



Department of Digital Business

Journal of Artificial Intelligence and Digital Business (RIGGS)

Homepage: <https://journal.ilmudata.co.id/index.php/RIGGS>

Vol. 5 No. 5 (2026) pp: 11043-11051

P-ISSN: 2963-9298, e-ISSN: 2963-914X

Analisis Kinerja YOLOv11 untuk Deteksi Makanan Program MBG

Charladinna Arvianne Reyvalda

Program Studi Teknik Informatika, Fakultas Teknik, Universitas Muhadi Setiabudi Brebes,
charladinnabeatbox@gmail.com

Abstrak

Program Makan Bergizi Gratis (MBG) merupakan salah satu program strategis pemerintah Indonesia yang bertujuan meningkatkan kualitas gizi peserta didik melalui penyediaan makanan bergizi seimbang. Monitoring jenis makanan dan estimasi kandungan gizi pada program tersebut masih banyak dilakukan secara manual dengan mengacu pada Tabel Komposisi Pangan Indonesia (TKPI), sehingga memerlukan waktu yang relatif lama, berpotensi menimbulkan kesalahan pencatatan, serta kurang efisien ketika jumlah paket makanan yang diproduksi semakin meningkat. Penelitian ini bertujuan menganalisis kinerja model YOLOv11 dalam mendeteksi berbagai jenis makanan pada paket Program Makan Bergizi Gratis (MBG) serta mengintegrasikan hasil deteksi dengan database TKPI untuk menghasilkan estimasi kandungan gizi secara otomatis. Dataset yang digunakan terdiri atas 410 citra dengan 14 kelas makanan, yaitu ayam, bakso, buah, kacang, keju, kentang, mie, nasi, roti, sayur, susu, tahu, tempe, dan telur. Proses anotasi dilakukan menggunakan Roboflow, sedangkan pelatihan model memanfaatkan framework Ultralytics YOLOv11 selama 30 epoch dengan ukuran citra 640×640 piksel. Evaluasi model dilakukan menggunakan metrik precision, recall, mAP50, mAP50-95, dan confusion matrix. Hasil pengujian menunjukkan nilai precision sebesar 0,91, recall sebesar 0,86, mAP50 sebesar 0,92, dan mAP50-95 sebesar 0,84, yang menunjukkan bahwa model memiliki kemampuan deteksi objek makanan dengan tingkat akurasi yang baik. Model kemudian diimplementasikan pada aplikasi berbasis Streamlit dan diintegrasikan dengan database TKPI sehingga mampu menampilkan estimasi kandungan energi, protein, lemak, karbohidrat, dan serat secara otomatis. Hasil penelitian menunjukkan bahwa integrasi YOLOv11, Streamlit, dan TKPI berpotensi mendukung proses monitoring makanan Program MBG secara lebih cepat, akurat, efisien, dan terstruktur, serta dapat menjadi dasar pengembangan sistem pemantauan gizi berbasis kecerdasan buatan pada institusi pendidikan maupun penyelenggara Program Makan Bergizi Gratis.

Kata kunci: YOLOv11, Deteksi Makanan, Computer Vision, Program Makan Bergizi Gratis, Tabel Komposisi Pangan Indonesia, Estimasi Gizi.

1. Pendahuluan

Program Makan Bergizi Gratis (MBG) merupakan salah satu program pemerintah Indonesia yang bertujuan meningkatkan kualitas gizi peserta didik melalui penyediaan makanan sehat dan bergizi secara rutin. Pemenuhan gizi yang baik berperan penting dalam mendukung pertumbuhan, kesehatan, dan kemampuan belajar peserta didik [1]. Dalam pelaksanaannya, setiap paket makanan terdiri atas beberapa jenis makanan yang memiliki kandungan energi, protein, lemak, karbohidrat, dan serat yang berbeda-beda [2].

Proses monitoring kandungan gizi pada makanan MBG umumnya masih dilakukan secara manual dengan mengacu pada Tabel Komposisi Pangan Indonesia (TKPI). Metode tersebut memerlukan waktu yang cukup lama karena petugas harus mengidentifikasi jenis makanan kemudian menghitung kandungan gizi berdasarkan data referensi yang tersedia [2]. Selain membutuhkan waktu yang lebih banyak, metode manual juga berpotensi menimbulkan kesalahan pencatatan maupun kesalahan perhitungan ketika jumlah makanan yang diproduksi semakin besar [3].

