

MobileNetV2 Implementation for On-Device Padang Food Classification using TensorFlow Lite on Android

Rizal Ahmad Saepulloh^{1*}, Kurnia Ramadhan Putra¹

¹Department of Information Systems, Institut Teknologi Nasional, Bandung, Indonesia

*Email Korespondensi: rizalahmadsaepulloh@gmail.com

Naskah Masuk 30 November 2025 | Direvisi 30 Januari 2026 | Diterima 15 Februari 2026

ABSTRAK

Penyakit tidak menular masih menjadi masalah kesehatan kritis di negara berkembang, yang sering kali diperburuk oleh rendahnya literasi gizi. Meskipun aplikasi pemantauan diet tersedia secara global, solusi tersebut sering kali kurang kompatibel dengan variasi masakan lokal Indonesia dan terkendala oleh kebutuhan koneksi internet yang stabil. Penelitian ini mengusulkan implementasi model On-Device AI menggunakan arsitektur MobileNetV2 yang dioptimalkan dengan TensorFlow Lite untuk klasifikasi citra makanan Padang secara offline pada aplikasi Android CaloCare. Penelitian menggunakan 1.346 citra yang dibagi dengan rasio 80:10:10. Melalui studi ablasi yang komprehensif, model dengan strategi Fine-Tuning dan augmentasi data terbukti unggul, mencapai akurasi uji 92,19% dan F1-Score 0,93, meningkat signifikan dibandingkan baseline tanpa fine-tuning (84,21%). Konversi ke format TFLite menghasilkan model yang sangat efisien dengan ukuran file 8,8 MB dan parameter 1.99 juta, serta mampu melakukan inferensi rata-rata dalam waktu 292 ms pada perangkat seluler. Hasil ini menegaskan bahwa MobileNetV2 menawarkan keseimbangan optimal antara akurasi tinggi dan efisiensi komputasi untuk sistem pemantauan nutrisi berbasis seluler.

Kata kunci: Machine Learning, Klasifikasi Gambar, Pelacakan Nutrisi, Aplikasi Android

ABSTRACT

Non-communicable diseases remain a critical health issue in developing countries, often exacerbated by low nutritional literacy. Although diet monitoring applications are available globally, these solutions are often incompatible with the variety of local Indonesian cuisine and constrained by the need for a stable internet connection. This study proposes the implementation of an On-Device AI model using the MobileNetV2 architecture optimized with TensorFlow Lite for offline classification of Padang food images on the CaloCare Android application. The study used 1,346 images divided in an 80:10:10 ratio. Through a comprehensive ablation study, the model with Fine-Tuning and data augmentation strategies proved to be superior, achieving a test accuracy of 92.19% and an F1-Score of 0.93, a significant improvement over the baseline without fine-tuning (84.21%). Conversion to TFLite format resulted in a highly efficient model with a file size of 8.8 MB and 1.99 million parameters, capable of performing inference in an average of 292 ms on mobile devices. These results confirm that MobileNetV2 offers an optimal balance between high accuracy and computational efficiency for mobile-based nutrition monitoring systems.

Keywords: Machine Learning, Image Classification, Nutrition Tracking, Android Application

1. PENDAHULUAN

Penyakit Tidak Menular kini telah berevolusi menjadi tantangan kesehatan paling kritis yang dihadapi oleh negara-negara berkembang, termasuk Indonesia. Transisi epidemiologi yang terjadi dalam dekade terakhir telah menggeser beban penyakit utama dari penyakit menular ke penyakit kronis. Merujuk pada data komprehensif dari Global Burden of Disease (GBD), tercatat bahwa penyakit kardiovaskular, diabetes, dan stroke kini berkontribusi pada lebih dari 70% total kematian dan kecacatan (Disability-Adjusted Life Years - DALYs) di tingkat nasional. Secara spesifik, prevalensi diabetes melitus di Indonesia menunjukkan tren kenaikan yang mengkhawatirkan, mencapai angka 11,7% pada populasi dewasa muda di tahun 2023 [1].

Akar permasalahan dari krisis kesehatan ini sangat erat kaitannya dengan pergeseran pola konsumsi masyarakat modern yang cenderung memilih makanan olahan tinggi kalori namun rendah serat, serta diperparah oleh rendahnya literasi gizi mengenai kandungan makanan lokal yang dikonsumsi sehari-hari.

