RASA-ID: SISTEM ANALISIS GIZI MAKANAN INDONESIA BERBASIS YOLOV8M

Saniyatul Mawaddah[1)], Rijal Abbad Fakhrillah[1)], dan Khozinatus Sadah[2)]

[1]Departemen Teknik Informatika dan Komputer, Politeknik Elektronika Negeri Surabaya
[2]Departemen Teknologi Multimedia Kreatif, Politeknik Elektronika Negeri Surabaya

E-mail: rijalabbad@it.student.pens.ac.id

Abstract

Indonesia continues to struggle with a triple burden of malnutrition stunting, micronutrient deficiency, and obesity largely driven by poor dietary monitoring at the household level. Existing nutrition applications often rely on manual food logging and international databases that poorly represent Indonesian local foods. This study presents RASA-ID, an AI-based system that detects Indonesian foods from photos using YOLOv8m and automatically calculates nutritional values based on the 2020 Indonesian Food Composition Table (TKPI). The system handles multi-item detection in a single image and includes a user correction mechanism that lays the foundation for active learning, where feedback data is stored and exported as retraining candidates for the administrator; the retraining cycle itself was not executed in this study. YOLOv8m was trained on 18 food classes using a curated and augmented dataset of 13,840 images in total (12,123 for training, 885 for validation, and 832 for testing) with transfer learning from COCO pre-trained weights. Testing on 832 images yielded mAP50 of 94.49%, precision of 94.52%, recall of 92.23%, and an average inference speed of 22.19 ms per image, surpassing all predefined minimum targets. Functional testing across five scenarios confirmed that food detection, nutritional analysis, user correction, and the feedback-export mechanism all performed as intended. Evaluation in this study focused on detection performance; the accuracy of the resulting nutritional values against reference measurements was not quantitatively assessed and remains a direction for future work.

Keywords: *food detection, YOLOv8m, nutritional analysis, TKPI, active learning*

Abstract

Indonesia masih menghadapi tiga masalah gizi sekaligus, yaitu stunting, kekurangan zat gizi mikro, dan obesitas yang sebagian besar didorong oleh rendahnya pemantauan pola makan di tingkat rumah tangga. Aplikasi gizi yang tersedia saat ini sering bergantung pada pencatatan makanan secara manual dan basis data internasional yang kurang merepresentasikan makanan lokal Indonesia. Penelitian ini menghadirkan RASA-ID, sebuah sistem berbasis kecerdasan buatan yang mendeteksi makanan Indonesia dari foto menggunakan YOLOv8m dan secara otomatis menghitung nilai gizi berdasarkan Tabel Komposisi Pangan Indonesia (TKPI) 2020. Sistem ini mendukung deteksi beberapa jenis makanan dalam satu citra dan memiliki mekanisme koreksi pengguna yang menjadi fondasi *active learning*, di mana data umpan balik disimpan dan diekspor sebagai kandidat *retraining* untuk administrator; siklus *retraining* itu sendiri belum dilaksanakan dalam penelitian ini. YOLOv8m dilatih pada 18 kelas makanan menggunakan dataset hasil kurasi dan augmentasi sebanyak 13.840 gambar, yang terdiri atas 12.123 gambar untuk *training*, 885 untuk *validation*, dan 832 untuk *testing*, dengan metode *transfer learning* dari bobot *pre-trained* COCO. Pengujian pada 832 gambar menghasilkan mAP50 sebesar 94,49%, *precision* sebesar 94,52%, *recall* sebesar 92,23%, dan kecepatan inferensi rata-rata 22,19 ms per gambar, yang melampaui seluruh target minimum yang telah ditetapkan. Pengujian fungsional pada lima skenario mengonfirmasi bahwa deteksi makanan, analisis gizi, koreksi pengguna, dan mekanisme ekspor umpan balik berjalan sesuai dengan rancangan. Evaluasi dalam penelitian

ini berfokus pada performa deteksi; akurasi nilai gizi yang dihasilkan terhadap pengukuran referensi belum dievaluasi secara kuantitatif dan menjadi arah penelitian selanjutnya.