Perkembangan teknologi Artificial Intelligence (AI) khususnya pada bidang computer vision memungkinkan proses identifikasi objek dilakukan secara otomatis menggunakan citra digital [4]. Salah satu metode yang banyak digunakan dalam object detection adalah You Only Look Once (YOLO). Metode ini mampu melakukan proses deteksi objek secara real-time dengan tingkat akurasi yang tinggi dan waktu inferensi yang relatif cepat dibandingkan beberapa metode lainnya [5].

Penelitian terkait deteksi makanan menggunakan metode YOLO telah banyak dilakukan. Min et al. menjelaskan bahwa teknologi food computing dan deep learning dapat dimanfaatkan untuk pengenalan makanan berbasis citra digital [6]. Wang et al. berhasil menerapkan model YOLO untuk mendeteksi berbagai jenis makanan pada citra digital dengan hasil yang cukup baik [7]. Ahmed et al. mengembangkan sistem pengenalan makanan berbasis web menggunakan pendekatan deep learning untuk membantu identifikasi makanan secara otomatis [8].

Meskipun demikian, sebagian besar penelitian masih berfokus pada proses identifikasi makanan dan belum menghubungkan hasil deteksi dengan estimasi kandungan gizi berdasarkan data referensi pangan. Oleh karena itu, penelitian ini dilakukan untuk menganalisis performa model YOLOv11 dalam mendeteksi jenis makanan pada Program Makan Bergizi Gratis (MBG). Hasil deteksi kemudian diintegrasikan dengan data Tabel Komposisi Pangan Indonesia (TKPI) sehingga dapat digunakan sebagai dasar estimasi kandungan gizi secara otomatis. Kebaruan penelitian ini terletak pada integrasi antara model YOLOv11, database TKPI, dan aplikasi berbasis web menggunakan Streamlit yang mendukung proses monitoring makanan secara lebih efektif dan terstruktur [9],[10].

Penelitian lain juga mengembangkan metode hybrid deep learning untuk pengenalan makanan dan estimasi kalori sehingga mampu meningkatkan akurasi dibandingkan penggunaan satu model saja [11]

Kontribusi penelitian ini meliputi analisis kinerja YOLOv11 untuk deteksi makanan Program MBG, integrasi hasil deteksi dengan data TKPI untuk estimasi kandungan gizi, dan implementasi sistem berbasis web menggunakan Streamlit untuk mendukung monitoring makanan secara otomatis. Pendekatan computer vision juga telah banyak digunakan untuk estimasi kandungan gizi berdasarkan hasil pengenalan makanan sehingga mendukung pengembangan sistem monitoring gizi otomatis [12]


2. Metode Penelitian

Proses anotasi dilakukan menggunakan platform Roboflow. Setiap objek makanan diberikan bounding box dan label sesuai kelas makanan yang telah ditentukan. Roboflow digunakan karena mampu membantu proses anotasi, augmentasi, dan pengelolaan dataset secara lebih efisien [13].

Pelatihan model dilakukan menggunakan framework Ultralytics YOLOv11 dengan parameter pelatihan berupa epoch sebanyak 30, image size 640×640 piksel, dan batch size sebesar 8. YOLOv11 dipilih karena memiliki peningkatan performa dalam ekstraksi fitur, efisiensi komputasi, dan kecepatan inferensi dibandingkan versi sebelumnya [13].

Evaluasi model dilakukan menggunakan Precision, Recall, mean Average Precision pada IoU 0.5 (mAP50), dan mean Average Precision pada rentang IoU 0.5 sampai 0.95 (mAP50-95). Metrik tersebut merupakan standar evaluasi yang umum digunakan dalam penelitian object detection [14].

Penelitian ini dilakukan melalui beberapa tahapan yang dimulai dari pengumpulan dataset makanan Program Makan Bergizi Gratis (MBG), proses anotasi menggunakan Roboflow, pembagian dataset menjadi data pelatihan, validasi, dan pengujian, pelatihan model YOLOv11, evaluasi performa model, implementasi model ke dalam aplikasi berbasis Streamlit, serta integrasi hasil deteksi dengan database Tabel Komposisi Pangan Indonesia (TKPI) untuk menghasilkan estimasi kandungan gizi makanan secara otomatis.



Gambar 1. Gambar Alur Penelitian

Dataset dibagi menjadi 378 data training (92,2%), 16 data validation (3,9%), dan 16 data testing (3,9%). Pembagian data dilakukan untuk memastikan model dapat dilatih dan dievaluasi menggunakan data yang berbeda sehingga mengurangi risiko overfitting.

