

Analisis Perbandingan Model Transfer Learning untuk Klasifikasi Bentuk Wajah pada Rekomendasi Bingkai Kacamata

Nanda Anis Fitria, Btari Mariska Purwaamijaya*, Rangga Gelar Guntara

Bisnis Digital, Universitas Pendidikan Indonesia, Tasikmalaya, Indonesia

Email: ¹nandaanis05@upi.edu, ^{2,*}btarimariska@upi.edu, ³ranggagelar@upi.edu

Email Penulis Korespondensi: btarimariska@upi.edu*

Submitted: 20/10/2025; Accepted: 07/11/2025; Published: 31/12/2025

Abstrak— Pemilihan bingkai kacamata yang sesuai dengan bentuk wajah masih menjadi tantangan, terutama dalam pembelian *online* yang tidak memungkinkan pengguna untuk mencoba produk secara langsung. Penelitian ini bertujuan menganalisis dan membandingkan performa beberapa arsitektur *transfer learning* berbasis *Convolutional Neural Network* (CNN) dalam klasifikasi bentuk wajah serta penerapannya pada sistem rekomendasi bingkai kacamata berbasis *knowledge-based recommender system*. Dataset yang digunakan diperoleh dari Kaggle dan terdiri atas 11.457 citra wajah yang terbagi ke dalam lima kelas bentuk wajah. Pendekatan yang digunakan dalam penelitian ini yaitu CRISP-DM yang meliputi tahapan *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment*. Empat arsitektur yang dibandingkan adalah MobileNetV2, MobileNetV3, DenseNet121, dan InceptionV3. Hasil penelitian menunjukkan bahwa MobileNetV2 memberikan akurasi terbaik sebesar 86,32% dengan konsistensi prediksi yang baik tanpa indikasi *overfitting*. Sistem rekomendasi yang dikembangkan mampu memberikan saran bingkai sesuai bentuk wajah pengguna berdasarkan *rule mapping*. Temuan ini menunjukkan bahwa MobileNetV2 merupakan arsitektur paling optimal dalam penelitian ini dan berpotensi dikembangkan lebih lanjut menjadi sistem rekomendasi *hybrid* yang mempertimbangkan preferensi pengguna serta diintegrasikan dengan fitur interaktif seperti *virtual try-on* berbasis *Augmented Reality* (AR) untuk meningkatkan pengalaman pengguna dalam pemilihan kacamata secara daring.

Kata Kunci: Transfer Learning; Convolutional Neural Network; Klasifikasi Wajah; Sistem Rekomendasi; Bingkai Kacamata

Abstract— Selecting eyeglass frames that match an individual's face shape remains challenging, especially in online shopping where users cannot try products physically. This study analyzes and compares the performance of four transfer learning architectures specifically MobileNetV2, MobileNetV3, DenseNet121, and InceptionV3 for face shape classification, and applies the results in a knowledge-based eyeglass recommendation system. The dataset, obtained from Kaggle, contains 11,457 facial images divided into five face shape classes. Using the CRISP-DM framework, the study covers business understanding, data preparation, modeling, evaluation, and deployment. Results show that MobileNetV2 achieves the highest accuracy of 86.32% with consistent predictions and no signs of overfitting. The developed recommendation system effectively provides frame suggestions through rule-based mapping. These findings indicate that MobileNetV2 is the most suitable architecture for this task and highlight its potential for further development into a hybrid system that incorporates user preferences and interactive features such as AR-based virtual try-on to enhance the online eyewear selection experience.

Keywords: Transfer Learning; Convolutional Neural Network (CNN); Face Shape Classification; Recommender System; Eyeglass Frame

1. PENDAHULUAN

Perkembangan teknologi digital dan pesatnya pertumbuhan *e-commerce* telah mendorong perubahan besar dalam perilaku belanja konsumen di berbagai sektor [1]. Namun, tren ini belum sepenuhnya diikuti oleh industri kacamata yang masih didominasi pembelian secara *offline*. Berdasarkan *Statista Market Forecast* (2025), sekitar 73,1% transaksi kacamata di Indonesia masih dilakukan secara *offline*, sedangkan pembelian *online* hanya 26,9% [2]. Padahal, pasar kacamata Indonesia diproyeksikan mencapai USD 195,77 juta pada tahun 2025 dengan rata-rata pertumbuhan sekitar 5,3% per tahun hingga 2030 [2]. Kondisi tersebut menunjukkan bahwa masih terdapat kendala yang dihadapi konsumen dalam proses pembelian kacamata secara *online*. Menurut Prabowo dkk., pembeli tidak dapat mencoba bingkai kacamata secara langsung sehingga sering kali mengalami kekecewaan ketika produk yang diterima tidak sesuai dengan harapan [3]. Salah satu solusi yang mulai dikembangkan adalah penerapan teknologi *Augmented Reality* (AR) yang memungkinkan pengguna mencoba kacamata secara virtual. Teknologi ini membantu pengguna memvisualisasikan tampilan kacamata secara langsung dan memberikan pengalaman interaktif dalam proses pemilihan produk [4].

Meskipun demikian, penerapan AR masih memiliki sejumlah keterbatasan diantaranya seperti ketergantungan pada pencahayaan dan kualitas kamera, serta belum mampu menilai kecocokan antara bentuk bingkai dan bentuk wajah pengguna secara objektif dan otomatis [5], [6]. Oleh karena itu, agar proses rekomendasi dapat dilakukan secara lebih akurat, diperlukan sistem yang tidak hanya menampilkan simulasi visual, tetapi juga dapat melakukan analisis bentuk wajah secara otomatis untuk menyesuaikan rekomendasi produk.

Dalam hal ini, penerapan *Artificial Intelligence* (AI) menjadi langkah penting, khususnya dengan metode *Convolutional Neural Network* (CNN). CNN memiliki kemampuan mengekstraksi ciri-ciri wajah secara otomatis dan melakukan klasifikasi bentuk wajah dengan tingkat akurasi yang tinggi [7], [8]. Dengan kemampuan tersebut, AI dapat melengkapi keterbatasan teknologi AR sehingga sistem rekomendasi kacamata dapat bersifat lebih personal dan efisien.

Namun demikian, berbagai penelitian sebelumnya menunjukkan bahwa model CNN yang digunakan masih belum optimal, baik dari segi akurasi maupun kemampuan generalisasi dalam sistem klasifikasi bentuk wajah dan rekomendasi bingkai kacamata. Sardjono dkk. menggunakan arsitektur InceptionV3 dengan akurasi pelatihan sebesar 96% dan akurasi validasi 78%, menunjukkan bahwa model masih belum mampu mengenali data baru secara optimal [9]. Hasil serupa juga ditemukan oleh Rifat dkk., yang menggunakan arsitektur InceptionV4 dan memperoleh akurasi pelatihan 91,77% serta akurasi pengujian 75,27% [10], menunjukkan bahwa peningkatan kompleksitas arsitektur belum secara signifikan meningkatkan kemampuan generalisasi model.

Penelitian berikutnya oleh Adityatama dan Putra kemudian mencoba pendekatan berbeda melalui arsitektur Xception yang memperoleh akurasi pelatihan 96,2% dan akurasi pengujian 85,1%, hasil ini menunjukkan peningkatan performa dibandingkan arsitektur Inception, namun model Xception masih tergolong kompleks dan memerlukan sumber daya komputasi yang tinggi [11]. Selanjutnya, Hidayatullah dkk. menerapkan arsitektur MobileNet sebagai model yang lebih ringan, tetapi akurasi yang diperoleh hanya sebesar 74% [12]. Sementara itu, Budianto dkk. mengombinasikan algoritma Viola–Jones dan CNN dan memperoleh akurasi sebesar 84,38%, meski cukup akurat, kombinasi tersebut belum efisien karena masih memerlukan dua tahap proses deteksi dan klasifikasi secara terpisah [13].

