



# Implementasi MobileNetV2 pada Aplikasi Mobile untuk Penilaian Objektif Kondisi Fisik Ponsel Bekas

Azriel Sebastian Pamungkas<sup>\*</sup>, Justin Matthew Triono, Emanuel Pinesthi Widi Utomo, Cinantya Paramita

Fakultas Ilmu Komputer, Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

Email: <sup>1</sup>\*111202314868@mhs.dinus.ac.id, <sup>2</sup>111202314877@mhs.dinus.ac.id, <sup>3</sup>111202314898@mhs.dinus.ac.id,

<sup>4</sup>cinantya.paramita@dsn.dinus.ac.id

Email Penulis Korespondensi: 111202314868@mhs.dinus.ac.id

**Abstrak**—Kurangnya perhatian mengenai sampah elektronik (*e-waste*), khususnya pada perangkat seluler atau ponsel, memberi dampak serius terhadap isu lingkungan secara global. Salah satu hambatan utama dalam sirkulasi ekonomi perangkat ini adalah subjektivitas dan kesulitan teknis dalam menilai kondisi fisik ponsel bekas secara akurat. Penelitian ini bertujuan mengatasi tantangan tersebut melalui pengembangan prototipe platform ekonomi sirkular berbasis aplikasi ponsel yang menyediakan layanan penilaian kondisi ponsel secara objektif dan otomatis. Sistem dirancang menggunakan *React Native Expo* dan mengintegrasikan model *Deep Learning MobileNetV2* melalui *TensorFlow Lite*. Metode *transfer learning* diterapkan pada dataset yang mencakup berbagai merek ponsel seperti Samsung, Xiaomi, dan OPPO untuk melatih model mengenali kerusakan fisik pada layar dan bodi. Hasil pengujian menunjukkan bahwa sistem mampu memberikan penilaian objektif dengan presisi tinggi pada ponsel kondisi prima (*Grade A*) sebesar 0,95. Namun, objektivitas pada ponsel rusak berat (*Grade D*) masih menghadapi tantangan dengan presisi 0,22 akibat ketidakseimbangan data latih. Meskipun demikian, prototipe aplikasi berhasil menyajikan fitur pemindaian *real-time* yang transparan. Penelitian ini berkontribusi dalam menghadirkan solusi teknis yang menjembatani kesenjangan kepercayaan melalui standarisasi penilaian otomatis, sehingga mampu meminimalisir subjektivitas inspeksi manual dan mendorong efisiensi rantai pasok dalam ekosistem ekonomi sirkular elektronik.

**Kata Kunci:** *MobileNetV2*; *Deep Learning*; Penilaian Kondisi Ponsel Bekas; Ekonomi Sirkular; *TensorFlow Lite*

**Abstract**—The lack of attention to electronic waste (*e-waste*), particularly regarding mobile phones, has a serious impact on global environmental issues. One of the main obstacles in the economic circulation of these devices is the subjectivity and technical difficulty in accurately assessing the physical condition of used phones. This research aims to address these challenges through the development of a circular economy platform prototype based on a mobile application that provides objective and automated phone condition assessment services. The system is designed using *React Native Expo* and integrates the *MobileNetV2 Deep Learning* model via *TensorFlow Lite*. *Transfer learning* methods are applied to a dataset covering various mobile phone brands such as Samsung, Xiaomi, and OPPO to train the model to recognize physical damage on the screen and body. Test results indicate that the system is capable of providing objective assessment with high precision for devices in prime condition (*Grade A*) at 0.95. However, objectivity for severely damaged phones (*Grade D*) remains a challenge with a precision of 0.22 due to training data imbalance. Nevertheless, the application prototype successfully presents a transparent real-time scanning feature. This research contributes to providing a technical solution that bridges the trust gap through automated assessment standardization, thereby minimizing manual inspection subjectivity and promoting supply chain efficiency in the electronic circular economy.

**Keywords:** *MobileNetV2*; *Deep Learning*; Used Smartphone Condition Assessment; Circular Economy; *TensorFlow Lite*

## 1. PENDAHULUAN

Pertumbuhan eksponensial industri elektronik telah memberikan dampak signifikan terhadap peningkatan volume limbah elektronik (*e-waste*) secara global. Pertumbuhan ini didorong oleh siklus hidup produk yang semakin pendek, perubahan preferensi konsumen, dan akselerasi inovasi teknologi yang menciptakan perangkat lebih canggih setiap tahunnya (Rahmatia et al., 2025). Dalam upaya mitigasi, konsep ekonomi sirkular hadir sebagai pendekatan alternatif dari model ekonomi linear yang berbasis pada paradigma *take-make-dispose* (Magrini et al., 2021). Ekonomi sirkular menawarkan strategi efisiensi sumber daya melalui penggunaan kembali (*reuse*), perbaikan (*refurbishment*), dan pembuatan ulang (*remanufacturing*). Dengan menerapkan prinsip – prinsip ini, ekonomi sirkular bertujuan memulihkan nilai jual perangkat sebelum akhirnya dibuang. Hal ini sangat penting mengingat setiap ponsel pintar memiliki nilai pemulihan material (*material recovery value*) yang berharga seperti emas, tembaga, dan kobalt, serta elemen penting lainnya yang dapat dimanfaatkan kembali dalam manufaktur produk baru (Nigam et al., 2021).

Urgensi penerapan konsep ini didorong oleh data faktual mengenai lonjakan limbah elektronik yang mencapai skala krisis. Menurut laporan *United Nations Institute for Training and Research (UNITAR)* tahun 2022, Indonesia menempati urutan pertama di antara negara-negara ASEAN sebagai penghasil limbah elektronik (*e-waste*) terbesar, dengan estimasi produksi mencapai 2 juta ton per tahun dan tingkat pertumbuhan 7-9% setiap tahunnya (Paminto et al., 2024). Angka ini menempatkan Indonesia dalam posisi kritis dalam manajemen limbah elektronik regional. Namun, fakta yang lebih mengkhawatirkan adalah bahwa dari jumlah masif tersebut, hanya sekitar 17,4% yang berhasil dikelola dengan baik melalui jalur daur ulang resmi, sementara sisanya sekitar 82,6% berakhir di tempat pembuangan akhir, pemukiman tidak resmi atau bahkan ekspor ilegal ke negara berkembang lainnya. Manajemen limbah yang tidak tepat ini memicu kerusakan lingkungan berkelanjutan melalui kontaminasi tanah, air dan polusi udara yang memicu kerusakan lingkungan serta hilangnya potensi nilai ekonomi yang sangat signifikan.

Meskipun potensi ekonomi sirkular sangat menjanjikan dalam menciptakan nilai tambah dan mendorong pertumbuhan ekonomi berkelanjutan, implementasinya menghadapi risiko dan tantangan teknis yang besar. Hambatan utama dalam rantai pasok daur ulang (*reverse supply chain*) perangkat elektronik tidak hanya terletak pada aspek



pengumpulan unit lama, melainkan terutama pada proses penilaian kondisi (*grading*) perangkat bekas (Laine, 2022). Penilaian kondisi adalah tahapan kritis yang menentukan nasib setiap perangkat, apakah akan direvitalisasi melalui perbaikan dan penjualan ulang (*refurbishment path*), atau langsung didaur ulang komponen-komponennya untuk ekstraksi material berharga (*recycling path*) (Shahabuddin et al., 2023). Tanpa analisis kondisi fisik yang presisi dan objektif, sangat sulit untuk menentukan rute optimal setiap perangkat, yang pada akhirnya mengakibatkan inefisiensi biaya operasional, peningkatan kerugian keuangan, dan hilangnya kepercayaan konsumen terhadap kredibilitas dan transparansi pasar barang *refurbished*.