2.1. Pengumpulan Data

Dataset diperoleh melalui proses dokumentasi makanan Program Makan Bergizi Gratis (MBG) di SPPG Pasarbatang Kabupaten Brebes. Pengambilan gambar dilakukan menggunakan kamera smartphone dengan variasi sudut pengambilan dan kondisi pencahayaan yang berbeda untuk meningkatkan keragaman data.

Dataset yang berhasil dikumpulkan terdiri atas 410 citra makanan dengan 14 kelas objek yaitu ayam, bakso, buah, kacang, keju, kentang, mie, nasi, roti, sayur, susu, tahu, telur, dan tempe



Gambar 2. Dataset Foto Menu Ompreng MBG

2.2. Anotasi Dataset

Proses anotasi dilakukan menggunakan platform Roboflow. Setiap objek makanan diberikan bounding box dan label sesuai kelas makanan yang telah ditentukan. Dataset kemudian dibagi menjadi data training, validation, dan testing.

Tabel 1. Distribusi Dataset

Dataset	Jumlah
Training	378
Validation	16
Testing	16
Total	410

2.3 Pelatihan Model

Pelatihan model dilakukan menggunakan framework Ultralytics YOLOv11 sesuai dokumentasi resmi Ultralytics [15]

Tabel 2. Parameter Pelatihan Model

Parameter	Nilai
Model	YOLOv11
Epoch	30
Image Size	640 x 640
Batch Size	8
Jumlah Kelas	14


2.4 Evaluasi Model

Evaluasi model dilakukan menggunakan Precision, Recall, mean Average Precision pada IoU 0.5 (mAP50), dan mean Average Precision pada rentang IoU 0.5 sampai 0.95 (mAP50-95). Selain itu digunakan Confusion Matrix untuk melihat tingkat kesalahan klasifikasi antar kelas makanan.

3. Hasil dan Diskusi

Berdasarkan hasil pelatihan diperoleh nilai Precision sebesar 0,91, Recall sebesar 0,86, mAP50 sebesar 0,92, dan mAP50-95 sebesar 0,84. Nilai tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam mendeteksi objek makanan pada paket MBG. Menurut Padilla et al., nilai mAP yang tinggi menunjukkan tingkat kesesuaian yang baik antara hasil prediksi model dengan objek sebenarnya pada dataset pengujian [14].

Model yang telah dilatih kemudian diintegrasikan ke dalam aplikasi berbasis web menggunakan Streamlit. Hasil deteksi makanan dipetakan ke database TKPI sehingga sistem dapat menampilkan estimasi energi, protein, lemak, karbohidrat, dan serat secara otomatis [2],[10].



Gambar 3. Grafik Hasil Pelatihan Model YOLOv11

Gambar 3 menunjukkan proses pelatihan model YOLOv11 selama 30 epoch. Nilai box loss, classification loss, dan distribution focal loss mengalami penurunan secara bertahap hingga akhir pelatihan. Pada saat yang sama nilai precision, recall, mAP50, dan mAP50-95 mengalami peningkatan yang menunjukkan bahwa model mampu mempelajari karakteristik objek makanan dengan baik. Hasil evaluasi model YOLOv11 ditunjukkan pada Tabel 3.

Tabel 3. Hasil Evaluasi Model

Metrik	Nilai
Precision	0.91
Recall	0.86
mAP50	0.92
mAP50-95	0.84

3.1 Hasil Deteksi Makanan

Nilai precision sebesar 0.91 menunjukkan bahwa sebagian besar objek yang berhasil dideteksi oleh model merupakan objek yang benar. Nilai recall sebesar 0.86 menunjukkan bahwa model mampu menemukan sebagian besar objek makanan yang terdapat pada citra. Nilai mAP50 sebesar 0.92 dan mAP50-95 sebesar 0.84 menunjukkan bahwa model memiliki kemampuan deteksi yang baik pada berbagai tingkat Intersection over Union (IoU). Hasil tersebut menunjukkan bahwa model YOLOv11 memiliki kemampuan yang baik dalam mengenali berbagai jenis makanan pada paket MBG. Tingginya nilai precision dan mAP menunjukkan bahwa model mampu menghasilkan prediksi yang akurat sehingga dapat digunakan sebagai dasar dalam proses estimasi kandungan gizi secara otomatis.




Gambar 4. Hasil Deteksi Makanan

Pada Gambar 4 terlihat bahwa model berhasil mendeteksi objek makanan seperti ayam, nasi, sayur, dan telur dengan nilai confidence yang tinggi. Tingginya nilai confidence menunjukkan bahwa model memiliki kemampuan yang baik dalam membedakan karakteristik visual setiap jenis makanan yang terdapat pada paket MBG.

