

Pengembangan Sistem Estimasi Gizi dan Kalori Berbasis MobilenetV3 dan Tensorflow

Sholeh Abdul Irfan Torodipo^{1*}, Nurchim², Sri Sumarlinda³

^{1*}Teknik Informatika

Universitas Duta Bangsa Surakarta

^{1*}220103034@mhs.udb.ac.id

²Teknik Informatika

Universitas Duta Bangsa Surakarta

²nurchim@udb.ac.id

³Teknik Informatika

Universitas Duta Bangsa Surakarta

³sri_sumarlinda@udb.ac.id

Abstrak— Manajemen nutrisi adalah faktor penentu dalam mencapai target kesehatan, baik untuk penurunan berat badan, pemeliharaan berat badan ideal, maupun peningkatan massa otot, namun masyarakat sering mengalami kesulitan mengidentifikasi kandungan gizi dan kalori makanan secara cepat dan akurat sehingga estimasi yang dihasilkan rawan bias. Penelitian ini bertujuan merancang dan mengembangkan sistem aplikasi estimasi gizi dan kalori berbasis Deep Learning yang mampu mengenali 34 kelas makanan Indonesia dan buah-buahan lokal dari citra digital secara otomatis dan real-time. Sistem dibangun menggunakan arsitektur MobileNetV3 dan framework TensorFlow dengan metode CNN dan Transfer Learning dua fase (feature extraction dan fine-tuning) serta augmentasi data, kemudian diimplementasikan sebagai Progressive Web App (PWA) dengan backend Flask dan frontend Vanilla JS yang mengintegrasikan hasil klasifikasi dengan basis data TKPI dan fatsecret. Dataset terdiri dari 5.690 citra yang dibagi 80:10:10, dan evaluasi pada 569 citra uji menghasilkan akurasi 95,08% serta Weighted Average F1-Score 95,1%, melampaui target awal 85%. Hasil ini membuktikan bahwa sistem yang dikembangkan layak digunakan sebagai solusi praktis pemantauan nutrisi harian berbasis citra, baik dari sisi akurasi model maupun kelengkapan fitur aplikasi. Penelitian selanjutnya dapat diarahkan pada penambahan deteksi multi-objek dalam satu frame serta integrasi sensor berat porsi untuk meningkatkan presisi estimasi kalori.

Kata kunci— Estimasi Kalori, Deep Learning, MobileNetV3, Transfer Learning, Deteksi Makanan

Abstract— Nutrition management is a key factor in achieving health goals, yet many people struggle to quickly and accurately identify the nutritional content and caloric value of food, often leading to biased manual estimation. This research aims to design and develop a nutrition and calorie estimation application capable of automatically and instantly recognizing 34 classes of Indonesian foods and local fruits from digital images. The system is built using the MobileNetV3 architecture and TensorFlow framework with a CNN method and two-phase Transfer Learning (feature extraction and fine-tuning) along with data augmentation, then deployed as a Progressive Web App (PWA) with a Flask backend and Vanilla JS frontend that integrates classification results with the TKPI and fatsecret databases. The dataset consists of 5,690 images split 80:10:10, and evaluation on 569 test images achieved 95.08% accuracy and a Weighted Average F1-Score of 95.1%, exceeding the 85% target. These results confirm that the developed system is feasible as a practical solution for image-based daily nutrition monitoring, both in terms of model accuracy and application feature completeness. Future research may focus on adding multi-object detection within a single frame and integrating a portion-weight sensor to improve calorie estimation precision.