Sebagai indikator utama untuk menentukan kualitas dan nilai jual, proses penilaian kondisi fisik ponsel saat ini masih sangat bergantung pada pemeriksaan manual yang dilakukan oleh teknisi berpengalaman, suatu pendekatan yang rentan terhadap subjektivitas manusia (Ma et al., 2018). Proses inspeksi konvensional ini membutuhkan keahlian teknis khusus, memakan waktu yang lama dan sering kali tidak memiliki standar yang konsisten antar teknisi maupun antar lokasi pemeriksaan. Ketidakpastian dalam menentukan apakah sebuah layar "rusak ringan" atau "rusak berat" atau apakah bodi memiliki goresan atau kerusakan menjadi hambatan operasional (*bottleneck*) yang memperlambat sirkulasi perangkat kembali ke pasar sekunder. Situasi ini menciptakan inefisiensi dalam rantai pasokan, meningkatkan biaya operasional dan mengurangi kompetitivitas ekonomi daur ulang elektronik dibandingkan dengan praktik ilegal atau ekspor tidak resmi.

Untuk mengatasi masalah subjektivitas dan ketidakkonsistenan penilaian manual tersebut, penelitian ini mengajukan solusi inovatif berbasis *machine learning* dan *computer vision* yang berfokus pada penilaian kondisi otomatis dan objektif. Pendekatan ini berbeda secara fundamental dengan penelitian terdahulu yang mayoritas berfokus pada manajemen logistik pengumpulan berbasis *IoT* atau pendekatan edukasi melalui gamifikasi (Cahyawati et al., 2020; Rimantho, 2021). Penelitian ini mengisi celah (*research gap*) dengan menerapkan teknologi *Computer Vision* dan *Deep Learning* untuk diagnosa kondisi fisik secara *real-time*, memberikan objektifitas yang sulit dicapai melalui inspeksi manual. Pendekatan ini memanfaatkan data citra digital dan algoritma pembelajaran mendalam untuk memberikan penilaian yang objektif, terstandarisasi dan dapat direplikasi.

Dalam beberapa tahun terakhir, pemanfaatan *deep learning* pada aplikasi kesehatan berbasis aplikasi ponsel menunjukkan potensi besar dalam mendukung deteksi dini penyakit secara lebih cepat dan terjangkau. Salah satu penelitian mengembangkan sistem deteksi katarak berbasis ponsel pintar dengan mengintegrasikan model *YOLOv10x* dan *framework Ionic*, yang mampu mencapai akurasi deteksi sebesar 81,4% sekaligus tetap dapat dijalankan pada perangkat dengan sumber daya komputasi terbatas (Mahendra et al., 2025). Di bidang dermatologi, studi lain mengevaluasi beberapa varian *YOLOv8* pada dataset dermoskopik HAM10000 untuk tugas deteksi multi-kelas lesi kulit, di mana *YOLOv8s* mencapai *mAP50* sebesar 0,890 dengan *precision* 0,840 dan *recall* 0,857, sementara *YOLOv8m* menunjukkan sensitivitas terbaik untuk lesi ganas dengan nilai *recall* 0,857 (Paramita et al., 2025). Hasil tersebut menegaskan bahwa arsitektur deteksi satu tahap yang ringan dan efisien sangat cocok diaplikasikan pada skenario diagnosis *real-time*, khususnya ketika model perlu di-*deploy* pada perangkat dengan keterbatasan komputasi seperti ponsel pintar.

Selain aspek performa model, beberapa penelitian juga menyoroti pentingnya integrasi model *deep learning* dengan antarmuka aplikasi yang dirancang berpusat pada pengguna. Implementasi sistem pendukung diagnosis yang memadukan model visi komputer dengan desain UX yang responsif dan intuitif terbukti dapat meningkatkan keterlibatan pengguna serta mempermudah adopsi sistem di lingkungan nyata (Paramita et al., 2024). Di sisi lain, kajian lain mengenai pemanfaatan arsitektur *YOLO* dan *CNN* untuk berbagai tugas deteksi objek *real-time* menunjukkan bahwa pendekatan *one-stage detector* mampu menyeimbangkan akurasi dengan waktu inferensi yang rendah (Dzaky et al., 2024), sehingga relevan untuk aplikasi lapangan yang membutuhkan respons cepat. Beberapa studi juga menegaskan bahwa keberhasilan model *CNN* pada tugas klasifikasi citra sangat dipengaruhi oleh strategi pengolahan data, di mana kombinasi teknik augmentasi dan penanganan ketidakseimbangan kelas melalui penerapan *class weighting* pada fungsi *loss* secara konsisten dilaporkan mampu meningkatkan akurasi serta stabilitas proses pelatihan (Waluyo et al., 2024).

Secara teknis penelitian ini mengembangkan prototipe aplikasi seluler menggunakan arsitektur *Deep Learning* bernama *MobileNetV2*, yang dioptimalkan khusus untuk berjalan efisien pada perangkat seluler dengan sumber daya terbatas. *MobileNetV2* dipilih karena kemampuannya yang unggul dalam menyeimbangkan akurasi klasifikasi dengan efisiensi komputasi (*memory footprint* dan *computational cost* yang rendah), menjadikannya ideal untuk aplikasi *realtime* di lapangan. Model dilatih menggunakan teknik *transfer learning* pada *dataset* komprehensif yang mencakup berbagai merek ponsel populer seperti Samsung, Xiaomi, OPPO, Realme, Asus, Infinix dan Adavan, dengan fokus pada pengenalan berbagai jenis kerusakan fisik pada layar (retak, *pixel* mati) dan bodi (goresan, penyok, perubahan warna). Implementasi praktis dicapai melalui integrasi model dengan kerangka kerja *TensorFlow Lite (TFLite)*, yang memungkinkan inferensi *Machine Learning* pada perangkat seluler tanpa memerlukan koneksi internet konstan, sehingga menjaga privasi data pengguna.

Kontribusi utama penelitian ini adalah menciptakan standar penilaian objektif untuk kondisi ponsel bekas yang mengurangi bias manusia dalam rantai pasok daur ulang elektronik, sekaligus menyediakan platform transparan yang mempermudah penilaian harga beli kembali (*buyback price*) yang adil. Dengan mengklasifikasikan perangkat ke dalam empat kategori standar, *Grade A (Excellent/Sempurna)*, *Grade B (Good/Baik)*, *Grade C (Fair/Sedang)*, dan *Grade D (Poor/Buruk)*, sistem mampu memberikan estimasi nilai yang terukur. Keberhasilan implementasi sistem ini diharapkan dapat mendorong pertumbuhan pasar daur ulang elektronik formal di Indonesia, meningkatkan efisiensi rantai pasokan,



dan memberikan insentif ekonomi yang lebih kuat bagi konsumen untuk memilih jalur daur ulang resmi dibandingkan dengan pembuangan sembarangan.