Dalam upaya memitigasi risiko tersebut, pemantauan asupan nutrisi harian menjadi intervensi mandiri yang sangat disarankan. Meskipun ekosistem aplikasi kesehatan digital telah berkembang pesat, mayoritas solusi pencatatan diet yang tersedia secara global masih memiliki keterbatasan fundamental ketika diterapkan pada konteks lokal Indonesia. Aplikasi-aplikasi tersebut sering kali menyajikan basis data makanan yang didominasi oleh menu barat dan memiliki antarmuka pengguna yang kompleks, sehingga menyulitkan pengguna awam untuk melakukan pencatatan secara konsisten. Lebih jauh lagi, tantangan teknis terbesar terletak pada kemampuan sistem untuk mengenali variasi masakan tradisional secara otomatis. Sebagaimana diuraikan dalam studi oleh Makhatbek dan Kabdrakhova mengenai klasifikasi makanan tradisional Kazakh, hidangan lokal sering kali memiliki kemiripan visual yang sangat tinggi antar kelas, baik dari segi tekstur maupun warna, yang membuat metode pengolahan citra konvensional gagal memberikan hasil akurat [2]. Hal senada diungkapkan oleh Patel dan Modi dalam penelitian mereka terhadap makanan India, yang menekankan bahwa variasi bumbu dan cara penyajian yang kompleks menuntut penggunaan metode ekstraksi fitur yang lebih mendalam untuk membedakan objek dengan fenotipe serupa [3].

Untuk menjawab kebutuhan akan sistem yang praktis dan mudah diakses, paradigma pengembangan kecerdasan buatan kini mulai beralih dari pemrosesan berbasis server (Cloud AI) menuju pemrosesan di perangkat pengguna (On-Device AI). Misra dalam penelitiannya menyoroti bahwa arsitektur On-Device AI merupakan solusi krusial untuk mengatasi dua hambatan utama aplikasi seluler yakni privasi data dan latensi jaringan. Dengan memproses data citra secara lokal, privasi pengguna lebih terjaga karena tidak ada data pribadi yang dikirimkan ke pihak ketiga, serta aplikasi dapat beroperasi secara real-time tanpa ketergantungan pada stabilitas koneksi internet [4]. Namun, implementasi model Deep Learning canggih pada perangkat seluler bukanlah tanpa kendala. Keterbatasan daya komputasi (CPU/GPU) dan kapasitas memori pada smartphone kelas menengah menjadi penghalang utama bagi penerapan model Convolutional Neural Network (CNN) standar yang biasanya memiliki jutaan parameter.

Oleh karena itu, pemilihan arsitektur model yang efisien menjadi kunci keberhasilan sistem. Penelitian ini mengusulkan penggunaan arsitektur MobileNetV2, sebuah model CNN yang dirancang spesifik untuk lingkungan komputasi terbatas. Keunggulan utama MobileNetV2 terletak pada mekanisme Depthwise Separable Convolutions dan Inverted Residuals, yang mampu mereduksi beban komputasi secara drastis tanpa mengorbankan akurasi klasifikasi secara signifikan. Efektivitas pendekatan ini telah divalidasi oleh berbagai studi empiris terbaru. Sahid dan Cahyadi membuktikan bahwa MobileNetV2 memberikan trade-off terbaik antara ukuran model dan akurasi dalam kasus deteksi penyakit tanaman pada perangkat bergerak [5]. Sementara itu, Rathod dkk. menunjukkan bahwa konversi model ke format yang lebih ringan, seperti TensorFlow Lite, mampu mengurangi ukuran file hingga 90% dan mempercepat waktu inferensi, memungkinkan aplikasi berjalan mulus bahkan pada perangkat dengan spesifikasi rendah [6]. Reliabilitas arsitektur ini juga dikonfirmasi oleh Saha dkk. yang sukses menerapkan sistem klasifikasi varietas tanaman secara real-time di perangkat edge, membuktikan bahwa model ringan mampu menangani tugas visual yang kompleks dengan latensi minimal [7].


Berdasarkan studi sebelumnya, penelitian ini bertujuan untuk mengembangkan model machine learning yang presisi untuk aplikasi CaloCare. Fokus utamanya adalah mengimplementasikan dan mengoptimalkan arsitektur *MobileNetV2* untuk mengklasifikasikan 9 jenis masakan Padang dengan domain kuliner yang memiliki tantangan visual yang cukup tinggi karena variasi visual yang unik. Melalui pendekatan *Transfer Learning* dan optimasi model menggunakan *TensorFlow Lite*, penelitian ini menargetkan terciptanya sistem yang tidak hanya akurat, tetapi juga sangat efisien dari segi penggunaan memori dan kecepatan deteksi. Oleh karena itu, kontribusi utama dari penelitian ini adalah implementasi model klasifikasi makanan on-device menggunakan arsitektur *MobileNetV2* yang dioptimalkan dengan *TensorFlow Lite*, yang dirancang dan divalidasi melalui studi ablasi untuk mencapai keseimbangan terbaik antara akurasi tinggi dan latensi rendah pada perangkat seluler.