Keywords— Calorie Estimation, Deep Learning, MobileNetV3, Transfer Learning, Food Detection

I. PENDAHULUAN

Keberhasilan mencapai target kesehatan baik menurunkan berat badan, menjaga berat badan ideal, maupun menambah massa otot sangat ditentukan oleh bagaimana nutrisi harian dikelola. Manajemen diet yang efektif sendiri tidak bisa dilepaskan dari peran pemantauan makanan berbasis citra [1]. Kebutuhan akan pengawasan gizi ini semakin terasa perlu sejak Program Makanan Bergizi Gratis mulai diterapkan, sebab program makan sekolah hanya dapat dikatakan berhasil apabila mutu pelaksanaannya terus dipantau, evaluasinya didukung data yang valid, dan kandungan gizi pada tiap porsi yang diterima siswa benar-benar transparan [12][13].

Beberapa penelitian telah mengkaji berbagai solusi permasalahan ini, salah satunya metode pencatatan manual memiliki kelemahan pada tingkat subjektivitas yang tinggi sehingga sering menghasilkan estimasi kalori yang keliru [2]. Di sisi lain, pendekatan berbasis Mask R-CNN melalui platform web memang menghasilkan akurasi deteksi yang cukup baik [3], hanya saja kebutuhan komputasinya yang besar membuat performanya melambat ketika dijalankan pada perangkat dengan spesifikasi rendah. Pendekatan serupa menggunakan MobileNetV2 dengan Transfer Learning terbukti mampu mengklasifikasikan hingga 190 kategori makanan sekaligus menyajikan estimasi nutrisi secara real-time melalui integrasi basis data nutrisi [15]. Beberapa kajian sistematis justru


memperlihatkan bahwa otomatisasi food recognition dan nutrition analysis untuk dietary assessment kini telah mengalami kemajuan pesat berkat deep learning [4].

Untuk kebutuhan platform web, arsitektur MobileNetV3 yang dipadukan dengan Transfer Learning dinilai mampu menghadirkan keseimbangan yang tepat antara tingkat akurasi dan efisiensi komputasi. Hal ini diperkuat oleh temuan Patel & Modi [5] yang menunjukkan bahwa akurasi klasifikasi dapat terdongkrak hingga 95,3% ketika MobileNetV3 dikombinasikan dengan augmentasi data. Delimayanti dkk. [14] juga membuktikan bahwa MobileNetV3Large mencapai akurasi 99,85% pada pengenalan jajanan tradisional Indonesia, melampaui varian MobileNet sebelumnya secara signifikan. Srikanth dkk. [6] dan Suneela dkk. [7] juga memvalidasi efektivitas arsitektur MobileNet untuk tugas pengenalan makanan sekaligus estimasi kalori secara real-time.

Penelitian ini mengembangkan sistem estimasi gizi berbasis MobileNetV3 yang diintegrasikan dengan Flask dan TensorFlow.js sebagai aplikasi web responsif. Sistem menggabungkan output klasifikasi dengan basis data nutrisi TKPI dan fatsecret untuk menyajikan informasi kalori, karbohidrat, protein, dan lemak secara instan kepada pengguna.

II. METODOLOGI PENELITIAN

Penelitian ini menggunakan pendekatan kuantitatif eksperimental yang dilaksanakan melalui lima tahapan berurutan dan iteratif, yaitu: (A) dataset dan pengumpulan data, (B) pra-pemrosesan data, (C) perancangan arsitektur model dan transfer learning menggunakan MobileNetV3 dan TensorFlow, (D) deployment sistem web, serta (E) evaluasi model dan pengujian fungsional aplikasi. Gambar 1 menunjukkan alur tahapan penelitian beserta posisi MobileNetV3 dan TensorFlow dalam keseluruhan proses.



Gambar 1 Alur Tahapan Penelitian

A. Dataset dan Pengumpulan Data

Dataset terdiri dari lebih dari 30 kelas makanan populer Indonesia dan buah-buahan lokal. Data dikumpulkan dari dua sumber, yaitu repositori publik Kaggle (Food-101) untuk kelas dengan ketersediaan data melimpah dan pengumpulan mandiri dari gambar di Google. Dataset dibagi dengan proporsi 80:10:10 untuk data training, validasi, dan pengujian menggunakan stratified sampling.

