Jurnal Manajemen Informatika Jayakarta
Volume 6, Nomor 4, November 2026: halaman 23-34

P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687

Deteksi Makanan Khas daerah Bogor dan Estimasi Makronutrien Berbasis Android dengan YOLO

[1.] Danar Mas Saputra, [2.] Iwan, [3.] Muji Santoso, [4.] Mudrika

[1, 2, 3, 4] Program Studi Teknik Informatika, Fakultas Teknologi Industri
Universitas Gunadarma
Jalan Margonda Raya No. 100, Depok, Indonesia

E-Mail : danarmas06@gmail.com [1], iwan@staff.gunadarma.ac.id [2],
muji_santoso@staff.gunadarma.ac.id [3], mudrika@staff.gunadarma.ac.id [4]

Abstrak . Makanan khas Bogor memiliki keragaman yang tinggi, namun informasi kandungan makronutriennya belum terdokumentasi secara digital sehingga masyarakat kesulitan memantau asupan gizi hariannya. Penelitian ini bertujuan membangun aplikasi Android yang mampu mendeteksi makanan khas Bogor dari citra sekaligus menampilkan estimasi kalori, karbohidrat, protein, dan lemak. Model deteksi dibangun menggunakan arsitektur *YOLOv8n-seg* dengan pendekatan segmentasi instans sehingga beberapa objek makanan dapat dikenali sekaligus dalam satu citra. Pengembangan mengikuti kerangka kerja *CRISP-DM* yang meliputi pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan penerapan. *Dataset* terdiri atas 316 citra yang dikumpulkan secara mandiri dan dianotasi dengan poligon untuk lima kelas, yaitu Doclang, Toge Goreng, Cungkring, Laksa, dan Asinan Bogor, kemudian dibagi secara stratifikasi dengan perbandingan 70:20:10. Data makronutrien mengacu pada Tabel Komposisi Pangan Indonesia dan disesuaikan menggunakan pengali porsi berbasis rasio luas kotak deteksi terhadap luas citra. Model diterapkan pada layanan peladen berbasis FastAPI di dalam kontainer Docker dan diakses aplikasi Android melalui REST API. Hasil evaluasi pada data pengujian memperoleh mAP50 sebesar 0,9273 dan mAP50-95 sebesar 0,7593, dengan presisi sebesar 0,881 dan *recall* sebesar 0,834. Pengujian kotak hitam terhadap lima belas skenario seluruhnya memberikan hasil yang sesuai, aplikasi berjalan pada tiga belas perangkat Android dari tujuh merek berbeda, dan pengujian penerimaan pengguna terhadap tiga belas responden memperoleh persentase kelayakan sebesar 88,17% yang termasuk kategori Sangat Baik.

Kata kunci :*CRISP-DM,Estimasi Makronutrien,Makanan Khas Bogor, Segmentasi Instans, YOLOv8*

Abstract. *Bogor traditional foods are highly diverse, yet their macronutrient content has not been documented digitally, making it difficult for the public to monitor their daily nutritional intake. This research aims to build an Android application capable of detecting Bogor traditional foods from images while presenting estimates of calories, carbohydrates, protein, and fat. The detection model was built using the YOLOv8n-seg architecture with an instance segmentation approach so that several food objects can be recognised simultaneously within a single image. The development followed the CRISP-DM framework, covering business understanding, data understanding, data preparation, modelling, evaluation, and deployment. The dataset consists of 316 independently collected images, polygon-annotated for five classes, namely Doclang, Toge Goreng, Cungkring, Laksa, and Asinan Bogor, and divided using a stratified split with*

This work is licensed under a Creative Commons Attribution 4.0 International License.
http://journal.stmikjayakarta.ac.id/index.php/JMIJayakarta

Jurnal Manajemen Informatika Jayakarta
Volume 6, Nomor 4, November 2026: halaman 23-34

P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687

a 70:20:10 ratio. Macronutrient data refers to the Indonesian Food Composition Table and is adjusted using a portion multiplier derived from the ratio of the detection box area to the image area. The model was deployed to a FastAPI server service inside a Docker container and accessed by the Android application through a REST API. Evaluation on the test data obtained an mAP50 of 0.9273 and an mAP50-95 of 0.7593, with a precision of 0.881 and a recall of 0.834. Black box testing of fifteen scenarios all produced conforming results, the application ran on thirteen Android devices from seven different brands, and user acceptance testing involving thirteen respondents obtained a feasibility percentage of 88.17%, which falls into the Very Good category.