## 2. METODOLOGI PENELITIAN

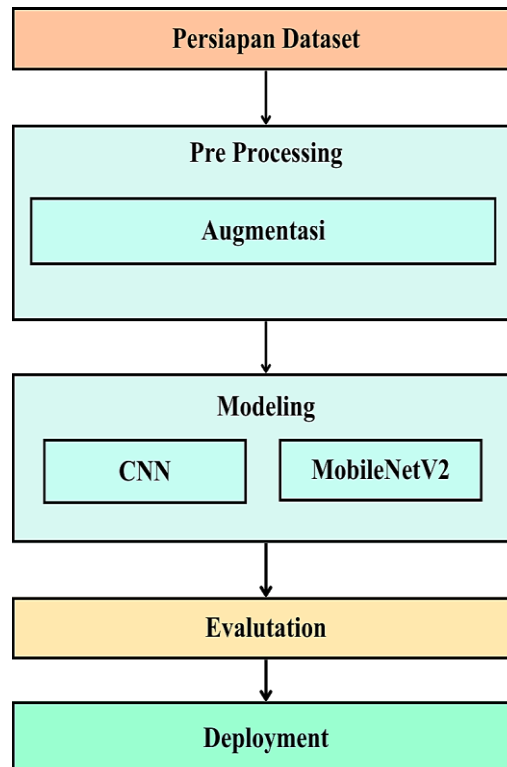
### 2.1 Kerangka Dasar Penelitian

Penelitian ini dilandaskan pada integrasi prinsip ekonomi sirkular dalam manajemen limbah elektronik (*e-waste*) dengan teknologi kecerdasan buatan untuk mengatasi inefisiensi model ekonomi linear yang bersifat *take-make-dispose*. Dalam ekosistem ekonomi sirkular, perpanjangan masa pakai produk melalui penggunaan kembali (*reuse*) dan perbaikan (*refurbishment*) menjadi strategi vital untuk mempertahankan nilai material setinggi mungkin. Namun, tantangan utama dalam rantai pasok balik ini adalah penilaian kondisi fisik perangkat yang saat ini masih didominasi oleh inspeksi manual. Metode manual ini dinilai sangat subjektif, memakan waktu, dan rentan terhadap kesalahan manusia akibat kelelahan atau inkonsistensi visual, sehingga sulit untuk diterapkan pada skala industri yang besar, sehingga diperlukan pendekatan yang lebih adaptif menggunakan *Deep Learning*. Sebagai solusi teknis, penelitian ini mengadopsi *Convolutional Neural Networks (CNN)* yang memiliki kemampuan unggul dalam mengekstraksi fitur hirarkis dari citra mentah secara otomatis tanpa memerlukan rekayasa fitur manual (Prastita et al., 2025). Untuk memastikan sistem dapat berjalan efisien pada perangkat seluler dengan sumber daya komputasi yang terbatas, arsitektur yang dipilih adalah *MobileNetV2*. *MobileNetV2* dirancang khusus untuk lingkungan perangkat seluler dengan memperkenalkan modul *inverted residual* dengan *linear bottlenecks*. Efisiensi komputasi *MobileNetV2* selanjutnya didorong oleh penggunaan *Depthwise Separable Convolutions*. Teknik ini memfaktorisasi konvolusi standar menjadi dua operasi terpisah dengan *depthwise convolution* untuk pemfilteran ringan dan *pointwise convolution* (konvolusi 1x1) untuk membangun kombinasi fitur linear (Dianda et al., 2025). Pendekatan ini mampu mengurangi biaya komputasi hingga 8 sampai 9 kali lipat dibandingkan konvolusi standar dengan hanya sedikit penurunan akurasi, menjadikannya sangat ideal untuk aplikasi pendeteksian cacat secara *real-time* pada ponsel. Mengingat keterbatasan jumlah *dataset* spesifik mengenai kerusakan fisik ponsel, penelitian ini menerapkan strategi *Transfer Learning*. Metode ini memanfaatkan model yang telah dilatih sebelumnya (*pre-trained*) pada *dataset* berskala besar seperti *ImageNet* untuk menyelesaikan tugas baru dengan data yang lebih sedikit, yang terbukti menghemat waktu pelatihan dan sumber daya komputasi secara signifikan (Thio & Susilo, 2025). Dengan mentransfer bobot dari model yang sudah terlatih, jaringan saraf mampu mengenali fitur-fitur dasar dengan lebih baik pada tahap awal pelatihan meskipun data latih terbatas.

Untuk mendukung implementasi praktis, model yang telah dilatih kemudian dikonversi dan dioptimalkan menggunakan kerangka kerja *TensorFlow Lite (TFLite)*. *TFLite* dirancang khusus untuk menjalankan inferensi *Machine Learning* pada perangkat *embedded* dan seluler dengan latensi rendah tanpa memerlukan koneksi internet yang konstan (Toyib et al., 2025), sehingga menjaga privasi data pengguna. Dalam proses konversi ini, teknik optimasi seperti kuantisasi (*quantization*) dapat diterapkan. Kuantisasi bekerja dengan mengurangi presisi representasi bobot model, misalnya dari *float32* ke *int8*, yang secara drastis mengurangi ukuran model dan mempercepat waktu respons *CPU* serta akselerator perangkat keras tanpa degradasi akurasi yang signifikan. Integrasi teknologi ini memungkinkan terciptanya platform penilaian kondisi ponsel yang objektif, cepat, dan dapat diakses secara luas, mendukung terciptanya ekosistem daur ulang elektronik yang lebih transparan dan efisien.

### 2.2 Tahapan Penelitian

Penelitian ini dirancang melalui lima tahapan utama. Pertama pengumpulan dataset dilakukan dari dua sumber dari *Kaggle*. Kedua, *pre-processing* dan augmentasi data dilakukan dengan normalisasi resolusi 224x224 piksel, pembagian data latih-validasi 80:20, serta teknik augmentasi untuk menangani ketidakseimbangan kelas. Ketiga, pengembangan model menggunakan *transfer learning MobileNetV2* dengan dua fase pelatihan yaitu fase *frozen* untuk menstabilkan bobot awal, dan fase *fine-tuning* untuk adaptasi fitur spesifik. Mekanisme *early stopping* dan *class weighting* diterapkan untuk mencegah *overfitting* dan menangani ketidakseimbangan kelas. Keempat, evaluasi model dilakukan menggunakan metrik *Precision*, *Recall*, dan *F1-Score* pada data validasi yang belum dilihat model, dengan analisis *confusion matrix* dan kurva histori pelatihan untuk mendeteksi kesalahan klasifikasi dan *overfitting*. Kelima, model dikonversi ke format *TensorFlow Lite* dan diintegrasikan ke aplikasi *mobile React Native Expo* untuk *deployment* dengan inferensi *real-time*.



