

Pengembangan Fitur Estimasi Gula Makanan Berbasis Image Recognition Menggunakan Machine Learning pada Aplikasi Gulakupedia

Development of an Image-Recognition-Based Food Sugar Estimation Feature Using Machine Learning in the Gulakupedia Application

M. Nabil Mustava¹, Ahmadi Irmansyah Lubis²

1,2 Program Studi Teknologi Rekayasa Perangkat Lunak, Jurusan Teknik Informatika, Politeknik Negeri Batam

nabilmustava26@gmail.com¹, ahmadi@polibatam.ac.id²

Article Info

Article history:

Received ...

Revised ...

Accepted ...

Keyword:

Image Recognition, Machine Learning, Convolutional Neural Network, YOLO, Diabetes Mellitus.

ABSTRACT

Type 2 Diabetes Mellitus is one of the most serious public health problems in Indonesia, with a national prevalence of 11.7% and an estimated 20.4 million adult patients. Controlling daily sugar intake is central to preventing and managing the disease, yet most traditional and home-cooked foods lack clear nutrition labels, making self-monitoring difficult. This study implements and integrates an image-recognition-based food sugar estimation feature into the Gulakupedia application, then measures the model accuracy and evaluates the feature functionality and usability. The problem is treated as a complex, multi-stage task: food classification from images, mapping sugar content to a standard serving size, and integration with the FatSecret nutrition database. A CRISP-DM framework was used to develop a YOLO object-detection model built on a Convolutional Neural Network (CNN) with transfer learning, while an Agile Scrum methodology guided the mobile application development. The detection model achieved a mAP50 of 0.691 on an independent test split, while the development target (mAP50 $\geq$ 0.70) was reached on the validation split (0.798); robustness against six image conditions was also examined. All 17 functional test cases in Black Box Testing passed (100% conformance), and the System Usability Scale (SUS) score was 75.97, categorized as Good/Acceptable. The quantized INT8 TFLite model (9.7 MB) ran on-device with a median end-to-end latency of about 2.04 s. The results indicate that the developed feature can help users monitor daily sugar intake independently and contribute to diabetes-complication prevention through practical, accessible technology.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Diabetes Melitus (DM) merupakan masalah kesehatan masyarakat yang serius, baik secara global maupun nasional. Menurut *International Diabetes Federation*, Indonesia termasuk lima besar negara dengan jumlah penderita diabetes terbanyak di dunia, dengan perkiraan 20,4 juta orang dewasa [1], sejalan dengan prevalensi DM nasional yang mencapai 11,7% pada penduduk usia 15 tahun ke atas [2]. DM Tipe 2 (DMT2) sebagian besar dapat dicegah dan ditunda

progresivitasnya melalui modifikasi gaya hidup, dengan pembatasan asupan gula bebas sebagai kunci utama [2], [3].

Tantangan utama terletak pada akurasi dan konsistensi pemantauan asupan gula sehari-hari, terutama karena banyak makanan rumahan atau tradisional tidak memiliki label gizi yang jelas. Kesulitan menghitung asupan secara mandiri menjadi penghalang utama penerapan intervensi diet secara ketat [4], [5], sehingga diperlukan solusi estimasi nutrisi yang cepat dan praktis.

Teknologi *Image Recognition* telah dimanfaatkan sejumlah aplikasi seperti MyFitnessPal, Fastic, dan Foodvisor untuk mengestimasi nutrisi makanan [6]. Namun solusi tersebut memiliki tiga keterbatasan: (1) berfokus pada kalori dan makronutrien secara umum, belum menempatkan gula sebagai keluaran utama padahal gula adalah faktor sentral pengendalian DMT2 [7]; (2) akurasi model menurun pada makanan non-Barat, yaitu estimasi energi cenderung berlebih pada pola makan Barat namun kurang pada pola makan Asia [8], sehingga kurang sesuai untuk makanan khas Indonesia; dan (3) sebagian besar penelitian masih berhenti pada tahap evaluasi model di dataset *benchmark*, belum terintegrasi ke produk yang dapat langsung digunakan pengguna akhir [6].

Perbedaan pendekatan penelitian ini terhadap solusi yang telah ada dirangkum pada tabel berikut.

