

# Sistem Klasifikasi Bentuk Wajah Menggunakan EfficientNet-B4 untuk Rekomendasi Gaya Rambut Berbasis Web

*A Face Shape Classification System Using EfficientNet-B4 for Web-Based Hairstyle Recommendation*

Dimas Maulana Putra<sup>1</sup>, Alfareza Kamal Santoso<sup>2</sup>, Alif Fadli<sup>3</sup>  
Febrian Ahmad Fatoni<sup>4</sup>, Agung Harri Novanto<sup>5</sup>,  
Fuad Nurhasan<sup>6</sup>  
Informatika, Universitas Bina Sarana Informatika  
E-mail: [fuadfnu@bsi.ac.id](mailto:fuadfnu@bsi.ac.id)<sup>1\*</sup>, [dimasmaulanaptra@gmail.com](mailto:dimasmaulanaptra@gmail.com)<sup>2</sup>

## Abstrak

Kesesuaian gaya rambut sangat ditentukan oleh bentuk wajah, tetapi identifikasi secara manual sering kali tidak konsisten karena adanya subjektivitas dari pengamat. Penelitian ini menciptakan sistem otomatis untuk mengklasifikasikan bentuk wajah menggunakan model EfficientNet-B4 dengan lima kategori: Heart, Oblong, Oval, Round, dan Square. Model tersebut dilatih dengan menggunakan 27.066 gambar yang sudah diberi label, terdiri dari 19.926 gambar untuk proses pelatihan, 3.512 untuk validasi, dan 3.628 untuk pengujian. Proses pelatihan dilakukan dengan cara transfer learning dalam dua tahap: pertama, pelatihan bagian head model, lalu fine-tuning pada backbone. Metode augmentasi data, penjadwalan laju pembelajaran, dan early stopping diterapkan untuk meningkatkan kinerja dan mencegah overfitting. Hasil evaluasi menunjukkan kinerja yang sangat baik dengan akurasi validasi sebesar 96,10%, akurasi pengujian 93,52%, dan macro-F1 sebesar 0,935. Kesalahan paling besar terjadi pada kategori Oval dan Oblong, sementara kategori Square menunjukkan konsistensi tertinggi. Sistem ini diterapkan dalam aplikasi web yang menggunakan Next.js dan Express.js, dengan deteksi wajah dilakukan di sisi klien menggunakan react-webcam dan face-api.js. Sistem ini juga menawarkan pratinjau gaya rambut untuk memperbaiki pengalaman pengguna.

**Kata kunci:** EfficientNet-B4, pengklasifikasian bentuk wajah, rekomendasi gaya rambut, transfer learning, aplikasi web.

## Abstract

*The suitability of a hairstyle is largely influenced by the shape of a person's face; however, manual identification can often lack consistency due to the observer's subjectivity. This study developed an automated system designed to classify face shapes using the EfficientNet-B4 model, categorizing them into five types: Heart, Oblong, Oval, Round, and Square. The model was trained on a dataset of 27,066 labeled images, which included 19,926 images for training, 3,512 for validation, and 3,628 for testing. The training process involved a two-phase transfer learning approach: first, training the head of the model, followed by fine-tuning the backbone. To enhance performance and mitigate overfitting, data augmentation, learning rate scheduling, and early stopping techniques were utilized. Evaluation results revealed exceptional performance, achieving a validation accuracy of 96.10%, a test accuracy of 93.52%, and a macro-F1 score of 0.935. The highest errors were found in the Oval and Oblong categories, whereas the Square category demonstrated the most consistency. This system is implemented in a web application*



*utilizing Next.js and Express, where face detection is carried out on the client-side using react-webcam and face-api.js. Additionally, the system provides a hairstyle preview to enhance the user experience.*

**Keywords:** *EfficientNet-B4, face shape classification, hairstyle recommendation, transfer learning, web application.*

## 1. PENDAHULUAN

Salah satu faktor yang sangat memengaruhi gaya rambut adalah bentuk wajah seseorang. Namun, dalam memilih model rambut, identifikasi manual sering kali tidak konsisten karena bergantung pada persepsi pribadi, sehingga rekomendasi yang diberikan sering kali kurang tepat. Banyak pria remaja merasa tidak cocok dengan potongan rambut yang dipilih, karena model rambut tersebut tidak sesuai dengan bentuk wajahnya. Oleh karena itu, pengolahan citra dan pembelajaran mesin dapat membantu mengidentifikasi bentuk wajah secara lebih objektif dan dapat direproduksi. Metode ini menggunakan ekstraksi fitur visual hierarkis melalui jaringan saraf tiruan konvolusioner (CNN). Berbagai penelitian di bidang wajah, seperti klasifikasi ekspresi wajah, menunjukkan bahwa CNN sangat efektif dalam memproses gambar wajah, sehingga sangat relevan untuk tugas pengenalan bentuk wajah [1].