**Gambar 1.** Arsitektur Sistem

### 2.3 Spesifikasi Hardware dan Software

Keberhasilan eksekusi penelitian ini sangat bergantung pada sinergi optimal antara perangkat keras (*hardware*) dan perangkat lunak (*software*). Guna menjamin efisiensi komputasi selama proses pengembangan dan pengujian, penelitian ini memanfaatkan perangkat keras dengan spesifikasi teknis yang meliputi prosesor Intel Core i5 yang didukung oleh memori RAM sebesar 8 GB, media penyimpanan SSD berkapasitas 128 GB, serta unit pemrosesan grafis (VGA) Intel Iris Graphics 6100 Di sisi perangkat lunak, platform *Kaggle Notebook (kaggle.com)* dimanfaatkan sebagai lingkungan utama untuk pengolahan data serta pelatihan model (*training*). Selanjutnya, tahap integrasi model dan pengembangan aplikasi dilakukan menggunakan *Visual Studio Code (VS Code)* untuk membangun aplikasi mobile berbasis *React Native*.


### 2.4 Persiapan Dataset

Dataset penelitian bersumber dari Kaggle yang terdiri dari dua sumber utama '*Cracked Screen Dataset*' (300 citra) dan '*Mobile Phone Defect Segmentation Data*' (1220 citra), dengan total 1520 gambar dari delapan merek ponsel (Samsung, Xiaomi, OPPO, Vivo, Realme, ASUS, Infinix, dan Advan).

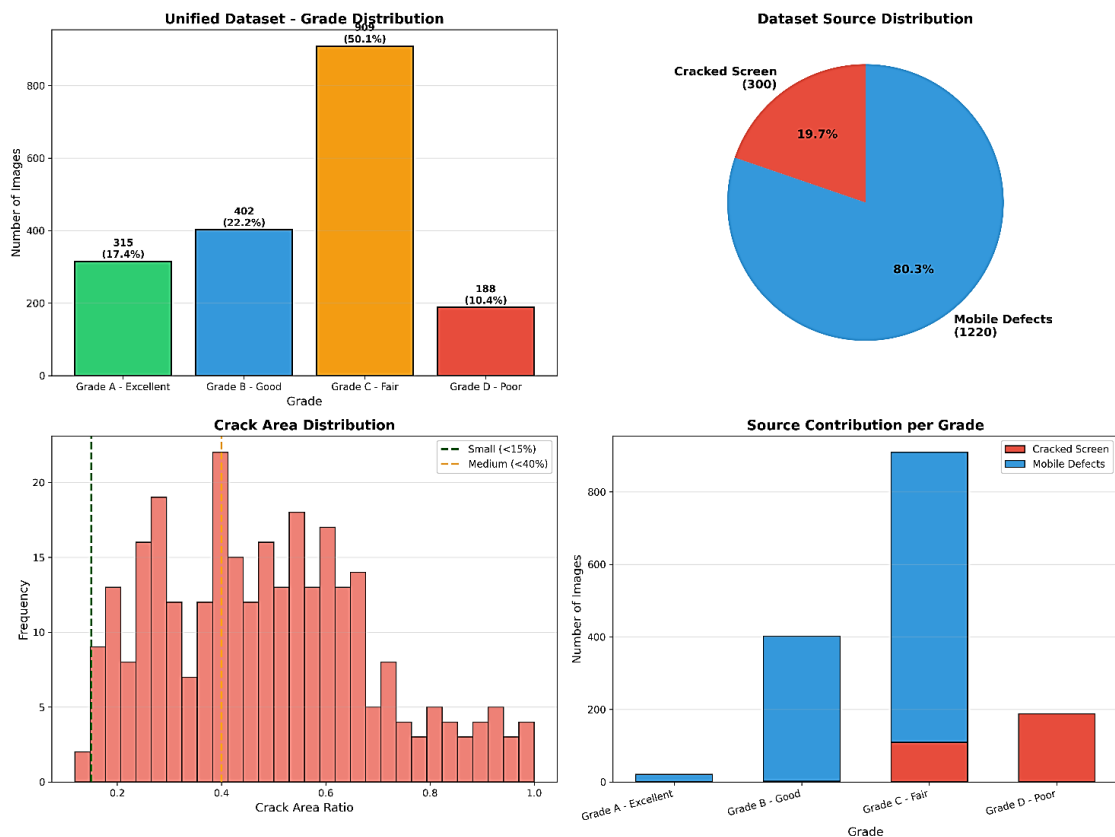
Contoh visual dataset layar retak ditampilkan pada Gambar 2. Setiap citra diklasifikasikan berdasarkan persentase area kerusakan dan jenis cacat visual menggunakan aturan logika yang ketat sebagaimana dirincikan pada Tabel 1. *Dataset* layar retak diklasifikasikan secara otomatis melalui *parsing XML PASCAL VOC*, sementara dataset defek ponsel diorganisir berdasarkan jenis kerusakan (*good, scratch, stain, oil*).

**Tabel 1.** Definisi Standar Penilaian

Label Kelas	Kriteria Visual & Logika Klasifikasi	Nilai Estimasi
Grade A (Excellent)	Kondisi fisik sempurna. Tidak ada cacat visual yang terlihat pada layar maupun bodi.	90-100%
Grade B (Good)	Terdapat goresan ringan ( <i>light scratch</i> ) atau noda tipis. Kerusakan retak sangat kecil (<15% area layar).	70-89%
Grade C (Fair)	Kerusakan terlihat jelas namun fungsional. Goresan dalam, noda minyak, atau retak layar sedang (15-40% area).	50-69%
Grade D (Poor)	Kerusakan parah atau cacat ganda ( <i>multiple defects</i> ). Retak layar mendominasi (>40% area).	20-49%



**Gambar 2.** Cracked Screen Dataset



**Gambar 3.** Distribusi dataset

Gambar 3 menunjukkan distribusi dataset gabungan yang menghasilkan 1.520 citra dengan ketidakseimbangan kelas signifika pada *Grade A* (21 citra, 1.4%), *Grade B* (402 citra, 26.4%), *Grade C* (909 citra, 59.8%), dan *Grade D* (188 citra, 12.4%). Dominasi dataset *Mobile Defects* (80.3%) terhadap *Cracked Screen* (19.7%) menjadi faktor penting dalam karakteristik distribusi grade akhir.

### 2.5 Pre-Processing Data

Penelitian ini menerapkan berbagai teknik transformasi geometris dan fotometrik seperti rotasi, *shift*, *shear*, *zoom*, flipping, serta penyesuaian kecerahan untuk meningkatkan keragaman data dan membuat model lebih tangguh terhadap

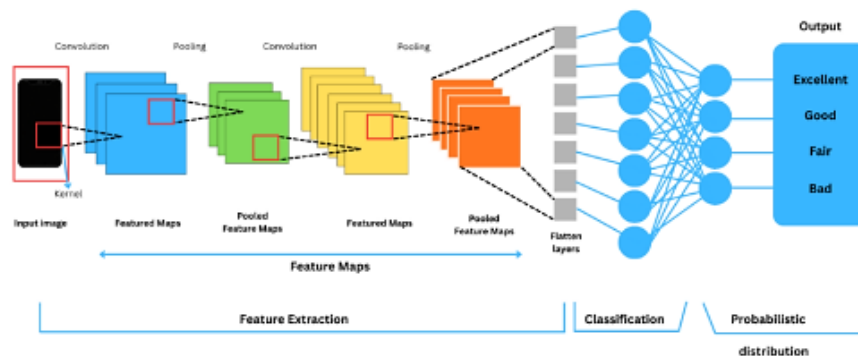
variasi sudut pengambilan gambar dan kondisi pencahayaan saat pengguna mengambil foto (Gupta et al., 2022). Model dilatih untuk menilai empat aspek visual penting, yaitu kondisi layar (retakan atau *pixel* mati), kerusakan di sudut-sudut bodi (penyok atau perubahan warna), dan kebersihan perangkat secara keseluruhan. Proses dimulai dengan normalisasi seluruh citra ke ukuran 224×224 piksel sesuai spesifikasi input *MobileNetV2*, diikuti dengan penskalaan ulang nilai intensitas piksel untuk mempercepat konvergensi dan menjaga stabilitas gradien, kemudian pembagian dataset menjadi 80% data latih dan 20% data validasi secara terstratifikasi. Untuk mengatasi ketidakseimbangan kelas, khususnya pada Grade A yang jumlah sampelnya sangat sedikit, strategi augmentasi tersebut difokuskan pada penambahan sampel Grade A sehingga distribusi dataset menjadi lebih seimbang, dan class weight diterapkan pada fungsi loss untuk memberi perhatian lebih pada kelas minoritas.