Kata kunci: *deteksi makanan, YOLOv8m, analisis gizi, TKPI, active learning*

PENDAHULUAN

Indonesia masih menghadapi tiga masalah gizi sekaligus, yaitu kekurangan gizi berupa *stunting* dan *wasting*, kekurangan zat gizi mikro, serta kelebihan gizi seperti *overweight* dan obesitas. Data Survei Kesehatan Indonesia (SKI) 2023 menunjukkan prevalensi *stunting* pada balita masih berada di angka 21,5%, sementara *overweight* mencapai 4,2% dan obesitas dewasa 23,4% (Kementerian Kesehatan RI, 2023). Pemerintah menargetkan penurunan angka *stunting* menjadi 14% pada tahun 2024. Kondisi ini sebagian besar disebabkan oleh rendahnya pemantauan asupan gizi sehari-hari, terutama di tingkat keluarga.

Banyak orang tua terkendala waktu dan keterbatasan pengetahuan gizi sehingga sulit menerapkan panduan Isi Piringku secara konsisten (Munawaroh et al., 2022). Berbagai aplikasi pencatat gizi sudah tersedia, tetapi sebagian besar masih bergantung pada *input* manual dan menggunakan *database* gizi internasional seperti USDA yang kurang sesuai untuk makanan lokal Indonesia (Li et al., 2024). Beberapa penelitian lokal sudah mencoba mendeteksi makanan Indonesia menggunakan model YOLO (Wiranata & Lestari, 2025; Utami et al., 2023), namun penerapannya masih terbatas pada jenis makanan tertentu, belum terhubung dengan Tabel Komposisi Pangan Indonesia (TKPI) sebagai sumber data gizi resmi (Kementerian Kesehatan RI, 2020), dan belum menyediakan mekanisme koreksi oleh pengguna.

Tabel 1
Perbandingan RASA-ID dengan Penelitian Terdahulu

Peneliti (Tahun)	Model	Jumlah Kelas	Sumber Data Gizi	Fitur Koreksi Pengguna	Hasil Utama
Wiranata & Lestari (2025)	YOLOv5n	20	Tidak dibahas (fokus estimasi kalori)	Tidak ada	Akurasi klasifikasi 89,2%; belum mencakup gizi lengkap (protein, lemak, karbohidrat)
Utami dkk. (2023)	YOLOv5	7	FatSecret (basis data internasional)	Tidak ada	Akurasi 98,6%, precision 95%, recall 95,3%; data gizi belum berbasis TKPI
RASA-ID (penelitian ini)	YOLOv8m	18	TKPI 2020 (basis data resmi nasional)	Ada (koreksi label, missed detection, class request)	mAP50 94,49%, precision 94,52%, recall 92,23%

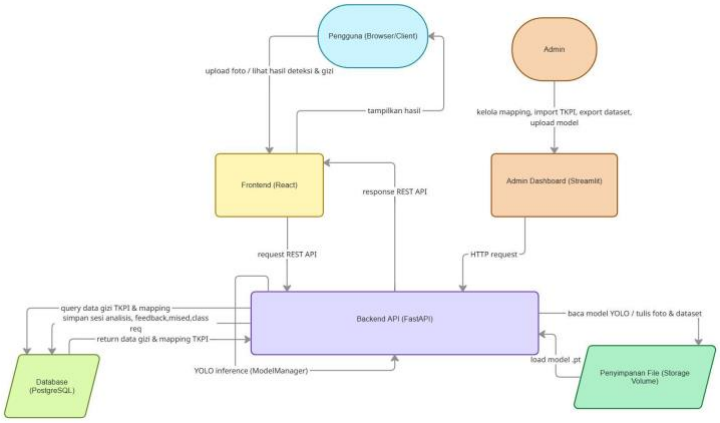
Perbedaan utama RASA-ID terletak pada penggunaan TKPI 2020 sebagai rujukan gizi resmi nasional, cakupan 18 kelas makanan sehari-hari, serta fitur koreksi pengguna yang belum tersedia pada kedua penelitian pembanding. Kedua penelitian sebelumnya berhenti pada tahap deteksi dan estimasi kalori atau gizi dari basis data internasional, tanpa mekanisme umpan balik untuk perbaikan model.