2. METODOLOGI

Penelitian ini menggunakan pendekatan eksperimental yang difokuskan sepenuhnya pada pengembangan dan optimasi model machine learning. Metodologi disusun secara sistematis untuk menghasilkan model yang memiliki akurasi tinggi namun tetap efisien saat nantinya diintegrasikan ke dalam lingkungan komputasi terbatas seperti perangkat seluler..


2.1 Pengumpulan data

Pengembangan model pembelajaran mesin bergantung pada *dataset* yang spesifik untuk memastikan pengenalan masakan lokal yang akurat pada model *machine learning*. Sumber data utama penelitian ini berasal dari dataset terbuka yang berisi data citra masakan Padang. Penggunaan dataset yang beragam dan augmentasi data sangat penting untuk meningkatkan kinerja model, strategi yang juga diterapkan dalam pengembangan sistem deteksi mata uang Bangladesh untuk memastikan ketahanan terhadap variasi visual [8]. Contoh sampel visual dari dataset yang digunakan, yang mencakup variasi penyajian pada setiap kelas masakan Padang, dapat dilihat pada Gambar 1.



Gambar 1. Visual Variasi Dataset

Selain variasi gambar visual yang ditampilkan, keseimbangan jumlah sampel antar kelas juga menjadi faktor krusial dalam keberhasilan pelatihan model. Distribusi jumlah citra untuk kesembilan kelas makanan Padang dalam dataset ini divisualisasikan pada Gambar 2.




Gambar 2. Diagram Distribusi Dataset

Berdasarkan Gambar 2, terlihat profil kuantitas data yang digunakan untuk pelatihan. Pemahaman terhadap distribusi ini sangat penting karena ketidakseimbangan data dapat menyebabkan model cenderung bias ke kelas mayoritas. Oleh karena itu, informasi dari distribusi ini menjadi landasan utama diterapkannya strategi Data Augmentation yang agresif pada tahap pra-pemrosesan untuk memperkaya variasi data dan menyeimbangkan model dalam mempelajari fitur dari setiap kelas makanan.

2.2 Pembagian data

Untuk menjamin validitas pengujian dan mencegah terjadinya data leakage atau kebocoran data selama proses pelatihan, penelitian ini menerapkan skema pembagian data (data splitting) yang ketat sebelum tahap pra-pemrosesan dimulai. Pendekatan ini krusial untuk menghindari bias estimasi performa dan memastikan model dievaluasi pada data yang benar-benar baru (unseen data) [9]. Dataset yang telah dikumpulkan dibagi secara acak menjadi tiga himpunan bagian utama yaitu data latih (training set), data validasi (validation set), dan data uji (testing set). Penelitian ini menetapkan rasio komposisi pembagian sebesar 80:10:10. Pemilihan rasio data latih sebesar 80% ini didasarkan pada studi komparatif yang menunjukkan bahwa proporsi data latih yang lebih besar memiliki korelasi positif terhadap peningkatan akurasi model dan efektif mencegah underfitting dibandingkan rasio yang lebih kecil [10]. Alur lengkap pembagian dataset dan perlakuan augmentasi yang diterapkan secara eksklusif pada data latih dapat dilihat pada Gambar 3.



Gambar 3. Alur Proses Pembagian Data Hingga Proses Augmentasi

Proporsi ini dipilih untuk memberikan porsi terbesar pada proses pembelajaran fitur, sekaligus menyisakan jumlah yang representatif untuk evaluasi model yang tidak bias. Berdasarkan skema tersebut, distribusi kuantitas citra untuk kesembilan kelas makanan Padang adalah sebagai berikut :

- Data Training* (80%) : Sebanyak 790 gambar. Subset ini digunakan sebagai *knowledge base* utama di mana model akan mempelajari pola, tekstur, dan bentuk dari setiap kelas makanan. Pada tahap inilah bobot (*weights*) dalam arsitektur *CNN* diperbarui secara iteratif
- Data Validation* (10%) : Sebanyak 95 gambar. Subset ini berfungsi sebagai kontrol internal selama proses pelatihan berlangsung. Data ini digunakan untuk memantau metrik akurasi dan *loss* per *epoch*, serta menjadi acuan dalam penyetelan *hyperparameter* guna mencegah *overfitting* sebelum model selesai dilatih
- Data Testing* (10%) : Sebanyak 108 gambar. *Subset* ini merupakan data yang tidak pernah dilihat oleh model selama proses pelatihan. Data ini digunakan secara eksklusif pada tahap akhir untuk mengukur performa generalisasi model yang sebenarnya di dunia nyata.