Temuan-temuan tersebut mengindikasikan bahwa meskipun berbagai pendekatan telah dilakukan, model CNN yang digunakan masih menghadapi tantangan dari segi generalisasi dan efisiensi komputasi. Sebagian besar penelitian menunjukkan gejala *overfitting*, yaitu performa tinggi pada data pelatihan namun menurun pada data pengujian[14]. Selain itu, arsitektur yang digunakan umumnya memiliki kompleksitas tinggi sehingga membutuhkan daya komputasi besar, yang membuatnya kurang sesuai untuk diimplementasikan pada platform berbasis web atau perangkat mobile dengan sumber daya terbatas.

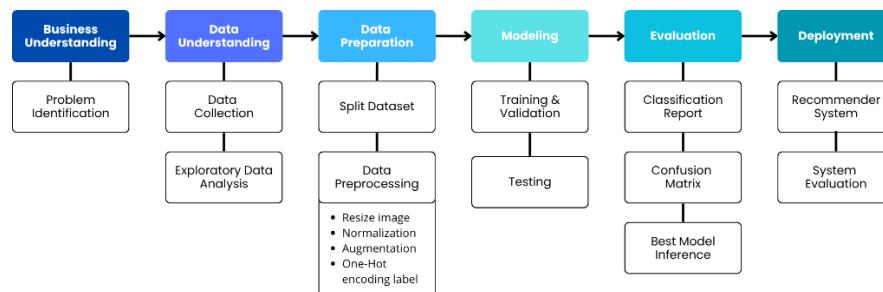
Permasalahan tersebut menegaskan pentingnya pemilihan arsitektur CNN yang tidak hanya akurat, tetapi juga efisien. Model ringan (*lightweight architecture*) seperti MobileNet memiliki potensi besar karena dirancang untuk efisiensi komputasi [15], namun performanya masih belum banyak dibandingkan secara sistematis dengan arsitektur *transfer learning* lain yang juga relatif ringan, seperti DenseNet121 dan InceptionV3.

Oleh karena itu, penelitian ini bertujuan untuk menganalisis dan membandingkan kinerja beberapa arsitektur *transfer learning* ringan yaitu MobileNetV2, MobileNetV3, DenseNet121, dan InceptionV3 dalam klasifikasi bentuk wajah sebagai dasar sistem rekomendasi bingkai kacamata. Penelitian ini berfokus pada dua pertanyaan utama yaitu: (1) bagaimana kinerja masing-masing arsitektur berdasarkan metrik akurasi, presisi, *recall*, dan F1-score; dan (2) arsitektur mana yang paling optimal untuk diimplementasikan pada sistem rekomendasi kacamata berbasis web dan mobile. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi teoretis berupa analisis komparatif terhadap efektivitas model *transfer learning* ringan dalam klasifikasi bentuk wajah, serta kontribusi praktis dalam pengembangan sistem rekomendasi bingkai kacamata yang efisien, akurat, dan mudah diintegrasikan pada platform digital seperti *website* maupun aplikasi *mobile*.

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Penelitian ini menggunakan pendekatan CRISP-DM (*Cross Industry Standard Process for Data Mining*) sebagai metodologi utama. Metode ini dirancang sebagai panduan sistematis dalam melakukan proses *data mining* untuk kebutuhan penelitian ataupun bisnis [16]. Enam langkah utama dalam penelitian ini ditunjukkan pada Gambar 2, yang sekaligus menggambarkan hubungan antar tahapan utama dari pemahaman masalah hingga implementasi model ke dalam sistem rekomendasi.



Gambar 2. Tahapan Penelitian

Gambar di atas memperlihatkan tahapan penelitian berdasarkan CRISP-DM. Adapun uraian dari setiap tahapan dijelaskan sebagai berikut:

1. *Business Understanding*

Tahap ini diawali dengan mengidentifikasi masalah dan tujuan penelitian. Permasalahan utama yang dihadapi adalah keterbatasan teknologi *Augmented Reality* (AR) yang masih bergantung pada kondisi pencahayaan, spesifikasi perangkat, serta belum mampu menilai kecocokan bentuk bingkai kacamata dengan bentuk wajah pengguna secara otomatis. Keterbatasan tersebut berdampak pada pengalaman pengguna yang kurang optimal, terutama dalam proses pemilihan bingkai kacamata secara *online*.

Untuk mengatasi permasalahan tersebut, penelitian ini mengadopsi pendekatan *Artificial Intelligence* (AI), khususnya *Convolutional Neural Network* (CNN), sebagai metode analisis citra wajah. Pendekatan ini dinilai mampu mengenali pola visual secara mendalam dan memberikan hasil yang lebih akurat dalam proses klasifikasi bentuk wajah [17]. Namun, penelitian sebelumnya menunjukkan bahwa hasil akurasi model masih belum maksimal, sementara kompleksitas arsitektur yang tinggi membuatnya kurang efisien untuk diterapkan pada perangkat mobile atau platform berbasis web.

Oleh karena itu, penelitian ini berfokus pada perbandingan empat arsitektur *transfer learning* yang dikenal ringan dan efisien, yaitu MobileNetV2, MobileNetV3, DenseNet121, dan InceptionV3. Pemilihan keempat model tersebut didasarkan pada karakteristik dan keunggulannya masing-masing. MobileNetV2 dirancang oleh Google dengan fokus pada efisiensi komputasi menggunakan *inverted residual* dan *linear bottleneck*, sehingga mampu mengurangi kompleksitas tanpa menurunkan akurasi secara signifikan. MobileNetV3 merupakan pengembangan dari MobileNetV2 dengan tambahan teknik *Neural Architecture Search (NAS)* dan blok *Squeeze-and-Excitation (SE)*, menjadikannya lebih ringan, lebih cepat, dan ideal untuk aplikasi *real-time* pada perangkat dengan sumber daya terbatas [18].

Sementara itu, DenseNet121 menggunakan konsep koneksi *dense*, di mana setiap lapisan terhubung langsung dengan semua lapisan sebelumnya. Pendekatan ini meningkatkan aliran informasi, mengurangi masalah *vanishing gradient*, serta meningkatkan efisiensi parameter. Adapun InceptionV3 dirancang untuk mencapai akurasi tinggi dengan efisiensi komputasi yang lebih baik melalui kombinasi kernel konvolusi dengan ukuran bervariasi dalam satu blok, sehingga mampu menangkap informasi dari berbagai skala fitur [18]. Dengan demikian, keempat arsitektur ini dipilih untuk dianalisis dan dibandingkan dalam konteks pengembangan sistem rekomendasi bingkai kacamata berbasis bentuk wajah, dengan tujuan menemukan model yang paling optimal dari segi akurasi dan efisiensi.

2. Data Understanding

Dataset diperoleh dari Kaggle, berisi 11.457 citra wajah yang diklasifikasikan ke dalam lima kelas bentuk wajah, yaitu square, oblong, oval, heart, dan round. Dataset ini juga telah dibagi ke dalam tiga subset dengan proporsi 87% untuk pelatihan, 8% untuk validasi, dan 4% untuk pengujian. Pembagian tersebut menunjukkan adanya ketidakseimbangan distribusi data karena sebagian besar dialokasikan untuk pelatihan, sehingga dapat memengaruhi stabilitas hasil evaluasi model. Oleh karena itu, pada tahap *Data Understanding* selanjutnya dilakukan *Exploratory Data Analysis (EDA)* untuk menganalisis kondisi dataset lebih lanjut.

3. Data Preparation

Pada tahapan ini, dataset diproses agar siap digunakan dalam pelatihan model CNN melalui beberapa langkah utama. Pertama, dataset di-split ulang menjadi 70% pelatihan, 15% validasi, dan 15% pengujian untuk memperoleh distribusi data yang lebih proporsional. Selanjutnya, seluruh gambar diubah ukurannya menjadi 128×128 piksel guna menyesuaikan kapasitas GPU dan RAM yang tersedia, sekaligus menjaga efisiensi komputasi tanpa menurunkan kualitas fitur visual yang penting.