Penelitian ini mengembangkan RASA-ID (*Rancang Analisis Gizi Makanan Indonesia*), sistem yang mengenali makanan lokal Indonesia dari foto menggunakan YOLOv8m dan menghitung kandungan gizinya secara otomatis berdasarkan TKPI 2020. YOLOv8m dipilih karena kemampuannya mengekstraksi fitur visual yang lebih kompleks, sehingga lebih sesuai untuk makanan Indonesia yang memiliki variasi bentuk, warna, dan penyajian yang tinggi. Sistem ini juga dilengkapi mekanisme koreksi pengguna sebagai dasar *active learning*, di mana data koreksi disimpan sebagai kandidat

retraining model secara bertahap (Wu et al., 2022). Tujuan penelitian ini adalah mengembangkan sistem RASA-ID yang mampu mendeteksi makanan Indonesia dari foto, menghitung nilai gizi berdasarkan TKPI 2020, dan mengelola *feedback* pengguna sebagai fondasi peningkatan model berkelanjutan.

METODE PENELITIAN

Sistem RASA-ID dikembangkan menggunakan arsitektur *client-server*. Sisi *frontend* dibangun dengan React.js, sedangkan *backend* menggunakan FastAPI yang menjalankan model YOLOv8m, memetakan hasil deteksi ke TKPI 2020, dan menghitung nilai gizi berdasarkan porsi pengguna. Data TKPI, riwayat analisis, dan *feedback* disimpan pada PostgreSQL, sementara Dashboard Admin berbasis Streamlit digunakan administrator untuk mengunduh *feedback* sebagai kandidat *retraining*. Gambaran keseluruhan arsitektur sistem disajikan pada Gambar 1.



Gambar 1 Arsitektur Sistem RASA-ID

Dataset diperoleh dari tiga sumber yang tersedia secara publik di *Roboflow*, yaitu Makanan Prasmanan Domain Gap (Roboflow Deteksi Makanan, 2025), *CaloryFix Dataset* (Roboflow Ayu, 2025), dan *Pisang Dataset* (Roboflow Food Dataset, 2025). Setelah diseleksi berdasarkan kesesuaian dengan *TKPI 2020*, dataset mencakup 18 kelas makanan sehari-hari dengan total 5.753 gambar asli. Jumlah gambar per kelas tidak merata; sebagai contoh, mie_pangsit dan kacang_merah_rebus tercatat sebagai dua kelas dengan data pelatihan paling sedikit, masing-masing 163 dan 148 gambar, sehingga variasi visual pada kedua kelas tersebut lebih terbatas dibandingkan kelas lain. Data *training* kemudian dilakukan augmentasi menggunakan *flip* horizontal, variasi kecerahan, *mosaic*, dan *scaling*, sehingga total gambar yang digunakan untuk pelatihan dan evaluasi menjadi 13.840, terdiri dari 12.123 gambar training (hasil augmentasi), 885 gambar validation, dan 832 gambar testing (validation dan testing tanpa augmentasi). Pembagian 5.753 gambar asli tersebut adalah 4.036 gambar untuk training (±70%), 885 gambar untuk validation (±15%), dan 832 gambar untuk testing (±15%); persentase bersifat mendekati karena pembagian dilakukan pada tingkat jumlah gambar utuh, bukan persentase eksak. Augmentasi hanya diterapkan pada data training, sedangkan data validation dan testing tetap menggunakan gambar asli tanpa augmentasi untuk mencegah kebocoran data (data leakage) antara proses pelatihan dan evaluasi.

Model yang digunakan adalah *YOLOv8m* (Ultralytics, 2025) dengan bobot *pre-trained COCO*. Dibandingkan varian ringan seperti *YOLOv8n, YOLOv8m* memiliki kapasitas ekstraksi fitur yang lebih besar (±25,9 juta parameter dibandingkan ±3,2 juta parameter pada YOLOv8n) sehingga secara teoritis lebih mampu menangani variasi

visual makanan Indonesia yang beragam dari sisi bentuk, warna, dan penyajian. Pemilihan ini didasarkan pada pertimbangan kapasitas parameter dan kematangan ekosistem Ultralytics, bukan hasil perbandingan empiris dengan varian YOLO lain pada dataset yang sama; perbandingan performa antar varian YOLO merupakan keterbatasan penelitian ini dan disarankan untuk kajian lanjutan. Pelatihan dilakukan pada *Google Colab* dengan *GPU NVIDIA T4*, dan model terbaik diperoleh pada *epoch* ke-45 dari total 67 *epoch*. Parameter pelatihan disajikan pada Tabel 2.