B. Pra-pemrosesan Data

Seluruh citra menjalani tahapan preprocessing: (1) resizing ke 224×224 piksel sesuai input standar MobileNetV3, (2) pra-pemrosesan otomatis secara internal oleh arsitektur MobileNetV3 tanpa perlu normalisasi rentang 0-1 secara manual, dan (3) augmentasi data pada data training menggunakan rotation ($\pm 40^\circ$), distorsi geser (Shear) sebesar 0.15, horizontal flip, width/height shift (0.2), zoom (0.2), dan brightness adjustment (0.7–1.3). Augmentasi tidak diterapkan pada data validasi dan uji.

C. Arsitektur Model dan Transfer Learning

Proses pembangunan model mengadopsi skema Transfer Learning dua fase, dengan MobileNetV3 Large yang telah di-pretrained pada ImageNet sebagai base model. Pada Fase 1 (Feature

Extraction), seluruh lapisan base model dibekukan terlebih dahulu sehingga hanya lapisan klasifikasi yang baru ditambahkan saja yang menjalani proses pelatihan (menggunakan optimizer Adam dengan $lr=1e-3$). Fase 2 (Fine-tuning): lapisan teratas base model di-unfreeze dan dilatih ulang dengan $lr=1e-4$ yang lebih kecil untuk menyesuaikan fitur dengan karakteristik makanan Indonesia. Untuk mencegah overfitting pada fitur ekstraksi baru, ditambahkan Batch Normalization, dua layer Dense (256 dan 128 neuron), serta dua layer Dropout dengan rate 0.5 dan 0.3 sebelum layer klasifikasi akhir Softmax (34 neuron).

D. Deployment Sistem Web

Model terlatih berformat .keras di-deploy menggunakan kerangka kerja backend Flask. Backend API ini mengimplementasikan library TensorFlow (Python) untuk memuat model secara dinamis dan mengeksekusi inferensi citra di sisi server (Server-Side Inference). Pendekatan ini dipilih agar beban komputasi TensorFlow tidak membebani perangkat pengguna. Frontend dibangun menggunakan HTML5, CSS3, dan Vanilla JavaScript, yang bertugas memetakan hasil prediksi dari backend TensorFlow ke dalam basis data nutrisi lokal untuk ditampilkan kepada pengguna.

E. Metode Evaluasi


Evaluasi model dilakukan menggunakan empat metrik: (1) Akurasi keseluruhan, (2) Confusion Matrix untuk analisis kesalahan antar kelas, (3) Precision, Recall, dan F1-Score per kelas, serta (4) Loss Graph untuk mendiagnosis konvergensi dan overfitting. Pengujian fungsional sistem menggunakan metode Black Box Testing untuk memverifikasi seluruh fitur dari perspektif pengguna [9].

III. HASIL DAN PEMBAHASAN

A. Karakteristik Dataset

Dataset yang digunakan terdiri dari 5.690 citra yang terbagi ke dalam 34 kelas makanan populer Indonesia dan buah-buahan lokal, dikumpulkan dari repositori publik Kaggle (Food-101) serta pengumpulan mandiri dari gambar di Google. Seluruh citra dibagi dengan proporsi 80:10:10 untuk data training, validasi, dan pengujian menggunakan

stratified sampling, menghasilkan 569 citra pada data uji. Sebelum pelatihan, seluruh citra di-resize ke 224×224 piksel sesuai input standar MobileNetV3, kemudian data training memperoleh augmentasi berupa rotation ($\pm 40^\circ$), shear 0.15, horizontal flip, width/height shift (0.2), zoom (0.2), dan brightness adjustment (0.7–1.3) untuk memperkaya variasi data dan mengurangi risiko overfitting. Augmentasi tidak diterapkan pada data validasi dan uji agar evaluasi tetap merepresentasikan kondisi citra asli.