Keywords *: Bogor Traditional Food, CRISP-DM, Instance Segmentation, Macronutrient Estimation, YOLOv8*

1. PENDAHULUAN *(or Introduction)*

Pola makan merupakan salah satu faktor yang paling berpengaruh terhadap kondisi kesehatan seseorang. Ketidakseimbangan antara asupan dan kebutuhan gizi dapat memicu berbagai gangguan kesehatan, seperti obesitas, diabetes melitus, dan penyakit jantung. Berdasarkan data Survei Kesehatan Indonesia tahun 2023, prevalensi obesitas pada penduduk berusia di atas 18 tahun meningkat dari 21,8% pada tahun 2018 menjadi 23,4% pada tahun 2023, sedangkan prevalensi diabetes melitus pada penduduk berusia 15 tahun ke atas meningkat dari 5,7% pada tahun 2007 menjadi 11,7% pada tahun 2023 (Kementerian Kesehatan Republik Indonesia, 2024). Salah satu pemicu peningkatan penyakit tidak menular tersebut adalah rendahnya kesadaran masyarakat dalam mengendalikan asupan makronutrien harian, yaitu zat gizi yang dibutuhkan tubuh dalam jumlah besar dan menjadi sumber energi utama, terutama kalori, karbohidrat, protein, dan lemak (Weisenberger, 2025).**[1]**

Kesulitan mengendalikan asupan tersebut semakin terasa pada makanan tradisional yang informasi gizinya jarang tersedia. Kota Bogor memiliki dua belas jenis makanan yang teridentifikasi sebagai makanan khas daerah, antara lain soto mi, soto kuning, laksa, asinan, doclang, cungkring, dan toge goreng (Mela dkk., 2021). Sebagian di antaranya bahkan telah diteliti secara khusus untuk memastikan keasliannya sebagai hidangan tradisional Kota Bogor, seperti toge goreng (Imroatuna dkk., 2023). Meskipun dikonsumsi secara luas, kandungan makronutrien setiap hidangan tersebut belum terdokumentasi secara digital dengan baik, bahkan sebagian di antaranya tercatat memiliki tingkat popularitas yang rendah sehingga berisiko semakin ditinggalkan.

Penelitian-penelitian tersebut membuktikan keandalan pendekatan deteksi objek pada domain makanan, tetapi umumnya berhenti pada identifikasi jenis makanan atau estimasi kalori tunggal. Belum ada penelitian yang secara khusus menyasar makanan khas Bogor, menggunakan segmentasi instans agar beberapa hidangan dapat dikenali sekaligus dalam satu citra, sekaligus melanjutkan hasil deteksi menjadi catatan jurnal makanan harian yang dibandingkan dengan target gizi tiap pengguna. Celah inilah yang menjadi landasan penelitian ini.

Untuk memastikan bahwa membangun model deteksi makanan khas Bogor menggunakan arsitektur *YOLOv8n-seg* yang mampu mengenali lima kelas, yaitu Doclang, Toge Goreng, Cungkring, Laksa, dan Asinan Bogor; mengukur performa model menggunakan metrik *mean Average Precision*, presisi, *recall*, dan F1-*score*; menghasilkan estimasi kalori, karbohidrat, protein, dan lemak yang mengacu pada Tabel Komposisi Pangan Indonesia dengan penyesuaian

This work is licensed under a Creative Commons Attribution 4.0 International License.
http://journal.stmikjayakarta.ac.id/index.php/JMIJayakarta

Jurnal Manajemen Informatika Jayakarta
Volume 6, Nomor 4, November 2026: halaman 23-34
P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687

pengali porsi; menerapkan model tersebut pada layanan peladen serta mengintegrasikannya dengan aplikasi Android; dan mengukur tingkat penerimaan pengguna terhadap aplikasi yang dihasilkan.

2. TINJAUAN LITERATUR *(or Literature Review)*

Rahma, L., Syaputra, H., Mirza, A. H., & Purnamasari, S. D. (2021) dalam Penelitiannya menerapkan algoritma YOLO untuk mendeteksi makanan khas daerah. Relevan karena memiliki kesamaan domain berupa makanan khas daerah dan pendekatan deteksi objek berbasis YOLO. Dengan Objek Deteksi Makanan Khas Palembang Menggunakan Algoritma YOLO (You Only Look Once).[1] Riswanto, R., Ahmad, A., Hazriani, H., & Tribuana, D. (2024) Pada Model SSD memperoleh mAP sebesar 65,09% dan total loss 0,1670681, serta berhasil diimplementasikan pada aplikasi mobile untuk estimasi kalori. Relevan karena memiliki kesamaan tujuan berupa estimasi kandungan gizi melalui citra pada perangkat mobile. Dengan Deteksi Kalori Makanan Tradisional Indonesia Menggunakan Metode Single Shot Multibox Detector (SSD).[2]

Nadiyah, N., Putri, M. E., Khairi, M., Furqan, M., & Yusman, B. (2024) Pada Model Mask R-CNN dilatih pada 5 kelas makanan dengan 220 citra dan memperoleh akurasi 40% hingga 80% per kelas. Relevan karena menggunakan pendekatan segmentasi, jumlah kelas, dan skala dataset yang sebanding dengan penelitian ini. Dengan Deteksi Objek untuk Menghitung Perkiraan Kalori Makanan Menggunakan Metode R-CNN Mask Berbasis Web.[3]