Proses *pre-processing* kemudian dilakukan dengan normalisasi nilai piksel ke rentang 0–1 agar model lebih cepat berkonvergensi, serta augmentasi data menggunakan teknik *flip*, *rotasi*, dan penyesuaian *brightness* serta *contrast* untuk meningkatkan variasi data dan mengurangi risiko *overfitting*. Terakhir, label kelas wajah dikonversi menggunakan *one-hot encoding* agar setiap kelas memiliki representasi numerik yang setara pada tahap pelatihan model.

4. Modeling

Pada tahap ini, dilakukan pelatihan terhadap empat arsitektur *transfer learning* berbasis *Convolutional Neural Network* (CNN), yaitu MobileNetV2, MobileNetV3, DenseNet121, dan InceptionV3. Seluruh proses pelatihan dilakukan menggunakan lingkungan Google Colab dengan rincian pada Tabel 1.

Tabel 1. Spesifikasi Lingkungan Eksperimen

Komponen	Spesifikasi
Platform	Google Colab
GPU	NVIDIA Tesla T4 (15 GB VRAM)
RAM	12.7 GB
Disk	112.6 GB
Library	TensorFlow 2.19.0, Keras 3.10.0
Environment	Jupyter Notebook (Python 3)

5. Evaluation

Tahapan evaluasi dilakukan dengan menggunakan metrik akurasi, presisi, *recall*, *F1-score* dan *confusion matrix* untuk menilai performa tiap model. *True Positive* (TP) adalah prediksi benar pada kelas positif, *True Negative* (TN) adalah prediksi benar pada kelas negatif, *False Positive* (FP) adalah prediksi salah ketika model memprediksi positif, dan *False Negative* (FN) adalah prediksi salah ketika model memprediksi negatif. Adapun rumus evaluasi yang digunakan adalah sebagai berikut:

- Akurasi (*Accuracy*), untuk mengukur proporsi total prediksi yang benar dari keseluruhan data uji.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

- Presisi (*Precision*), untuk mengukur kualitas prediksi positif model. Presisi sangat penting untuk meminimalkan kesalahan prediksi atau *False Positive* (FP).

$$\text{Precision} = \frac{TP}{TP+FP} \quad (2)$$

- Recall*, untuk mengukur kelengkapan prediksi positif model. *Recall* penting untuk meminimalkan kegagalan model dalam mengenali bentuk wajah tertentu atau *False Negative* (FN).

$$\text{Recall} = \frac{TP}{TP+FN} \quad (3)$$

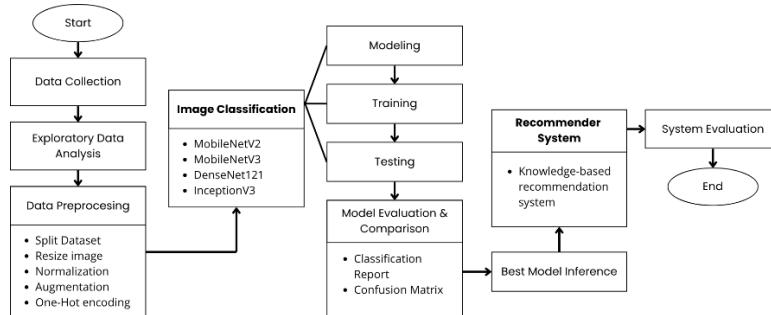
- F1-Score*, merupakan rata-rata antara Presisi dan *Recall*.

$$\text{F1 Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

6. Deployment

Model terbaik kemudian diintegrasikan ke dalam sistem rekomendasi berbasis *knowledge-based recommendation system*. Sistem ini memetakan hasil klasifikasi bentuk wajah ke kategori bingkai sesuai aturan yang telah ditentukan, dan selanjutnya diuji kembali melalui *inference* untuk memastikan kesesuaian rekomendasi dengan kebutuhan pengguna.

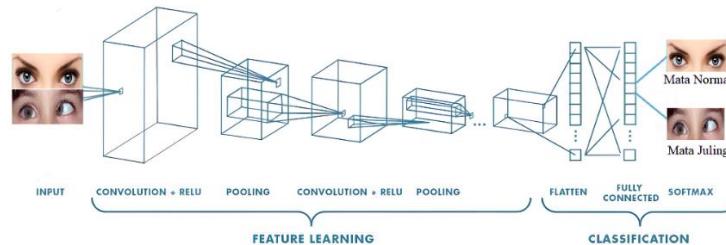
Selain tahapan CRISP-DM secara umum, penelitian ini juga memiliki alur penelitian yang lebih spesifik sebagaimana ditunjukkan pada Gambar 3, yang menggambarkan hubungan antar proses mulai dari *data collection* hingga integrasi model ke dalam sistem rekomendasi.



Gambar 3. Alur Penelitian

2.2 Convolutional Neural Network

Menurut Aggarwal, CNN adalah jenis jaringan saraf tiruan yang dirancang khusus untuk memproses data yang memiliki struktur grid seperti foto ataupun video [19]. CNN bekerja dengan mengekstraksi fitur dari data melalui beberapa lapisan utama, yaitu *convolution* untuk mengekstraksi fitur, *ReLU* sebagai fungsi aktivasi untuk mengubah nilai-nilai *feature map* pada jarak tertentu, *pooling* untuk mereduksi ukuran data, *flatten* untuk mengubah hasil ekstraksi menjadi nomor, *fully connected layer* untuk menggabungkan informasi, serta *softmax* untuk menghasilkan probabilitas kelas output [20]. Lapisan utama CNN dapat dilihat pada gambar di bawah ini:



Gambar 4. Arsitektur CNN [21]

2.3 Transfer Learning

Transfer learning merupakan pendekatan di mana pengetahuan dari model yang telah dilatih pada tugas besar sebelumnya digunakan untuk menyelesaikan tugas baru dengan data terbatas [22]. Pendekatan ini memungkinkan

model belajar lebih cepat dan akurat meskipun jumlah data baru terbatas [23]. Dalam penelitian ini, akan digunakan beberapa model *transfer learning* berbasis CNN yang ringan dan mudah diimplementasikan ke dalam web atau aplikasi mobile, yaitu MobileNetV2, MobileNetV3, DenseNet121, dan InceptionV3 [18].

2.4 Sistem Rekomendasi

Sistem rekomendasi merupakan sistem yang membantu pengguna menemukan item sesuai kebutuhannya. Salah satu pendekatan yang digunakan adalah *knowledge-based recommendation system*, yaitu metode yang memanfaatkan aturan dan basis pengetahuan untuk mencocokkan kebutuhan pengguna dengan atribut item [24]. Dalam penelitian ini, sistem rekomendasi akan menyesuaikan bentuk bingkai dengan bentuk wajah berdasarkan aturan yang telah ditentukan. Hal ini sejalan dengan penelitian Thangavel yang menunjukkan bahwa sistem rekomendasi bingkai kacamata berbasis aturan dapat mencocokkan atribut wajah dengan bingkai dalam katalog produk, sehingga rekomendasi menjadi lebih spesifik meskipun sangat bergantung pada kelengkapan basis pengetahuan yang digunakan [25].

3. HASIL DAN PEMBAHASAN

3.1 Data Understanding

Untuk mengetahui kondisi awal dataset, dilakukan *Exploratory data analysis* yang terbagi ke dalam beberapa proses yaitu:

- Melihat distribusi data pada setiap kategori

Analisis distribusi ini dilakukan untuk melihat kemungkinan *imbalance* pada dataset yang bisa berpotensi pada adanya bias dalam proses pelatihan. Kondisi awal distribusi dataset disajikan dalam tabel 1.

Tabel 2. Distribusi dataset

Kelas	Pelatihan	Validasi	Pengujian	Total
Square	2045	219	99	2363
Oblong	1662	149	92	1903
Oval	2106	188	105	2399
Heart	2112	202	89	2403
Round	2091	205	93	2389
Total	10,016	963	478	11,457

Berdasarkan tabel di atas, terlihat bahwa pembagian dataset pada subkategori kurang ideal karena sebagian besar data dialokasikan untuk pelatihan (87%), sedangkan validasi hanya 8% dan pengujian 4%. Jumlah data validasi dan pengujian yang kecil dapat menyebabkan pengukuran performa model menjadi kurang kuat dan kurang stabil [26].