Masalah yang ada adalah, meskipun platform media sosial telah berkembang pesat sebagai referensi gaya hidup, tidak semua orang memahami pentingnya mencocokkan gaya rambut dengan bentuk wajah yang sesuai. Banyak individu yang hanya mengikuti tren tanpa mempertimbangkan apakah gaya tersebut cocok dengan mereka, yang dapat mengakibatkan rasa ketidakpuasan terhadap hasil yang diperoleh. Dalam penelitian ini, kami merancang model CNN yang memanfaatkan EfficientNet-B4 untuk secara akurat mengidentifikasi bentuk wajah (Hati, Panjang, Oval, Bulat, Persegi). Selain itu, kami mencari strategi pelatihan yang efisien, seperti transfer learning bertahap, peningkatan data, dan penyesuaian kecepatan belajar, untuk memastikan kinerja yang baik di berbagai kategori. Kami juga berkeinginan untuk menghubungkan model ini dengan layanan web guna mendukung prediksi secara real-time dan memberikan rekomendasi mengenai gaya rambut yang mudah dipahami oleh pengguna. Penelitian sebelumnya lebih fokus pada teknik pemotongan atau tren gaya rambut itu sendiri, tanpa mempertimbangkan interaksi digital dan bagaimana pengaruh visual di media sosial memengaruhi keputusan konsumen. Tujuan dari penelitian ini adalah untuk menciptakan model pengenalan bentuk wajah menggunakan EfficientNet-B4 yang memiliki tingkat akurasi tinggi saat diuji dan divalidasi. Kami melaksanakan pelatihan secara bertahap (pertama melatih bagian atas, kemudian menyempurnakan bagian bawah) dengan tambahan teknik augmentasi data dan pengaturan laju belajar yang fleksibel (contohnya ReduceLROnPlateau atau EarlyStopping). Kami juga menerapkan layanan web (dengan Next.js–Express dan Hugging Face Spaces) untuk mengunggah gambar, memberikan hasil secara instan, dan menyarankan gaya rambut dengan bantuan AI [2].

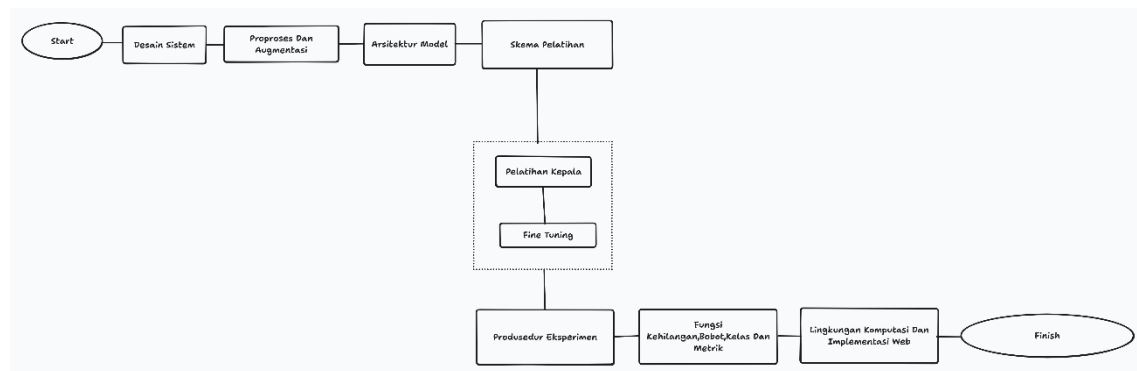
Penelitian sebelumnya menyatakan bahwa ada berbagai metode yang dapat digunakan untuk mengklasifikasikan bentuk wajah dengan menggunakan machine learning. Beberapa metode yang telah diuji meliputi K-Nearest Neighbors(KNN), Linear Discriminant Analysis(LDA), Support Vector Machines with Linear Kernel(SVM-LIN), Support Vector Machines with Radial Basis Function Kernel(SVM-RBF), dan Multi-Layer Perceptron(MLP) [3]. EfficientNet merupakan salah satu arsitektur CNN terbaru yang mengoptimalkan akurasi dan efisiensi komputasi melalui teknik compound scaling. Khususnya, EfficientNet-B4 menawarkan keseimbangan yang baik antara performa dan kebutuhan memori, menjadinya cocok untuk tugas klasifikasi gambar seperti klasifikasi bentuk wajah. Penelitian ini bertujuan untuk



membangun sistem klasifikasi bentuk wajah menggunakan EfficientNet-B4 dengan pendekatan transfer learning dan mengimplementasikannya dalam framework Pytorch[9]. Evaluasi dilakukan untuk mengukur performa model pada data uji dan menganalisis efektivitas pendekatan yang digunakan [4].

## 2. METODE PENELITIAN

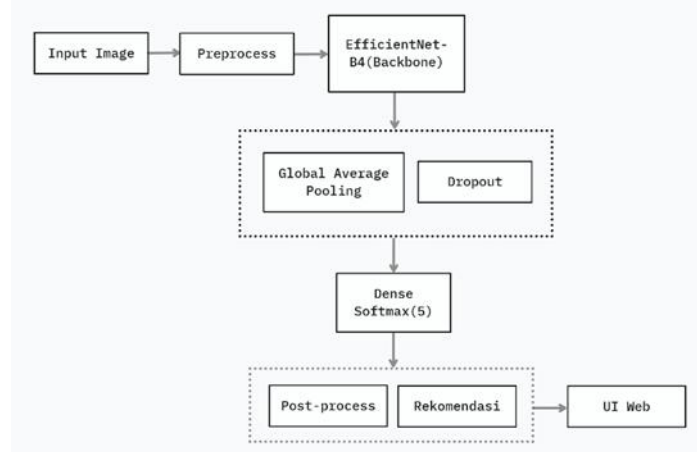
Metodologi yang digunakan untuk melakukan penelitian dapat dilihat dalam diagram berikut.



Gambar 1 Diagram Alur

### 2.1 Desain Sistem

Desain sistem identifikasi wajah dalam studi ini terdiri dari dua elemen kunci yang beroperasi secara terpadu dalam satu alur proses citra. Sistem ini terdiri dari dua tingkat yang saling melengkapi. Tingkat pertama adalah model pengenalan bentuk wajah yang memanfaatkan EfficientNet-B4, sementara tingkat kedua adalah layanan berbasis web yang dengan cepat mengelola inferensi dan memberikan rekomendasi [5].