TABEL 1
PERBANDINGAN PENDEKATAN DENGAN SOLUSI YANG ADA

Aspek	Aplikasi Umum (MyFitnessPal, Fastic, Foodvisor)	Gulakupedia (Penelitian Ini)
Keluaran utama	Kalori dan makronutrien secara umum	Estimasi gula sebagai keluaran utama
Cakupan makanan	Umumnya dioptimalkan untuk pola makan Barat	Dilatih dan disesuaikan untuk 26 kelas makanan khas Indonesia
Tahap pengembangan	Sebagian besar berhenti pada evaluasi model di dataset benchmark	Terintegrasi ke aplikasi yang telah digunakan pengguna nyata, diuji hingga tahap on-device

Kesenjangan inilah yang menjadi titik tolak penelitian ini: belum tersedianya fitur estimasi gula makanan yang menjadikan gula sebagai keluaran utama, dilatih dan disesuaikan untuk makanan khas Indonesia, sekaligus terintegrasi langsung ke dalam aplikasi yang telah digunakan pengguna nyata. Kebutuhan ini diperkuat temuan empiris: hanya 20% dari 30 pasien DMT2 mampu mengklasifikasikan makanan berkarbohidrat dengan benar [4], dan survei terhadap 196 penyandang diabetes tipe 1 merekomendasikan pengembangan aplikasi dengan fitur pengenalan citra dan personalisasi [5].

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan: (1) mengimplementasikan dan mengintegrasikan fitur estimasi gula berbasis *Image Recognition* ke dalam aplikasi Gulakupedia, termasuk menghubungkan hasil identifikasi makanan dengan takaran saji standar dan basis data gizi operasional (FatSecret API) serta menampilkan hasil estimasi gula yang dapat disesuaikan porsinya oleh pengguna; (2) mengukur tingkat akurasi deteksi dan klasifikasi model *Image Recognition* sebagai dasar fitur estimasi gula; dan (3) menguji fungsionalitas serta kualitas penggunaan fitur tersebut. Kontribusi utama penelitian terletak pada integrasi *pipeline* deteksi makanan khas Indonesia dan estimasi kandungan gula ke dalam satu aplikasi yang berjalan secara *on-device*, disertai bukti empiris kelayakan penerapannya pada perangkat fisik.

II. METODE PENELITIAN

A. Kerangka Metodologi

Penelitian ini menggunakan kerangka *Cross-Industry Standard Process for Data Mining* (CRISP-DM) untuk pengembangan model, karena inti permasalahannya adalah persoalan *supervised learning* yang berpusat pada data [9]. CRISP-DM mencakup enam tahap: pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan penerapan. Setiap tahap menjadi dasar analisis: pemahaman dan persiapan data mendasari analisis kualitas dataset; pemodelan dan evaluasi mendasari analisis kinerja model dan estimasi gula; penerapan mendasari analisis fungsionalitas dan kualitas pengguna.

Metodologi pengembangan perangkat lunak mengadopsi *Scrum* [10], [11], dipilih karena siklus pelatihan ulang model *Machine Learning* pada penelitian ini sulit direncanakan sepenuhnya di awal, sebab jumlah epoch, skema augmentasi, dan konfigurasi hyperparameter yang efektif baru diketahui setelah beberapa kali percobaan. Setiap *sprint* diakhiri dengan evaluasi terhadap bobot model terbaru; apabila target mAP50 belum tercapai, *sprint* berikutnya menyesuaikan strategi pelatihan sebelum berlanjut ke tahap integrasi aplikasi.

B. Landasan Teknis

Image Recognition merupakan cabang *Computer Vision* yang mengidentifikasi dan mengklasifikasikan objek dari citra digital dengan mengekstraksi fitur visual seperti bentuk, warna, dan tekstur menggunakan algoritma *Deep Learning*. Arsitektur dominan untuk pengolahan citra adalah *Convolutional Neural Network* (CNN), yang terdiri atas lapisan konvolusi, *pooling*, dan aktivasi non-linear untuk mengenali pola spasial [12]. Melalui *transfer learning* dan *fine-tuning*, model yang telah dilatih pada dataset besar disesuaikan dengan domain makanan lokal untuk mempercepat pelatihan dan meningkatkan akurasi.

Penelitian ini memilih arsitektur YOLO (*You Only Look Once*) sebagai detektor utama berdasarkan tiga pertimbangan. Pertama, pendekatan *one-stage* seperti YOLO memproses citra dalam satu lintasan jaringan sehingga jauh lebih cepat daripada pendekatan *two-stage*; Faster R-CNN membutuhkan rata-rata 5,1 detik per citra sedangkan YOLO hanya 1,16 detik [13]. Kedua, YOLO memiliki dukungan matang terhadap penerapan mobile melalui kuantisasi INT8 dan ekspor ke format TFLite [14]. Ketiga, YOLO memiliki rekam jejak mapan pada domain deteksi makanan [15]. Karena estimasi gula dihitung secara deterministik dari label kelas dan takaran saji, ketepatan identifikasi kelas lebih menentukan hasil dibandingkan ketepatan geometris kotak pembatas, sehingga mAP50 dipilih sebagai metrik acuan utama dan mAP50-95 sebagai pelengkap.

