakukan secara lebih akurat, efisien, dan berbasis data, sehingga mendukung optimalisasi pelaksanaan Program MBG secara berkelanjutan.

2. Metodologi


Knowledge Discovery in Databases (KDD) yang meliputi delapan tahapan terstruktur: (1) perencanaan tujuan dan lingkup penelitian; (2) studi literatur melalui telaah jurnal ilmiah dan buku yang relevan sebagai landasan metodologis (Paul *et al.*, 2021); (3) seleksi data; (4) *preprocessing* dan pembersihan data; (5) transformasi data; (6) penggalian data atau *data mining* menggunakan YOLOv11 dan GRU; (7) evaluasi pola dan analisis hasil; serta (8) penyajian pengetahuan melalui implementasi sistem berbasis web. Alur tahapan penelitian secara lengkap ditunjukkan pada Gambar 1.



Gambar 1: Alur metode penelitian berbasis KDD.

2.1 Bahan dan Data

Citra dikumpulkan menggunakan kamera iPhone 11 (resolusi 4032×3024 piksel) dalam kondisi pencahayaan indoor alami maupun buatan, dengan sudut pengambilan dari atas (top-down) dan diagonal pada jarak 20 - 40 cm dari objek makanan. Variasi kondisi pengambilan mencakup perbedaan wadah penyajian, tata letak makanan di atas nampan, dan latar belakang meja distribusi SPPG untuk mendukung kemampuan generalisasi model, dengan rata-rata 155 citra per jenis menu, mencakup 10 variasi kombinasi menu harian MBG dengan distribusi 4 hingga 5 jenis makanan per hari. Setiap jenis makanan dilengkapi informasi kandungan gizi yang meliputi energi (kkal), protein (g), lemak (g), karbohidrat (g), dan serat (g) berdasarkan standar Tabel Komposisi Pangan Indonesia (TKPI). Gambar 2 menampilkan contoh dokumentasi citra dataset yang telah dikumpulkan dari program MBG.



Gambar 2: Contoh dokumentasi dataset citra menu makanan MBG.

Kedua, data numerik deret waktu berupa 87 record data gizi harian dari 3 SPPG, yaitu SPPG Bogor Kemang, SPPG Bogor Kemang Jampang, dan SPPG Bogor Kemang Jampang 2, yang dikumpulkan dari periode 1 Desember 2025 hingga 19 Mei 2026. Data riil ini mencakup 10 fitur gizi numerik untuk dua ukuran porsi (porsi besar dan porsi kecil) meliputi energi (kkal), protein (g), lemak (g), serat (g), dan karbohidrat (g), serta informasi menu dan komposisi 233 komponen makanan unik. Standar porsi makan siang MBG ditetapkan sebesar 30 - 35% dari kebutuhan energi harian, menghasilkan standar seperti Tabel 1.

Tabel 1: Standar kebutuhan *energi* dan gizi makan siang MBG (30-35% AKG).

Kelompok Usia	<i>Energi (kkal)</i>	<i>Protein (g)</i>	<i>Lemak (g)</i>	<i>Karbohidrat (g)</i>
10-12 tahun (porsi kecil)	600 – 680	≥ 15	≤ 30	82 – 99
13-15 tahun (porsi besar)	690 – 748	≥ 20	≤ 35	95 – 107
16-18 tahun (porsi besar)	748 – 805	≥ 20	≤ 35	107 – 115

2.2 Metode Penelitian

2.2.1 *Preprocessing* dan Transformasi Data

Preprocessing data citra dilakukan melalui proses anotasi menggunakan platform anotasi berbasis YOLO, di mana setiap citra dianotasi untuk menentukan lokasi dan bentuk objek dalam format *instance segmentation mask* beserta bounding box sesuai format label YOLO. Dataset kemudian dibagi dengan proporsi 70% data pelatihan (1.084 citra), 20% data validasi (310 citra), dan 10% data pengujian (154 citra). *Augmentasi* diterapkan melalui sembilan jenis *transformasi* sebagaimana Tabel 2 untuk meningkatkan kemampuan generalisasi model dengan mensimulasikan variasi kondisi pengambilan citra di lapangan.

Tabel 2: Jenis *transformasi augmentasi* data citra.