Tabel 2
Parameter Pelatihan Model YOLOv8m

No	Parameter	Nilai
1	Model	YOLOv8m dengan bobot pre-trained COCO
2	Ukuran Gambar	640 × 640 piksel
3	Epoch	67, best epoch ke-45
4	Batch Size	8
5	Learning Rate	0,0005
6	Optimizer	AdamW
7	Confidence Threshold	0,5
8	IoU Threshold	0,5
9	Patience	20 epoch

Label hasil deteksi *YOLOv8m* dipetakan ke *TKPI 2020* melalui tabel *yolo_tkpi_mapping* untuk mengambil data energi, protein, lemak, dan karbohidrat. Sistem tidak mengestimasi berat atau porsi makanan secara langsung dari citra; setelah makanan terdeteksi, pengguna memilih faktor porsi (0,5x, 1x, atau 1,5x) terhadap porsi acuan per 100 gram pada TKPI. Nilai gizi dihitung dengan mengalikan kandungan gizi per 100 gram dengan faktor porsi tersebut, mengacu pada pendekatan Ukuran Rumah Tangga (URT) (Fayasari, 2020), lalu dijumlahkan untuk seluruh item yang terdeteksi menggunakan persamaan berikut.

$$Total\ Nilai\ Gizi\ x = \sum_{i=1}^{n} \left(Gizi100_{x,i} \times Porsi_i / 100\right)$$

Keterangan: *x* adalah jenis zat gizi; *Gizi100(x,i)* adalah nilai gizi *x* per 100 gram makanan ke-*i*; *Porsi(i)* adalah berat porsi makanan ke-*i*; dan *n* adalah jumlah makanan terdeteksi.

Untuk mendukung peningkatan model secara bertahap, sistem menyediakan tiga mekanisme *feedback* pengguna, yaitu koreksi label salah, *missed detection*, dan *class request*. Seluruh data *feedback* disimpan pada PostgreSQL dan dapat diekspor administrator sebagai kandidat *retraining*. Evaluasi model dilakukan pada 832 gambar *testing* menggunakan metrik *precision*, *recall*, mAP50, dan mAP50-95, serta uji fungsional pada lima skenario.

HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil evaluasi model YOLOv8m pada data *testing* dan pengujian fungsional sistem RASA-ID pada lima skenario.

Model YOLOv8m mencapai mAP50 sebesar 94,49%, mAP50-95 sebesar 79,53%, *precision* 94,52%, *recall* 92,23%, dan kecepatan inferensi rata−rata 22,19 ms/gambar. Seluruh metrik melampaui target minimum yang ditetapkan, yaitu mAP50 ≥ 70%, *precision* ≥ 70%, *recall* ≥ 65%, dan

waktu inferensi < 300 ms/gambar, sebagaimana dirangkum pada Tabel 3.

Tabel 3
Hasil Evaluasi Model YOLOv8m pada Data Testing

No	Metrik	Nilai	Keterangan
1	mAP50	94,49%	Akurasi deteksi pada IoU ≥ 0,5
2	mAP50-95	79,53%	Rata-rata akurasi pada IoU 0,5–0,95
3	Precision	94,52%	Ketepatan hasil deteksi
4	Recall	92,23%	Kemampuan menemukan objek
5	Kecepatan Inferensi	22,19 ms/gambar	Rata-rata waktu proses per gambar

Terdapat selisih yang cukup signifikan antara mAP50 (94,49%) dan mAP50-95 (79,53%), yang menunjukkan bahwa performa model menurun ketika dievaluasi pada ambang IoU yang lebih ketat. Kondisi ini umum terjadi pada model deteksi objek dan mengindikasikan bahwa presisi lokalisasi *bounding box* masih dapat ditingkatkan, terutama untuk kelas dengan variasi bentuk penyajian yang tinggi.