Agar dapat berjalan pada perangkat berdaya terbatas, model dioptimalkan melalui *quantization* (32-bit ke 8-bit), *pruning*, dan *knowledge distillation*, serta dijalankan melalui kerangka *edge AI* seperti TensorFlow Lite [16]. Strategi *on-device inference* ini meningkatkan efisiensi, kecepatan, dan privasi karena data tidak dikirim ke *cloud* [16].

C. Penentuan Porsi dan Formula Estimasi Gula


Porsi tidak diestimasi dari dimensi spasial citra, yang merupakan persoalan kompleks dan rentan kesalahan [17], melainkan ditetapkan berdasarkan takaran saji standar (*standard serving size*) per jenis makanan dengan nilai bawaan seragam 100 gram yang dapat disesuaikan pengguna. Kandungan gula dihitung dengan formula Gula estimasi = (Berat estimasi / 100) x Gula per 100 gram, dengan nilai gula per 100 gram diperoleh dari basis data gizi operasional FatSecret API, sedangkan USDA *Food Data Central* digunakan secara terpisah sebagai pembandingan independen.

D. Alat, Bahan, dan Dataset

Pelatihan model dijalankan menggunakan Python (3.9+) pada GPU NVIDIA A100-SXM4-40GB, sedangkan aplikasi dikembangkan menggunakan Dart/Flutter. Dataset gambar merupakan kombinasi dua sumber: bobot *transfer learning* dari dataset publik internasional (Food-101, Food-256) untuk fitur visual umum, dan dataset kustom hasil pengumpulan serta anotasi mandiri sebanyak 26 kelas makanan khas Indonesia melalui Roboflow untuk *fine-tuning*. Setiap kelas dipetakan ke takaran saji standar dan nilai gula per 100 gram dari FatSecret API.

E. Perancangan Sistem

Fitur yang dikembangkan merupakan penambahan pada aplikasi Gulakupedia yang telah berjalan, bukan aplikasi baru. Komponen yang telah tersedia (antarmuka, autentikasi, basis data pengguna/riwayat, *backend* Firebase) dipertahankan, sedangkan komponen baru meliputi antarmuka kamera, modul deteksi objek berbasis YOLO, modul pemetaan takaran saji ke kandungan gula, dan modul penyajian hasil. Sistem mengintegrasikan FatSecret API sebagai sumber nutrisi eksternal dan Firebase (*backend as a service*) untuk penyimpanan data. Kontribusi penelitian berfokus pada dua kebutuhan fungsional: FR-14 (pengguna mengunggah foto asupan dan memperoleh informasi gizi) dan FR-12 (pengguna mengubah nilai takaran saji dalam gram sehingga sistem menghitung ulang estimasi gula otomatis). Kebutuhan fungsional lain telah tersedia sebelumnya dan diuji sebagai pengujian regresi.



Gambar 1. Antarmuka aplikasi Gulakupedia: (a) beranda pencatatan asupan, (b) pencarian dan grade produk gula, (c) pemindaian kamera/barcode, (d) penyesuaian takaran saji.


F. Rencana Analisis

Analisis dilakukan pada lima aspek: (1) kualitas dataset; (2) kinerja model *Image Recognition* menggunakan mAP, *precision*, dan *recall* pada *test set* independen; (3) estimasi kandungan gula, dengan nilai gula sistem (FatSecret) dibandingkan terhadap USDA sebagai rujukan independen untuk menghindari pengujian sirkular; (4) fungsionalitas sistem melalui *Black Box Testing* atas seluruh kebutuhan fungsional; dan (5) kualitas pengguna melalui *System Usability Scale* (SUS) [18], yang diinterpretasikan menggunakan *Adjective Rating*, *Acceptability Range*, dan *Quartile Ranges* [19].