Gambar 2 Contoh Sampel Dataset per Kelas

B. Konfigurasi Hyperparameter


Tabel 1 menyajikan konfigurasi hyperparameter yang digunakan pada kedua fase pelatihan model, mencakup optimizer, learning rate tiap fase, batch size, fungsi loss, dropout, dan kriteria early stopping.

Tabel 1 Konfigurasi Hyperparameter


Hyperparameter	Nilai
Base Model	MobileNetV3 Large
Optimizer	Adam
Learning Rate (F1)	0,001 (1e-3)
Learning Rate (F2)	0,0001 (1e-4)
Batch Size	32
Loss Function	Categorical Cross-Entropy
Dropout	0.5 dan 0.3
Early Stopping	Patience = 5 (val_loss)

C. Pengujian Model

Pelatihan berlangsung 40 epoch dalam dua fase dan berhenti pada epoch 38. Gambar 3 dan gambar 4 menunjukkan grafik akurasi dan loss seluruh proses pelatihan.



Gambar 3 Grafik Akurasi Model



Gambar 4 Grafik Loss Function

Pada Fase 1 (epoch 1–14), validation accuracy melampaui target 85% mulai epoch ke-7, mencapai ~88%. Penurunan sesaat pada awal Fase 2 (epoch 15–16) merupakan fenomena wajar pada Transfer Learning akibat penyesuaian learning rate yang lebih kecil saat fine-tuning dimulai [5]. Setelah stabilisasi, akurasi terus meningkat hingga konvergen di epoch 35–38 dengan training accuracy ~95% dan validation accuracy ~94%. Selisih kecil antara keduanya mengindikasikan tidak adanya overfitting yang signifikan berkat dropout dan augmentasi data.


Grafik loss menunjukkan penurunan konsisten pada kedua fase: training loss turun dari ~2,7 ke ~0,1 dan validation loss secara konsisten lebih rendah sepanjang pelatihan, mengkonfirmasi kemampuan generalisasi model yang baik.

Model dievaluasi pada 569 citra uji dan mencapai test accuracy 95,08% dengan loss 0,1804. Tabel 2 menyajikan classification report beberapa kelas.

Tabel 2 Classification Report

Kelas	P	R	F1	Sup
nasi_goreng	0.96	0.83	0.89	30
mie_goreng	0.90	0.90	0.90	30
mie_ayam	1.00	0.93	0.96	30
bakso	1.00	0.84	0.91	13
rendang	1.00	1.00	1.00	13
sate_ayam	1.00	1.00	1.00	15
soto	0.92	0.81	0.86	16
semangka	1.00	1.00	1.00	13
pisang	1.00	1.00	1.00	10
pepaya	1.00	1.00	1.00	13
Accuracy			0.951	569
Macro Avg	0.960	0.959	0.958	569
Weighted Avg	0.955	0.951	0.951	569

Sebagian besar kelas mencapai F1-Score sempurna (1.00), seperti nasi putih, rendang, sate ayam, rawon, nasi padang, dan seluruh kelas buah, yaitu pisang, mangga, pepaya, semangka, jeruk. Beberapa kelas memiliki F1 di bawah 0.90 akibat kemiripan visual atau beragamnya topping, seperti gado-gado (F1: 0.86), soto (F1: 0.86), nasi goreng (F1: 0.89), ayam goreng (F1: 0.83).




Gambar 5 Subset Confusion Matrix

Secara keseluruhan, model menunjukkan dominasi prediksi benar pada diagonal utama. Mengingat jumlah 34 kelas terlalu padat untuk divisualisasikan secara utuh, Gambar 5 menampilkan cuplikan (subset) Confusion Matrix yang difokuskan pada kasus kesalahan klasifikasi tertinggi. Kesalahan paling signifikan terjadi antara


ikan_goreng–ikan_bakar (2 sampel) dan bakso–soto (2 sampel), konsisten dengan analisis per kelas. Walaupun terdapat sedikit misclassification pada kelas-kelas yang memiliki kemiripan visual tinggi tersebut, secara agregat untuk 34 kelas, Macro Average F1-Score mencapai 95,8% dan Weighted Average F1-Score 95,1%.