No	Jenis <i>Transformasi</i>	No	Jenis <i>Transformasi</i>
1	<i>Horizontal Flip</i>	6	Penyesuaian Saturasi ($\pm 25\%$)
2	<i>Rotasi 90°</i> (searah/berlawanan)	7	Penyesuaian <i>Brightness</i> ($\pm 15\%$)
3	<i>Rotasi Minor</i> (-15° s/d $+15^\circ$)	8	Efek Blur (hingga 2 piksel)

Evaluasi kinerja model menggunakan metrik standar deteksi objek, yaitu *precision*, *recall*, *F1-score*, dan *Mean Average Precision* (mAP). *Precision* dihitung menggunakan persamaan:

$$Precision = \frac{TP}{TP + FP}. \quad (1)$$

Recall dihitung menggunakan persamaan:

$$Recall = \frac{TP}{TP + FN}. \quad (2)$$

F1-score merupakan rata-rata harmonik antara *precision* dan *recall* yang dirumuskan sebagai:

$$F1-Score = \frac{2 \times Precision \times Recall}{Precision + Recall}. \quad (3)$$

Sedangkan *Mean Average Precision* pada *threshold* IoU 0,5 dihitung menggunakan persamaan:

$$mAP@50 = \frac{1}{N} \sum_{k=1}^N AP_k. \quad (4)$$

dengan N menyatakan jumlah kelas dan AP_k merupakan *Average Precision* pada kelas ke- k . Fungsi loss total pada YOLOv11 dirumuskan sebagai:

$$L_{total} = L_{cls} + L_{box} + L_{seg}. \quad (5)$$

di mana L_{cls} merupakan *classification loss*, L_{box} merupakan *bounding box regression loss*, dan L_{seg} merupakan *segmentation loss*. komponen L_{box} menggunakan *Complete Intersection over Union* (CloU) *loss* yang mempertimbangkan jarak pusat, rasio aspek, serta ukuran *bounding box* prediksi terhadap *ground truth* (Bochkovski et al., 2020).

2.2.3 Pemodelan *Gated Recurrent Unit* (GRU)

Arsitektur deep GRU dengan dua lapisan tersembunyi dipilih berdasarkan bukti empiris bahwa penambahan lapisan GRU mampu meningkatkan kemampuan model dalam menangkap pola temporal yang kompleks pada data deret waktu (Arwansyah et al., 2022). Model GRU menggunakan arsitektur dua lapisan dengan 96 unit tersembunyi pada setiap lapisan dan dropout sebesar 0,25 untuk meningkatkan kemampuan generalisasi model. Keluaran model terdiri atas dua komponen, yaitu: (1) *regresi* 10 fitur gizi yang mencakup energi, protein, lemak, serat, dan karbohidrat untuk porsi besar dan kecil; serta (2) klasifikasi multi-label terhadap 233 komponen makanan untuk rekomendasi menu. Mekanisme gerbang pada GRU meliputi update gate yang dirumuskan sebagai:

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z). \quad (6)$$

yang berfungsi mengontrol seberapa banyak informasi masa lalu dipertahankan, serta *reset gate* yang dirumuskan sebagai:


$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r). \quad (7)$$

Pelatihan model dilakukan hingga maksimal 120 *epoch* dengan mekanisme early stopping (*patience* = 20) menggunakan *optimizer AdamW* dengan *weight decay* 1e-4 dan *batch size* 16. Konfigurasi pembagian data 80:20 digunakan berdasarkan keterbatasan jumlah data nyata, menghasilkan 52 *sequence* asli yang ditingkatkan melalui *noise augmentation* menjadi 208 *sequence* pelatihan dan 14 *sequence* validasi. Pemilihan arsitektur GRU didasarkan pada kemampuannya menangkap dependensi temporal jangka panjang pada data sekuensial dengan kompleksitas komputasi yang lebih efisien dibandingkan LSTM. Kemampuan model berbasis GRU dalam memprediksi status dan kebutuhan gizi anak secara akurat dari data historis longitudinal telah dibuktikan oleh Begashaw *et al.* (2025).