Gambar 2 Diagram Arsitektur System (Umum)

Prosesnya cukup sederhana: pengguna mengunggah foto wajah gambar diperbaiki (diproses sebelumnya) model mengkategorikan ke dalam salah satu dari lima bentuk (Heart, Oblong, Oval, Round, Square) dan menghasilkan vektor probabilitas modul rekomendasi menggunakan hasil tersebut untuk menunjukkan gaya rambut yang direkomendasikan di

antarmuka. EfficientNet-B4 dipilih karena metode pemodelan kompaunnya mampu menjaga tingkat akurasi tinggi sambil memastikan kebutuhan komputasi tetap dalam batas wajar, sehingga ideal untuk aplikasi web yang memerlukan latensi rendah dan efisiensi sumber daya.

## 2.2 Dataset

Dataset yang dipakai dalam studi ini terdiri dari dua dataset sekunder dari Kaggle, yaitu Face Shape Dataset dan Hair Type Dataset, yang masing-masing memuat gambar wajah dan rambut dengan label berdasarkan kategorinya. Face Shape Dataset ini terorganisir menjadi lima kategori bentuk wajah. Dalam penelitian ini, kami memanfaatkan dataset publik yang dikenal dengan sebutan Face Shape Dataset, diambil dari Kaggle, yang mencakup 27.066 gambar dengan label yang terpisah jelas menjadi 19.926 untuk pelatihan, 3.512 untuk validasi, dan 3.628 untuk pengujian. Setiap gambar diberi salah satu dari lima label yang merepresentasikan tipe bentuk wajah. Meskipun distribusinya secara umum cukup seimbang, penghitungan bobot kelas tetap dilakukan sebagai langkah antisipatif untuk mengatasi kemungkinan adanya ketidakseimbangan lokal di subset tertentu (seperti dalam validasi atau pengujian) agar proses pelatihan berjalan lancar [6].

<https://www.kaggle.com/datasets/niten19/face-shape-dataset>

<https://www.kaggle.com/datasets/riandanalysis/faceshape-roboflow>

<https://www.kaggle.com/datasets/idealm99/face-shape-new>

<https://www.kaggle.com/code/rajeshandra/face-shape-classification-v2>

Tabel 1 Ringkasan dataset

Kelas	Train	Validasi	Uji	Total
Heart	3970	700	712	5382
Oblong	3960	698	759	5417
Oval	4028	710	735	5473
Round	3978	701	715	5395
Square	3990	703	707	5400
Jumlah	19926	3512	3628	<b>27066</b>

Sebagaimana terlihat pada tabel di atas, setiap citra diklasifikasikan ke dalam lima kategori bentuk wajah utama, yaitu: *Heart*, *Oblong*, *Oval*, *Round*, dan *Square*. Pengkategorian ini sejalan dengan standar klasifikasi yang diterapkan dalam pengembangan sistem rekomendasi gaya rambut berbasis *Artificial Intelligence*. Penggunaan dataset yang terstruktur ini bertujuan untuk memastikan model dapat mengenali fitur wajah dengan akurasi yang tinggi guna mendukung pengalaman pengguna yang optimal [7].

## 2.3 Preproses dan Augmentasi

Tahapan ini dilaksanakan untuk mempermudah pengolahan informasi serta menjamin kualitas data yang digunakan dalam studi menjadi lebih baik. Setiap citra disesuaikan ukurannya menjadi 300×300 piksel dan dinormalisasi agar kompatibel dengan format input model. Dataset dibagi menjadi tiga kategori: pelatihan, validasi, dan pengujian. Pada data pelatihan, dilakukan augmentasi (rotasi hingga 10°, translasi 6%, zoom 12%, flip horizontal, dan penyesuaian kecerahan) yang bertujuan untuk meningkatkan variasi data dan mencegah terjadinya *overfitting* [8]. Sedangkan untuk data validasi dan pengujian, hanya dilakukan pengubahan ukuran dan normalisasi tanpa augmentasi agar evaluasi mencerminkan situasi inferensi yang sesungguhnya.



Guna mempercepat proses pelatihan dan inferensi, diterapkan teknik *mixed precision* (fp16) dan optimasi XLA untuk meningkatkan efisiensi komputasi [9].

#### 2.4 Arsitektur Model

Gaya modern menekankan bentuk dan fungsi dengan desain yang sederhana dan minimalis. Pada model, EfficientNet-B4 digunakan sebagai backbone (`include_top=False`, `pooling='avg'`), kemudian ditambah Dropout untuk mencegah overfitting, dan diakhiri dengan Dense softmax berisi lima neuron untuk klasifikasi [10].

#### 2.5 Skema Pelatihan (Transfer Learning Dua Fase)

Skema Pelatihan pengenalan pola yang dikembangkan dalam penelitian ini. Pada Tahap 1, backbone terkunci dan hanya lapisan klasifikasi yang dilatih menggunakan Adam dengan laju pembelajaran  $1 \times 10^{-3}$ , serta menggunakan callback seperti ModelCheckpoint, EarlyStopping, dan ReduceLROnPlateau untuk memastikan adanya stabilitas. Pada Tahap 2, seluruh backbone dibuka untuk disempurnakan (*fine-tuning*) dengan Adam yang memiliki laju pembelajaran lebih rendah, yaitu  $1 \times 10^{-4}$ , dan penerapan label smoothing sebesar 0,05. Callback yang sama diterapkan, dan laju pembelajaran secara otomatis akan diturunkan jika akurasi validasi tidak menunjukkan peningkatan [11].