Mustofa, A. A. S., Wulanningrum, R., & Sahertian, J. (2025) Pada Model YOLOv8 memperoleh mAP rata-rata 89,9% dan F1-score 86,5% pada 5 kelas kue tradisional dengan anotasi Roboflow. Relevan karena memiliki kesamaan algoritma, jumlah kelas, platform anotasi, dan objek makanan tradisional Indonesia. Dengan Deteksi dan Klasifikasi Kue Tradisional Indonesia Menggunakan YOLOv8.[4]

Iqbal, A. M., Jumadi, J., & Nurlatifah, E. (2025) Pada Model YOLOv8n dengan pendekatan CRISP-DM memperoleh accuracy 0,98, precision 0,988, recall 0,993, mAP50 0,994, dan mAP50-95 0,955, serta diterapkan pada aplikasi Android. Relevan karena menggunakan kombinasi metodologi yang sama, yaitu CRISP-DM, YOLOv8, dan penerapan pada Android. Dengan Implementasi YOLOv8 Sebagai Pendeteksi Nominal Uang Rupiah Kertas Berbasis Android.[5]

Berkaitan dengan uraian di atas, penelitian mengenai Deteksi Makanan Khas daerah dan Estimasi Makronutrien Berbasis Android dengan YOLO, lebih dahulu dilakukan oleh Iqbal, A. M., Jumadi, J., & Nurlatifah, E. (2025) dengan penelitiannya yang berjudulengan Implementasi YOLOv8 Sebagai Pendeteksi Nominal Uang Rupiah Kertas Berbasis Android. [6]

3. METODE PENELITIAN *(or Research Method)*

Penelitian ini menggunakan kerangka kerja *CRISP-DM* (*Cross Industry Standard Process for Data Mining*) yang terdiri atas enam tahapan, yaitu pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan penerapan. Kerangka kerja ini dipilih karena bersifat berulang dan sesuai dengan alur pengembangan sistem deteksi objek berbasis citra, ketika kualitas data dan hasil pelatihan kerap memerlukan perbaikan berulang (Chapman dkk., 2000).

1. Pemahaman Bisnis

Tahap ini menetapkan sasaran pengembangan model, yaitu mendeteksi lima jenis makanan

This work is licensed under a Creative Commons Attribution 4.0 International License.
http://journal.stmikjayakarta.ac.id/index.php/JMIJayakarta

Jurnal Manajemen Informatika Jayakarta
Volume 6, Nomor 4, November 2026: halaman 23-34
P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687

khas Bogor dari citra masukan dan mendukung proses estimasi makronutrien pada aplikasi Android. Pada tahap ini juga ditetapkan ruang lingkup *dataset*, metode anotasi, serta metrik evaluasi yang menjadi acuan pemilihan model terbaik, yaitu presisi, *recall*, F1-*score*, mAP50, dan mAP50-95.

2. Pemahaman Data

Citra makanan dikumpulkan secara mandiri melalui mesin pencari menggunakan ekstensi peramban Fatkun Batch Download Image. Setiap citra ditinjau kualitasnya dari sisi pencahayaan, sudut pengambilan, dan latar belakang, kemudian citra yang tidak relevan disaring. Struktur folder, jumlah data per kelas, dan keseimbangan antarkelas diperiksa, lalu sampel citra beserta anotasinya divisualisasikan untuk memverifikasi kebenaran label. Data makronutrien dikumpulkan dari Data Komposisi Pangan Indonesia yang dikelola Kementerian Kesehatan Republik Indonesia (Kementerian Kesehatan Republik Indonesia, 2026), lalu disusun ulang ke dalam berkas berformat CSV agar sesuai dengan kebutuhan sistem.

3. Persiapan Data

Anotasi dilakukan pada peladen daring Roboflow menggunakan poligon yang mengikuti kontur objek, bukan kotak pembatas, agar area makanan terpisah lebih presisi dari latar belakang. Pembersihan data mencakup pemeriksaan kesesuaian pasangan berkas citra dan label, anotasi kosong, serta citra rusak. *Dataset* kemudian dibagi secara stratifikasi menjadi data pelatihan, validasi, dan pengujian dengan perbandingan 70:20:10 agar distribusi kelas tetap seimbang pada setiap bagian. Augmentasi diterapkan hanya pada data pelatihan dan meliputi perubahan warna pada ruang HSV, rotasi, translasi, penskalaan, pencerminan mendatar, dan mosaik, sedangkan *mixup*, *copy-paste*, dan pencerminan tegak tidak digunakan. Dengan demikian, data validasi dan data pengujian tetap merepresentasikan kondisi asli *dataset*.