3. Hasil dan Pembahasan

3.1 Evaluasi Model YOLOv11s-seg

Evaluasi model YOLOv11s-seg pada data pengujian menunjukkan performa yang sangat baik pada 39 kelas makanan MBG. Berdasarkan *confusion matrix* yang ditampilkan pada Gambar 5, diperoleh total *True Positive* (TP) = 1.585, *False Positive* (FP) = 8, dan *False Negative* (FN) = 8. Nilai dominan pada diagonal utama *confusion matrix* mengindikasikan bahwa sebagian besar objek makanan berhasil diklasifikasikan dengan benar, sementara kesalahan klasifikasi antar kelas terjadi dalam jumlah yang sangat kecil.



Gambar 4: *Confusion matrix (absolute)* evaluasi model YOLOv11s-.


Tabel 3: Ringkasan metrik evaluasi model YOLOv11s-seg.

Metrik Evaluasi	Nilai	Keterangan
<i>True Positive</i> (TP)	1.585	Objek terklasifikasi benar
<i>False Positive</i> (FP)	8	Deteksi salah positif
<i>False Negative</i> (FN)	8	Objek tidak terdeteksi
<i>Precision</i> (rata-rata)	0,9688	96,88% prediksi positif benar
<i>Recall</i> (rata-rata)	0,9775	97,75% objek terdeteksi
<i>F1-Score</i> (rata-rata)	0,9730	<i>Harmonik precision-recall</i>
mAP@50	0,9766	<i>Mean Average Precision @IoU 0,5</i>

Dari 39 kelas makanan yang diuji, sebagian besar kelas memperoleh nilai *F1-score* di atas 0,95 dan beberapa kelas mendekati nilai sempurna 1,0. Hasil tersebut menunjukkan bahwa model YOLOv11s-seg mampu melakukan deteksi dan segmentasi menu makanan MBG dengan tingkat akurasi yang sangat baik. Nilai mAP@50 sebesar 0,9766 menunjukkan bahwa model memiliki kemampuan tinggi dalam mengenali objek makanan pada berbagai variasi menu MBG secara konsisten. Selain itu, nilai *precision* dan *recall* yang tinggi mengindikasikan bahwa model mampu meminimalkan kesalahan deteksi positif maupun objek yang tidak terdeteksi. Hasil evaluasi ini menunjukkan bahwa pendekatan YOLOv11s-seg efektif diterapkan untuk segmentasi dan identifikasi menu makanan pada sistem pemantauan gizi Program MBG.

3.2 Evaluasi Model GRU

Evaluasi model GRU dilakukan menggunakan 14 sequence validasi yang tidak terlibat dalam pelatihan. Proses pelatihan dihentikan lebih awal pada *epoch* ke-28 melalui mekanisme *early stopping*, dengan *best validation loss* sebesar 0,3245 yang mengindikasikan kemampuan model dalam mempelajari pola temporal data nyata. Grafik konvergensi pelatihan ditampilkan pada Gambar 6.

Gambar 5: Kurva *training loss* dan *validation loss* model GRU.


Tabel 4: Hasil evaluasi model GRU pada data validasi.

Fitur Gizi	MAE	RMSE	Rata-rata Aktual
Energi (kkal)	45,85	60,90	640,57
Protein (g)	3,37	5,35	20,79
Lemak (g)	3,31	4,61	22,14
Serat (g)	2,02	2,50	3,60
Karbohidrat (g)	16,25	24,55	86,26
Energi (kkal)	53,38	73,36	438,31
Protein (g)	3,19	4,38	15,10
Lemak (g)	3,74	4,65	15,60
Serat (g)	1,48	1,80	2,66
Karbohidrat (g)	9,31	11,96	62,78