Tabel 2 Hiperparameter utama

Item	Phase-1 (Head)	Phase-2 (FT)
Batch Size	32	32
Epoch	15	35
Optimizer	Adam	Adam
Learning rate	1e-3	1e-4
Label smoothing	0.0	0.05
Callbacks inti	Checkpoint(best), EarlyStopping ( $\pm 8$ ), RLRP (0.2, $\pm 4$ )	Checkpoint(best), EarlyStopping ( $\pm 6$ ), RLRP (0.5, $\pm 3$ , <code>min_lr=1e-6</code> )
Lainnya	Mixed precision, XLA	Mixed precision, XLA

#### 2.6 Fungsi Kehilangan, Bobot Kelas, dan Metrik

Model menggunakan *Categorical Cross-Entropy* dengan *label smoothing* ( $\epsilon = 0,0$  pada tahap awal dan  $\epsilon = 0,05$  pada *fine-tuning*) agar prediksi lebih stabil. Bobot kelas sempat digunakan untuk mengatasi ketidakseimbangan, tetapi dimatikan ketika pelatihan lebih stabil tanpa itu. Evaluasi dilakukan menggunakan akurasi, *precision/recall/F1*, *macro-F1*, *confusion matrix*, *ROC-AUC*, kurva *Precision-Recall*, dan *optional top-k accuracy*, serta pengecekan kalibrasi probabilitas melalui *ECE* dan *reliability diagram*. Pendekatan evaluasi berbasis analisis *loss* dan *confusion matrix* ini diadopsi sebagai standar validasi performa model CNN pada klasifikasi citra wajah [12].

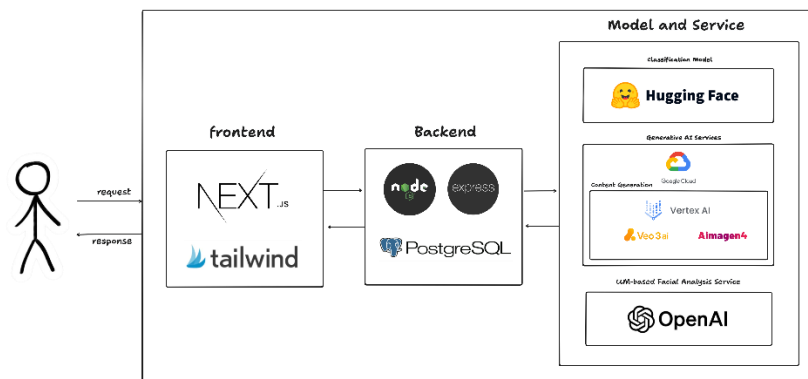
$$\gamma = 1 - \epsilon \text{ yone} - \text{hot} + \epsilon / C \quad \gamma \quad C = 5$$

#### 2.7 Lingkungan Komputasi dan Implementasi Web

Sistem dikembangkan dengan arsitektur web terintegrasi yang memisahkan fungsi menjadi tiga lapisan frontend, backend, dan layanan model/AI eksternal. Pada sisi frontend, Next.js mengelola perenderan dan rute halaman, sementara Tailwind CSS mempercepat perancangan antarmuka yang responsif. Lapisan backend dibangun dengan Node.js dan Express untuk menangani logika aplikasi, orkestrasi API, serta integrasi ke penyedia model, penyimpanan



data persisten dikelola oleh PostgreSQL. Melalui skema komunikasi request–response, backend mengakses lapisan Model dan Service yang mencakup model klasifikasi pada ekosistem Hugging Face, layanan Generative AI Google Cloud Vertex AI, Veo 3 AI, dan Imagen 4 untuk pembuatan konten, serta layanan analisis wajah berbasis LLM dari OpenAI. Pemisahan tanggung jawab ini memastikan skalabilitas, kemudahan pemeliharaan, dan fleksibilitas integrasi fitur baru, sekaligus menjaga alur data efisien dari antarmuka pengguna hingga keluaran inferensi.



Gambar 4 Arsitektur Sistem Web dan Integrasi Layanan AI


Arsitektur sistem yang terdiri atas frontend (Next.js, Tailwind), backend (Node.js/Express, PostgreSQL), dan integrasi layanan AI eksternal Hugging Face untuk klasifikasi, Google Cloud Vertex AI/Veo 3 AI/Imagen 4 untuk generasi konten, serta OpenAI untuk analisis wajah dalam alur request–response.

### 3. HASIL DAN PEMBAHASAN

#### 3.1 Dinamika Pelatihan (Phase-1 dan Phase-2)

Model klasifikasi bentuk wajah yang memanfaatkan arsitektur EfficientNet-B4 dengan metodologi transfer learning dievaluasi menggunakan beragam metrik dan visualisasi. Phase-1 Pelatihan dihentikan di epoch 13 disebabkan oleh penerapan early stopping. Val\_accuracy masih mengalami variasi dan hanya mencapai sekitar 0,387 meskipun learning rate sudah dikurangi oleh ReduceLRonPlateau. Bobot optimal dari fase ini dijadikan acuan untuk tahap fine-tuning. Phase-2 Model dilatih ulang dengan membuka semua backbone dan menunjukkan perkembangan signifikan, hingga val\_accuracy mencapai 0,961 pada epoch 36. Checkpoint terbaik pada epoch 36 digunakan untuk evaluasi dan menghasilkan akurasi uji 0,9352 (macro-F1 0,935).





Gambar 5 Phase-1(Head) & Phase-2 (FT)

Pada gambar Kurva akurasi dan loss Phase-1 (latih vs validasi) Menunjukkan bahwa akurasi validasi masih tidak stabil dan belum meningkat signifikan. Kurva training naik perlahan, tetapi kurva validasi berfluktuasi sehingga early stopping aktif. Kurva akurasi dan loss Phase-2 (latih vs validasi) Menunjukkan peningkatan akurasi yang konsisten setelah backbone dibuka. Akurasi validasi stabil mendekati 1,0 dan loss validasi turun tanpa tanda overfitting.