2.3 Pra-pemrosesan data

pada tahap pra-pemrosesan data data mentah yang telah dikumpulkan akan dimulai dengan proses agregasi dan validasi *dataset* berlabel dari *Kaggle*. Setelah proses pembersihan dan penyeragaman format, *dataset* kemudian dinormalisasi sebelum digunakan pada tahap pemodelan menggunakan *TensorFlow* di lingkungan *Google Colab*. Untuk meningkatkan akurasi model dan memastikan kemampuan generalisasi yang lebih baik, teknik data augmentation diterapkan secara intensif, strategi yang terbukti efektif dalam berbagai penelitian terdahulu untuk menangani variabilitas visual. Penelitian terbaru dalam pengembangan *DeepBiteNet* menunjukkan bahwa augmentasi data seperti rotasi, penyesuaian warna, dan variasi pencahayaan sangat penting ketika objek memiliki kemiripan visual yang tinggi, karena teknik ini membantu model mengenali pola visual secara lebih akurat terhadap perubahan kondisi lingkungan [11].


Temuan serupa dilaporkan dalam studi *AgroAid*, yang menekankan bahwa augmentasi berbasis rotasi, *flipping*, dan penyesuaian warna mampu meningkatkan performa model pada dataset yang bervariasi secara alami dan memperbaiki sensitivitas model terhadap perbedaan visual yang halus [12]. Selain itu, studi identifikasi daun berbasis *Android* menegaskan bahwa augmentasi citra diperlukan untuk memaksimalkan

pembelajaran dari data yang tersedia, terutama dengan memisahkan *set* validasi dari data pelatihan untuk mengatasi masalah ketidakseimbangan data [13]. Strategi serupa juga diterapkan dalam sistem deteksi mata uang, yang menggunakan teknik rotasi, *flipping*, *scaling*, dan translasi untuk memperkaya dataset dan mencegah *overfitting* [8]. Pendekatan augmentasi data ini juga terbukti krusial dalam sistem pengenalan makanan mobile untuk mengatasi ketidakseimbangan jumlah sampel antar kelas makanan, sehingga meningkatkan robustitas model [14]. Prinsip ini relevan dalam konteks hidangan Indonesia yang memiliki tekstur, warna bumbu, dan komposisi visual yang mirip antar kelas. Berbagai bentuk augmentasi yang digunakan dalam penelitian ini meliputi rotasi, *flipping* horizontal dan vertikal, serta penyesuaian skala. Rincian konfigurasi parameter augmentasi yang diterapkan disajikan secara lengkap dalam Tabel 1.

Tabel 1. Konfigurasi Parameter Augmentasi Data

Parameter Augmentasi	Nilai Konfigurasi	Keterangan
Rescale	1./255	Normalisasi nilai piksel menjadi rentang 0-1
Rotation Range	20	Rotasi gambar secara acak hingga 20 derajat
Horizontal Flip	True	Membalik citra secara horizontal (kiri-kanan)
Shear Range	0.2	Penerapan distorsi geser sebesar 20%
Zoom Range	0.2	Perbesaran objek secara acak hingga 20%
Fill Mode	'nearest'	Mengisi piksel kosong akibat rotasi dengan nilai piksel terdekat
Validation Split	0.2	Pemisahan 20% data untuk validasi (validation set)

Penerapan parameter di atas menghasilkan variasi data latih yang lebih kaya. Visualisasi penerapan teknik augmentasi data, yang meliputi hasil rotasi, *flipping*, dan *rescaling*, ditunjukkan secara rinci pada Gambar 4.




Gambar 4. Visualisasi Proses Data augmentasi

2.4 Arsitektur model machine learning

Pengembangan model pembelajaran mesin, seperti diilustrasikan pada Gambar 5, mengandalkan arsitektur *MobileNetV2*. Arsitektur ini dipilih karena menawarkan keseimbangan optimal antara akurasi dan efisiensi komputasi, sehingga sangat cocok untuk aplikasi berbasis perangkat *mobile*. *MobileNetV2* menggunakan *depthwise separable convolutions* yang secara drastis mengurangi beban komputasi dibandingkan konvolusi standar, menjadikannya salah satu solusi untuk implementasi pada perangkat dengan sumber daya terbatas. Dalam penelitian *Agro.Aid*, menunjukkan bahwa *MobileNetV2* merupakan salah satu arsitektur terbaik untuk aplikasi berbasis *mobile* karena ukurannya yang ringan namun tetap mampu mencapai akurasi tinggi setelah penerapan *transfer learning*, serta bekerja lebih efisien dibandingkan model yang lebih besar seperti *EfficientNet-B0* atau *NasNetMobile* ketika dikonversi ke *TensorFlow Lite* [12]. Keunggulan efisiensi ini diperkuat oleh studi