Berdasarkan Tabel 4, model GRU menghasilkan MAE energi sebesar 45,85 kkal dan RMSE 60,90 kkal untuk porsi besar, serta MAE energi 53,38 kkal dan RMSE 73,36 kkal untuk porsi kecil pada konfigurasi 80:20. Nilai galat ini wajar mengingat variasi energi data nyata berkisar antara 481–745 kkal dan keterbatasan jumlah *sequence validasi* (14 *sequence*). Jumlah 14 *sequence validasi* yang relatif kecil merupakan implikasi langsung dari keterbatasan data historis nyata Program MBG yang baru berjalan sejak Desember 2025. Keterbatasan ini berpotensi memengaruhi representativitas evaluasi, khususnya pada performa klasifikasi komponen makanan yang menghasilkan *F1-score micro* sebesar 0,058 nilai yang rendah bukan karena kelemahan arsitektur model, melainkan karena sparsitas label pada 233 kelas komponen makanan dari hanya 14 *sequence* uji. Sebagai perbandingan, prediksi kandungan gizi numerik yang lebih stabil secara distribusi menghasilkan MAE energi 45,85 kkal (7,16% dari rata-rata aktual 640,57 kkal), yang menunjukkan kemampuan model dalam menangkap pola temporal gizi meskipun dengan data terbatas. Evaluasi yang lebih representatif memerlukan perluasan data dari lebih banyak SPPG dan periode waktu yang lebih Panjang. Untuk prediksi protein dan lemak porsi besar, model mencapai MAE masing-masing 3,37 g dan 3,31 g. Prediksi komponen makanan menggunakan *threshold* 0,35 menghasilkan *accuracy micro* 73,27%, dengan *precision* 0,0314, *recall* 0,4030, dan *F1-score* 0,0583, yang mencerminkan tantangan sparsitas label pada 233 kelas makanan dari data nyata.

3.3 Integrasi Sistem dan Antarmuka Web

Kedua model diintegrasikan ke dalam aplikasi berbasis web menggunakan Python yang memungkinkan pengguna mengunggah citra menu makanan dan mendapatkan secara langsung: (1) hasil deteksi dan segmentasi instansi beserta label kelas dan *confidence score*; (2) estimasi total kandungan gizi berdasarkan menu yang terdeteksi; (3) rekomendasi menu untuk hari berikutnya berdasarkan prediksi model GRU; serta (4) analisis kecukupan gizi terhadap standar AKG. Antarmuka halaman deteksi menu ditampilkan pada Gambar 6.



Gambar 6: Antarmuka web halaman deteksi dan segmentasi menu makanan MBG.

Tabel 5 menunjukkan contoh output rekomendasi menu hari berikutnya yang dihasilkan sistem berdasarkan prediksi model GRU, beserta nilai probabilitas dan *final score* yang memperhitungkan *diversity penalty* untuk memastikan variasi menu yang memadai bagi siswa.

Tabel 5: Contoh output rekomendasi menu hari berikutnya (prediksi model GRU).

No	Jenis Makanan	Food Score	Nutrition Score
1	Nasi, Dori Asam Manis, Tahu Goreng, Tumis Jagung Semi, Wortel & Kapri, Jeruk	0,580	0,819
2	Nasi, Dori Lada Hitam, Tempe Goreng, Tumis Jagung Semi dan Wortel, Jeruk	0,589	0,762
3	Lontong, Telur Rebus, Tahu Kukus, Kuah Lontong, Sayur Isi Pepaya, Pisang	0,523	0,862
4	Susu Full Cream, Apel Fuji, Dimsum	0,586	0,717
5	Nasi, Pisang Cavendish, Adamame, Dori Asam Manis, Tumis Jagung	0,538	0,775

Tabel 6 menampilkan prediksi total kandungan gizi dan analisis kecukupan terhadap standar AKG. Sistem secara otomatis membandingkan total gizi menu yang terdeteksi dengan nilai *mid-point* AKG makan siang dan memberikan status kecukupan.



Gambar 7: Prediksi total kandungan gizi dan analisis kecukupan AKG.

Gambar 7 menampilkan kartu rekomendasi menu hari berikutnya yang dihasilkan sistem untuk SPPG. Panel kiri menyajikan prediksi kandungan gizi menu rekomendasi terhadap standar AKG dalam dua kategori porsi dengan indikator status kecukupan gizi secara visual. Panel kanan atas menampilkan delapan komponen makanan dengan probabilitas tertinggi berdasarkan prediksi model GRU, sedangkan panel kanan bawah menyajikan radar chart profil nutrisi prediksi relatif terhadap nilai tengah AKG. Visualisasi terpadu ini memungkinkan pengelola program MBG mengidentifikasi kecukupan setiap zat gizi dan komponen makanan yang disarankan secara bersamaan dalam satu tampilan berbasis data.