Tabel 3 Ringkasan epoch kunci selama pelatihan

Fase	Epoch	Perubahan penting	Val_accuracy	Learning_rate	catatan
Phase-1	1	Mulai head training	0,3457	1e-3	Kurva validasi belum stabil
Phase-1	10	LR turun (RLRP)	0,3861	2e-4	Penurunan LR pertama
Phase-1	13	Early stopping	0,3870	2e-4	Simpan bobot terbaik Phase-1
Phase-2	16	Mulai fine-tuning	0,7659	1e-4	Lonjakan awal signifikan
Phase-2	22	-	0,9043	1e-4	Validasi terus membaik
Phase-2	28	-	0,9234	1e-4	Menjelang LR turun
Phase-2	29	LR turun (RLRP)	0,9456	2e-5	Stabilitas meningkat
Phase-2	32		0,9564	2e-5	Mendekati puncak
Phase-2	36	LR turun (RLRP)	0,9610	4e-6	Puncak validasi (best ckpt)




Phase-2	40	LR turun (RLRP)	0,9593	8e-7	Plateau di sekitar 0,959–0,961
Test	-	Evaluasi akhir	Akurasi 0,9352	-	Macro-F1 0,935

Tabel menunjukkan perkembangan pelatihan di setiap fase: mulai dari peningkatan val\_accuracy, momen ketika learning rate diturunkan otomatis (ReduceLROnPlateau), hingga checkpoint terbaik. Phase-1 berhenti di epoch 13 karena early stopping, sedangkan di Phase-2 penurunan learning rate secara bertahap menyebabkan peningkatan stabil hingga mencapai performa terbaik di epoch 36. Model ini menjaga generalisasi dengan perbedaan val vs test yang kecil dan wajar.

### 3.2 Evaluasi pada Himpunan Validasi

Model mencapai akurasi validasi 96,10% dan macro-F1  $\approx 0,961$ , dengan presisi–recall tiap kelas seimbang. Kesalahan utama terjadi pada kelas yang mirip (Oval vs Oblong).



Gambar 6 Confusion Matrix (Vall) (Counts) & (Vall) (Normalized)

Pada gambar matriks kebingungan, kotak diagonal memiliki nilai tertinggi (true positive), menunjukkan model banyak memprediksi tepat sesuai kelas sebenarnya. Kesalahan prediksi terjadi terutama pada kotak di luar diagonal, dan sebagian besar kesalahan hanya terjadi antara kelas yang bentuknya mirip, misalnya Oval  $\leftrightarrow$  Oblong. Kelas seperti Round dan Square hampir tidak tertukar, menandakan fitur geometrisnya lebih mudah dibedakan oleh model.

Tabel 4 Ringkasan metrik global (Validasi)


Metrik	Nilai
Akurasi	0,9610
Macro-Precision	0,962
Macro-Recall	0,961
Macro-F1	0,961



Top-3 Accuracy	0,9926
----------------	--------

### 3.3 Evaluasi pada Data Uji (Generalitas Model)

Nilai evaluasi untuk klasifikasi dalam bentuk wajah menggunakan confusion matrix(test) (normalized), seperti pada Gambar 7, menunjukkan hasil evaluasi yang cukup mirip dengan nilai evaluasi baseline, di mana akurasi tertinggi mencapai 96%. Di sisi lain, Kelas Normal memperlihatkan akurasi yang cukup baik (96,2%) tetapi memiliki tingkat recall yang relatif rendah (97,5%), yang menunjukkan bahwa banyak contoh Normal yang tidak terdeteksi. Model ini diuji menggunakan dataset baru dan berhasil memperoleh akurasi sebesar 93,52% dengan skor macro-F1 sekitar 0,935, yang menggambarkan kemampuan generalisasi yang cukup baik. Selisih antara akurasi validasi (96,10%) masih berada dalam batas yang dapat diterima [13].



Gambar 7 Confusion Matrix (Test) (normalized)

Pada gambar matriks kebingungan, nilai tertinggi berada pada diagonal, menunjukkan sebagian besar sampel berhasil diklasifikasikan benar sesuai kelasnya. Kelas Square tampil paling konsisten (presisi dan recall tinggi). Kesalahan terbanyak terjadi pada kelas Oblong, yang beberapa sampelnya terprediksi sebagai Oval karena kesamaan bentuk wajah, terlihat dari nilai pada sel off-diagonal antara Oblong → Oval.

Tabel 5 Performa per kelas (Uji).


Kelas	Precision	Recal	F1-Score	Support
Heart	0,9101	0,9382	0,9239	712
Oblong	0,9688	0,8999	0,9331	759
Oval	0,9110	0,9048	0,9078	735
Round	0,9223	0,9622	0,9418	715
Square	0,9663	0,9745	0,9704	707
Rata-rata (macro)	0,936	0,936	0,935	3628

Berdasarkan hasil evaluasi pada set uji (Tabel 5), model mencapai nilai precision, recall, dan F1-score rata-rata sebesar 0,936 / 0,936 / 0,935 pada total 3.628 sampel. Kelas Square menunjukkan performa terbaik dengan F1-score sebesar 0,9704, yang menunjukkan bahwa kontur sudut rahang yang tegas mudah dibedakan oleh model. Sebaliknya, kelas Oblong memiliki

recall terendah (0,8999), yang mengindikasikan bahwa sebagian sampel Oblong sering salah diklasifikasikan sebagai Oval yang memiliki kemiripan morfologis. Sementara itu, kelas Heart, Oval, dan Round memperlihatkan performa yang stabil dengan F1-score di atas 0,90. Perbedaan akurasi antara validasi (96,10%) dan pengujian (93,52%) masih wajar dan mengindikasikan kemampuan generalisasi yang baik. Secara keseluruhan, model sudah mampu mengklasifikasikan bentuk wajah dengan akurat dan konsisten pada data yang belum pernah dilihat sebelumnya.