benchmark pengenalan emosi wajah pada perangkat mobile yang menemukan bahwa model *MobileNetV2* secara konsisten memberikan performa yang baik dengan latensi rendah pada berbagai perangkat Android, menjadikannya pilihan yang stabil untuk penerapan real-time [15]. Studi terbaru pada industri makanan juga menegaskan bahwa *MobileNetV2* mampu memberikan pengenalan makanan otomatis yang akurat dan *real-time* dengan biaya komputasi rendah [16]. Efektivitas arsitektur *MobileNetV2* juga telah dibuktikan dalam berbagai domain klasifikasi citra lainnya. Penelitian sebelumnya berhasil menggunakan *MobileNetV2* dengan *transfer learning* untuk klasifikasi ras kucing, mencapai akurasi terbaik dibandingkan model lain seperti *VGG16* dan *InceptionV3* [17]. Selain itu, kombinasi teknik *transfer learning* pada model yang telah dilatih sebelumnya terbukti secara signifikan meningkatkan akurasi pengenalan citra makanan dibandingkan pelatihan dari awal [18].

Demikian pula, penelitian lainnya memanfaatkannya dalam aplikasi penerjemah Bahasa Isyarat Indonesia (BISINDO), di mana model ini mampu memberikan tingkat akurasi yang tinggi (0.9995) dengan performa deteksi yang optimal pada perangkat mobile [19]. Lebih lanjut, dalam konteks medis, penelitian lain menunjukkan bahwa *MobileNetV2* yang digabungkan dengan *Joint Attention Network* mampu mencapai hasil klasifikasi terbaik dengan akurasi 89% untuk citra *OCT* mata manusia, mengungguli arsitektur yang lebih sederhana [20]. Arsitektur *MobileNetV2* pada penelitian ini memproses citra input dan menggunakan *bottleneck layers* untuk mempertahankan representasi fitur yang efisien sebelum klasifikasi akhir.



Gambar 5. Alur Arsitektur Machine Learning

penelitian ini menerapkan teknik *Transfer Learning* dengan memanfaatkan bobot pra-latih dari *dataset ImageNet* sebagai inisialisasi awal *base model*, di mana lapisan klasifikasi asli digantikan oleh serangkaian lapisan kustom yang terdiri dari *Global Average Pooling* untuk mereduksi dimensi fitur, diikuti oleh lapisan *Dense* dengan 512 neuron yang dilengkapi aktivasi *ReLU*, serta lapisan *Dropout* sebesar 0.5 untuk mencegah overfitting. Untuk memastikan model mampu membedakan fitur visual yang sangat spesifik dan mirip pada masakan Padang dilakukan proses *Fine-Tuning* dengan membuka kunci (*unfreezing*) pada 20 lapisan terakhir dari blok *MobileNetV2* dan melatihnya kembali menggunakan learning rate rendah, sebuah strategi adaptasi domain yang terbukti efektif dalam meningkatkan sensitivitas model terhadap variasi visual lokal sebagaimana disarankan oleh Patel dan Modi dalam klasifikasi makanan yang kompleks.


3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pengembangan sistem, berfokus pada keberhasilan model pembelajaran mesin.

3.1 Kinerja model


Proses pelatihan model dieksekusi untuk memastikan stabilitas dan ekstraksi fitur yang optimal. Model *MobileNetV2* yang dikembangkan mencapai akurasi uji sebesar 92,19% dengan grafik konvergensi pelatihan yang stabil, sebagaimana ditampilkan pada Gambar 6. Capaian ini sejalan dengan penelitian penerjemah

Bahasa Isyarat Indonesia (BISINDO) yang juga memanfaatkan arsitektur serupa untuk memaksimalkan akurasi pada platform *Android* [19]. Selain unggul dalam akurasi, pemilihan MobileNetV2 terbukti menawarkan *trade-off* terbaik dari sisi efisiensi komputasi. Hal ini diperkuat oleh studi komparatif pada klasifikasi citra medis, di mana model yang lebih kompleks justru tidak memberikan peningkatan performa signifikan pada perangkat seluler dibandingkan model ringan yang teroptimasi dengan baik. [20].