4. Simpulan dan Saran

Model GRU dilatih pada 87 *record* data nyata dari 3 SPPG dengan arsitektur dua lapisan (96 *hidden units*, *dropout* 0,25) dan *sliding window* 7 hari, menghasilkan MAE energi 45,85 kkal dan RMSE 60,90 kkal untuk porsi besar (konfigurasi 80:20), dengan *accuracy* multi-label komponen makanan sebesar 73,27%. Integrasi kedua model ke dalam aplikasi berbasis web berhasil menyatukan fungsi identifikasi menu otomatis, estimasi kandungan gizi, rekomendasi menu harian berbasis data nyata, serta analisis kecukupan gizi AKG dalam satu sistem yang efisien dan berbasis data.

Untuk pengembangan selanjutnya, disarankan: (1) memperluas cakupan dataset citra dan data gizi dengan variasi menu MBG dari lebih banyak SPPG di berbagai daerah Indonesia guna meningkatkan kemampuan generalisasi model; (2) memperpanjang periode pengumpulan data historis nyata guna meningkatkan jumlah *sequence* pelatihan GRU dan mengatasi tantangan sparsitas label komponen makanan; (3) mengeksplorasi arsitektur YOLOv11n yang lebih ringan untuk deployment pada perangkat mobile; dan (4) mengembangkan fitur pemantauan gizi jangka panjang berbasis riwayat individu siswa, serta mengeksplorasi integrasi model generatif untuk rekomendasi yang lebih adaptif dan dipersonalisasi sebagaimana diusulkan oleh (Papastratis *et al.*, 2024), guna mendukung intervensi gizi yang lebih tepat sasaran.

Daftar Pustaka

- 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). <https://doi.org/10.3390/nu16071073>
- Arwansyah, A., Suryani, S., SY, H., Usman, U., Ahyuna, A., & Alam, S. (2022). Time Series Forecasting Menggunakan Deep Gated Recurrent Units. *Digital Transformation Technology*, 4(1), 410–416. <https://doi.org/10.47709/digitech.v4i1.4141>
- Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal Speed and Accuracy of Object Detection. *arXiv preprint arXiv:2004.10934*. <https://doi.org/10.48550/arXiv.2004.10934>
- O'Hara, C., & Gibney, E. R. (2024). Dietary Intake Assessment Using a Novel, Generic Meal-Based Recall and a 24-Hour Recall: Comparison Study. *Journal of Medical Internet Research*, 26(1). <https://doi.org/10.2196/48817>
- Paul, J., Lim, W. M., O'Cass, A., Hao, A. W., & Bresciani, S. (2021). Scientific procedures and rationales for systematic literature reviews (SPAR-4-SLR). *International Journal of Consumer Studies*. <https://doi.org/10.1111/ijcs.12695>
- Utami, G. C., Widiawati, C. R., & Subarkah, P. (2023). Detection of Indonesian Food to Estimate Nutritional Information Using YOLOv5. *Teknika*, 12(2), 158–165. <https://doi.org/10.34148/teknika.v12i2.636>
- Meriani, A. P., & Rahmatulloh, A. (2024). Perbandingan Gated Recurrent Unit (GRU) dan Algoritma Long Short Term Memory (LSTM) Linear Regression dalam Prediksi Harga Emas Menggunakan Model Time Series. *Jurnal Informatika dan Teknik Elektro Terapan*, 12(1). <https://doi.org/10.23960/jitet.v12i1.3808>
- Ferreira, J., Cerqueira, P., & Ribeiro, J. (2025). Food waste detection in canteen plates using YOLOv11. *Applied Sciences*, 15(13), 7137. <https://doi.org/10.3390/app15137137>
- Papastratis, I., Konstantinidis, D., & Daras, P. (2024). AI nutrition recommendation using a deep generative model and ChatGPT. *Scientific Reports*, 14, 15349. <https://doi.org/10.1038/s41598-024-65438-x>
- Begashaw, G. B., Zewotir, T., & Fenta, H. M. (2025). A deep learning approach for classifying and predicting children's nutritional status in Ethiopia using LSTM-FC neural networks. *BioData Mining*, 18, 25. <https://doi.org/10.1186/s13040-025-00425-0>