Hasil deteksi tersebut selanjutnya digunakan sebagai masukan untuk proses estimasi kandungan gizi berdasarkan data Tabel Komposisi Pangan Indonesia (TKPI). Dengan demikian, proses identifikasi makanan dan perhitungan kandungan gizi dapat dilakukan secara otomatis tanpa memerlukan pencatatan manual oleh pengguna.

3.2 Analisis Confusion Matrix




Gambar 5. Analisis Confusion Matrix

Hasil confusion matrix menunjukkan bahwa kelas nasi, mie, susu, kentang, dan roti memiliki tingkat deteksi yang tinggi. Beberapa kesalahan klasifikasi masih ditemukan pada kelas buah, bakso, dan telur. Kesalahan tersebut diduga terjadi karena adanya kemiripan bentuk, warna, maupun posisi objek pada saat pengambilan gambar. Selain itu, variasi pencahayaan dan sudut pengambilan gambar juga dapat mempengaruhi kemampuan model dalam membedakan objek yang memiliki karakteristik visual serupa.

Secara keseluruhan, hasil confusion matrix menunjukkan bahwa model YOLOv11 mampu melakukan klasifikasi objek makanan dengan baik. Tingkat kesalahan yang relatif rendah menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik terhadap data pengujian yang digunakan dalam penelitian ini.

3.3 Implementasi Sistem

Model YOLOv11 yang telah dilatih kemudian diintegrasikan ke dalam aplikasi berbasis web menggunakan Streamlit. Sistem menyediakan fitur login, registrasi pengguna, deteksi makanan, estimasi kandungan gizi, laporan deteksi, pengelolaan data TKPI, dan riwayat deteksi pengguna.



Gambar 6. Halaman Deteksi Makanan

Pada halaman deteksi makanan, pengguna dapat mengunggah gambar makanan yang akan dianalisis oleh sistem. Setelah gambar berhasil diunggah, model YOLOv11 akan melakukan proses deteksi objek secara otomatis dan menampilkan hasil deteksi berupa nama makanan beserta bounding box pada setiap objek yang berhasil dikenali.

Selanjutnya, sistem akan mencocokkan hasil deteksi dengan database TKPI untuk memperoleh informasi kandungan gizi dari setiap jenis makanan yang terdeteksi. Informasi yang ditampilkan meliputi nilai energi, protein, lemak, karbohidrat, dan serat. Hasil estimasi gizi tersebut dapat digunakan sebagai bahan monitoring kualitas makanan pada Program Makan Bergizi Gratis.

Selain fitur deteksi makanan, sistem juga menyediakan fitur login pengguna, registrasi akun, pengelolaan data TKPI, riwayat deteksi, serta laporan hasil deteksi. Dengan adanya integrasi antara model YOLOv11, database TKPI, dan aplikasi web berbasis Streamlit, proses identifikasi makanan dan estimasi kandungan gizi dapat dilakukan secara lebih cepat, efektif, dan terstruktur dibandingkan metode manual.

Hasil implementasi menunjukkan bahwa sistem mampu menjalankan proses deteksi makanan secara real-time dengan tingkat akurasi yang sesuai dengan hasil evaluasi model. Oleh karena itu, sistem yang dikembangkan berpotensi untuk mendukung proses monitoring makanan pada Program Makan Bergizi Gratis secara lebih efisien.

3.4 Perbandingan Kinerja YOLOv11 dengan Penelitian Sebelumnya

Model YOLOv11 yang digunakan pada penelitian ini menunjukkan performa yang baik dalam mendeteksi objek makanan pada Program Makan Bergizi Gratis (MBG). Berdasarkan hasil pengujian diperoleh nilai precision sebesar 0,91, recall sebesar 0,86, mAP50 sebesar 0,92, dan mAP50-95 sebesar 0,84. Nilai tersebut menunjukkan bahwa sebagian besar objek makanan berhasil dikenali dengan tingkat ketepatan yang tinggi meskipun terdapat variasi bentuk, ukuran, maupun posisi makanan pada setiap paket MBG.