Gambar 6. Grafik Performa Akurasi Model


Selain metrik akurasi, analisis terhadap grafik Model *Loss* pada Gambar 7 memberikan indikasi kuat mengenai kesehatan proses pembelajaran model. Terlihat bahwa nilai *loss* (kerugian) menurun secara eksponensial pada fase awal pelatihan dan mulai melandai secara stabil seiring bertambahnya *epoch*. Fenomena ini menandakan bahwa model berhasil meminimalkan kesalahan prediksi secara iteratif. Yang paling krusial, jarak (*gap*) yang sangat tipis antara kurva training *loss* dan validation *loss* mengindikasikan bahwa model memiliki kemampuan generalisasi yang sangat baik. Kurva validasi yang bergerak beriringan dengan kurva pelatihan tanpa adanya divergensi yang signifikan membuktikan bahwa teknik regularisasi dan augmentasi data yang diterapkan berhasil mencegah terjadinya overfitting atau suatu kondisi di mana model hanya menghafal data latih namun gagal mengenali data baru. Keunggulan stabilitas ini, dipadukan dengan performa akurasi yang tinggi, menegaskan bahwa pemilihan MobileNetV2 menawarkan *trade-off* terbaik dari sisi efisiensi komputasi. Hal ini diperkuat oleh studi komparatif pada klasifikasi citra medis, di mana model yang lebih kompleks justru tidak memberikan peningkatan performa yang signifikan pada perangkat seluler dibandingkan model ringan yang teroptimasi dengan baik, namun membebani memori jauh lebih besar [20]. Oleh karena itu, stabilitas konvergensi *loss* dan akurasi tinggi yang dihasilkan model ini menjadi validasi bahwa MobileNetV2 sangat layak untuk diimplementasikan dalam aplikasi *CaloCare*.



Gambar 7. Grafik Performa Loss Model

Untuk menganalisis lebih dalam mengenai distribusi kesalahan prediksi pada setiap kelas makanan, evaluasi dilanjutkan dengan menggunakan Confusion Matrix sebagaimana ditampilkan pada Gambar 8. Matriks ini

memvisualisasikan seberapa akurat model dalam membedakan satu jenis makanan Padang dengan jenis lainnya.



Gambar 8. Confusion Matrix

Berdasarkan Gambar 8 bahwa model memiliki tingkat keberhasilan yang tinggi dalam mengidentifikasi hidangan dengan tekstur yang sangat khas dan kontras warna yang kuat, seperti Rendang dan Dendeng. Dominasi warna diagonal utama pada matriks menunjukkan bahwa True Positive (prediksi benar) jauh lebih tinggi dibandingkan False Positive atau False Negative. Namun, terdapat sedikit misklasifikasi yang terdeteksi antara kelas makanan yang memiliki basis kuah santan dengan warna serupa, misalnya antara Gulai Ayam dan Gulai Tunjang. Kesalahan prediksi minor ini dapat dimaklumi mengingat kemiripan visual yang tinggi dari segi warna kuah dan cara penyajian. Meskipun *Confusion Matrix* memberikan gambaran distribusi kesalahan, analisis lebih mendalam diperlukan untuk mengukur presisi dan sensitivitas model terhadap setiap jenis makanan. Tabel 2 menyajikan laporan klasifikasi lengkap yang mencakup metrik Precision, Recall, dan F1-Score untuk kesembilan kelas makanan Padang.

Secara keseluruhan, model mencapai rata-rata tertimbang atau weighted average sebesar 93% untuk semua metrik, yang menunjukkan konsistensi kinerja model pada dataset yang seimbang (support berkisar antara 11 hingga 13 sampel per kelas). Analisis per kelas menunjukkan bahwa Gulai Ikan merupakan kelas yang paling mudah dikenali oleh model, mencapai skor sempurna (1.00) pada seluruh metrik. Hal ini mengindikasikan bahwa fitur visual Gulai Ikan (seperti tekstur kulit ikan dan warna kuah) sangat distingtif dibandingkan kelas lain. Di sisi lain, kelas Ayam Pop mencatat kinerja terendah dengan F1-Score sebesar 0.83. Penurunan performa pada kelas ini kemungkinan disebabkan oleh karakteristik visual Ayam Pop yang berwarna pucat (putih/krem) dan minim tekstur kontras, sehingga model terkadang kesulitan membedakannya dari objek latar belakang atau bagian lemak pada hidangan lain. Namun, secara umum, nilai Precision di atas 0.83 pada seluruh kelas membuktikan bahwa model memiliki tingkat False Positive yang rendah dan layak diimplementasikan.