III. HASIL DAN PEMBAHASAN

A. Implementasi Sistem

Arsitektur akhir bekerja mengikuti alur berurutan: pengguna mengambil citra makanan melalui antarmuka kamera, lalu modul deteksi YOLO mengidentifikasi jenis makanan beserta tingkat kepercayaan; hasil deteksi diteruskan ke modul pemetaan yang menghubungkan kelas dengan takaran saji standar dan mengambil nilai gula per 100 gram dari FatSecret API; sistem menghitung estimasi gula sesuai porsi yang dapat disesuaikan pengguna; hasil ditampilkan dan disimpan ke basis data riwayat pada Firebase. Penambahan komponen baru tidak mengubah arsitektur inti aplikasi, melainkan menyisipkan jalur pemrosesan khusus untuk fitur estimasi gula. Komposisi akhir dataset dirangkum pada Tabel II.



Gambar 2. Alur end-to-end fitur estimasi gula berbasis *Image Recognition* pada aplikasi Gulakupedia.

TABEL II
KOMPOSISI DATASET MAKANAN INDONESIA (RINGKAS)

Statistik	Nilai
Jumlah kelas	26
Total anotasi	20.744
Train / Valid / Test	18.578 / 1.291 / 875
Rentang objek per kelas	321 - 1.952
Koefisien variasi antar-kelas	0,61

Model dilatih menggunakan YOLO26s (yolo26s.pt) dengan *transfer learning* dari bobot pra-latih. Konfigurasi pelatihan dirangkum pada Tabel III.

TABEL III
KONFIGURASI PELATIHAN MODEL YOLO

Parameter	Nilai
Model	yolo26s.pt
Epochs	150
Batch size	-1 (AutoBatch)
Input size	640 x 640
Optimizer	AdamW
Patience (early stop)	20
Mosaic / Mixup	1.0 / 0.05
Label smoothing	0.1
Flip (LR)	0.5
HSV-H / S / V	0.015 / 0.7 / 0.4
GPU	NVIDIA A100-40GB

Estimasi gula dihitung mengikuti formula pada Subbab II-C. Takaran saji bawaan ditetapkan 100 gram karena sumber data gizi tidak selalu mencantumkan berat gram untuk satuan seperti satu porsi atau satu potong, sehingga basis 100 gram menjaga keseragaman dan keterverifikasian perhitungan. Pengguna dapat mengubah nilai tersebut dan sistem menghitung ulang estimasi secara proporsional (FR-12).

B. Analisis Kualitas Dataset

Terdapat *class imbalance* dengan koefisien variasi 0,61 (rentang 321-1.952 objek per kelas), namun distribusi dinilai cukup representatif untuk domain target. Dari 8.306 gambar, 7.872 (94,8%) hanya memuat satu jenis makanan dan hanya 434 (5,2%) memuat lebih dari satu jenis. Proporsi *multi-food* yang kecil ini menyebabkan kapabilitas deteksi multi-makanan baru teruji secara terbatas. Analisis ko-okurensi menunjukkan pasangan soto-telur (139 gambar) dan ayam goreng-nasi putih (101 gambar) sebagai kombinasi tersering, konsisten dengan kebiasaan penyajian makanan Indonesia (lauk dan makanan pokok) sehingga menguatkan urgensi deteksi multi-objek.

C. Kinerja Model Image Recognition


Target pengembangan (mAP50 lebih besar sama dengan 0,70) tercapai pada *validation split* dengan nilai 0,798 (*precision* 0,808; *recall* 0,756). Namun karena *validation split* digunakan sebagai dasar *early stopping* dalam pemilihan bobot terbaik, nilai tersebut bersifat optimistis. Pada *test split* independen (318 citra, 875 anotasi), model memperoleh mAP50 0,691 (*precision* 0,793; *recall* 0,668; mAP50-95 0,597), dan nilai inilah yang dijadikan acuan utama. Kinerja tertinggi dicapai kelas soto (0,965), nasi putih (0,962), dan mie (0,955); terendah pada bakwan (0,229), ayam goreng

(0,327), dan gado-gado (0,356). Rincian per kelas disajikan pada Tabel IV. Selisih 0,107 antara kedua split ditelusuri melalui pemeriksaan kebocoran data (tidak ditemukan citra yang tersebar di lebih dari satu split) dan perbedaan komposisi: proporsi citra multi-food pada test split mencapai 17,3%, lebih tinggi dibandingkan 13,9% pada validation split, sementara kinerja model pada citra multi-food jauh lebih rendah (mAP50 0,340) dibandingkan citra single-food (mAP50 0,768).