**Tabel 2.** Parameter Augmentasi Data

Parameter	Nilai
Rotasi Acak	hingga 30°
<i>Width &amp; Height Shift</i>	0.48, 0.55
Transformasi <i>Shear &amp; Zoom</i>	0.22
Pembalikan <i>Horizontal &amp; Vertical</i>	<i>True</i>
Modulasi Kecerahan	[0.7, 1.3]
Mode <i>Fill</i>	<i>Nearest</i>


### 2.6 Modeling

Komponen kecerdasan buatan pada sistem ini memanfaatkan pendekatan *Deep Learning* berbasis *Convolutional Neural Networks (CNN)* dengan mengimplementasikan teknik *transfer learning* menggunakan *MobileNetV2 pretrained model* (Sandler et al., 2018). Arsitektur ini dipilih karena kemampuannya yang unggul dalam menjaga keseimbangan antara akurasi klasifikasi dan efisiensi sumber daya pada lingkungan mobile dengan komputasi terbatas (Ding et al., 2022). *MobileNetV2* terdiri dari 154 lapisan konvolusi yang dioptimalkan melalui *inverted residual blocks* dan *depthwise separable convolutions*, memungkinkan pengurangan biaya komputasi hingga 8-9 kali lipat dibandingkan konvolusi standar tanpa degradasi akurasi signifikan.



**Gambar 4.** Arsitektur *Convolutional Neural Network*

Arsitektur inti yang digunakan adalah *Convolutional Neural Network (CNN)* yang secara otomatis mengekstraksi fitur hierarkis dari citra melalui rangkaian *convolutional layer* dan *pooling layer*, kemudian memetakan representasi fitur tersebut ke label kelas melalui *fully connected layer* di bagian akhir. Pendekatan ini memungkinkan model menangkap pola visual mulai dari tepi dan tekstur hingga bentuk objek yang lebih kompleks secara efisien, sehingga sesuai untuk tugas klasifikasi kondisi fisik ponsel pada skala besar



**Gambar 5.** Arsitektur dasar *MobileNetV2*. (Sharma, 2023)

Gambar 5 menunjukkan arsitektur spesifik *MobileNetV2* yang diimplementasikan dalam penelitian ini. Model ini terdiri dari base *MobileNetV2 pre-trained* sebagai *feature extractor* dan *custom classification head* untuk klasifikasi



empat kategori *grade* kondisi ponsel. *Base MobileNetV2* menggunakan 154 lapisan yang telah dilatih pada dataset *ImageNet*, dioptimalkan dengan *inverted residual blocks* dan *depthwise separable convolution* untuk efisiensi komputasi maksimal. *Custom head* dirancang khusus untuk mengadaptasi *output base model* ke tugas klasifikasi spesifik dengan menggabungkan *global average pooling*, *dense layers* dengan aktivasi *ReLU*, *batch normalization*, dan *dropout layers* untuk regularisasi.

**Tabel 3.** Distribusi parameter

Layer (Tipe)	Output Shape	Parameter #
mobilenetv2_1.00_224 (Functional)	(None, 7, 7, 1280)	2,257,984
global_avg_pooling (GlobalAveragePooling2D)	(None, 1280)	0
dropout_0.3_pre (Dropout)	(None, 1280)	0
dense_256 (Dense)	(None, 256)	327,936
batch_norm (BatchNormalization)	(None, 256)	1,024
dropout_0.6 (Dropout)	(None, 256)	0
output (Dense)	(None, 4)	1,028
Total		2,587,972

Model yang digunakan mengikuti arsitektur standar *MobileNetV2* dengan total sekitar 2,59 juta parameter dan ukuran model  $\pm 9,9$  MB, di mana pada fase pelatihan awal hanya bagian *head* klasifikasi yang dibuat *trainable*, sedangkan pada fase *fine-tuning* sebagian lapisan atas *MobileNetV2* juga dibuka untuk adaptasi terhadap *dataset* kerusakan ponsel. Pendekatan ini menjaga efisiensi komputasi sekaligus memberikan kapasitas yang cukup untuk membedakan empat kategori *grade* kondisi perangkat.

**Tabel 4.** Konfigurasi Pelatihan

Parameter	Nilai / Pengaturan
Arsitektur Input	224 x 224 pixels (RGB)
Batch Size	32
Learning Rate	Fase 1 (Frozen): 0.0005 Fase 2 (Fine-tuning): 0.00005
Epochs	Fase 1: 25 Epochs Fase 2: 15 Epochs
Patience (Early Stopping)	8 Epochs

Proses pelatihan dilaksanakan dalam dua fase strategis dengan beberapa konfigurasi (tabel 2), pada Fase 1 (*frozen base*, *epoch* 0–25), seluruh 154 lapisan *MobileNetV2* dibekukan untuk menstabilkan bobot awal dan mencegah *catastrophic forgetting*, sehingga hanya *custom classification head* dengan 329.476 parameter yang dapat dilatih. *Class weights* diterapkan untuk menangani ketidakseimbangan kelas dengan bobot masing-masing *Grade A* sebesar 1,44, *Grade B* 1,13, *Grade C* 0,50, dan *Grade D* 2,41. Selama fase ini digunakan mekanisme *EarlyStopping* dengan *patience* delapan *epoch* yang memonitor nilai *validation loss*, dikombinasikan dengan *ReduceLROnPlateau* dengan faktor penurunan 0,5 dan *patience* tiga *epoch*, serta *ModelCheckpoint* untuk menyimpan model dengan performa terbaik sehingga proses pelatihan berlangsung lebih stabil dan efisien.

Pada Fase 2 (*fine-tuning*, *epoch* 26–40), nilai learning rate diperkecil menjadi 0,00005 atau sepuluh kali lebih rendah dibandingkan fase pertama, dan 30 lapisan teratas *MobileNetV2* dibuka kembali agar dapat beradaptasi dengan fitur-fitur spesifik pada dataset citra ponsel. Perubahan ini menyebabkan jumlah parameter yang dapat dilatih meningkat menjadi 1.855.876 atau sekitar 71% dari total parameter model. Konfigurasi *callback* dipertahankan sama seperti pada Fase 1 sehingga proses *fine-tuning* tetap terlindungi dari *overfitting* yang berlebihan dan model mampu mempelajari detail *visual* penting yang dibutuhkan untuk klasifikasi kondisi ponsel secara lebih akurat.