Tabel 2. Laporan Klasifikasi Model MobileNetV2

Nama Kelas	Precision	Recall	F1-Score	Support
------------	-----------	--------	----------	---------

Ayam Goreng	1	0.92	0.96	12
Daging Rendang	0.92	0.92	0.92	12
Dendeng Batokok	0.92	0.92	0.92	12
Gulai Ikan	1	1	1	11
Gulai Tambusu	0.91	0.91	0.91	11
Gulai Tunjang	0.93	1	0.96	13
Telur Balado	1	0.92	0.96	12
Telur Dadar	0.86	0.92	0.89	13
Ayam Pop	0.83	0.83	0.83	12
Accuracy			0.93	108
Macro Avg	0.93	0.93	0.93	108
Weighted Avg	0.93	0.93	0.93	108

3.2 Studi Ablasi dan Perbandingan Performa

Untuk memvalidasi efektivitas strategi pelatihan yang diterapkan, dilakukan studi ablasi dengan membandingkan model baseline terhadap model yang diusulkan dengan *Fine-Tuning* pada 20 lapisan terakhir. Perbandingan kinerja kedua skenario tersebut disajikan dalam Tabel 3.

Tabel 3. Laporan Perbandingan Performa

Model	Akurasi	Macro-F1	Total Parameter	Ukuran	Latency	Keterangan
MobileNetV2 Baseline	84.21%	0.84	791.049	8.8 MB	285 ms	<i>Frozen weights</i> , hanya melatih <i>classifier</i>
MobileNetV2 FineTuned	92.19%	0.93	1.997.129	8.8 MB	295 ms	<i>Unfreeze</i> 20 layer terakhir dan <i>Retraining</i>
MobileNetV2 FineTuned Tanpa Augmented Data	91.58%	0.91	1.997.129	8.8 MB	295 ms	<i>Unfreeze</i> 20 layer terakhir dan <i>Retraining</i> dan tanpa Proses <i>augmentasi</i>

Hasil eksperimen pada Tabel 3 menunjukkan bahwa model dengan strategi Fine-Tuning menghasilkan akurasi validasi sebesar 92,19%, meningkat signifikan sebesar 7,98% dibandingkan model baseline yang hanya mencapai 84,21%. Peningkatan kualitas prediksi juga terkonfirmasi dari skor Macro-F1 yang mencapai 0.93, mengindikasikan keseimbangan performa yang lebih baik antar kelas. peningkatan performa ini dicapai tanpa membebani sumber daya komputasi. Kedua model memiliki perbedaan jumlah parameter yang dilatih dan ukuran file masih terbukti sama. Selain itu, latensi inferensi rata-rata hanya mengalami kenaikan menjadi 292 ms, membuktikan bahwa penyesuaian bobot pada lapisan akhir mampu meningkatkan kecerdasan model secara signifikan tanpa mengorbankan kecepatan real-time yang dibutuhkan aplikasi Android.

4. KESIMPULAN

Studi ini berhasil mengembangkan dan mengoptimalkan model Deep Learning berbasis MobileNetV2 untuk klasifikasi citra makanan Padang pada lingkungan komputasi terbatas (mobile). Berdasarkan hasil eksperimen dan studi ablasi, strategi Fine-Tuning pada 20 lapisan terakhir terbukti memberikan dampak signifikan, meningkatkan akurasi validasi sebesar 7,98% dari model baseline (84,21%) menjadi 92,19% dengan rata-rata F1-Score 0,93. Augmentasi data juga terbukti krusial dalam menjaga stabilitas prediksi pada kelas dengan kemiripan visual tinggi, seperti Gulai Ikan.

Dari sisi efisiensi sistem, implementasi *TensorFlow Lite* berhasil menjaga ukuran model tetap ringkas di angka 8,8 MB dengan parameter konstan sebesar 1.997.129. Pengujian pada perangkat Android menunjukkan latensi inferensi rata-rata sebesar 295 ms, yang memenuhi standar operasional real-time. Hal ini menegaskan bahwa arsitektur *MobileNetV2* adalah solusi optimal untuk penerapan *On-Device AI* yang membutuhkan keseimbangan ketat antara performa cerdas dan efisiensi sumber daya. Pengembangan selanjutnya disarankan untuk memperluas variasi dataset kuliner nusantara dan mengintegrasikan fitur estimasi volume makanan untuk perhitungan kalori yang lebih presisi.