Apabila dibandingkan dengan penelitian terdahulu yang menggunakan YOLOv5 maupun YOLOv8 pada deteksi makanan, YOLOv11 memiliki peningkatan pada efisiensi komputasi dan kemampuan ekstraksi fitur sehingga mampu menghasilkan proses inferensi yang lebih cepat tanpa mengurangi tingkat akurasi. Peningkatan tersebut sangat bermanfaat apabila sistem diterapkan pada proses monitoring makanan secara real-time karena mampu mempercepat proses identifikasi objek dalam jumlah yang besar. Selain itu, penggunaan dataset yang berasal langsung dari menu MBG menjadikan model lebih sesuai dengan kondisi lapangan dibandingkan model yang dilatih menggunakan dataset makanan umum. Dengan demikian, hasil penelitian ini memiliki potensi implementasi yang lebih tinggi pada lingkungan penyelenggara Program MBG.

3.5 Analisis Faktor yang Mempengaruhi Akurasi Model

Keberhasilan model YOLOv11 dalam mengenali objek makanan dipengaruhi oleh beberapa faktor. Faktor pertama adalah kualitas dataset yang digunakan selama proses pelatihan. Dataset yang memiliki variasi sudut pengambilan gambar, pencahayaan, dan komposisi menu akan membantu model mempelajari karakteristik visual setiap objek secara lebih baik sehingga meningkatkan kemampuan generalisasi model terhadap data baru.

Faktor kedua adalah proses anotasi menggunakan Roboflow. Bounding box yang dibuat secara tepat memungkinkan model mempelajari posisi objek dengan lebih akurat. Sebaliknya, kesalahan anotasi dapat menyebabkan model menghasilkan prediksi yang kurang optimal sehingga menurunkan nilai precision maupun recall. Selain kualitas data, parameter pelatihan seperti jumlah epoch, ukuran citra (image size), batch size, dan learning rate juga mempengaruhi performa model. Pada penelitian ini digunakan image size 640×640 piksel dan pelatihan selama 30 epoch. Kombinasi parameter tersebut mampu menghasilkan keseimbangan antara waktu pelatihan dan tingkat akurasi model.

3.6 Implementasi Sistem pada Program MBG

Model YOLOv11 yang telah dilatih kemudian diintegrasikan ke dalam aplikasi berbasis Streamlit. Pengguna dapat mengunggah foto paket makanan MBG melalui antarmuka sistem. Selanjutnya model akan mendeteksi setiap objek makanan yang terdapat pada citra dan memberikan label beserta nilai confidence untuk masing-masing objek.

Setelah proses deteksi selesai, sistem melakukan pencocokan dengan database Tabel Komposisi Pangan Indonesia (TKPI). Setiap objek makanan yang berhasil dikenali akan dikonversi menjadi informasi kandungan energi, protein, lemak, karbohidrat, dan serat. Seluruh informasi tersebut kemudian dijumlahkan sehingga menghasilkan estimasi kandungan gizi total dari satu paket makanan MBG. Implementasi ini memberikan keuntungan berupa percepatan proses monitoring makanan, mengurangi kesalahan pencatatan secara manual, serta memudahkan petugas dalam melakukan evaluasi kualitas menu yang disajikan kepada peserta didik.

3.7 Kelebihan dan Keterbatasan Penelitian

Penelitian ini memiliki beberapa kelebihan. Pertama, penggunaan YOLOv11 memungkinkan proses deteksi makanan dilakukan secara real-time dengan tingkat akurasi yang baik. Kedua, sistem berhasil mengintegrasikan hasil deteksi objek dengan database TKPI sehingga mampu menghasilkan estimasi kandungan gizi secara otomatis. Ketiga, aplikasi berbasis Streamlit memberikan kemudahan bagi pengguna dalam melakukan monitoring tanpa memerlukan perangkat keras khusus.

Di sisi lain, penelitian ini juga memiliki beberapa keterbatasan. Dataset yang digunakan masih berasal dari satu lokasi SPPG sehingga variasi menu makanan belum sepenuhnya mewakili kondisi di seluruh Indonesia. Selain itu, sistem belum mampu memperkirakan berat aktual makanan sehingga estimasi kandungan gizi masih mengacu pada data referensi yang telah ditentukan. Penelitian selanjutnya dapat mengembangkan metode estimasi berat makanan menggunakan pendekatan computer vision sehingga hasil perhitungan gizi menjadi lebih akurat.

3.8 Implikasi Penelitian

Hasil penelitian ini menunjukkan bahwa teknologi computer vision berbasis YOLOv11 memiliki potensi besar dalam mendukung digitalisasi Program Makan Bergizi Gratis. Sistem yang dikembangkan mampu membantu petugas melakukan identifikasi menu makanan secara otomatis, mempercepat proses pencatatan, serta meningkatkan efisiensi monitoring kandungan gizi.