## 2.7 Deployment

Integrasi model ke sistem nyata merupakan tantangan utama dalam siklus *machine learning* agar hasil prediksi dapat diakses pengguna dengan mudah. Pada tahap ini, model yang telah dilatih dari Fase 2 diekspor dari format *TensorFlow Keras* (.keras) ke dalam format *TensorFlow Lite* (.tflite) untuk memungkinkan inferensi efisien pada perangkat mobile dengan sumber daya komputasi terbatas (Rashidi, 2022). Selanjutnya, proses integrasi dan pengembangan antarmuka dilakukan menggunakan *Visual Studio Code*, di mana model tersebut disematkan ke dalam kerangka kerja *React Native* hingga menghasilkan aplikasi seluler yang utuh.

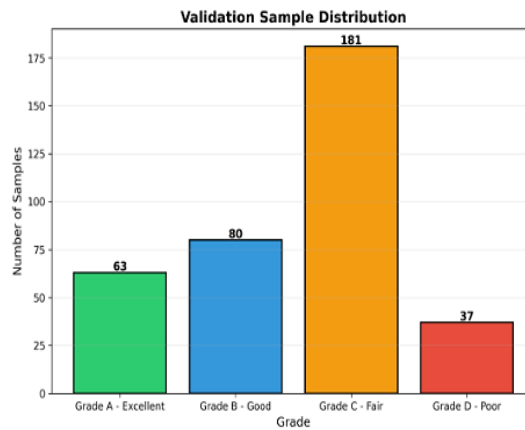
## 3. HASIL DAN PEMBAHASAN

Data yang digunakan pada tahap evaluasi ini adalah *validation dataset* dengan total sampel yang bervariasi. Tabel 5 menunjukkan hasil pengujian performa klasifikasi terhadap 4 (empat) label kelas, yaitu *Grade A*, *B*, *C*, dan *D* menggunakan metrik *Precision*, *Recall*, dan *F1-Score*.

**Tabel 5.** Hasil Performa tiap Kategori

Grade	Precision	Recall	F1-Score
A - Excellent	0.95	0.84	0.89
B – Good	0.48	0.26	0.34
C – Fair	0.55	0.39	0.46
D - Poor	0.22	0.78	0.35

Evaluasi performa keseluruhan model menunjukkan presisi rata-rata tertimbang sebesar 0.54 dan *recall* tertimbang 0.56, mengindikasikan model memiliki performa moderat dengan tantangan signifikan pada klasifikasi kelas minoritas. Akurasi *overall* model pada validation set mencapai 56%, menunjukkan bahwa model mampu memprediksi dengan benar lebih dari setengah sampel validasi, meskipun masih jauh dari ideal. Berdasarkan data yang diperoleh, *Grade A (Excellent)* mengungguli 3 kategori lainnya dengan skor *Precision* tertinggi, yaitu 0.95. Hal ini menunjukkan bahwa model sangat efektif dalam mengenali pola kualitas terbaik. Sebaliknya, performa terendah terjadi pada *Grade D (Poor)* yang hanya mencatatkan presisi 0.22. Rendahnya nilai presisi pada *Grade D* (0.22) mengindikasikan tingginya tingkat *False Positive*, di mana model cenderung terlalu agresif memprediksi kerusakan parah. Berdasarkan analisis *Confusion Matrix* (Gambar 7), terlihat bahwa kontribusi kesalahan terbesar berasal dari *Grade C*, di mana 39,78% sampel *Grade C* salah diklasifikasikan sebagai *Grade D*. Hal ini menunjukkan adanya ambiguitas visual yang signifikan antara kategori 'rusak sedang' (*Grade C*) dan 'rusak berat' (*Grade D*). Model kesulitan menarik batas tegas antara kedua kelas ini karena fitur visual seperti retakan layar yang luas (*Grade C*) sering kali menyerupai kerusakan total (*Grade D*) pada resolusi input 224×224 piksel. Sebaliknya, tingginya nilai *Recall Grade D* (0.78) menegaskan bahwa model sebenarnya mampu mengenali fitur kerusakan berat, namun gagal membedakannya dari kerusakan sedang. Kesenjangan performa yang signifikan ini mengindikasikan bahwa model cenderung bias terhadap kelas mayoritas, mengingat distribusi dari *validation sample* pada data *Grade D* sangat minim (37 *sample*) dibandingkan *Grade C* yang mendominasi (181 *sample*) seperti terlihat pada Gambar 6.




**Gambar 6.** Distribusi Sampel

Lalu pada *Grade A (Excellent)* juga mendominasi dalam aspek sensitivitas dengan skor *recall* mencapai 84%, menunjukkan kemampuan model yang andal dalam mendeteksi sebagian besar perangkat yang benar-benar berada dalam kondisi baik. Sebaliknya, *Grade B* menunjukkan presisi 0.48 dengan *recall* hanya 0.26, mengindikasikan model sering salah mengklasifikasikan ponsel *Grade B* atau gagal mendeteksinya. Hal ini kemungkinan disebabkan oleh ambiguitas visual antara *Grade B* (defek ringan) dengan *Grade A* (sempurna) dan *Grade C* (defek sedang), karena karakteristik visual ketiganya memiliki *overlap* yang signifikan. *Grade D* menunjukkan *recall* tinggi 0.78 tetapi presisi rendah 0.22, berarti model berhasil mendeteksi mayoritas ponsel *Grade D*, namun banyak salah prediksi dari *Grade C* yang diprediksi sebagai *Grade D*, mencerminkan kesulitan model membedakan antara kerusakan sedang dan parah.



**Gambar 7.** Confusion Matrix

Analisis *confusion matrix* memperlihatkan tantangan klasifikasi yang signifikan pada kelas-kelas yang berdekatan (*adjacent grades*), yang sering kali memiliki fitur visual yang ambigu sebagaimana divisualisasikan pada Gambar 7. *Matrix* menunjukkan pola *error* yang jelas: (1) *Grade A* memiliki *error rate* 16%, di mana 33.33% prediksi salah masuk ke *Grade B*, menunjukkan kemiripan fitur visual antara kondisi sempurna dan baik yang sulit dibedakan model; (2) *Grade B* mengalami *error rate* tertinggi 74%, dengan distribusi *error* tersebar ke *Grade A* (mungkin dianggap terlalu sempurna) dan *Grade C* (dianggap lebih rusak), mengindikasikan *Grade B* paling ambigu secara visual; (3) *Grade C* memiliki *error rate* 61%, di mana 39.78% sampel salah diprediksi sebagai *Grade D (Poor)*, kemungkinan disebabkan oleh subjektivitas visual antara kondisi "sedang rusak" dan "sangat rusak" pada citra beresolusi rendah; (4) *Grade D* menunjukkan *error rate* hanya 22% tetapi bias ke prediksi positif, dengan mayoritas prediksi benar, namun kontribusi *false positive* dari *Grade C* menyebabkan presisi rendah. Pola kesalahan ini mengkonfirmasi bahwa kesalahan klasifikasi utama terjadi pada kelas-kelas yang visual *characteristic*-nya berdekatan