TABEL IV
KINERJA MODEL PER KELAS PADA TEST SPLIT

Kelas	Precision	Recall	mAP50	mAP50-95
ayam bakar	0,843	0,586	0,635	0,528
ayam goreng	0,519	0,346	0,327	0,224
bakso	0,781	0,950	0,940	0,865
bakwan	0,492	0,194	0,229	0,158
bihun	0,947	0,739	0,758	0,705
capcay	0,908	0,450	0,510	0,437
gado-gado	0,548	0,400	0,356	0,335
ikan goreng	0,932	0,919	0,939	0,800
kerupuk	0,913	0,927	0,934	0,658
martabak telur	0,893	0,868	0,948	0,772
mie	0,969	0,952	0,955	0,864
nasi goreng	0,957	0,936	0,955	0,929
nasi putih	0,912	0,885	0,962	0,801
nugget	0,680	0,722	0,791	0,740
opor ayam	0,963	0,800	0,840	0,789
pempek	0,542	0,587	0,553	0,391
rendang	0,872	0,514	0,510	0,486
roti	0,872	0,773	0,868	0,719
sate	0,809	0,652	0,560	0,380
sosis	0,766	0,531	0,553	0,460
soto	1,000	0,915	0,965	0,908
tahu	0,857	0,560	0,686	0,597
telur	0,654	0,522	0,514	0,488
tempe	0,557	0,290	0,378	0,311
tumis kangkung	0,935	0,900	0,895	0,784
udang	0,507	0,450	0,398	0,395
Keseluruhan	0,793	0,668	0,691	0,597

Pola kegagalan utama adalah kegagalan deteksi (objek tidak terdeteksi), bukan kesalahan klasifikasi; baris *background* pada *confusion matrix* tinggi untuk gado-gado (0,60), capcay (0,45), dan udang (0,45), konsisten dengan *recall* rendah pada kelas tersebut. Kegagalan ini terutama disebabkan oklusi dan tumpang tindih antar-objek pada citra *multi-food* (mAP50 0,340) dibanding *single-food* (mAP50 0,768). Kesalahan klasifikasi yang terjadi umumnya antar-kelas mirip secara visual (bihun dengan mie, bakwan dengan martabak telur, tahu dengan tempe). Beberapa kelas hanya memiliki sekitar 20-25 anotasi pada *test split*, sehingga nilai per kelas dibaca sebagai indikasi kecenderungan, sedangkan nilai keseluruhan (875 anotasi) lebih andal.



Gambar 3. Confusion matrix model YOLO pada 26 kelas makanan (test split, 875 anotasi).

D. Analisis Estimasi Kandungan Gula

Estimasi gula bersifat deterministik (perkalian aritmetika langsung), sehingga tidak memiliki *error* yang perlu dilatih atau divalidasi. Untuk menggambarkan konsistensi nilai gizi acuan, nilai gula FatSecret dibandingkan dengan USDA pada takaran saji sama (Tabel V). Selisih antar-sumber kecil dan mencerminkan variasi pembulatan serta perbedaan sumber data, bukan ukuran akurasi model deteksi.

TABEL V
PERBANDINGAN NILAI GULA ANTAR-BASIS DATA (FatSecret vs USDA, PER 100 g)

Sampel (Kelas)	FatSecret	USDA	Selisih
Nasi Putih	0,05 g	0,05 g	0,00 g
Capcay	2,12 g	3,63 g	1,51 g
Tahu	2,72 g	2,72 g	0,00 g
Telur	0,83 g	0,40 g	0,43 g
Sosis	0,00 g	0,00 g	0,00 g
Nugget	0,88 g	0,08 g	0,80 g
Bihun	1,30 g	0,03 g	1,27 g
Udang	0,91 g	0,20 g	0,71 g
Ayam Goreng	0,22 g	0,00 g	0,22 g
Kerupuk	3,23 g	3,12 g	0,11 g

E. Fungsionalitas Sistem

Pengujian *Black Box* dilakukan menyeluruh terhadap seluruh 17 kebutuhan fungsional (FR-01 s.d. FR-17), dengan pendalaman pada FR-12 dan FR-14. Seluruh 17 kasus uji berhasil dengan kesesuaian 100%. Dua kasus kontribusi utama: KU-01 (FR-12) memindai nasi goreng dengan takaran bawaan 100 g (estimasi 0,76 g), lalu mengubah ke 50 g menghasilkan estimasi terhitung ulang menjadi 0,38 g dan tersimpan sesuai nilai baru; KU-02 (FR-14) mengunggah foto berisi lebih dari satu jenis makanan, dan sistem menyimpan setiap makanan sebagai catatan asupan terpisah.