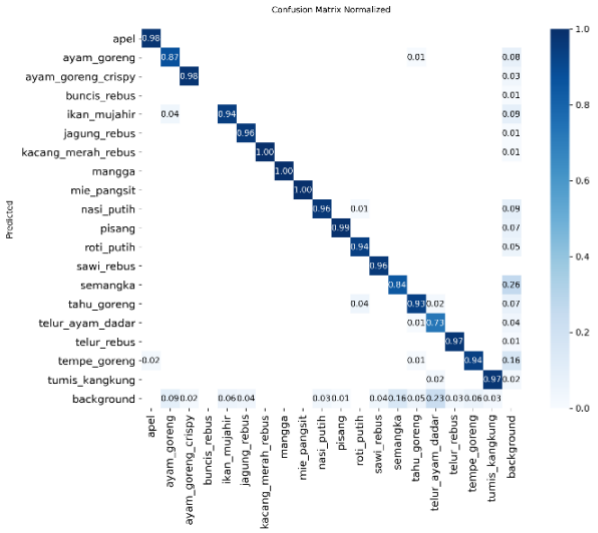
Tabel 4
Hasil Evaluasi Model YOLOv8m per Kelas Makanan

No	Kelas Makanan	Precision	Recall	mAP50	Keterangan
1	mangga	100%	99,5%	99,5%	Terbaik
2	kacang_merah_rebus	93,5%	100%	100%	Terbaik
3	mie_pangsit	97,9%	100%	99,5%	Terbaik
4	pisang	97,7%	99,4%	99,4%	Sangat Baik
5	sawi_rebus	98,0%	96,2%	99,3%	Sangat Baik
6	tumis_kangkung	95,8%	95,9%	99,0%	Sangat Baik
7	ayam_goreng_crispy	94,5%	94,5%	98,7%	Sangat Baik
8	nasi_putih	95,9%	96,0%	98,6%	Sangat Baik
9	roti_putih	92,6%	92,7%	97,5%	Sangat Baik
10	apel	98,8%	97,9%	97,5%	Sangat Baik
11	telur_rebus	96,7%	97,2%	96,0%	Sangat Baik
12	jagung_rebus	94,9%	91,7%	95,9%	Baik
13	tahu_goreng	92,5%	91,1%	95,7%	Baik
14	ikan_mujahir	92,4%	90,8%	94,2%	Baik
15	tempe_goreng	89,8%	86,2%	93,7%	Baik
16	ayam_goreng	90,1%	82,9%	87,4%	Cukup
17	semangka	81,3%	79,2%	80,3%	Cukup
18	telur_ayam_dadar	91,2%	64,6%	77,4%	Cukup

Berdasarkan Tabel 4, kelas dengan performa terbaik adalah mangga, kacang_merah_rebus, dan mie_pangsit dengan mAP50 masing-masing 99,5%. Performa tinggi tersebut menunjukkan bahwa ketiga kelas memiliki karakteristik visual yang relatif konsisten, meskipun hasil pada kacang_merah_rebus dan mie_pangsit masih perlu diverifikasi pada data dunia nyata yang lebih beragam.

Kelas dengan performa terendah adalah telur_ayam_dadar dengan mAP50 77,4% dan *recall* 64,6%, diikuti semangka (80,3%) dan ayam_goreng (87,4%). Rendahnya performa ketiga kelas ini disebabkan oleh kemiripan visual yang tinggi dengan kelas lain — ayam_goreng mudah tertukar dengan ayam_goreng_crispy, sedangkan telur_ayam_dadar dan semangka memiliki variasi bentuk dan warna yang cukup lebar

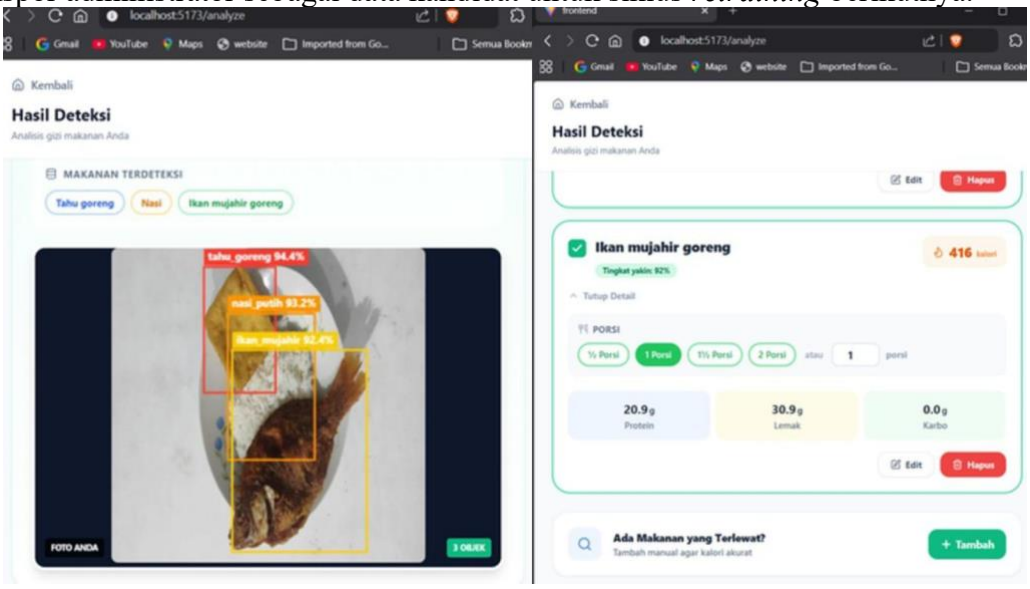
antar sampel. Meskipun demikian, seluruh kelas tetap melampaui target minimum mAP50 ≥ 70% dan menjadi prioritas perbaikan pada siklus *active learning* berikutnya.