4. Pemodelan

Pelatihan dilakukan pada Google Colaboratory menggunakan pustaka Ultralytics dengan bobot pralatih *YOLOv8n-seg* sebagai penerapan *transfer learning* dari bobot COCO. Varian *nano* dipilih karena berukuran paling ringan dalam keluarga *YOLOv8* sehingga sesuai untuk peladen tanpa akselerasi grafis (Terven dkk., 2023). Konfigurasi pelatihan yang digunakan ditunjukkan pada Tabel 1.

Tabel 1. Konfigurasi Pelatihan Model *YOLOv8n-seg*

Parameter	Nilai
Arsitektur dasar	*yolov8n-seg.pt* (pralatih COCO)
Jumlah kelas	5 kelas
Epoch maksimum	100 (*patience* 20)
Ukuran citra	640 × 640 piksel
Ukuran *batch*	16
Optimizer	AdamW
Learning rate awal	0,001

This work is licensed under a Creative Commons Attribution 4.0 International License.
http://journal.stmikjayakarta.ac.id/index.php/JMIJayakarta

Jurnal Manajemen Informatika Jayakarta
Volume 6, Nomor 4, November 2026: halaman 23-34
P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687

Parameter	Nilai
Lingkungan pelatihan	Google Colaboratory, GPU Tesla T4
Ukuran model akhir	86 lapisan, 3.259.039 parameter, 11,3 GFLOPs

5. Evaluasi

Model dievaluasi pada data pengujian yang belum pernah digunakan selama pelatihan. Metrik yang digunakan adalah presisi, *recall*, F1-*score*, mAP50, dan mAP50-95, dihitung baik pada tingkat keseluruhan maupun per kelas, dan dilengkapi *confusion matrix* serta visualisasi hasil prediksi. Hasil evaluasi menjadi dasar penentuan apakah model sudah memadai atau perlu diulang kembali ke tahap persiapan data maupun pemodelan.

6. Penerapan

Bobot terbaik hasil pelatihan diekspor, lalu dimuat oleh layanan peladen berbasis FastAPI yang menjalankan inferensi, menghitung pengali porsi, dan mencocokkan hasil deteksi dengan basis data gizi. Nilai gizi pada Tabel Komposisi Pangan Indonesia dinyatakan per 100 gram, sedangkan berat porsi tidak dapat diukur langsung dari foto dua dimensi.

7. Pengujian Sistem

Pengujian dilakukan melalui tiga pendekatan. Pertama, pengujian kotak hitam (*black box testing*) untuk memverifikasi kesesuaian fungsi terhadap kebutuhan fungsional tanpa meninjau struktur kode. Kedua, pengujian pada beragam perangkat Android untuk menilai kompatibilitas. Ketiga, pengujian penerimaan pengguna (*User Acceptance Testing*) menggunakan kuesioner berskala Likert lima titik yang diisi setelah responden mencoba seluruh fitur aplikasi.

4. HASIL DAN PEMBAHASAN *(or Results and Analisys)*

4.1. Gambaran Umum Penelitian

Sistem yang dibangun diberi nama Nutrify dan tersusun atas tiga lapisan yang saling terhubung. Lapisan pertama adalah aplikasi Android berbasis Flutter yang berperan sebagai antarmuka pengguna untuk mengambil gambar makanan melalui kamera atau memilih gambar dari galeri. Lapisan kedua adalah layanan peladen berbasis FastAPI yang menjalankan inferensi model, menghitung pengali porsi, dan mengambil data makronutrien dari basis data PostgreSQL. Lapisan ketiga adalah model *YOLOv8n-seg* yang dimuat sekali pada saat layanan dinyalakan sehingga tidak perlu dimuat ulang pada setiap permintaan.

Proses kerja sistem dimulai ketika pengguna membuka fitur deteksi dan mengambil gambar makanan. Citra dikirim ke peladen untuk diproses model. Apabila makanan dikenali sebagai salah satu dari lima kelas yang didukung, peladen mengambil data makronutrien dari basis data,

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

Jurnal Manajemen Informatika Jayakarta
Volume 6, Nomor 4, November 2026: halaman 23-34
P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687

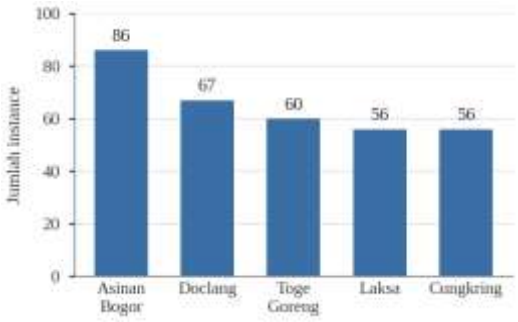
menghitung pengali porsi, kemudian mengembalikan hasil deteksi ke aplikasi. Selanjutnya aplikasi menampilkan nama makanan beserta estimasi kalori, karbohidrat, protein, dan lemak, lalu menyesuaikannya dengan target gizi berdasarkan data personalisasi pengguna. Apabila keyakinan deteksi berada di bawah ambang batas 0,15, aplikasi menampilkan keterangan bahwa objek tidak dikenali sehingga pengguna dapat melakukan pemindaian ulang. Alur kerja sistem secara keseluruhan ditunjukkan pada Gambar 1.