D. Pengujian Aplikasi

Sistem diimplementasikan sebagai Progressive Web App (PWA) yang dapat diakses melalui browser komputer maupun smartphone tanpa instalasi tambahan, dengan empat menu utama: Beranda, Jurnal, Riwayat, dan Profil. Gambar 6 menampilkan beranda (sebelum analisis) dan gambar 7 menampilkan hasil analisis pada tampilan web smartphone. Halaman beranda menyediakan tracker kalori harian, panel unggah citra via kamera atau galeri, dan pencarian makanan manual. Halaman hasil analisis menampilkan label estimasi (contoh: Mie Ayam, confidence 92,8%), estimasi 420 kkal per 250 gram, dan rincian makronutrien: karbohidrat 46,0 g, protein 18,0 g, lemak 16,0 g, bersumber dari fatsecret indonesia. Pengguna juga dapat menyesuaikan estimasi porsi melalui slider dinamis (25–300%) sebelum hasil dicatat ke Jurnal Harian, sehingga estimasi kalori dapat disesuaikan dengan ukuran porsi yang sebenarnya dikonsumsi.



Gambar 6 Beranda (sebelum deteksi)



Gambar 7 Hasil Deteksi

Verifikasi terhadap seluruh fitur sistem dari sudut pandang pengguna akhir tanpa perlu menelusuri

kode internal dilakukan melalui pengujian fungsional dengan metode Black Box Testing [8].

Terdapat 6 skenario uji diantaranya:

- Upload citra makanan valid (JPG/PNG)
- Akses kamera perangkat langsung
- Upload file bukan gambar (.pdf/.docx)
- Deteksi citra non-makanan
- Slider porsi dinamis (25–300%)
- Pencatatan ke Jurnal Harian

Status pass (berhasil) yang diperoleh dari keenam skenario uji menjadi bukti bahwa sistem telah berjalan sesuai dengan spesifikasi fungsional yang telah ditetapkan sebelumnya. Khusus untuk fitur slider porsi dinamis (25–300%) maupun Jurnal Harian, keduanya mengandalkan localStorage sehingga seluruh prosesnya berlangsung di sisi klien; pendekatan ini membuat sistem tidak bergantung pada koneksi server tambahan sekaligus menjaga performa dan privasi data pengguna.

E. Discussion

Hasil pengujian model menunjukkan bahwa akurasi 95,08% dan Weighted Average F1-Score 95,1% yang dicapai sistem melampaui penelitian Patel & Modi [4] (95,3% pada makanan India dengan arsitektur serupa namun domain berbeda) dan Srikanth dkk. [5] (92% dengan MobileNet standar), sehingga mengkonfirmasi bahwa fitur ImageNet bersifat transferable untuk pengenalan makanan lokal Indonesia. Khusus untuk kelas buah-buahan, capaian F1-Score sempurna (1,00) pada seluruh 5 kelas buah yang diuji konsisten dengan temuan Gulzar [16] yang menunjukkan bahwa Transfer Learning berbasis MobileNet mampu mencapai akurasi 99% pada klasifikasi 40 jenis buah, mengonfirmasi efektivitas arsitektur ringan ini untuk domain produk hortikultura. Kombinasi deteksi dan estimasi berat melalui arsitektur hybrid seperti yang ditunjukkan dalam penelitian terkait [10] serta pendekatan hybrid segmentasi-klasifikasi-estimasi volume pada penelitian lain [11] membuka peluang pengembangan lanjutan untuk meningkatkan akurasi estimasi nutrisi berbasis volume ke depannya.