F. Kualitas Pengguna (SUS)

Evaluasi SUS melibatkan 31 responden. Kuesioner merupakan instrumen gabungan SUS-UEQ, dan hanya sepuluh pernyataan baku SUS yang diekstrak dan dihitung.

Diperoleh skor rata-rata 75,97, termasuk kategori *Good* dan berada pada rentang *Acceptable*. Sebanyak 24 dari 31 responden (77,4%) memberikan skor di atas ambang 68, yang memperkuat validitas kemudahan penggunaan aplikasi.

G. Ketahanan Model pada Berbagai Kondisi Citra

Pengujian dilakukan pada 318 citra *test split* yang dimodifikasi terkontrol menjadi enam kondisi (Tabel VI). Kondisi yang telah terwakili dalam skema augmentasi pelatihan (kecerahan dan rotasi) hanya menurunkan mAP50 masing-masing 0,006 dan 0,021, sedangkan *Gaussian blur* yang tidak terwakili menghasilkan penurunan mAP50 terbesar (0,026). Kelas yang dikenali melalui tekstur halus paling terdampak *blur* (ayam bakar turun dari 0,635 menjadi 0,159; nasi goreng turun 0,149), sedangkan kelas yang dikenali melalui bentuk dan warna (bakso, mie, soto) hampir tidak terpengaruh. Temuan ini mengindikasikan penambahan augmentasi *blur* pada pelatihan berpotensi meningkatkan ketahanan terhadap citra kabur akibat guncangan kamera atau fokus kurang tepat.



Gambar 4. Perbandingan deteksi YOLO pada kelas roti untuk kondisi baseline dan lima kondisi augmentasi terkontrol.

TABEL VI
KINERJA MODEL PADA ENAM KONDISI CITRA

Kondisi	Precision	Recall	mAP50	Selisih mAP50
Baseline	0,793	0,668	0,691	+0,000
Brightness -20%	0,787	0,650	0,684	-0,006
Brightness +20%	0,819	0,647	0,684	-0,006
Rotasi 15 derajat	0,760	0,626	0,669	-0,021
Gaussian blur	0,765	0,613	0,664	-0,026
Resolusi rendah	0,780	0,662	0,682	-0,008

H. Evaluasi Penerapan On-Device

Pengujian pada perangkat fisik Samsung SM-S928B menunjukkan waktu latensi *end-to-end* median 2,04 detik (rata-rata 1,96 detik; persentil-95 2,08 detik; 100 iterasi). Kuantisasi menurunkan ukuran model dari 20,4 MB (FP32) menjadi 9,7 MB (INT8). Penggunaan memori naik dari 275,6 MB saat *idle* menjadi 457 MB saat inferensi, dengan komponen *native* meningkat dari 43,8 MB menjadi 145,7 MB (beban *interpreter* TFLite pada lapisan C++), dan

penggunaan CPU dari 0% menjadi 26%. Hasil ini menegaskan kelayakan penerapan deteksi makanan secara *on-device* tanpa pemrosesan sisi server. Perlu dicatat bahwa nilai akurasi (mAP50, precision, recall) yang dilaporkan pada Subbab III-C merupakan hasil model presisi penuh (FP32), sedangkan model yang dijalankan *on-device* adalah versi terkuantisasi INT8 yang kinerjanya dapat berbeda per kelas—misalnya kelas bakso mengalami penurunan mAP50 dari 0,940 (FP32) menjadi 0,737 (INT8)—sehingga akurasi aktual pada perangkat perlu dibaca dengan mempertimbangkan efek kuantisasi tersebut.

I. Pembahasan

Penelitian berhasil mengintegrasikan model deteksi berbasis *Image Recognition* ke aplikasi Gulakupedia dengan *transfer learning* pada YOLO, mencapai mAP50 0,691 pada *test split* independen. Pencapaian ini didorong kelas dengan tekstur dan warna khas (soto, nasi putih, mie, nasi goreng), menunjukkan *fine-tuning* pada dataset lokal efektif ketika variasi visual antar-gambar dalam satu kelas relatif konsisten. Sebaliknya, kinerja rendah pada bakwan, ayam goreng, dan gado-gado menegaskan *domain adaptation* belum sepenuhnya menutup kesenjangan pada kelas dengan variasi penyajian tinggi.