### 3.4 ROC/PR dan Kalibrasi Probabilitas

Kurva ROC dan Precision–Recall menunjukkan pemisahan kelas yang sangat baik, sedangkan grafik kalibrasi dan histogram confidence membuktikan bahwa probabilitas prediksi model sudah akurat dan stabil.




Gambar 8 ROC- Val & Precision-Recall-Val

Pada gambar Kurva ROC (macro/OVR):Grafik menunjukkan area ROC yang luas, menandakan model mampu membedakan tiap kelas dengan baik (semakin luas area, semakin baik pemisahan kelas).Kurva Precision–Recall (macro/OVR):Kurva berada pada area atas grafik, yang berarti model mampu menjaga precision dan recall tetap tinggi, bahkan pada skenario data yang sulit.

### 3.5 Kalibrasi Probabilitas dan Kepercayaan Model

Diagram reliabilitas menunjukkan bahwa probabilitas prediksi model sudah akurat (terkalibrasi baik), sedangkan histogram confidence menunjukkan bahwa sebagian besar prediksi memiliki tingkat keyakinan tinggi.




Gambar 9 Reliability Diagram Kurva & Histogram Confidence

Pada gambar Reliability Diagram Kurva mendekati garis diagonal, artinya probabilitas output model sesuai dengan kebenaran sebenarnya (tidak overconfident atau underconfident). Histogram Confidence Sebagian besar prediksi berada pada confidence tinggi. Namun masih ada area confidence sedang yang dapat dimanfaatkan, misalnya untuk menampilkan top-2 recommendation pada antarmuka.

### 3.6 Analisis Kesalahan

Kesalahan klasifikasi paling sering terjadi antara Oval dan Oblong karena kemiripan bentuk wajah. Square tetap yang paling stabil.



Gambar 10 Kolase “top errors”

Pada gambar menampilkan kumpulan contoh wajah yang salah diklasifikasikan oleh model (misclassification gallery atau top errors). Setiap gambar mewakili kasus dimana prediksi model tidak sesuai dengan label aslinya. Biasanya pada kolase tersebut terdapat dua informasi penting untuk tiap gambar:

- Label asli (ground truth) – bentuk wajah yang benar berdasarkan anotasi dataset.
- Prediksi model – bentuk wajah yang dipilih oleh model EfficientNet-B4.

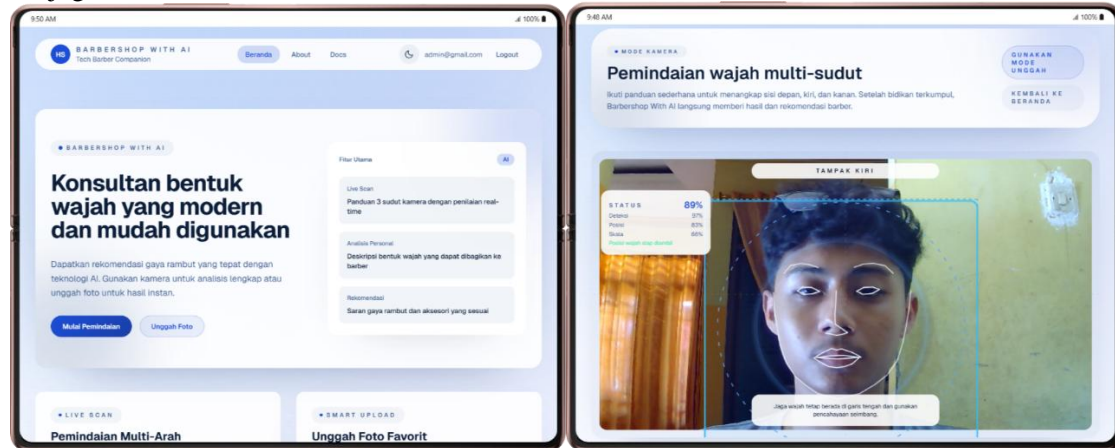
### 3.7 Implementasi Web dan Evaluasi Kelayakan Produksi

Model menunjukkan kinerja yang stabil dan siap diterapkan di lingkungan produksi. Evaluasi pada himpunan validasi menghasilkan akurasi 96,10% dengan macro-F1  $\approx 0,961$ , sedangkan pengujian pada data baru mencapai akurasi 93,52% dengan macro-F1  $\approx 0,935$ ; selisih ini masih wajar dan menandakan generalisasi yang baik tanpa indikasi overfitting. Kalibrasi probabilitas juga memadai dengan ECE  $\approx 0,046$ , sehingga skor kepercayaan dapat diinterpretasikan secara realistis. Praktisnya, ambang kepercayaan sekitar 0,80–0,90 efektif untuk menampilkan satu–dua rekomendasi utama kepada pengguna.

Arsitektur layanan web dirancang berlatensi rendah. Next.js dan Tailwind CSS menyajikan antarmuka serta routing di sisi klien, sedangkan Node.js/Express berperan sebagai orchestrator inferensi di sisi server dengan PostgreSQL sebagai penyimpanan. Demi privasi dan efisiensi jaringan, deteksi wajah serta landmark dijalankan di sisi klien menggunakan face-api.js; hanya crop wajah berukuran 300×300 px yang dikirim ke server. Backend memuat model .keras dan melakukan inferensi TensorFlow; setelah warm-up, waktu respons berada pada ratusan milidetik sehingga cukup untuk interaksi nyaris real-time.