- Melihat contoh gambar pada dataset

Dilakukan untuk memahami karakteristik visual pada dataset, mendeteksi kemungkinan adanya kesalahan serta menentukan strategi *pre-processing* yang sesuai sebelum tahap pemodelan.



Gambar 5. Contoh gambar pada dataset

Gambar di atas memperlihatkan bahwa data memiliki keragaman kecerahan dan kontras sehingga diperlukan proses *pre-processing* seperti normalisasi dan augmentasi untuk menyamakan kualitas citra serta meningkatkan kemampuan model dalam mengenali pola secara konsisten.

- Dimensi Awal Gambar

Dimensi asli gambar pada dataset gambar 640 x 640 piksel. Ukuran ini sebenarnya sudah seragam, tetapi terlalu besar jika langsung digunakan untuk pelatihan model CNN karena akan memakan banyak memori dan waktu komputasi.

3.2 Data Preparation

3.2.1 Split Dataset

Berdasarkan hasil eksplorasi awal (EDA), dataset bentuk wajah menunjukkan adanya ketidakseimbangan jumlah gambar antar subkategori. Untuk mengatasi hal tersebut, dataset kemudian dibagi ulang ke dalam tiga sub kategori dengan proporsi 70% untuk pelatihan, 15% untuk validasi, dan 15% untuk pengujian. Dengan pembagian ulang ini, distribusi data menjadi lebih proporsional sehingga model dapat belajar secara lebih adil dari tiap kelas dan hasil evaluasi lebih objektif.

Tabel 3. Distribusi dataset setelah *re-split*

Kelas	Pelatihan	Validasi	Pengujian	Total
Square	1654	354	355	2363
Oblong	1332	285	286	1903
Oval	1679	360	360	2399
Heart	1682	361	360	2403
Round	1672	359	358	2389
Total	8,019	1,719	1,719	11,457

3.2.2 Data Preprocessing

Sebelum digunakan untuk pelatihan, dataset melalui beberapa tahapan *preprocessing* agar lebih sesuai dengan kebutuhan CNN diantaranya:

- Resize* Gambar, proses ini dilakukan untuk mengubah dimensi gambar dari 640x640 piksel menjadi 128x128 piksel karena dimensi asli gambar pada dataset terlalu besar untuk diproses langsung oleh CNN.
- Normalisasi Piksel, untuk memastikan model bisa belajar dengan stabil, nilai piksel pada gambar asli yang semula 0–255 akan dinormalisasi ke rentang 0-1.
- Augmentasi Data, untuk memperbanyak variasi data, khususnya pada *train* set, diterapkan augmentasi secara acak. Beberapa augmentasi yang digunakan antara lain *flip horizontal* dan *vertical*, rotasi 90°–270°, penyesuaian kecerahan, dan kontras. Augmentasi ini membuat dataset lebih beragam dan membantu mengurangi risiko *overfitting*.
- One-Hot Encoding* Label, awalnya label kelas ditulis pakai angka, yaitu 0 = Square, 1 = Oblong, 2 = Oval, 3 = Heart, 4 = Round. Supaya model lebih mudah belajar, label ini diubah ke bentuk *one-hot encoding* [27], seperti berikut: Square (0) menjadi [1, 0, 0, 0, 0]; Oblong (1) menjadi [0, 1, 0, 0, 0]; Oval (2) menjadi [0, 0, 1, 0, 0]; Heart (3) menjadi [0, 0, 0, 1, 0]; Round (4) menjadi [0, 0, 0, 0, 1].

3.3 Modeling

Pada tahap ini, peneliti menggunakan empat arsitektur *transfer learning* yaitu MobileNetV2, MobileNetV3, DenseNet121, dan InceptionV3, adapun jumlah parameter dari setiap model disajikan dalam tabel 4.

Tabel 4. Jumlah parameter setiap model

Arsitektur	Total Params	Trainable Params	Non-trainable Params
MobileNetV2	2,592,325	1,537,861	1,054,464
MobileNetV3	3,247,493	1,202,421	2,045,072
DenseNet121	7,305,285	632,901	6,672,384
InceptionV3	22,336,805	2,465,285	19,871,520

Kemudian, masing-masing arsitektur disesuaikan dengan kebutuhan penelitian dan dilatih menggunakan konfigurasi *hyperparameter* tertentu. Parameter yang digunakan dalam penelitian ini disajikan pada Tabel berikut.

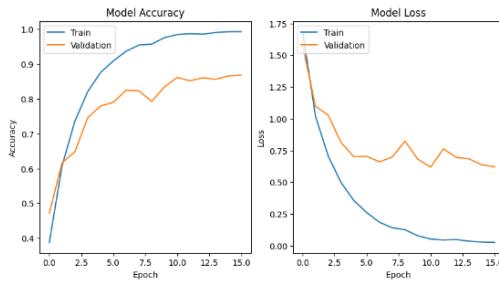
Tabel 5. Hyperparameter

Parameter	Nilai
<i>Input size</i>	128 piksel
<i>Batch size</i>	32
<i>Epochs</i>	30
<i>Optimizer</i>	<i>Adaptive Moment Estimation</i> (Adam)
<i>Learning rate</i>	0.0001
<i>Loss function</i>	Categorical Crossentropy
<i>Dropout rate</i>	0.4
<i>Callbacks</i>	EarlyStopping, ReduceLROnPlateau

3.3.1 Training dan Validation

a. MobileNetV2

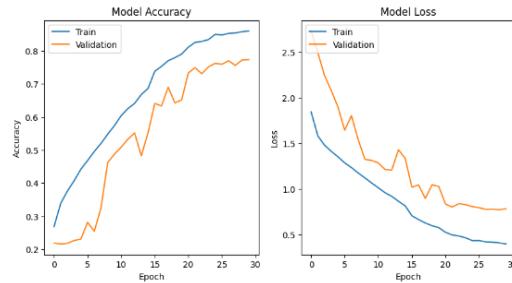
Pada tahap pelatihan, MobileNetV2 menunjukkan proses belajar yang cepat dan stabil. Akurasi pelatihan meningkat hingga 99,27% dengan *loss* 0,0287, sedangkan akurasi validasi mencapai 87,80% dengan *loss* 0,5215. Model mampu mengenali pola wajah secara stabil meskipun terdapat perbedaan yang cukup besar antara data pelatihan dan validasi. Pelatihan dihentikan pada *epoch* ke-18 karena tidak ada peningkatan signifikan pada akurasi validasi, sehingga digunakan *early stopping* untuk mencegah *overfitting*.



Gambar 6. Akurasi dan *Loss* pada Pelatihan dan Validasi MobileNetV2

b. MobileNetV3

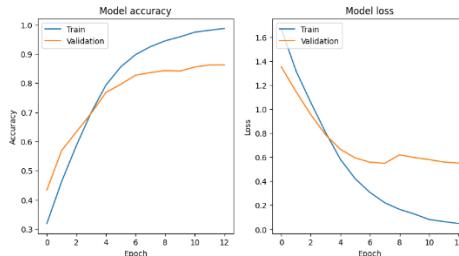
Pada tahap pelatihan, MobileNetV3 menunjukkan peningkatan akurasi pelatihan yang lebih lambat dibandingkan MobileNetV2, dengan akurasi akhir 86,01% dan *loss* 0,4024. Akurasi pada data validasi hanya mencapai 77,35% dengan *loss* 0,7829. Hal ini menunjukkan bahwa model mengalami kesulitan dalam belajar dari dataset dan kurang mampu mengenali pola wajah secara optimal. Pelatihan selesai dijalankan hingga *epoch* ke-30 untuk memastikan model mendapatkan kesempatan belajar penuh dari data, meskipun peningkatan akurasi validasi mulai melambat dan stagnan.