Gambar 4.1. Alur Penetian

4.2.1 Karakteristik dan Pembagian *Dataset*

Dataset citra yang terkumpul berjumlah 316 citra untuk lima kelas makanan khas Bogor. Distribusi jumlah *instance* pada setiap kelas ditunjukkan pada Gambar 2. Kelas Asinan Bogor memiliki jumlah *instance* terbanyak, yaitu 86, diikuti Doclang 67, Toge Goreng 60, serta Laksa dan Cungkring yang masing-masing berjumlah 56. Distribusi ini tergolong cukup seimbang meskipun kelas Asinan Bogor unggul sekitar setengah kali lipat dibanding kelas terkecil.



Gambar 2. Distribusi Jumlah *Instance* pada Setiap Kelas

Pembagian *dataset* secara stratifikasi menghasilkan komposisi seperti ditunjukkan pada Tabel 2. Perbedaan jumlah citra dan jumlah anotasi terjadi karena satu citra dapat memuat lebih dari satu objek makanan, sehingga pendekatan segmentasi instans memang diperlukan agar setiap objek

This work is licensed under a Creative Commons Attribution 4.0 International License.
http://journal.stmikjayakarta.ac.id/index.php/JMIJayakarta

Jurnal Manajemen Informatika Jayakarta
Volume 6, Nomor 4, November 2026: halaman 23-34
P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687

dihitung secara terpisah.

Tabel 2. Hasil Pembagian *Dataset* Secara Stratifikasi

Bagian Data	Proporsi	Citra	Anotasi
Pelatihan	70%	217	223
Validasi	20%	61	62
Pengujian	10%	36	38

4.2.2 Hasil Pelatihan dan Evaluasi Model

Pada data validasi, model memperoleh mAP50 sebesar 0,902 dan mAP50-95 sebesar 0,743 dengan presisi 0,818 dan *recall* 0,825. Evaluasi kemudian dilanjutkan pada data pengujian yang belum pernah dilihat model selama pelatihan. Hasil evaluasi keseluruhan memperoleh mAP50 sebesar 0,9273 dan mAP50-95 sebesar 0,7593, dengan presisi sebesar 0,881 dan *recall* sebesar 0,834. Nilai F1-*score* keseluruhan yang dihitung dari presisi dan *recall* tersebut adalah 0,857. Rincian performa per kelas ditunjukkan pada Tabel 3.

Tabel 3. Hasil Evaluasi Model pada Data Pengujian

Kelas	Presisi	*Recall*	mAP50	mAP50-95
Asinan Bogor	0,934	0,800	0,913	0,779
Cungkring	0,939	1,000	0,995	0,759
Doclang	0,842	0,750	0,927	0,729
Laksa	0,848	0,936	0,972	0,847
Toge Goreng	0,844	0,684	0,829	0,683
Keseluruhan	0,881	0,834	0,927	0,759

Keterangan: evaluasi dilakukan pada 36 citra (38 *instance*) data pengujian; nilai mAP50-95 merupakan nilai untuk topeng segmentasi.

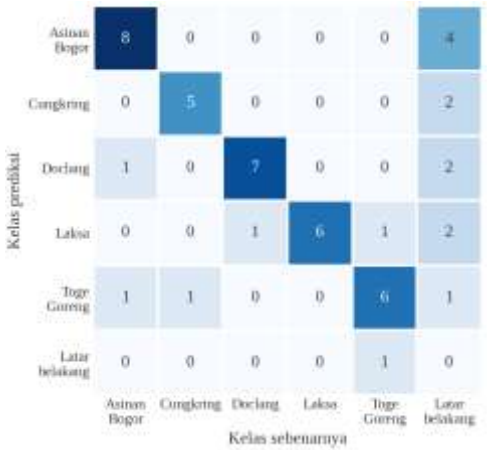
Laksa menjadi kelas dengan performa terkuat, dengan mAP50 sebesar 0,972 dan mAP50-95 sebesar 0,847, karena kuah kuning kentalnya membentuk pola warna dan tekstur yang khas dan konsisten antarcitra. Cungkring memperoleh *recall* sempurna sebesar 1,000 dan mAP50 tertinggi sebesar 0,995, namun mAP50-95-nya relatif lebih rendah. Hal ini menunjukkan seluruh objek Cungkring berhasil ditemukan, tetapi batas topeng segmentasinya kurang rapat pada ambang IoU yang lebih ketat, yang wajar terjadi pada hidangan bertekstur tidak beraturan seperti kikil dan paru bertusuk.