Karena berat makanan berasal dari masukan pengguna, tanggung jawab model terbatas pada penentuan kelas. Galat merambat melalui dua jalur: kesalahan klasifikasi kelas, sehingga nilai gula per 100 gram menjadi keliru dan seluruh perhitungan mewarisi kesalahan tersebut; serta *false negative*, yaitu makanan tidak terdeteksi sehingga estimasi tidak tersedia sama sekali. Dengan demikian, estimasi gula sebaiknya diperlakukan sebagai perkiraan indikatif untuk membantu kesadaran konsumsi gula, bukan pengganti pengukuran laboratorium.

Nilai gula bersumber dari FatSecret yang sebagian besar dikontribusikan komunitas dan tidak seluruhnya terverifikasi terhadap standar seperti Tabel Komposisi Pangan Indonesia (TKPI); makanan tradisional Indonesia juga tidak memiliki resep baku sehingga tidak ada nilai tunggal yang mewakili seluruh variasi. Dari sisi skalabilitas, arsitektur YOLO tidak mendukung penambahan kelas inkremental karena penambahan kelas mengubah dimensi lapisan keluaran dan menuntut pelatihan ulang; karena model dikemas sebagai aset lokal, setiap pembaruan menuntut *rebuild* dan perlisian ulang aplikasi. Dibandingkan pendekatan estimasi porsi geometris [20], penelitian ini memilih pemetaan hasil deteksi ke takaran saji standar karena lebih ringan untuk perangkat mobile, dengan konsekuensi keterbatasan akurasi porsi aktual.

Merujuk pada tiga tujuan penelitian yang diajukan pada Bagian I, capaian penelitian ini dapat dirangkum sebagai berikut: tujuan pertama (implementasi dan integrasi fitur) tercapai sepenuhnya, dibuktikan oleh keberhasilan seluruh 17 kasus uji Black Box; tujuan kedua (pengukuran akurasi deteksi) tercapai dengan mAP50 0,691 pada *test split* independen, meskipun belum mencapai target 0,70 pada data

yang sama; dan tujuan ketiga (pengujian fungsionalitas dan kualitas penggunaan) terpenuhi melalui skor SUS 75,97. Evaluasi SUS pada penelitian ini melibatkan 31 responden dari lingkungan pengguna awal Gulakupedia, sehingga generalisasi skor ke populasi pengguna yang lebih luas maupun ke kelompok penyandang DMT2 secara khusus masih memerlukan validasi lanjutan pada sampel yang lebih besar dan lebih beragam.

IV. KESIMPULAN

Arsitektur *Machine Learning* berhasil diimplementasikan ke aplikasi Gulakupedia menggunakan *transfer learning* pada YOLO, terintegrasi *end-to-end*: model mendeteksi jenis makanan, lalu sistem memetakan ke takaran saji standar dan menarik nilai gizi dari FatSecret API untuk menghitung estimasi gula. Model mencapai mAP50 0,691, *precision* 0,793, dan *recall* 0,668 pada *test split* independen; target pengembangan (mAP50 lebih besar sama dengan 0,70) tercapai pada *validation split* (0,798). Estimasi gula bersifat deterministik dan konsisten terhadap masukan; perbandingan terhadap USDA menunjukkan selisih antar-sumber yang kecil.

Pengujian *Black Box* mengonfirmasi seluruh 17 kasus uji fungsional (termasuk skenario multi-makanan FR-12 dan FR-14) berjalan sesuai skenario (100%), dan skor SUS 75,97 menempatkan fitur pada kategori Good/Acceptable. Pengujian ketahanan pada enam kondisi citra menunjukkan model tahan terhadap perubahan pencahayaan (penurunan mAP50 hanya 0,006), dengan penurunan terbesar pada Gaussian blur (0,026). Sistem terbukti berjalan *on-device* pada perangkat fisik dengan waktu proses sekitar 2,04 detik, ukuran model 9,7 MB, serta penggunaan memori dan CPU dalam batas wajar.

Saran pengembangan lanjutan meliputi estimasi berat/porsi langsung dari citra (misalnya *depth estimation*), perluasan basis data gizi lokal terverifikasi (TKPI) dan penambahan kelas, deduplikasi deteksi berbasis ambang IoU pada pencatatan multi-makanan, serta penambahan augmentasi berbasis *blur* dan degradasi resolusi pada pelatihan.

UCAPAN TERIMA KASIH

Atas bimbingan yang diberikan sepanjang penyusunan penelitian ini, penulis menyampaikan apresiasi kepada Bapak Ahmadi Irmansyah Lubis, S.Kom., M.Kom., dosen pembimbing program studi. Terima kasih juga penulis sampaikan kepada keluarga serta rekan-rekan mahasiswa angkatan 2022 yang telah memberikan dukungan selama penelitian berlangsung.