Gambar 7. Akurasi dan *Loss* pada Pelatihan dan Validasi MobileNetV3

c. DenseNet121

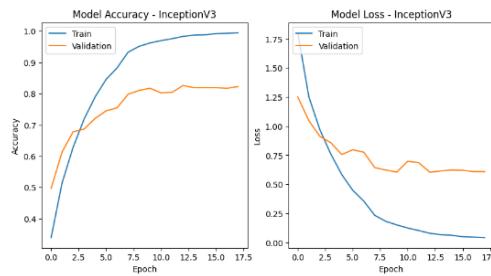
Pada tahap pelatihan, DenseNet121 menunjukkan proses belajar yang cukup baik. Akurasi pelatihan mencapai 98,65% dengan *loss* 0,0489, sedangkan akurasi validasi berada di 86,24% dengan *loss* 0,5515. Pelatihan dihentikan pada *epoch* ke-13 menggunakan *early stopping* karena akurasi validasi tidak menunjukkan peningkatan yang signifikan.



Gambar 8. Akurasi dan *Loss* pada Pelatihan dan Validasi DenseNet121

d. InceptionV3

Pada tahap pelatihan, InceptionV3 menunjukkan kemampuan belajar yang tinggi pada data pelatihan. Akurasi pelatihan mencapai 99,53% dengan *loss* 0,0418, sedangkan akurasi validasi berada di 82,23% dengan *loss* 0,6093. Pelatihan dihentikan pada *epoch* ke-18 menggunakan *early stopping* karena akurasi validasi stagnan dan menunjukkan indikasi *overfitting*.



Gambar 9. Akurasi dan *Loss* pada Pelatihan dan Validasi InceptionV3

3.3.2 Testing

Setelah proses pelatihan selesai, model diuji menggunakan dataset pengujian yang sebelumnya tidak digunakan pada pelatihan maupun validasi. Tujuan dari tahap pengujian adalah untuk mengetahui performa masing-masing model ketika menghadapi data baru. Berikut hasil pengujian untuk masing-masing model:

Tabel 6. Hasil pengujian model

Model	Akurasi Pengujian	Loss
MobileNetV2	0.8632	0.5220
MobileNetV3	0.7719	0.7274
DenseNet121	0.8412	0.5529
InceptionV3	0.8386	0.5367

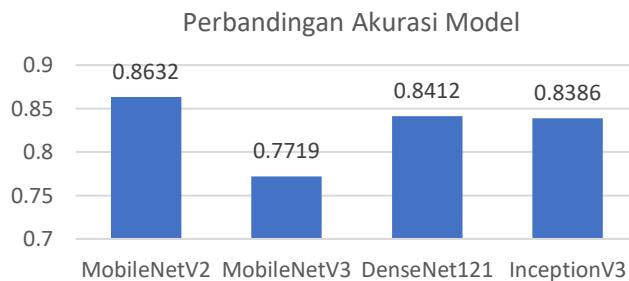
Dari tabel tersebut, terlihat bahwa masing-masing model memiliki performa berbeda dalam mengenali bentuk wajah pada dataset pengujian. Akurasi pengujian menunjukkan seberapa baik model mengklasifikasikan citra dengan benar, sedangkan *Loss* menunjukkan gambaran kesalahan prediksi model pada data baru.

3.4 Evaluation

Setelah seluruh model selesai dilatih dan diuji, performa dievaluasi menggunakan metrik *precision*, *recall*, dan *F1-score*, serta akurasi pada data pelatihan, validasi, dan pengujian.

Tabel 7. Classification Report (ringkasan rata-rata per model)

Model	Akurasi Pelatihan	Akurasi Validasi	Akurasi Pengujian	Precision (avg)	Recall (avg)	F1-score (avg)
MobileNetV2	0.9927	0.8780	0.8632	0.86	0.86	0.86
MobileNetV3	0.8601	0.7735	0.7719	0.78	0.77	0.77
DenseNet121	0.9865	0.8624	0.8412	0.84	0.84	0.84
InceptionV3	0.9953	0.8223	0.8386	0.84	0.84	0.84



Gambar 10. Perbandingan Akurasi Model

Tabel 7 menampilkan ringkasan metrik evaluasi dari keempat arsitektur yang dibandingkan, meliputi akurasi pada data pelatihan, validasi, dan pengujian, serta nilai rata-rata *precision*, *recall*, dan *F1-score*. Hasil menunjukkan bahwa MobileNetV2 memiliki performa terbaik dengan nilai *precision*, *recall*, dan *F1-score* yang seimbang, serta akurasi pengujian tertinggi sebesar 0,8632. Model ini menunjukkan keseimbangan antara kemampuan belajar dan kemampuan generalisasi, menandakan bahwa model tidak mengalami *overfitting* secara signifikan.

Visualisasi pada Gambar 10 memperlihatkan perbandingan akurasi antar model. Terlihat bahwa MobileNetV2 secara konsisten unggul dalam hal akurasi yang diikuti oleh DenseNet121 dan InceptionV3 dengan performa yang relatif mirip, sedangkan MobileNetV3 menempati posisi terendah.

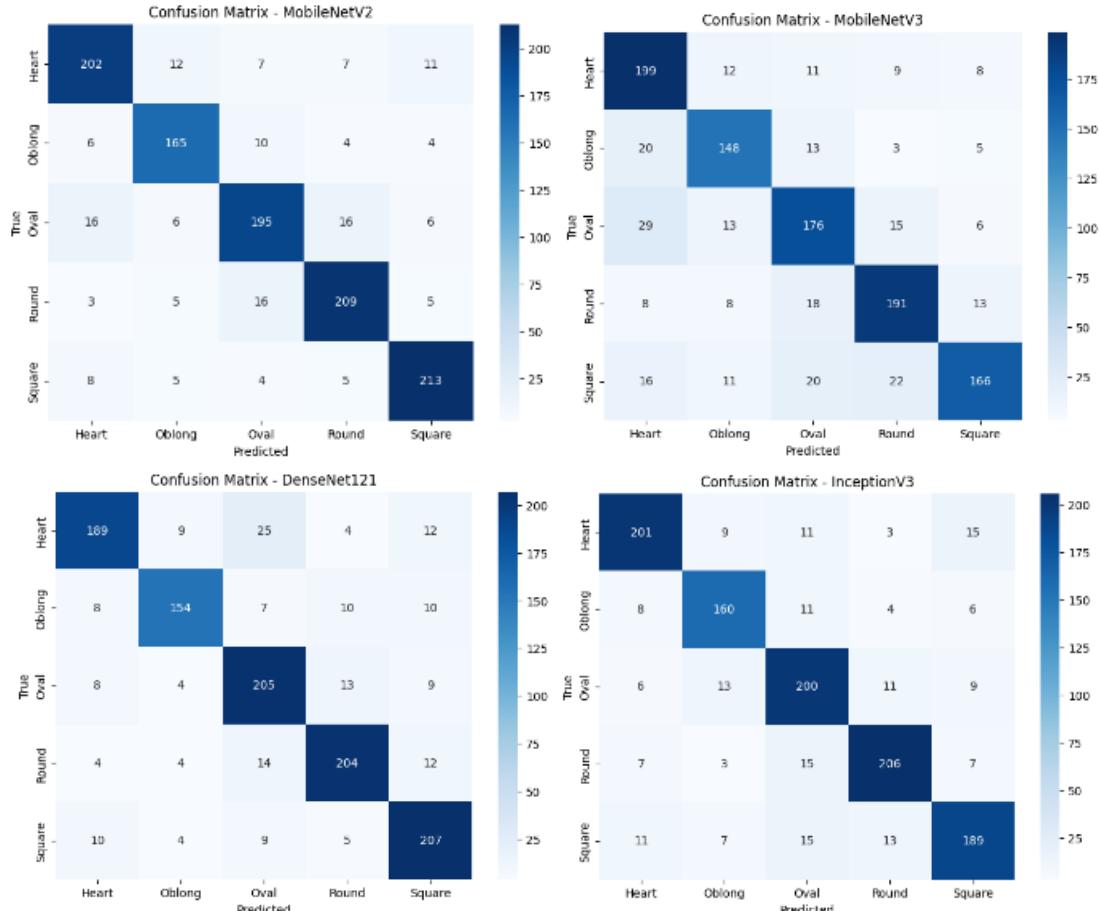
Keunggulan MobileNetV2 didapatkan dari arsitekturnya yang menggabungkan *depthwise separable convolution*, *inverted residual*, dan *linear bottleneck*, memungkinkan proses ekstraksi fitur yang efisien dengan jumlah parameter yang relatif kecil. Pendekatan ini mengurangi kompleksitas komputasi tanpa mengorbankan akurasi secara signifikan. Sebaliknya, DenseNet121 dan InceptionV3 memiliki jumlah parameter jauh lebih besar, sehingga meskipun mampu menghasilkan representasi fitur kompleks, keduanya memerlukan sumber daya komputasi lebih besar dan cenderung berisiko mengalami *overfitting* pada dataset terbatas seperti pada penelitian ini.