Fitur generatif disematkan sebagai pelengkap setelah prediksi kelas diperoleh. Pratinjau gaya rambut (gambar/video) dihasilkan melalui layanan generatif dan teks penjelas disajikan pada antarmuka, namun komponen ini tidak memengaruhi proses klasifikasi. Seluruh hasil visual

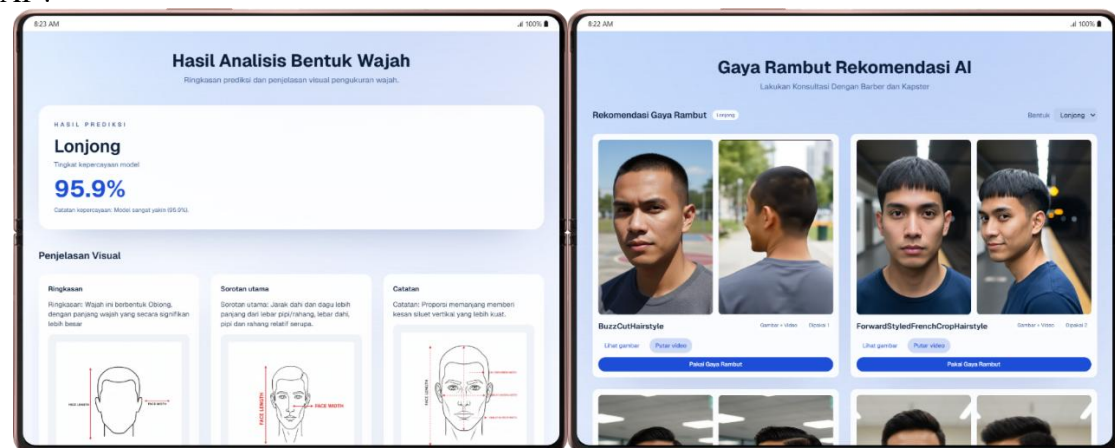
diberi label “ilustrasi AI” serta diawasi melalui pencatatan API dan penyaring konten untuk menjaga keamanan dan efisiensi.



Gambar 3 Antarmuka Beranda (Onboarding) & Mode Pemindaian Kamera

Cuplikan beranda (onboarding) menampilkan ajakan untuk memulai pemindaian atau unggah foto serta ringkasan fitur (Live Scan, Analisa Personal). Ketika pengguna memilih mode kamera, antarmuka menampilkan panduan penempatan wajah, overlay landmark, dan indikator status/kepercayaan selama proses pemindaian multi-sudut (kiri–depan–kanan). Penjelasan: proses ini selaras dengan rancangan sisi klien—deteksi dilakukan lokal dengan face-api.js, kemudian hanya crop 300×300 yang dikirim ke backend untuk inferensi cepat.

Setelah pemindaian selesai, aplikasi menampilkan halaman hasil berisi label bentuk wajah dan tingkat kepercayaan beserta penjelasan visual berbasis LLM OpenAI proporsi wajah. Berikutnya, galeri rekomendasi gaya rambut ditampilkan sesuai label prediksi, pengguna dapat melihat gambar/video pratinjau dan menerapkan gaya terpilih melalui tombol aksi. Penjelasan: karena skor kepercayaan telah terkalibrasi, antarmuka memanfaatkan ambang 0,80–0,90 untuk menonjolkan satu–dua gaya terbaik; konten generatif berfungsi sebagai ilustrasi terlabel “ilustrasi AI”.



Gambar 4 Hasil Prediksi & Rekomendasi Gaya Rambut AI.

Secara keseluruhan, alur end-to-end dari pemindaian hingga rekomendasi berjalan mulus dan mendukung penerapan produksi. Tantangan tersisa terutama pada kondisi ekstrem,

pencahayaan keras, occlusion oleh aksesoris, serta kemiripan morfologis antar-kelas (mis. Oval dan Oblong). Arah peningkatan meliputi perluasan data pada kondisi sulit, augmentasi gambar saat evaluasi, penambahan variasi contoh gaya rambut.

### 3.8 Ringkasan Kinerja Inti

EfficientNet-B4 mencapai akurasi validasi 96,10% dan akurasi uji 93,52% dengan macro-F1 0,935 pada lima kelas bentuk wajah. Performa antar kelas stabil, dengan kesulitan utama pada Oval dan Oblong karena kemiripan morfologinya. Evaluasi ROC/PR dan kalibrasi menunjukkan kualitas prediksi yang baik, sementara integrasi ke web memastikan inferensi cepat dan pengalaman pengguna yang jelas. Hasil ini menegaskan bahwa EfficientNet-B4 efektif untuk klasifikasi bentuk wajah dan rekomendasi gaya rambut berbasis web.

## KESIMPULAN DAN SARAN

Sistem klasifikasi bentuk wajah berbasis EfficientNet-B4 berhasil mencapai akurasi validasi 96,10% dan akurasi pengujian 93,52% dengan macro-F1 0,935 untuk lima kategori. Pelatihan dua fase (training head → fine-tuning backbone) menghasilkan model yang stabil, dan kalibrasi probabilitas menunjukkan kepercayaan prediksi yang reliabel ( $ECE \approx 0,046$ ). Tantangan utama terdapat pada kelas Oval–Oblong karena kemiripan morfologis. Implementasi web menggunakan Next.js di sisi klien dan Express–TensorFlow di server, sehingga inferensi berjalan cepat karena hanya gambar wajah 300×300 yang dikirim. Demo di Hugging Face memudahkan pengujian, sementara modul visualisasi gaya rambut meningkatkan pengalaman pengguna.

Pengembangan saran:

- 1) penambahan data pada kondisi sulit dan kelas yang mirip,
- 2) penambahan dan penyajian konten generatif yang aman dan terlabel “ilustrasi AI”.
- 3) Menambahkan fitur try on secara langsung pada gaya rambut yang dipilih.