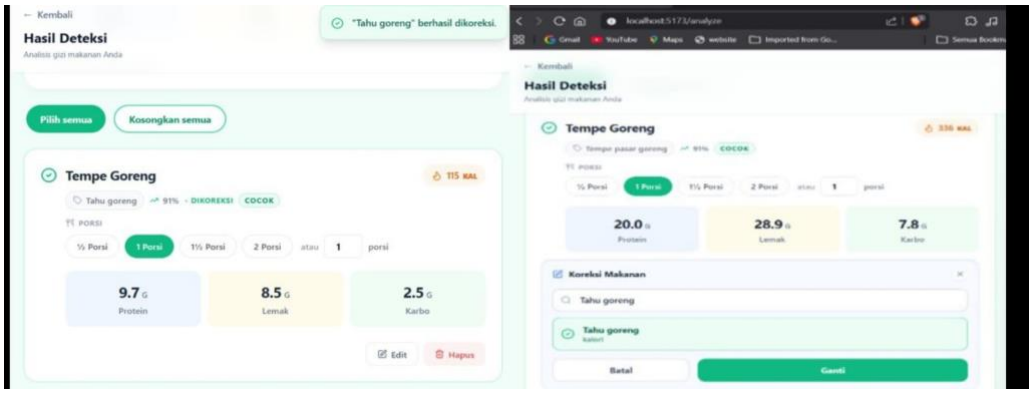
Gambar 2 Confusion Matrix Normalized Hasil Evaluasi Model YOLOv8m

Gambar 2 menunjukkan *confusion matrix* normalized, di mana sebagian besar kelas memiliki nilai tinggi pada diagonal utama. Kelas mangga, kacang_merah_rebus, dan mie_pangsit mencapai nilai 1,00, sedangkan telur_ayam_dadar memiliki nilai terendah 0,73.

Pengujian fungsional dilakukan melalui lima skenario pada lingkungan lokal. Deteksi *single item* berhasil pada tiga jenis makanan berbeda, dan deteksi *multi item* mampu mengenali hingga tiga objek sekaligus dalam satu foto dengan total gizi dihitung otomatis. Pada skenario *missed detection*, pengguna berhasil menambahkan makanan yang terlewat melalui fitur pencarian database. Koreksi label salah berjalan sesuai rancangan, dengan nilai gizi diperbarui secara otomatis setelah pengguna mengganti label. *Class request* membuktikan bahwa laporan makanan baru tersimpan dan dapat diekspor administrator sebagai data kandidat untuk siklus *retraining* berikutnya.



Gambar 3 Contoh Hasil Deteksi Multi-Item pada Sistem RASA-ID



Gambar 4 Proses Koreksi Label Pengguna pada Sistem RASA-ID dari Pengisian Form hingga Nilai Gizi Diperbarui Otomatis

Gambar 4 menunjukkan mekanisme koreksi label pada sistem RASA-ID. Ketika model mendeteksi makanan dengan label yang keliru, pengguna dapat mengganti label melalui fitur Koreksi Makanan dengan mengetikkan nama makanan yang sebenarnya. Setelah pengguna mengkonfirmasi, sistem secara otomatis memperbarui label beserta nilai gizinya sesuai data TKPI 2020, ditandai dengan munculnya *badge* DIKOREKSI pada kartu hasil deteksi. Data koreksi ini tersimpan ke *database* dan dapat diekspor administrator sebagai kandidat *retraining* model pada siklus *active learning* berikutnya.