Sementara itu, MobileNetV3, yang sebenarnya merupakan pengembangan dari MobileNetV2 dengan tambahan blok *Squeeze-and-Excitation (SE)* dan *Neural Architecture Search (NAS)*, menunjukkan akurasi lebih rendah karena desainnya dioptimalkan untuk efisiensi ekstrem pada perangkat seluler. Akibatnya, beberapa detail fitur penting dari citra wajah berpotensi tidak terpelajari secara optimal.

Berdasarkan hal tersebut, dapat disimpulkan adanya *trade-off* antara akurasi dan kompleksitas model. Model besar seperti InceptionV3 dan DenseNet121 memiliki kapasitas tinggi tetapi lebih berat dan berpotensi *overfitting*,

sedangkan model yang terlalu ringan seperti MobileNetV3 lebih cepat namun kehilangan ketepatan. MobileNetV2 menempati posisi ideal dengan keseimbangan terbaik antara akurasi dan efisiensi, menjadikannya model paling optimal untuk klasifikasi bentuk wajah pada penelitian ini.

Untuk memahami lebih lanjut pola kesalahan dan distribusi prediksi antar kelas, evaluasi berikutnya dilakukan menggunakan confusion matrix.



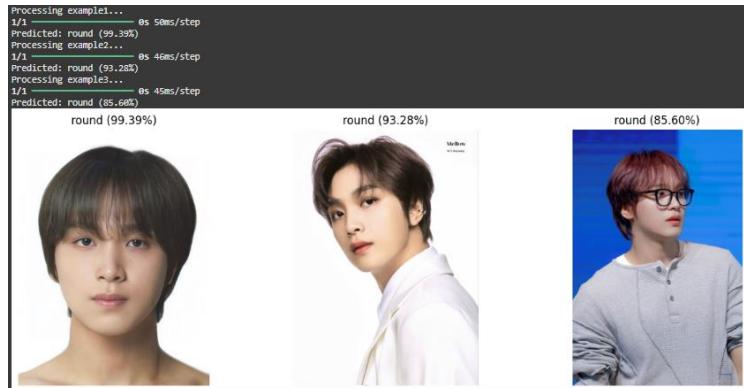
Gambar 11. Confusion Matrix

Berdasarkan Gambar 11, yang menampilkan *confusion matrix* untuk keempat arsitektur, dapat diamati distribusi prediksi benar dan salah pada setiap kelas bentuk wajah. MobileNetV2 menunjukkan diagonal utama dengan nilai tertinggi dan distribusi kesalahan paling kecil dibandingkan model lainnya, menandakan performa klasifikasi yang paling stabil di seluruh kelas. Kelas *Round* dan *Square* merupakan kategori yang paling mudah dikenali oleh semua model, dengan jumlah prediksi benar mencapai lebih dari 200 sampel, terutama pada MobileNetV2 dan DenseNet121. Hal ini menunjukkan bahwa fitur visual pada kedua bentuk wajah tersebut memiliki karakteristik yang lebih tegas dan mudah dibedakan, seperti kontur rahang dan proporsi wajah yang khas.

Sebaliknya, kesalahan klasifikasi paling banyak terjadi antara kelas *Oval* dan *Heart*, yang memiliki kemiripan struktur wajah bagian bawah, sehingga beberapa model terutama MobileNetV3 dan InceptionV3 cenderung salah mengklasifikasikan keduanya. Kelas *Oblong* juga menunjukkan tingkat kesalahan relatif tinggi pada MobileNetV3, karena ciri bentuk wajah ini lebih halus dan sulit dibedakan dari kelas lain, sehingga model kurang mampu menangkap perbedaannya secara konsisten.

Secara keseluruhan, MobileNetV2 memiliki distribusi prediksi benar paling merata antar kelas dan kesalahan paling sedikit pada kategori serupa, memperkuat hasil evaluasi kuantitatif sebelumnya bahwa model ini mencapai keseimbangan terbaik antara akurasi dan efisiensi komputasi. Hasil ini menjadi dasar pemilihan MobileNetV2 sebagai model utama untuk tahap implementasi sistem rekomendasi bingkai kacamata pada penelitian ini.

Berdasarkan temuan tersebut, tahap berikutnya adalah *inference*, yaitu menguji model terbaik (MobileNetV2) pada data baru untuk melihat bagaimana performanya ketika diterapkan pada kasus nyata. Hasil yang ditampilkan pada Gambar 12 menunjukkan bahwa model mampu mengklasifikasikan bentuk wajah dengan tingkat kepercayaan yang konsisten. Ketiga contoh yang digunakan dikategorikan sebagai bentuk wajah *round*, dengan probabilitas prediksi masing-masing sebesar 99,39%, 93,28%, dan 85,60%.



Gambar 12. Hasil inference

Konsistensi nilai prediksi ini memperlihatkan bahwa model tetap mampu melakukan klasifikasi dengan baik meskipun terdapat variasi pada kondisi gambar, seperti sudut pengambilan wajah, pencahayaan, maupun keberadaan aksesoris, misalnya kacamata. Hal ini membuktikan bahwa MobileNetV2 tidak hanya unggul pada evaluasi berbasis metrik kuantitatif, tetapi juga memiliki kemampuan generalisasi yang kuat ketika dihadapkan pada data yang benar-benar baru pada tahap *inference*.

3.5 Deployment

Tahap *deployment* dilakukan dengan cara mengimplementasikan model klasifikasi bentuk wajah ke dalam sebuah *recommender system*. Sistem ini dibangun menggunakan pendekatan *knowledge-based recommender system*, di mana hasil prediksi model mengenai bentuk wajah pengguna dihubungkan dengan aturan pemetaan (*rule mapping*) yang telah ditentukan sebelumnya [24]. Aturan ini disusun berdasarkan panduan pemilihan kacamata yang disesuaikan dengan penelitian rifat dkk. yang juga memberikan rekomendasi kategori bingkai kacamata sesuai dengan tipe wajah [10].

Tabel 8. Rule mapping

Bentuk Wajah	Rekomendasi Frame	Contoh Frame
Heart	Round, Square, Cateye	
Oblong	Rectangle, Square, Aviator	
Oval	Aviator, Geometric, Rectangle	
Round	Rectangle, Square, Cateye	
Square	Aviator, Round, Cateye	

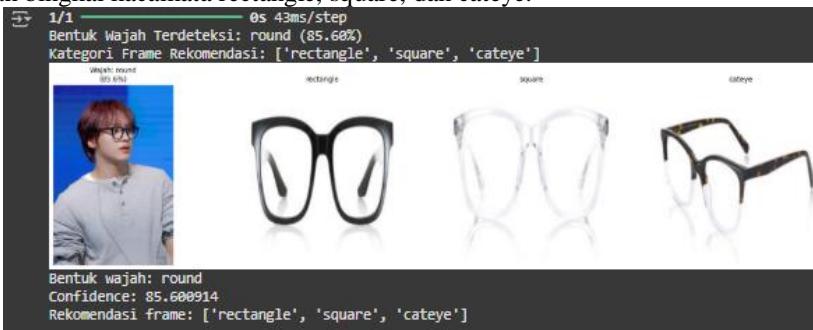
Implementasi sistem dilakukan dalam tiga tahap utama. Pertama, model klasifikasi mendeteksi bentuk wajah dari citra *input*. Kedua, hasil klasifikasi dicocokkan dengan *rule mapping* untuk menentukan kategori bingkai kacamata yang relevan. Ketiga, sistem menampilkan rekomendasi berupa daftar tipe bingkai kacamata yang sesuai, dilengkapi dengan contoh visualisasi dari dataset, sehingga pengguna memperoleh gambaran nyata mengenai model kacamata yang disarankan.