Capaian akurasi model yang tinggi tidak serta-merta menjamin keberhasilan sistem secara keseluruhan apabila tidak diimbangi dengan antarmuka yang mudah digunakan dan fitur aplikasi

yang relevan dengan kebutuhan pengguna. Hasil pengujian fungsional menunjukkan bahwa seluruh 6 skenario uji, mulai dari unggah citra, akses kamera, penanganan input tidak valid, deteksi citra non-makanan, penyesuaian porsi, hingga pencatatan ke Jurnal Harian berjalan sesuai spesifikasi, sehingga model yang akurat dapat dimanfaatkan secara nyata oleh pengguna akhir melalui antarmuka PWA yang responsif. Dengan demikian, sistem berhasil menjembatani capaian teknis model deep learning dengan kebutuhan praktis pemantauan nutrisi harian, sejalan dengan tujuan penelitian untuk mengembangkan sistem aplikasi yang utuh dan bukan sekadar model klasifikasi citra.

IV. KESIMPULAN

Penelitian ini berhasil merancang dan mengembangkan sistem aplikasi estimasi gizi dan kalori, mulai dari model klasifikasi citra hingga antarmuka aplikasi web yang siap digunakan pengguna akhir. Pada sisi model, arsitektur MobileNetV3 dengan Transfer Learning dua fase berhasil mengklasifikasikan 34 kelas makanan Indonesia dan buah-buahan lokal dengan akurasi keseluruhan 95,08%, Weighted Average F1-Score 95,1%, Macro Average 95,8%, loss graph tanpa indikasi overfitting, serta confusion matrix yang mengkonfirmasi dominasi prediksi benar pada diagonal utama. Pada sisi aplikasi, sistem berhasil diimplementasikan sebagai Progressive Web App (PWA) yang mengintegrasikan hasil klasifikasi dengan basis data nutrisi TKPI dan fatsecret, dilengkapi fitur tracker kalori harian, penyesuaian porsi dinamis, dan Jurnal Harian, dengan seluruh 6 skenario Black Box Testing menghasilkan status pass (100%). Capaian pada kedua sisi tersebut membuktikan bahwa sistem layak digunakan sebagai solusi praktis pemantauan nutrisi harian berbasis citra, baik dari aspek keandalan model maupun kelengkapan fungsional aplikasi.

Penelitian selanjutnya dapat dikembangkan dengan menambahkan kemampuan deteksi multi-objek dalam satu frame dan integrasi sensor berat porsi untuk meningkatkan presisi estimasi kalori.

REFERENSI

- [1] A. Rouhafzay, G. Rouhafzay, dan J. Jbilou, "Image-based food monitoring and dietary management for patients living with diabetes: a scoping review of calorie counting applications," *Front. Nutr.*, vol.