DAFTAR PUSTAKA

- [1] Institute for Health Metrics and Evaluation, “Announcing launch of the GBD 2023 study results | Institute for Health Metrics and Evaluation.” Accessed: Feb. 08, 2026. [Online]. Available: <https://www.healthdata.org/announcing-launch-gbd-2023-study-results>
- [2] I. Makhatbek and S. Kabdrakhova, “KAZAKH TRADITIONAL FOOD IMAGE CLASSIFICATION USING CNNs,” *Journal of Problems in Computer Science and Information Technologies*, vol. 3, no. 2, pp. 45–58, Jun. 2025, doi: 10.26577/jpcsit20253204.
- [3] J. Patel and K. Modi, “Indian Food Image Classification and Recognition with Transfer Learning Technique Using MobileNetV3 and Data Augmentation ‡,” *Engineering Proceedings*, vol. 56, no. 1, 2024, doi: 10.3390/ASEC2023-15341.
- [4] M. K. Misra, “On-Device AI for Privacy-Preserving Mobile Applications: A Framework using TensorFlow Lite,” *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 13, no. 8, pp. 1963–1972, Aug. 2025, doi: 10.22214/ijraset.2025.73873.
- [5] A. N. Sahid and D. R. Cahyadi, “Ahmad Nur Sahid: Image Classification Using MobileNet ... Image Classification Using MobileNet Based on CNN Architecture for Grape Leaf Disease Detection,” 2025. [Online]. Available: <https://journal.apitika.org/index.php/jistics>
- [6] A. Rathod, D. Panchal, N. Minocha, and D. Bhatt, “Crop Disease Detection Using Lightweight Deep Learning Model for Smartphone,” 2025.
- [7] D. Saha, M. P. Mangukia, and A. Manickavasagan, “Real-Time Deployment of MobileNetV3 Model in Edge Computing Devices Using RGB Color Images for Varietal Classification of Chickpea,” *Applied Sciences (Switzerland)*, vol. 13, no. 13, Jul. 2023, doi: 10.3390/app13137804.
- [8] S. J. Jaman, M. Z. Haque, R. Islam, and U. A. Noor, “BD Currency Detection: A CNN-Based Approach with Mobile App Integration,” 2025.
- [9] D. J. Rumala, “How You Split Matters: Data Leakage and Subject Characteristics Studies in Longitudinal Brain MRI Analysis,” Sep. 2023, doi: 10.1007/978-3-031-45249-9_23.
- [10] M. Sivakumar, S. Parthasarathy, and T. Padmapriya, “Trade-off between training and testing ratio in machine learning for medical image processing,” *PeerJ Comput. Sci.*, vol. 10, 2024, doi: 10.7717/PEERJ-CS.2245.
- [11] D. Khasanov *et al.*, “DeepBiteNet: A Lightweight Ensemble Framework for Multiclass Bug Bite Classification Using Image-Based Deep Learning,” *Diagnostics*, vol. 15, no. 15, Aug. 2025, doi: 10.3390/diagnostics15151841.
- [12] M. Reda, R. Suwwan, S. Alkafri, Y. Rashed, and T. Shanableh, “AgroAId: A Mobile App System for Visual Classification of Plant Species and Diseases Using Deep Learning and TensorFlow Lite,” *Informatics*, vol. 9, no. 3, Sep. 2022, doi: 10.3390/informatics9030055.
- [13] M. H. H. Minhat, S. Saon, A. K. Mahamad, and U. Fadlillah, “Android Application of Leaf Identification System,” *International Journal of Interactive Mobile Technologies*, vol. 16, no. 15, pp. 62–77, 2022, doi: 10.3991/ijim.v16i15.31881.
- [14] Ş. Aktı, M. Qaraqe, and H. K. Ekenel, “A Mobile Food Recognition System for Dietary Assessment,” Apr. 2022, [Online]. Available: <http://arxiv.org/abs/2204.09432>
- [15] M. Krumnikl and V. Maiwald, “Facial Emotion Recognition for Mobile Devices: A Practical Review,” *IEEE Access*, vol. 12, pp. 15735–15747, 2024, doi: 10.1109/ACCESS.2024.3358455.
- [16] S. Rokhva, B. Teimourpour, H. Amir, and S. A. Soltani, “Computer Vision in the Food Industry: Accurate, Real-time, and Automatic Food Recognition with Pretrained MobileNetV2,” 2024.
- [17] A. T. Ramadhan and A. Setiawan, “Catbreedsnet: An Android Application for Cat Breed Classification Using Convolutional Neural Networks,” *Jurnal Online Informatika*, vol. 8, no. 1, pp. 52–60, Jun. 2023, doi: 10.15575/join.v8i1.1007.

- [18] L. Bu, C. Hu, and X. Zhang, “Recognition of food images based on transfer learning and ensemble learning,” *PLoS One*, vol. 19, no. 1 January, Jan. 2024, doi: 10.1371/journal.pone.0296789.
- [19] M. Yunus and Y. Anwar, “APLIKASI PENERJEMAH BAHASA ISYARAT INDONESIA KE DALAM HURUF ABJAD,” 2022. [Online]. Available: <https://jurnal.umpar.ac.id/index.php/sylog>■257
- [20] A. Stankiewicz, T. Marciniak, N. Budna, R. Chwalek, and M. Dziedzic, “Classification of OCT Images of the Human Eye Using Mobile Devices,” *Applied Sciences (Switzerland)*, vol. 15, no. 6, Mar. 2025, doi: 10.3390/app15062937.