Selanjutnya untuk menguji kinerja sistem, dilakukan pengujian menggunakan beberapa citra wajah berbeda. Pada pengujian pertama, sistem menerima *input* gambar dan mendeteksi wajah berbentuk square dengan probabilitas deteksi 80,6%, dan menghasilkan rekomendasi berupa round, aviator, dan cateye sesuai *rule mapping*.



Gambar 13. Hasil pengujian 1

Pengujian kedua mendeteksi wajah berbentuk *round* dengan probabilitas deteksi 85,60%, dan sistem merekomendasikan bingkai kacamata rectangle, square, dan cateye.



Gambar 12. Hasil pengujian 2

Hasil *inference* di atas menunjukkan bahwa sistem mampu mengidentifikasi bentuk wajah dengan cukup baik serta memberikan rekomendasi bingkai kacamata yang konsisten dengan *rule mapping* yang ditetapkan, sehingga menunjukkan bahwa *deployment* berhasil berjalan sesuai tujuan penelitian.

3.6 Pembahasan

Hasil penelitian menunjukkan bahwa arsitektur MobileNetV2 merupakan model dengan performa terbaik dalam klasifikasi lima bentuk wajah. Model ini mencapai akurasi sebesar 86,32% dengan nilai *precision*, *recall*, dan *F1-score* rata-rata 0,86. Performa tersebut konsisten pada data pelatihan, validasi, dan pengujian, sehingga tidak menunjukkan indikasi *overfitting* yang signifikan. Keunggulan ini menunjukkan bahwa mekanisme *inverted residual* dan *linear bottleneck* yang diterapkan pada MobileNetV2 berhasil meningkatkan efisiensi representasi fitur tanpa mengorbankan akurasi [15]. Jika dibandingkan dengan penelitian terdahulu, hasil yang diperoleh menunjukkan peningkatan baik dari sisi akurasi maupun stabilitas model. Dalam penelitian Sardjono dkk. dan Rifat dkk., arsitektur InceptionV3 dan InceptionV4 memang mampu menghasilkan akurasi tinggi pada data pelatihan, namun memiliki kesenjangan besar antara akurasi pelatihan dan pengujian akibat kompleksitas model yang tinggi [9], [10]. Sebaliknya, MobileNetV2 dengan jumlah parameter yang jauh lebih sedikit menunjukkan keseimbangan lebih baik antara akurasi dan efisiensi komputasi. Sementara itu, penelitian Adityatama dan Putra (2023) menggunakan arsitektur Xception dan berhasil mencapai akurasi pengujian sebesar 85,1%, menunjukkan performa yang sangat baik. Namun demikian, model tersebut masih memiliki kompleksitas yang lebih tinggi dibandingkan MobileNetV2, sehingga memerlukan sumber daya komputasi yang lebih besar untuk mencapai performa serupa [11]. Temuan ini juga konsisten dengan studi Hidayatullah dkk. [12], yang menunjukkan bahwa MobileNet generasi awal memiliki keterbatasan dalam mengenali variasi bentuk wajah yang kompleks, sementara versi V2 memberikan peningkatan signifikan dalam kecepatan dan akurasi.

Kemudian, apabila dibandingkan dengan pendekatan klasik seperti Viola–Jones yang dikombinasikan dengan CNN oleh Budianto dkk. [13], MobileNetV2 terbukti lebih efektif dalam mengekstraksi karakteristik bentuk wajah yang halus, seperti kontur rahang dan proporsi wajah, tanpa memerlukan dua tahap proses deteksi dan klasifikasi secara terpisah. Dengan demikian, penelitian ini menegaskan bahwa MobileNetV2 menawarkan keseimbangan optimal antara akurasi, efisiensi, dan kemampuan generalisasi, menjadikannya pilihan paling relevan untuk diimplementasikan pada sistem rekomendasi bingkai kacamata berbasis *web* maupun aplikasi *mobile*.

4. KESIMPULAN

Penelitian ini berhasil menunjukkan bahwa arsitektur MobileNetV2 merupakan model paling optimal dalam klasifikasi lima bentuk wajah, dengan akurasi pengujian mencapai 86,32% serta nilai *precision*, *recall*, dan *F1-score* rata-rata 0,86. Keunggulan model ini tidak hanya terletak pada tingkat akurasi yang tinggi, tetapi juga pada kemampuannya mempertahankan stabilitas performa di berbagai tahap pelatihan tanpa indikasi *overfitting* yang signifikan. Secara ilmiah, temuan ini memperkuat pemahaman bahwa pendekatan *lightweight convolutional*

network seperti MobileNetV2 dapat mencapai keseimbangan ideal antara efisiensi komputasi dan kemampuan generalisasi, bahkan dalam domain klasifikasi citra kompleks seperti bentuk wajah. Kontribusi ilmiah utama dari penelitian ini adalah penerapan dan pembuktian efektivitas arsitektur MobileNetV2 dalam konteks sistem rekomendasi berbasis bentuk wajah, yang sebelumnya masih jarang dieksplorasi secara mendalam. Hasil penelitian ini juga memperluas literatur terkait *transfer learning* pada domain *face shape classification*, dengan menegaskan bahwa arsitektur ringan mampu menandingi bahkan melampaui performa model besar seperti InceptionV3, InceptionV4, dan Xception. Selain itu, integrasi pendekatan berbasis *knowledge-based recommender system* menjadikan penelitian ini sebagai contoh penerapan nyata kecerdasan buatan dalam sistem personalisasi produk berbasis visual. Dari sisi praktis, model yang dihasilkan memiliki potensi tinggi untuk diimplementasikan pada aplikasi *web* atau *mobile* yang memberikan rekomendasi bingkai kacamata secara otomatis berdasarkan bentuk wajah pengguna. Pendekatan ini dapat meningkatkan pengalaman pengguna, mengurangi ketidakpastian dalam pembelian *online*, serta membuka peluang penerapan pada sektor lain seperti ritel fesyen hingga tata rias. Penelitian ini dapat dikembangkan lebih lanjut melalui penerapan *hybrid system* yang menggabungkan *knowledge-based* dengan algoritma sistem rekomendasi lain seperti *content-based* ataupun *collaborative*. Selain itu, integrasi dengan teknologi *Augmented Reality* (AR) juga dapat menjadi inovasi berikutnya untuk memberikan pengalaman *virtual try-on* yang lebih interaktif dan realistik bagi pengguna. Penelitian selanjutnya juga dapat mengeksplorasi adaptasi model pada data tiga dimensi atau menerapkan *multi-task learning* agar sistem tidak hanya mengenali bentuk wajah, tetapi juga menganalisis atribut estetika lainnya, seperti warna kulit dan gaya pribadi.