DAFTAR PUSTAKA

- [1] International Diabetes Federation, IDF Diabetes Atlas, 11th ed. Brussels, Belgium: IDF, 2025.
- [2] PERKENI, Pedoman Pengelolaan dan Pencegahan Diabetes Melitus Tipe 2 di Indonesia 2024. Jakarta: Perkumpulan Endokrinologi Indonesia, 2024.

-
- [3] American Diabetes Association, "Prevention or delay of diabetes and associated comorbidities: Standards of care in diabetes 2025," *Diabetes Care*, vol. 48, no. Suppl. 1, pp. S50-S58, 2024.
 - [4] K. M. Richardson et al., "Abbreviated dietary self-monitoring for type 2 diabetes management: Mixed methods feasibility study," *JMIR Diabetes*, doi: 10.2196/28930.
 - [5] A. Housni, A. Katz, L. J. Bergeron, A. Simard, and A. Finkel, "Bridging the gap in carbohydrate counting with a mobile app: Needs assessment survey," *JMIR Diabetes*, vol. 27, pp. 1-12, doi: 10.2196/63278.
 - [6] G. A. Tahir, "A comprehensive survey of image-based food recognition and volume estimation methods for dietary assessment," *Healthcare*, vol. 9, no. 12, 2021.
 - [7] M. Y. Kardawi, F. M. Saragih, L. Rahadiani, and A. M. Arymurthy, "Indonesian food classification using deep feature extraction and ensemble learning for dietary assessment," *J. Appl. Inform. Comput.*, vol. 9, no. 5, pp. 2009-2018, 2025.
 - [8] X. Li, A. Yin, H. Y. Choi, V. Chan, M. Allman-Farinelli, and J. Chen, "Evaluating the quality and comparative validity of manual food logging and AI-enabled food image recognition in apps for nutrition care," *Nutrients*, vol. 16, no. 15, 2024.
 - [9] C. Schroer, F. Kruse, and J. M. Gomez, "A systematic literature review on applying CRISP-DM process model," *Procedia Comput. Sci.*, vol. 181, pp. 526-534, 2021.
 - [10] S. Al-Saqqah, S. Sawalha, and H. Abdel-Nabi, "Agile software development: Methodologies and trends," *Int. J. Interact. Mobile Technol.*, vol. 14, no. 11, pp. 246-270, 2020.
 - [11] K. Schwaber and J. Sutherland, *The Scrum Guide*, 2020.
 - [12] X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, "A review of convolutional neural networks in computer vision," *Artif. Intell. Rev.*, vol. 57, no. 4, 2024.
 - [13] S. Reddy, N. Pillay, and N. Singh, "Comparative evaluation of convolutional neural network object detection algorithms for vehicle detection," *J. Imaging*, vol. 10, no. 7, 2024.
 - [14] H. C. Moon, S. Lee, J. Jeong, and S. Kim, "YOLOv6+: Simple and optimized object detection model for INT8 quantized inference on mobile devices," *Signal Image Video Process.*, vol. 19, no. 8, pp. 1-9, 2025.
 - [15] G. Chrintz-Gath, M. Daivadanam, L. Matta, and S. McKeever, "Image-based dietary assessment using the Swedish plate model: Evaluation of YOLO models," *JMIR Formative Res.*, vol. 9, pp. 1-15, 2025.
 - [16] P. Mittal, "A comprehensive survey of deep learning-based lightweight object detection models for edge devices," *Artif. Intell. Rev.*, vol. 57, no. 9, 2024.
 - [17] G. Liu, Y. Jiao, J. Chen, B. Zhu, and Y. G. Jiang, "From canteen food to daily meals: Generalizing food recognition to more practical scenarios," *IEEE Trans. Multimedia*, vol. 27, pp. 2724-2733, 2025.
 - [18] J. Brooke, "SUS: A quick and dirty usability scale," in *Usability Evaluation in Industry*, 1996, pp. 207-212.
 - [19] A. Bangor, P. T. Kortum, and J. T. Miller, "An empirical evaluation of the system usability scale," *Int. J. Hum.-Comput. Interact.*, vol. 24, no. 6, pp. 574-594, 2008.
 - [20] A. Sanatbyek et al., "A multitask deep learning model for food scene recognition and portion estimation - the Food Portion Benchmark (FPB) dataset," *IEEE Access*, vol. 13, pp. 152033-152045, 2025.