Sebaliknya, Toge Goreng menjadi kelas terlemah dengan *recall* sebesar 0,684 dan mAP50 sebesar 0,829. Penyebab utamanya adalah kemiripan visual dengan kelas lain, terutama Doclang, karena keduanya sama-sama disajikan dengan potongan ketupat dan siraman bumbu kacang berwarna cokelat kekuningan sehingga model kerap keliru membedakan keduanya. Pola kesalahan tersebut terlihat pada *confusion matrix* yang ditunjukkan pada Gambar 3.

This work is licensed under a Creative Commons Attribution 4.0 International License.
http://journal.stmikjayakarta.ac.id/index.php/JMIJayakarta

Jurnal Manajemen Informatika Jayakarta
Volume 6, Nomor 4, November 2026: halaman 23-34
P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687



Gambar 3. *Confusion Matrix* Model *YOLOv8n-seg*

Berdasarkan Gambar 3, sebagian besar objek berhasil diklasifikasikan pada kelas yang sesuai, terlihat dari nilai yang terkonsentrasi pada diagonal utama. Kesalahan yang tersisa berupa satu objek Asinan Bogor yang diprediksi sebagai Doclang, satu objek Asinan Bogor dan satu objek Cungkring yang diprediksi sebagai Toge Goreng, serta satu objek Doclang dan satu objek Toge Goreng yang diprediksi sebagai Laksa. Selain itu, kolom latar belakang memuat sebelas deteksi yang tidak berpasangan dengan objek sebenarnya, sedangkan baris latar belakang menunjukkan satu objek Toge Goreng yang tidak berhasil ditemukan model. Pola tersebut memperlihatkan bahwa sisa kesalahan model lebih banyak berupa deteksi tambahan pada area yang menyerupai makanan daripada kesalahan menukar satu kelas dengan kelas lainnya.

Secara visual, model tidak hanya menghasilkan kotak pembatas dan label kelas, tetapi juga topeng segmentasi yang memisahkan area makanan dari latar belakang, sebagaimana ditunjukkan pada Gambar 4. Bagian atas gambar memperlihatkan topeng segmentasi pada kelas Cungkring, sedangkan bagian bawah memperlihatkan kemampuan model mengenali dua objek Asinan Bogor sekaligus dalam satu citra, yang menjadi keunggulan pendekatan segmentasi instans dibanding klasifikasi citra tunggal.

This work is licensed under a Creative Commons Attribution 4.0 International License.
http://journal.stmikjayakarta.ac.id/index.php/JMIJayakarta

Jurnal Manajemen Informatika Jayakarta
Volume 6, Nomor 4, November 2026: halaman 23-34

P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687



Gambar 4. Contoh Hasil Prediksi Model pada Data Pengujian

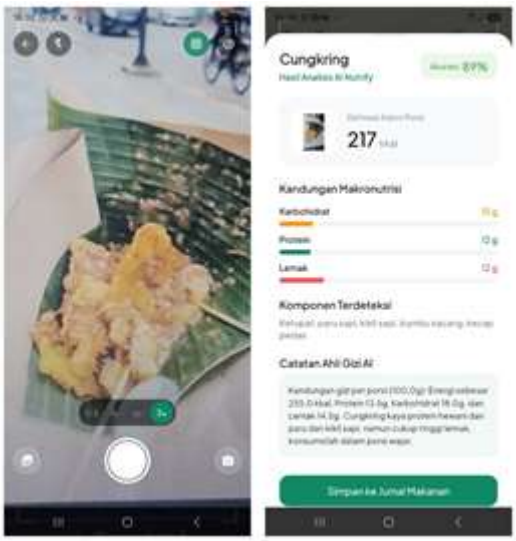
This work is licensed under a Creative Commons Attribution 4.0 International License.
http://journal.stmikjayakarta.ac.id/index.php/JMIJayakarta

Jurnal Manajemen Informatika Jayakarta
Volume 6, Nomor 4, November 2026: halaman 23-34
P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687