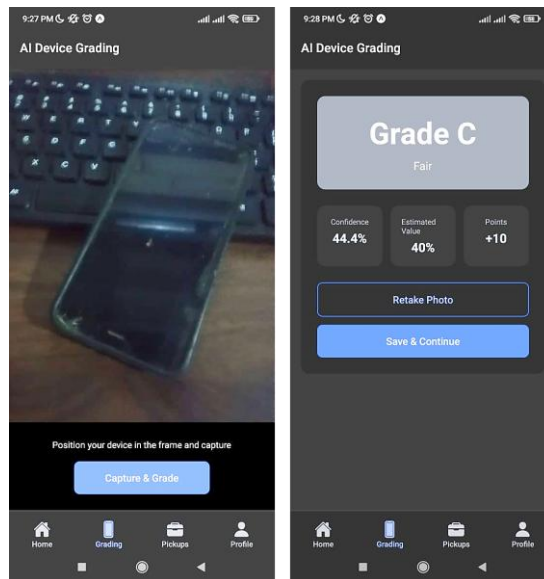


**Gambar 8.** Kurva Histori Pelatihan

Gambar 8 menampilkan dinamika loss dan akurasi selama dua fase pelatihan. Pada Fase 1 (*Frozen*, 0-25 *epoch*), *training loss* menurun stabil dari 3.2 menjadi ~0.57, sementara *validation loss* turun ke 2.69 pada *epoch* 1 kemudian mengalami peningkatan bertahap hingga *epoch* 9. Pola ini mengindikasikan model mulai *overfit* meski lapisan dibekukan. Pada Fase 2 (*Fine-tuning*, *epoch* 26-40), *training loss* menurun lebih agresif mencapai ~0.58, namun *validation loss* menunjukkan fluktuasi signifikan naik turun dari 1.56 hingga mencapai 6.43 pada *epoch* 40, dengan *training accuracy* mencapai 67.4% namun *validation accuracy* stabil di 48.2%. Lonjakan *validation loss* di Fase 2 ini mengindikasikan severe *overfitting*, di mana model mempelajari detail spesifik *training set* (terutama pada 30 lapisan yang *unfrozen*) namun gagal generalisasi ke *validation set*. Fenomena *overfitting* yang ekstrem pada Fase 2 (*fine-tuning*) ditandai dengan lonjakan *validation loss* yang mencapai titik 6.43 pada *epoch* ke-40, kontras dengan *training loss* yang terus menurun hingga 0.58. Disparitas ini terjadi akibat keputusan untuk membuka kembali (*unfreeze*) 30 lapisan teratas *MobileNetV2* pada *dataset* yang sangat tidak seimbang. Dengan jumlah sampel minoritas yang sangat terbatas (*Grade D* hanya 37 sampel validasi), model yang memiliki kapasitas parameter besar (1,8 juta parameter latih) cenderung melakukan *memorization* terhadap fitur-fitur spesifik (*noise*) pada data latih *Grade D*, alih-alih mempelajari fitur generalisasi kerusakan. Akibatnya, ketika diuji dengan data validasi yang belum pernah dilihat, model gagal memberikan prediksi yang konsisten, yang mengonfirmasi bahwa strategi *fine-tuning* pada arsitektur *deep learning* memerlukan jumlah data kelas minoritas yang lebih proporsional untuk mencegah degradasi performa validasi. Penyebab utama adalah *class imbalance* yang ekstrem. *Grade C* mendominasi dengan 181 sampel, sementara *Grade D* hanya 37 sampel, menyebabkan model *overfit* pada fitur *Grade C* dan memperlakukan *Grade D* sebagai *outlier*. *Early stopping* terpicu pada *epoch* 11 (*patience*=8), menyelamatkan model dari degradasi lebih lanjut.

Temuan ini menyarankan perlunya penerapan strategi mitigasi yang lebih kuat pada pengembangan selanjutnya, antara lain: (1) *augmentasi* data yang lebih agresif, khususnya untuk *Grade B* dan *Grade D* yang memiliki karakteristik visual paling ambigu, melalui teknik seperti *mixup* atau *cutmix*; (2) *focal loss* sebagai pengganti *categorical crossentropy* untuk memberikan penalti lebih besar pada *hard negatives*; (3) *class reweighting* yang lebih ekstrem; (4) *ensemble methods* dengan *multiple models* untuk meningkatkan *robustness*; serta (5) peningkatan resolusi citra input dari 224×224 menjadi 448×448 atau lebih tinggi untuk menangkap detail kerusakan yang ambigu pada *Grade B* dan *C*.

Implementasi praktis model yang telah dilatih dilakukan melalui konversi ke *TensorFlow Lite* dan integrasi ke aplikasi mobile *React Native Expo*. Prototipe aplikasi berhasil mengintegrasikan model dalam *runtime TFLite*, memungkinkan inferensi *real-time* pada perangkat mobile tanpa koneksi internet. Fitur pemindaian berbasis kamera ditampilkan pada Gambar 9, di mana pengguna dapat menangkap citra ponsel secara langsung. Setelah pemindaian selesai, hasil penilaian disajikan secara transparan mencakup prediksi *grade* (*Grade A* hingga *D*) dan estimasi nilai residu berdasarkan faktor depresiasi yang telah ditentukan. Sistem berhasil menampilkan output yang *user-friendly* dengan *latency* inferensi kurang dari 500 ms per prediksi, memastikan pengalaman pengguna yang responsif di lapangan.



**Gambar 9.** Fitur Pemindaian Berbasis AI

#### 4. KESIMPULAN

Hasil pengujian klasifikasi kondisi perangkat elektronik menunjukkan bahwa pendekatan *Deep Learning* menggunakan arsitektur *MobileNetV2* memiliki efektivitas yang bervariasi, dengan keunggulan signifikan dalam mendeteksi perangkat kondisi prima (*Grade A*) yang mencapai presisi 0,95, namun masih menghadapi tantangan *overfitting* dan bias pada kelas minoritas (*Grade D*) akibat ketidakseimbangan distribusi data. Terlepas dari kendala tersebut, integrasi model yang dikonversi ke format *TensorFlow Lite* ke dalam aplikasi berbasis *React Native Expo* terbukti berhasil memungkinkan inferensi secara *real-time* pada perangkat seluler dengan efisiensi komputasi yang baik. Secara keseluruhan, prototipe ini membuktikan kelayakan teknis sistem penilaian otomatis sebagai solusi untuk mengurangi subjektivitas manusia dalam rantai pasok ekonomi sirkular, sekaligus memberikan landasan empiris mengenai pentingnya strategi penanganan data tidak seimbang (*class imbalance*) yang lebih agresif untuk pengembangan fitur diagnosa kerusakan di masa depan.