SIMPULAN

Penelitian ini berhasil mengembangkan sistem RASA-ID yang mampu mendeteksi makanan lokal Indonesia dari foto menggunakan model YOLOv8m dan menghitung nilai gizinya berdasarkan TKPI 2020 sebagai acuan resmi nasional. Model dilatih pada 18 kelas makanan menggunakan total 13.840 gambar hasil kurasi dan augmentasi (12.123 training, 885 validation, 832 testing), dan menghasilkan mAP50 sebesar 94,49% dengan kecepatan inferensi 22,19 ms/gambar, melampaui seluruh target minimum yang ditetapkan. Pengujian fungsional pada lima skenario membuktikan bahwa fitur deteksi, perhitungan gizi, koreksi pengguna, dan mekanisme ekspor data untuk *active learning* berjalan sesuai rancangan. Evaluasi pada penelitian ini berfokus pada performa deteksi objek; akurasi nilai gizi (energi, protein, lemak, karbohidrat) yang dihasilkan sistem terhadap nilai referensi belum diukur secara kuantitatif dan menjadi agenda penelitian lanjutan. Siklus retraining otomatis (seleksi data, pelatihan ulang, dan evaluasi peningkatan performa) juga belum dilaksanakan; sistem baru menyediakan fondasi berupa pengumpulan dan ekspor data feedback sebagai kandidat retraining.

Sistem ini memiliki keterbatasan dalam hal generalisasi terhadap data dunia nyata, di mana variasi pencahayaan, sudut, dan penyajian makanan dapat menurunkan akurasi deteksi. Keterbatasan tersebut dapat diatasi secara bertahap melalui pipeline *active learning* yang telah tersedia. Penelitian selanjutnya disarankan untuk memperluas cakupan kelas makanan, melaksanakan siklus *retraining* penuh, serta mengembangkan fitur rekomendasi gizi agar sistem tidak hanya menganalisis kandungan gizi tetapi juga memberikan saran pemenuhan gizi harian yang lebih bermanfaat bagi pengguna.

DAFTAR PUSTAKA

Fayasari, A. (2020). Penilaian Konsumsi Pangan. Kun Fayakun.

Kementerian Kesehatan Republik Indonesia. (2020). Tabel Komposisi Pangan Indonesia 2020. Kementerian Kesehatan RI.

Kementerian Kesehatan Republik Indonesia. (2023). Survei Kesehatan Indonesia (SKI) 2023. Kementerian Kesehatan RI.

Li, X., Yin, A., Choi, H. Y., Chan, V., Allman-Farinelli, M., & Chen, J. (2024). Evaluating the quality and comparative validity of manual food logging and AI-enabled food image recognition in apps for nutrition care. Nutrients, 16(15). https://doi.org/10.3390/nu16152573

Munawaroh, H., Nada, N. K., & Hasjiandito, A. (2022). Peranan orang tua dalam pemenuhan gizi seimbang sebagai upaya pencegahan stunting pada anak usia 4-5 tahun. Seminar Nasional, IVET.

Ultralytics. (2025). YOLOv8 documentation. https://docs.ultralytics.com

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

Wiranata, M. A., & Lestari, C. C. (2025). YOLOv5 implementation for image classification in Indonesian cuisine calorie estimation system. Jurnal Teknik Informatika dan Sistem Informasi, 11(1), 121-131. https://doi.org/10.28932/jutisi.v11i1.10284

Wu, X., Xiao, L., Sun, Y., Zhang, J., Ma, T., & He, L. (2022). A survey of human-in-the-loop for machine learning. Future Generation Computer Systems, 1-22. https://doi.org/10.1016/j.future.2022.05.014

Roboflow Ayu. (2025). CaloryFix Dataset. Diakses 30 Oktober 2025, dari https://universe.roboflow.com/ayu-asipq/caloryfix

Roboflow Deteksi Makanan. (2025). Makanan-Prasmanan-Domain-Gap Computer Vision Model. Diakses 30 Oktober 2025, dari https://universe.roboflow.com/deteksi-makanan-bapkg/makanan-prasmanan-domain-gap-frvjt

Roboflow Food Dataset. (2025). Pisang Dataset. Diakses 30 Oktober 2025, dari https://universe.roboflow.com/food-udl8a/pisang-fhasw