Dengan langkah-langkah di atas, sistem diharapkan menjadi lebih kuat dalam penggunaan nyata, memberikan rekomendasi yang lebih personal dan dapat diandalkan, serta tetap efisien untuk layanan berbasis web.

## DAFTAR PUSTAKA

- [1] M. Y. Putra, “Rancang Bangun Deteksi Bentuk Wajah Untuk Menentukan Gaya Rambut Menggunakan Algoritma CNN,” *Repeater : Publikasi Teknik Informatika dan Jaringan*, vol. 2, no. 3, pp. 206–212, Jul. 2024, doi: 10.62951/repeater.v2i3.139.
- [2] A. Maghfiroh, I. Nurhayati, N. Atikah, M. I. Putri, and M. J. Nabila, “Pengaruh Media Sosial Terhadap Pemilihan Pangkas Rambut Desain Sesuai Dengan Bentuk Wajah,” *JURNAL MULTIDISIPLIN ILMU AKADEMIK*, vol. 2, no. 3, pp. 11–20, May 2025, doi: 10.61722/jmia.v2i3.4448.
- [3] V. Ramadhan, M. W. Sardjono, M. Cahyanti, E. R. Swedia, and M. R. D. Septian, “Klasifikasi Bentuk Bingkai (Frame) Kacamata Menggunakan CNN dengan Arsitektur Inception V3 dan Augmented Reality Berbasis Android,” *Journal of System and Computer Engineering (JSCE) ISSN*, vol. 5, no. 2, pp. 204–218, 2024, doi: 10.61628/jsce.v5i2.1292.
- [4] J. C. Wicaksono, J. Sahertian, and R. H. Irawan, “Klasifikasi Bentuk Wajah Menggunakan Efficientnet-B4,” *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, vol. 9, pp. 2119–2127, 2025, Accessed: Nov. 28, 2025. [Online]. Available: <https://proceeding.unpkediri.ac.id/index.php/inotek/>





- 
- [5] R. Imanuel, R. N. W. Dafalah, R. C. P. Murdoko, F. Budiman, and M. Muslih, “Deteksi Dan Klasifikasi Citra Wajah Menggunakan MTCNN Dan MOBILENET,” *Integrative Research in Computer Science*, vol. 1, no. 1, pp. 23–39, 2025, Accessed: Nov. 28, 2025. [Online]. Available: <https://ritecs.org/journal/index.php/IRCS/article/view/4>
  - [6] A. Dhiya 'Ulhaq and I. K. D. Nuryana, “Sistem Rekomendasi Gaya Rambut Personal Berdasarkan Analisis Wajah dan Rambut,” *JINACS: Journal of Informatics and Computer Science*, vol. 07, no. 1, pp. 340–347, 2025, Accessed: Nov. 28, 2025. [Online]. Available: <https://ejournal.unesa.ac.id/index.php/jinacs/article/view/72775>
  - [7] S. Mewandari *et al.*, “Implementasi Framework Flutter Untuk Aplikasi Rekomendasi Gaya Rambut Menggunakan Artificial Intelligence Vision Chatgpt,” *Jurnal Mahasiswa Teknik Informatika*, vol. 8, no. 3, pp. 4026–4032, Jun. 2024, doi: 10.36040/jati.v8i3.9800.
  - [8] F. A. J. Handani, E. Wijayanti, and R. Fiati, “Implementation Of Convolutional Neural Network Method In Classifying Pandawa Shadow Puppets,” *Jurnal Teknik Informatika (Jutif)*, vol. 6, no. 1, pp. 211–219, Feb. 2025, doi: 10.52436/1.jutif.2025.6.1.1851.
  - [9] M. Wasil, Harianto, and Fathurrahman, “Pengaruh Epoch pada Akurasi menggunakan Convolutional Neural Network untuk Klasifikasi fashion dan Furniture,” *Infotek: Jurnal Informatika dan Teknologi*, vol. 5, no. 1, pp. 53–61, Jan. 2022, doi: 10.29408/jit.v5i1.4393.
  - [10] Moch. F. Alfathoni, I. Kadir, and A. Ma'ruf, “Penerapan Arsitektur Modern Pada Gedung Pusat Pendidikan Modeling Dan Fashion Designer Di Kota Kendari,” *GARIS: Jurnal Mahasiswa Jurusan Arsitektur*, vol. 9, no. 2, pp. 58–64, Aug. 2024, Accessed: Nov. 27, 2025. [Online]. Available: <https://garis.uho.ac.id/index.php/journal/article/view/155>
  - [11] M. S. Azzahra, S. S. Maesaroh, and R. G. Guntara, “Penggunaan Convolutional Neural Network dan Transfer Learning untuk Rekomendasi Gaya Rambut Pria,” *Jurnal Algoritma*, vol. 21, no. 2, pp. 173–183, Nov. 2024, doi: 10.33364/algoritma/v.21-2.2134.
  - [12] A. Z. Pramuditha, Suroso, and M. Fadhli, “Deteksi Wajah Dengan Model Arsitektur VGG 19 Pada Metode Convolutional Neural Network,” *Sistemasi: Jurnal Sistem Informasi*, vol. 13, no. 5, pp. 1998–2007, 2024, doi: 10.32520/stmsi.v13i5.4399.
  - [13] M. M. Santoni, N. Chamidah, and D. S. Prasvita, “Strategi Ensemble Deep Learning pada Global Multi-Scale dan Local Attention Features pada Pengenalan Ekspresi Wajah,” *Krea-TIF: Jurnal Teknik Informatika*, vol. 12, no. 1, pp. 12–23, 2024, doi: 10.32832/krea-tif.v12i1.16287.