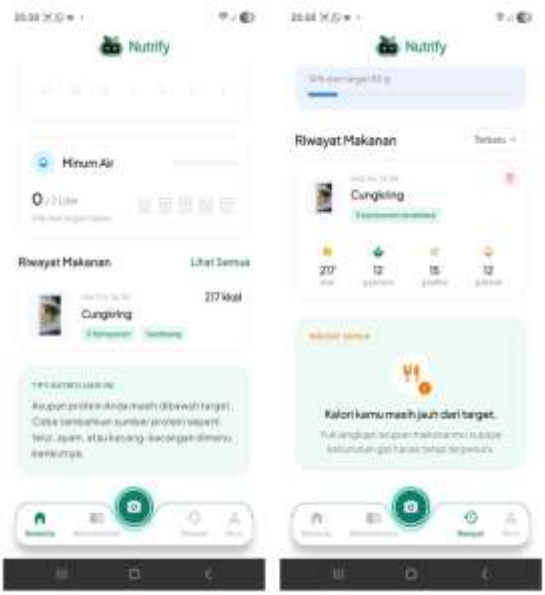
4.2.3 Implementasi Aplikasi

Aplikasi Nutrify menyediakan alur penggunaan yang dimulai dari layar pembuka, perkenalan aplikasi, autentikasi, lalu pengisian data personalisasi berupa data fisik, tingkat aktivitas, tujuan, riwayat kesehatan, alergi, dan pantangan. Setelah tahap tersebut selesai, pengguna dapat mengakses lima menu utama, yaitu Beranda, Kamera, Rekomendasi, Riwayat, dan Akun. Antarmuka pemindaian dan hasil deteksi ditunjukkan pada Gambar 5.



Gambar 5. Antarmuka Pemindaian (kiri) dan Hasil Deteksi beserta Estimasi Makronutrien (kanan)

Berdasarkan Gambar 5, hasil pemindaian menampilkan nama makanan, tingkat keyakinan model, estimasi kalori porsi, rincian karbohidrat, protein, dan lemak, komponen bahan yang terdeteksi, serta catatan gizi ringkas. Hasil tersebut dapat langsung disimpan ke jurnal makanan. Ringkasan gizi harian dan riwayat pencatatan ditunjukkan pada Gambar 6.



Gambar 6. Antarmuka Beranda (kiri) dan Riwayat beserta *Insight* (kanan)

This work is licensed under a Creative Commons Attribution 4.0 International License.
http://journal.stmikjayakarta.ac.id/index.php/JMIJayakarta

Jurnal Manajemen Informatika Jayakarta
Volume 6, Nomor 4, November 2026: halaman 23-34
P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687

4.2.3 Penerapan pada Peladen

Layanan peladen dijalankan pada peladen maya dengan spesifikasi dua inti prosesor AMD EPYC, memori 2 GB DDR5, dan penyimpanan 40 GB NVMe bersistem operasi Ubuntu Server. Mengingat ketiadaan akselerasi grafis, inferensi dijalankan sepenuhnya pada mode prosesor. Seluruh komponen dikemas menggunakan Docker dan berjalan sebagai empat kontainer, yaitu layanan FastAPI melalui Uvicorn pada porta 8000, basis data PostgreSQL pada porta 5432, antarmuka pengelolaan basis data, serta Caddy sebagai *reverse proxy* yang menangani porta 80 dan 443. Pemantauan setelah penerapan menunjukkan beban sistem sebesar 0,01 dengan penggunaan penyimpanan 62% dan penggunaan memori 47%, yang menandakan layanan mampu berjalan stabil tanpa membebani sumber daya peladen secara berlebihan.

4.2.4 Hasil Pengujian Sistem

Pengujian kotak hitam dilakukan terhadap lima belas skenario yang mencakup lima modul inti, yaitu autentikasi, personalisasi, pemindaian makanan, pencatatan jurnal, dan rekomendasi. Skenario yang diuji meliputi registrasi dengan data lengkap, registrasi dengan surel yang sudah terdaftar, masuk dengan kredensial benar dan salah, pengajuan pemulihan kata sandi, penyelesaian tahap personalisasi, pemindaian citra makanan yang valid, pemindaian citra di luar lima kelas, penyimpanan hasil pemindaian ke jurnal, pembukaan *tab* Riwayat, pengubahan porsi, penyuntingan rincian bahan, penghapusan entri, pembukaan *tab* Rekomendasi, serta pemunculan peringatan berbasis kondisi kesehatan. Seluruh skenario memberikan keluaran yang sesuai dengan yang diharapkan, sehingga seluruh kebutuhan fungsional yang dirancang dinyatakan terpenuhi.

Pengujian kompatibilitas dilakukan pada tiga belas perangkat Android milik responden yang berasal dari tujuh merek berbeda, yaitu Samsung, Xiaomi, Poco, Asus, Infinix, Realme, dan OPPO, dengan rentang spesifikasi dari kelas menengah hingga kelas atas. Aplikasi berhasil berjalan pada seluruh perangkat tanpa kendala fungsional.