- 12, no. March, 2025, doi: 10.3389/fnut.2025.1501946.
- [2] B. Kalivaraprasad, M. V. D. Prasad, dan N. K. Gattim, "Deep learning-based food calorie estimation method in dietary assessment: An advanced approach using convolutional neural networks," *Int. J. Adv. Comput. Sci. Appl.*, vol. 15, no. 3, hal. 1044–1050, 2024, doi: 10.14569/IJACSA.2024.01503104.
 - [3] Nadiyah, M. E. Putri, M. Khairi, M. Furqan, dan B. Yusman, "Jurnal Kecerdasan Buatan , Komputasi dan Teknologi Informasi Deteksi Objek Untuk Menghitung Perkiraan Kalori Makanan Menggunakan Metode R-CNN Mask Berbasis Web," vol. 5, no. 1, hal. 84–92, 2024.
 - [4] M. Mansouri, S. Benabdellah Chaouni, S. Jai Andaloussi, dan O. Ouchetto, "Deep Learning for Food Image Recognition and Nutrition Analysis Towards Chronic Diseases Monitoring: A Systematic Review," *SN Comput. Sci.*, vol. 4, no. 5, hal. 513, 2023, doi: 10.1007/s42979-023-01972-1.
 - [5] J. Patel dan K. Modi, "Indian Food Image Classification and Recognition with Transfer Learning Technique Using MobileNetV3 and Data Augmentation," in *The 4th International Electronic Conference on Applied Sciences*, 2023. doi: 10.3390/asec2023-15341.
 - [6] N. Srikanth, K. Sagar, C. Sravanthi, dan K. Saranya, "Deep Learning Driven Food Recognition and Calorie Estimation Using Mobile Net Architecture," in *2024 5th International Conference for Emerging Technology (INCET)*, 2024, hal. 1–7. doi: 10.1109/incet61516.2024.10593068.
 - [7] M. Suneela, M. Sahithi, N. Vamsi, N. B. Naik, dan N. S. Chowdary, "Enhancing Dietary Monitoring using Deep Learning: Food Recognition and Calorie Estimation," in *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 2024, hal. 1–6. doi: 10.1109/icccnt61001.2024.10725324.
 - [8] A. Alsajri dan A. V. Hacimahmud, "Review of deep learning: Convolutional Neural Network Algorithm," *Babylonian J. Mach. Learn.*, vol. 2023, hal. 19–25, 2023, doi: 10.58496/BJML/2023/004.
 - [9] M. Zen dan M. D. P. Ananda, "BULLETIN OF COMPUTER SCIENCE RESEARCH Implementasi dan Pengujian Menggunakan Metode BlackBox Testing Pada Sistem Informasi Tracer Study," vol. 4, no. 4, hal. 327–340, 2024, doi: 10.47065/bulletincsr.v4i4.359.
 - [10] C. Wimalasiri dan P. K. Sahoo, "Vision-Based Approach for Food Weight Estimation from 2D Images," 2024. doi: 10.48550/arXiv.2405.16478.
 - [11] R. Agarwal, T. Choudhury, N. J. Ahuja, dan T. Sarkar, "Hybrid Deep Learning Algorithm-Based Food Recognition and Calorie Estimation," *J. Food Process. Preserv.*, vol. 2023, hal. 6612302, 2023, doi: 10.1155/2023/6612302.
 - [12] Pramesthi, I. L., Wiradnyani, L. A., Anggraini, R., Februhartanty, J., Widaryat, W., Waluyo, B., Wahyunto, A. T., Mansyur, M., & Fahmida, U. (2025). Evaluating the Impact of Indonesia's National School Feeding Program (ProGAS) on Children's Nutrition and Learning Environment: A Mixed-Methods Approach. *Nutrients*, 17. <https://doi.org/10.3390/nu17223575>
 - [13] Sulistiani, T., Dewi, H., Fitriani, A., & Hartati, M. S. (2026). National Policies for Child Nutrition Security and Their Impact on Learning Outcomes. *Blantika: Multidisciplinary Journal*. <https://doi.org/10.57096/blantika.v4i1.473>
 - [14] Delimayanti, M. K., Azizah, Z., Danaryani, S., Widodo, R. A., & Nasution, S. R. M. (2025). A Comparative Study of Deep Learning Models for Digital Image Recognition of Traditional Indonesian Snacks. *2025 Tenth International Conference on Informatics and Computing (ICIC)*, 1-5. <https://doi.org/10.1109/icic68054.2025.11309401>
 - [15] Moumane, K., Asri, I. E., Cheniguer, T., & Elbiki, S. (2023). Food Recognition and Nutrition Estimation using MobileNetV2 CNN architecture and Transfer Learning. *2023 14th International Conference on Intelligent Systems: Theories and Applications (SITA)*, 1-7. <https://doi.org/10.1109/sita60746.2023.10373725>
 - [16] Gulzar, Y. (2023). Fruit Image Classification Model Based on MobileNetV2 with Deep Transfer Learning Technique. *Sustainability*. <https://doi.org/10.3390/su15031906>