#### REFERENCES

- Cahyawati, A. N., Kusuma, L. T. W. N., & Ardianwiliandri, R. (2020). Integrasi Sistem Digital Bank Sampah Dengan Sistem Layanan Puskesmas Melalui Pendekatan Iot Platform. *Journal of Innovation and Applied Technology*, 6(2), 1081–1089. <https://doi.org/10.21776/ub.jiat.2020.006.02.11>
- Dianda, N., Rachman, A. S., & Yadhya, M. S. (2025). Identifikasi Citra Motif Kain Tenun Sumbawa (Kre Alang) Menggunakan Metode Convolutional Neural Network Arsitektur MobileNetV2. *Journal of Information System Research (JOSH)*, 6(2), 1225–1234. <https://doi.org/10.47065/josh.v6i2.6774>
- Ding, K., Niu, Z., Hui, J., Zhou, X., & Chan, F. T. S. (2022). A Weld Surface Defect Recognition Method Based on Improved MobileNetV2 Algorithm. *Mathematics*, 10(19), 3678. <https://doi.org/10.3390/math10193678>
- Dzaky, A. A., Zeniarja, J., Supriyanto, C., Shidik, G. F., Paramita, C., Subhiyakto, E. R., & Rakasiwi, S. (2024). Optimization Chatbot Services Based on DNN-Bert for Mental Health of University Students. *Journal of Applied Informatics and Computing*, 8(1), 13–21. <https://doi.org/10.30871/jaic.v8i1.7403>
- Gupta, J., Pathak, S., & Kumar, G. (2022). Deep Learning (CNN) and Transfer Learning: A Review. *Journal of Physics: Conference Series*, 2273(1), 012029. <https://doi.org/10.1088/1742-6596/2273/1/012029>
- Laine, E. (2022). *Neural Network Architectures for Mobile Device Screen Crack Detection* [Master's thesis, Aalto University]. <https://aaltdoc.aalto.fi/handle/123456789/115176>
- Ma, L., Lu, Y., Nan, X. F., Liu, Y. M., & Jiang, H. Q. (2018). Defect Detection of Mobile Phone Surface Based on Convolution Neural Network. *DEStech Transactions on Computer Science and Engineering*, (icmsie). <https://doi.org/10.12783/dtce/icmsie2017/18645>
- Magrini, C., Nicolas, J., Berg, H., Bellini, A., Paolini, E., Vincenti, N., Campadello, L., & Bonoli, A. (2021). Using Internet of Things and Distributed Ledger Technology for Digital Circular Economy Enablement: The Case of Electronic Equipment. *Sustainability*, 13(9), 4982. <https://doi.org/10.3390/su13094982>
- Mahendra, B. A., Supriyanto, C., Paramita, C., Safar, N. Z. B. M., & Dewi, I. N. (2025). Development of a Smartphone-Based Cataract Detection System Using YOLOv10x and Ionic Framework with a UI/UX Centric Approach. *2025 International Conference on Smart Computing, IoT and Machine Learning (SIML)*, 1–5. <https://doi.org/10.1109/SIML65326.2025.11081150>



- Nigam, S., Jha, R., & Singh, R. P. (2021). A different approach to the electronic waste handling – A review. *Materials Today: Proceedings*, 46, 1519–1525. <https://doi.org/10.1016/j.matpr.2021.01.081>
- Paminto, A. K., Lautetu, L. M., Prayoga, M. B. R., R, C. M., & Debora, D. D. (2024). Evaluasi Pengelolaan Limbah Elektronik di Indonesia. *Waste, Society and Sustainability*, 1(1), 1–22. <https://doi.org/10.61511/wass.v1i1.2024.462>
- Paramita, C., Supriyanto, C., Amalia, & Putra, K. R. (2024). Comparative Analysis of YOLOv5 and YOLOv8 Cigarette Detection in Social Media Content. *Scientific Journal of Informatics*, 11(2), 341–352. <https://doi.org/10.15294/sji.v11i2.2808>
- Paramita, C., Supriyanto, C., Šolić, P., Wada, C., & Dzaky, A. A. (2025). Performance Evaluation of YOLOv8 Models for Multi-Class Skin Lesion Detection from Dermoscopic Images. *2025 International Conference on Smart Computing, IoT and Machine Learning (SIML)*, 1–6. <https://doi.org/10.1109/SIML65326.2025.11080819>
- Prastita, D. A., Setiawan, A., & Ashari, I. F. (2025). Analisis Perbandingan Metode Convolutional Neural Network (CNN) untuk Deteksi Warna pada Objek. *Bulletin of Computer Science Research*, 5(4), 821–830. <https://doi.org/10.47065/bulletincsr.v5i4.617>
- Rahmatia, R., Sampetoding, E. A. M., & Pongtambang, Y. S. (2025). Kajian Literatur: Strategi Transformasi Digital Berbasis AI-Android untuk Efisiensi Daur Ulang Sampah Elektronik. *Jurnal Humaniora Teknologi*, 11(2), 81–91. <https://doi.org/10.34128/jht.v11i2.216>
- Rashidi, M. (2022). *Application of TensorFlow lite on embedded devices: A hands-on practice of TensorFlow model conversion to TensorFlow Lite model and its deployment on Smartphone to compare model's performance* [Bachelor's thesis, Mid Sweden University]. <https://urn.kb.se/resolve?urn=urn:nbn:se:miun:diva-46160>
- Rimantho, D. (2021). Pengelolaan limbah elektronika di DKI Jakarta menggunakan pendekatan Soft System Methodology. *Jurnal Pengelolaan Lingkungan Berkelanjutan (Journal of Environmental Sustainability Management)*, 4(3), 552–564. <https://doi.org/10.36813/jplb.4.3.552-564>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). *MobileNetV2: Inverted Residuals and Linear Bottlenecks*. 4510–4520. [https://openaccess.thecvf.com/content\\_cvpr\\_2018/html/Sandler\\_MobileNetV2\\_Inverted\\_Residuals\\_CVPR\\_2018\\_paper.html](https://openaccess.thecvf.com/content_cvpr_2018/html/Sandler_MobileNetV2_Inverted_Residuals_CVPR_2018_paper.html)
- Shahabuddin, M., Uddin, M. N., Chowdhury, J. I., Ahmed, S. F., Uddin, M. N., Mofijur, M., & Uddin, M. A. (2023). A review of the recent development, challenges, and opportunities of electronic waste (e-waste). *International Journal of Environmental Science and Technology*, 20(4), 4513–4520. <https://doi.org/10.1007/s13762-022-04274-w>
- Sharma, N. (2023, December 31). What is MobileNetV2? Features, Architecture, Application and More. *Analytics Vidhya*. <https://www.analyticsvidhya.com/blog/2023/12/what-is-mobilenetv2/>
- Thio, S. E., & Susilo, J. (2025). Identifikasi Pemilahan Sampah Berbasis Algoritma Transfer Learning CNN Menggunakan MobileNetV2 dan EfficientNetB0. *Bit-Tech*, 8(1), 25–32. <https://doi.org/10.32877/bt.v8i1.1900>
- Toyib, R., Affandi Mussa, A. P., Wijaya, A., & Sonita, A. (2025). Indonesian Sign System Introduction Application with Tensorflow Lite and Firebase Authentication. *Jurnal Teknik Informatika Dan Sistem Informasi*, 11(1), 31–48. <https://doi.org/10.28932/jutisi.v11i1.9678>
- Waluyo, D. E., Paramita, C., Kinasih, H. W., Pergiwati, D., & Rafrastara, F. A. (2024). Aplikasi Prediksi IHSG Berbasis Web Dengan Integrasi Multi-Algoritma. *Jurnal Informatika: Jurnal Pengembangan IT*, 9(2), 121–129. <https://doi.org/10.30591/jpit.v9i2.6193>