REFERENCES

- [1] M. T. Faisal and M. I. Fasa, "Transformasi digital: Peran e-commerce dalam pertumbuhan ekonomi digital di Indonesia," *Jurnal Media Akademik (JMA)*, vol. 3, no. 4, Apr. 2025, doi: 10.62281/e0ae0685.
- [2] "Eyewear - Indonesia | Statista Market Forecast," *Statista*. Accessed: Sept. 29, 2025. [Online]. Available: <http://frontend.xmo.prod.aws.statista.com/outlook/cmo/eyewear/indonesia>
- [3] I. Prabowo, M. Fakhriza, and M. D. Irawan, "The effect of augmented reality on glasses purchasing decisions using the structural equation model method," *Journal of Informatics and Telecommunication Engineering*, vol. 7, no. 1, pp. 257–270, July 2023, doi: 10.31289/jite.v7i1.10084.
- [4] M. C. Wibowo, *Kekuatan AR (Augmented Reality) dan VR (Virtual Reality) dalam Bisnis*. Semarang: Yayasan Prima Agus Teknik bekerja sama dengan Universitas Sains dan Teknologi Komputer (Universitas STEKOM), 2023. ISBN: 978-623-8642-63-2. Accessed: Nov. 3, 2025. [Online]. Available: <https://penerbit.stekom.ac.id/index.php/yayasanpat/article/view/555/581>
- [5] V. Valensia and K. Kurniabudi, "Pemanfaatan media sosial berbasis AR untuk mengidentifikasi dalam pemilihan bingkai kacamata pada toko kacamata Idri," *Jurnal Manajemen Sistem Informasi*, vol. 8, no. 3, pp. 555–567, Oct. 2023, doi: 10.33998/jurnalmssi.2023.8.3.1490.
- [6] T. Abdulghani and R. M. Sembada, "Pemanfaatan teknologi augmented reality untuk memilih model kacamata di Central Optikal 165 dengan menggunakan metode markerless berbasis Android," *MJI*, vol. 13, no. 1, p. 36, June 2021, doi: 10.35194/mji.v13i1.1299.
- [7] D. Riswan, H. E. R. Putra, and R. N. Saputra, "Pengembangan sistem rekomendasi berbasis kecerdasan buatan untuk meningkatkan pengalaman pengguna di platform e-commerce," *Jurnal Komputer Teknologi Informasi Sistem Informasi (JUKTISI)*, vol. 2, no. 3, pp. 572–580, Feb. 2024, doi: 10.62712/juktisi.v2i3.145.
- [8] S. A. E. Albakia and R. A. Saputra, "Identifikasi jenis daun tanaman obat menggunakan metode convolutional neural network (CNN) dengan model VGG16," *Jurnal Informatika Polinema*, vol. 9, no. 4, pp. 451–460, Aug. 2023, doi: 10.33795/jip.v9i4.1420.
- [9] M. W. Sardjono, V. Ramadhan, M. Cahyanti, and E. R. Swedia, "Klasifikasi bentuk bingkai (frame) kacamata menggunakan CNN dengan arsitektur Inception V3 dan augmented reality berbasis Android," *Journal of System and Computer Engineering*, vol. 5, no. 2, pp. 204–218, July 2024, doi: 10.61628/jsce.v5i2.1292.
- [10] R. H. Rifat, S. Siddique, L. R. Das, and M. A. Haque, "Facial shape-based eyeglass recommendation using convolutional neural networks," in *Proc. 2023 IEEE Symposium Series on Computational Intelligence (SSCI)*, Dec. 2023, pp. 867–872, doi: 10.1109/SSCI52147.2023.10371836.
- [11] R. Adityatama and A. Putra, "Image classification of human face shapes using convolutional neural network Xception architecture with transfer learning," *Recursive Journal of Informatics*, vol. 1, pp. 102–109, Sept. 2023, doi: 10.15294/rji.v1i2.70774.
- [12] M. T. Hidayatullah, N. Mardiyantoro, and M. Hidayat, "Sistem identifikasi bentuk wajah untuk pemilihan frame kacamata menggunakan metode transfer learning," *Biner: Jurnal Ilmiah Informatika dan Komputer*, vol. 1, no. 1, pp. 70–78, Jan. 2022, doi: 10.32699/biner.v1i1.2853.
- [13] W. Budianto, D. E. Herwindati, and J. Hendryli, "Pengenalan bentuk wajah dengan metode convolutional neural network untuk pemilihan model kacamata secara online," *Infotech: Journal of Technology Information*, vol. 9, no. 2, pp. 129–136, Nov. 2023, doi: 10.37365/jti.v9i2.176.
- [14] W. A. Kurniawan and A. Salam, "Penggunaan feature space SMOTE untuk mengurangi overfitting akibat imbalance dataset," *Teknika Komputer (tc)*, vol. 23, no. 2, pp. 328–337, May 2024, doi: 10.62411/tc.v23i2.10215.
- [15] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "MobileNetV2: Inverted residuals and linear bottlenecks," *arXiv preprint arXiv:1801.04381*, Mar. 21, 2019, doi: 10.48550/arXiv.1801.04381.
- [16] A. T. Sari, J. Jumadi, and E. Nurlatifah, "Penerapan convolutional neural network untuk mengklasifikasikan citra sampah organik dan non organik," *Jutisi: Jurnal Ilmiah Teknik Informatika dan Sistem Informasi*, vol. 14, no. 1, pp. 1–11, Apr. 2025, doi: 10.35889/jutisi.v14i1.2534.

- [17] M. B. Septyono, F. T. Anggraeny, and R. Mumpuni, "Pengenalan ekspresi wajah dengan LBP dan multi-level CNN," *Jurnal Informatika Polinema*, vol. 11, no. 4, pp. 469–476, Aug. 2025, doi: 10.33795/jip.v11i4.7351.
- [18] A. Younesi et al., "A comprehensive survey of convolutions in deep learning: Applications, challenges, and future trends," *IEEE Access*, vol. 12, pp. 41180–41218, 2024, doi: 10.1109/ACCESS.2024.3376441.
- [19] C. C. Aggarwal, *Neural Networks and Deep Learning: A Textbook*. Cham: Springer International Publishing, 2018, doi: 10.1007/978-3-319-94463-0.
- [20] K. Azmi, S. Defit, and S. Sumijan, "Implementasi convolutional neural network (CNN) untuk klasifikasi batik tanah liat Sumatera Barat," *Jurnal Teknologi Universal*, vol. 16, no. 1, pp. 28–40, June 2023, doi: 10.5207/unitek.v16i1.504.
- [21] Q. Lina, "Implementasi deep learning menggunakan convolutional neural network untuk klasifikasi gambar (mata juling dan mata normal) dengan R," *Medium.com*, Sept. 30, 2025. Accessed: Oct. 1, 2025. [Online]. Available: <https://medium.com/@16611110/implementasi-deep-learning-menggunakan-convolutional-neural-network-untuk-klasifikasi-gambar-mata-87dcc0ad26e0>
- [22] A. Mufidatuzzainiya and M. Faisal, "Penggunaan teknik transfer learning pada metode CNN untuk pengenalan tanaman bunga," *JISKA (Jurnal Informatika Sunan Kalijaga)*, vol. 10, no. 2, pp. 195–206, May 2025, doi: 10.14421/jiska.2025.10.2.195-206.
- [23] M. S. Azzahra, S. S. Maesaroh, and R. G. Guntara, "Penggunaan convolutional neural network dan transfer learning untuk rekomendasi gaya rambut pria," *Jurnal Algoritma*, Jan. 2025. Accessed: Oct. 6, 2025. [Online]. Available: <https://jurnal.itg.ac.id/index.php/algoritma/article/view/2134>
- [24] A. D. Ulhaq, D. Hartanti, and A. A. Sari, "Sistem rekomendasi pemilihan jenis lensa kacamata menggunakan metode knowledge based recommendation (studi kasus: Optik Wiratama Kacamata 2)," *STRING (Satuan Tulisan Riset dan Inovasi Teknologi)*, vol. 10, no. 1, pp. 118–127, Aug. 2025, doi: 10.30998/string.v10i1.28938.
- [25] P. Thangavel and S. Mohanasundaram, "Machine vision based intelligent eyeglass recommender," *International Journal on Applications in Engineering and Technology*, vol. 9, no. 2, pp. 69–75, June 2023, ISSN: 2455-0523.
- [26] A. Zheng, *Evaluating Machine Learning Models: A Beginner's Guide to Key Concepts and Pitfalls*. Sebastopol, CA: O'Reilly Media, 2015.
- [27] P. Rodríguez, M. A. Bautista, J. González, and S. Escalera, "Beyond one-hot encoding: Lower dimensional target embedding," *Image and Vision Computing*, vol. 75, pp. 21–31, July 2018, doi: 10.1016/j.imavis.2018.04.004.