Selain diterapkan pada Program MBG, sistem ini juga berpotensi digunakan pada rumah sakit, kantin sekolah, institusi pendidikan, maupun layanan katering yang memerlukan proses identifikasi makanan dan estimasi kandungan gizi secara cepat. Dengan pengembangan lebih lanjut, sistem dapat diintegrasikan dengan perangkat bergerak (mobile) maupun kamera pemantau sehingga proses monitoring dapat dilakukan secara real-time.

Framework Streamlit dipilih karena mampu mempercepat pengembangan aplikasi machine learning berbasis web dengan antarmuka yang sederhana [10]

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, model YOLOv11 mampu mendeteksi jenis makanan pada Program Makan Bergizi Gratis dengan performa yang baik. Hasil evaluasi menunjukkan nilai precision sebesar 0.91, recall sebesar 0.86, mAP50 sebesar 0.92, dan mAP50-95 sebesar 0.84. Integrasi model YOLOv11 dengan database TKPI dan aplikasi berbasis web memungkinkan proses estimasi kandungan gizi dilakukan secara otomatis sehingga dapat membantu proses monitoring makanan menjadi lebih efektif dan terstruktur. Pada penelitian selanjutnya dapat dilakukan penambahan jumlah dataset dan penerapan estimasi berat makanan otomatis untuk meningkatkan akurasi perhitungan kandungan gizi. Penggunaan model YOLO untuk pengenalan makanan dan estimasi porsi telah menunjukkan potensi yang baik dalam mendukung sistem pemantauan gizi otomatis [16]

Referensi

- [1] World Food Programme, "State of School Feeding Worldwide 2022," 2022.
- [2] Kementerian Kesehatan Republik Indonesia, *Tabel Komposisi Pangan Indonesia (TKPI)*. Jakarta: Kementerian Kesehatan Republik Indonesia, 2020.
- [3] Badan Ketahanan Pangan, "Platform Data Komposisi Pangan Indonesia (Panganku)," 2023. <https://www.panganku.org>
- [4] I. G. Y. B. A. Courville, *Deep Learning*. MIT Press, 2021.
- [5] A. M. T. Rahman, M. S. Hossain, and M. A. Rahman, "Real-Time Object Detection Using YOLO Algorithm: A Review," *Int. J. Adv. Comput. Sci. Appl.*, vol. 14, no. 2, pp. 45–52, 2023.
- [6] W. Min, S. Jiang, L. Liu, Y. Rui, and R. Jain, "A Survey on Food Computing," *ACM Comput. Surv.*, vol. 52, no. 5, pp. 1–36, 2020.

- [7] A. Tahir, J. Ahmad, K. Muhammad, and S. W. Baik, "Recognition of Food Images Using Deep Learning Techniques," *IEEE Access*, vol. 9, 2021.
- [8] M. Bolanos and P. Radeva, "Food Recognition and Nutrition Estimation Using Computer Vision," *Comput. Vis. Image Underst.*, vol. 210.
- [9] M. H. M. A. Khanam, "YOLOv11: An Overview of the Key Architectural Enhancements," *Int. J. Adv. Comput. Sci. Appl.*, 2024.
- [10] A. Singh, "Streamlit: Rapid Development of Machine Learning Applications," *J. Open Source Softw.*, vol. 8, no. 81, p. 4873, 2023.
- [11] R. Agarwal, T. Choudhury, N. J. Ahuja, and T. Sarkar, "Hybrid Deep Learning Algorithm-Based Food Recognition and Calorie Estimation," *J. Food Process. Preserv.*, 2023.
- [12] M. Bolanos and P. Radeva, "Food Recognition and Nutrition Estimation Using Computer Vision," *Comput. Vis. Image Underst.*, vol. 210, p. 103239, 2021.
- [13] Ultralytics, "YOLO Documentation," 2024. <https://docs.ultralytics.com>
- [14] R. Padilla;, W. Passos;, S. Netto;, and E. Silva, "A Comparative Analysis of Object Detection Metrics with a Companion Open Source Toolkit," *Electronics*, vol. 10, no. 3, p. 279, 2021.
- [15] Ultralytics, "Ultralytics YOLO Documentation," 2024. <https://docs.ultralytics.com>
- [16] G. Chrintz-Gath, M. Daivadanam, L. Matta, and S. McKeeve, "Image-Based Dietary Assessment Using the Swedish Plate Model," *JMIR Form. Res.*, 2025.