5. KESIMPULAN *(or Conclusion)*

Aplikasi Android Nutrify untuk deteksi makanan khas Bogor dan estimasi makronutrien berhasil dibangun menggunakan kerangka kerja *CRISP-DM* dengan arsitektur tiga lapis, yaitu aplikasi Flutter sebagai antarmuka pengguna, layanan FastAPI sebagai penghubung, serta model *YOLOv8n-seg* dan basis data PostgreSQL sebagai lapisan pemrosesan. Model yang dihasilkan mampu melakukan segmentasi sekaligus klasifikasi terhadap lima kelas makanan khas Bogor dengan mAP50 sebesar 0,9273 dan mAP50-95 sebesar 0,7593 pada data pengujian, disertai presisi 0,881 dan *recall* 0,834. Laksa menjadi kelas dengan performa terkuat, sedangkan Toge Goreng menjadi kelas terlemah akibat kemiripan visual dengan Doclang yang sama-sama menggunakan ketupat dan bumbu kacang. Estimasi makronutrien berhasil dihasilkan dengan mengacu pada Tabel Komposisi Pangan Indonesia dan disesuaikan menggunakan pengali porsi berbasis rasio luas kotak deteksi terhadap luas citra pada rentang 0,85 sampai 1,25.

REFERENSI *(Reference)*

[1] Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., dan Wirth, R. 2000. *CRISP-DM 1.0: Step-by-Step Data Mining Guide*. SPSS Inc., Chicago.

[2] Imroatuna, Farhah, G., Amanda, D., Erlangga, H. N., Kurnia, I., dan Prabandari, D. 2023. 'Otentikasi Taoge Goreng sebagai Makanan Tradisional Khas Kota Bogor'. *Journal of Food and Culinary*.

This work is licensed under a Creative Commons Attribution 4.0 International License.
http://journal.stmikjayakarta.ac.id/index.php/JMIJayakarta

P-ISSN: 2746-5985
e-ISSN: 2797-0930

DOI: https://doi.org/10.52362/jmijayakarta.v6i4.2687

Vol. 6 No. 1. pp. 1–13. URL: https://doi.org/10.12928/jfc.v6i1.8003

[3] Iqbal, A. M., Jumadi, J., dan Nurlatifah, E. 2025. 'Implementasi YOLOv8 sebagai Pendeteksi Nominal Uang Rupiah Kertas Berbasis Android'. *SMATIKA Jurnal*. Vol. 15 No. 2. pp. 268–277. URL: https://doi.org/10.32664/smatika.v15i02.1545

[4] Kementerian Kesehatan Republik Indonesia. 2024. *Survei Kesehatan Indonesia (SKI) 2023 dalam Angka*. Badan Kebijakan Pembangunan Kesehatan, Jakarta. URL: https://www.badankebijakan.kemkes.go.id/ski-2023-dalam-angka/

[5] Kementerian Kesehatan Republik Indonesia. 2026. *Data Komposisi Pangan Indonesia*. Diakses pada 7 Juli 2026. URL: https://panganku.org/

[6] Mela, E., Wijonarko, G., dan Suciani, I. A. 2021. 'Strategi Perbaikan Makanan Khas Bogor'. *agriTECH*. Vol. 41 No. 2. pp. 152–160. URL: https://doi.org/10.22146/agritech.45291

[7] Mustofa, A. A. S., Wulanningrum, R., dan Sahertian, J. 2025. 'Deteksi dan Klasifikasi Kue Tradisional Indonesia Menggunakan YOLOv8'. *NERO: Networking Engineering Research Operation*. Vol. 10 No. 1. pp. 25–36.

[8] Nadiyah, N., Putri, M. E., Khairi, M., Furqan, M., dan Yusman, B. 2024. 'Deteksi Objek untuk Menghitung Perkiraan Kalori Makanan Menggunakan Metode R-CNN Mask Berbasis Web'. *COREAI: Jurnal Kecerdasan Buatan, Komputasi dan Teknologi Informasi*. Vol. 5 No. 1. pp. 84–92

[9] Rahma, L., Syaputra, H., Mirza, A. H., dan Purnamasari, S. D. 2021. 'Objek Deteksi Makanan Khas Palembang Menggunakan Algoritma YOLO (You Only Look Once)'. *Jurnal Nasional Ilmu Komputer*. Vol. 2 No. 3. pp. 213–232. URL: https://doi.org/10.47747/jurnalnik.v2i3.534

[10] Riswanto, R., Ahmad, A., Hazriani, H., dan Tribuana, D. 2024. 'Deteksi Kalori Makanan Tradisional Indonesia Menggunakan Metode Single Shot Multibox Detector (SSD)'. *MALCOM: Indonesian Journal of Machine Learning and Computer Science*. Vol. 4 No. 3.

[11] Terven, J., Córdova-Esparza, D.-M., dan Romero-González, J.-A. 2023. 'A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS'. *Machine Learning and Knowledge Extraction*. Vol. 5 No. 4. pp. 1680–1716. URL: https://doi.org/10.3390/make5040083

This work is licensed under a Creative Commons Attribution 4.0 International License.
http://journal.stmikjayakarta.ac.id/index.php/JMIJayakarta