

Sistem Rekomendasi Gaya Rambut Personal Berdasarkan Analisis Wajah dan Rambut

Arafat Dhiya 'Ulhaq¹, I Kadek Dwi Nuryana²

^{1,2} Sistem Informasi, Universitas Negeri Surabaya

¹arafat.21024@mhs.unesa.ac.id

²dwinuryana@unesa.ac.id

Abstrak— Pemilihan gaya rambut seringkali bersifat subjektif dan tidak didasarkan pada karakteristik visual yang objektif, sehingga mengurangi tingkat personalisasi dan kepuasan pengguna. Penelitian ini bertujuan untuk mengembangkan sistem identifikasi gaya rambut berbasis website yang mampu memberikan rekomendasi personal berdasarkan analisis data visual. Untuk mencapai tujuan tersebut, penelitian ini menerapkan pendekatan deep learning dengan mengembangkan dua arsitektur *Convolutional Neural Network* (CNN) pada *EfficientNetB0* untuk tugas klasifikasi bentuk wajah dan *ResNet50* untuk klasifikasi jenis rambut. Metode penelitian yang digunakan adalah *Cross-Industry Standard Process for Data Mining* (CRISP-DM), yang mencakup tahapan pemahaman bisnis, pemahaman data, persiapan data dengan augmentasi, pemodelan menggunakan transfer learning, evaluasi, hingga implementasi. Hasil dari penelitian ini adalah sebuah aplikasi web fungsional yang mampu melakukan klasifikasi bentuk wajah dan jenis rambut dari gambar yang diunggah pengguna. Sistem ini berhasil mengintegrasikan kedua model untuk memberikan identifikasi gaya rambut yang lebih akurat dan personal, sehingga dapat menjadi solusi objektif dalam industri kecantikan digital.

Kata Kunci— Identifikasi Gaya Rambut, Klasifikasi Gambar, *EfficientNet*, *ResNet*, Personalisasi Rambut.

I. PENDAHULUAN

Perkembangan teknologi Artificial Intelligence (AI) telah merevolusi berbagai aspek kehidupan, termasuk industri estetika dan kecantikan [1]. Pemilihan gaya rambut yang selama ini cenderung bersifat subjektif dan dipengaruhi tren sesaat sering menimbulkan kesulitan bagi individu untuk memperoleh rekomendasi yang sesuai dengan karakteristik personal. Keterbatasan ini menyoroti kebutuhan akan pendekatan berbasis data yang lebih objektif. Dengan kemajuan computer vision, kini tersedia peluang untuk mengembangkan sistem identifikasi gaya rambut yang akurat, konsisten, dan berbasis analisis data visual [2].

Gaya rambut dipandang sebagai elemen penting yang berperan besar dalam membentuk penampilan dan kepercayaan diri seseorang. Namun, banyak individu masih kesulitan menemukan potongan rambut yang sesuai dengan bentuk wajah dan tipe rambut mereka. Keterbatasan pengetahuan mengenai keterkaitan kedua aspek tersebut membuat pemilihan gaya rambut sering kali kurang optimal, bergantung pada intuisi penata rambut, atau sekadar mengikuti tren umum [3]. Kondisi ini menunjukkan perlunya solusi berbasis teknologi yang mampu memberikan personalisasi lebih mendalam melalui analisis data objektif.

Hasil survei Zen Beauty Index pada tahun 2024 memperkuat urgensi ini, dengan 96,7% pria Indonesia menyatakan bahwa rambut berpengaruh signifikan terhadap penampilan, dan 37,6% menilai rambut sebagai faktor yang sangat penting dalam menunjang penampilan sehari-hari. Fakta ini menegaskan bahwa rambut bukan hanya aspek estetika, tetapi juga menjadi bagian krusial dalam membangun citra diri. Oleh karena itu, diperlukan sistem identifikasi gaya rambut berbasis teknologi yang dapat memberikan rekomendasi personal sesuai karakteristik individu [4].

Penelitian sebelumnya menunjukkan efektivitas *Convolutional Neural Networks* (CNN) dalam klasifikasi gambar. Tan dan Le pada tahun 2019 memperkenalkan arsitektur *EfficientNet* yang mampu mencapai akurasi tinggi dengan efisiensi komputasi melalui *compound scaling* [5]. Sementara itu, Han pada tahun 2020 menegaskan keunggulan *ResNet* dalam mendistribusikan informasi antar-layer, yang menjadikannya efektif pada dataset kompleks [6]. Namun, hingga saat ini, fokus penelitian masih terbatas, dan belum banyak yang mengintegrasikan klasifikasi bentuk wajah dan tipe rambut sebagai dasar sistem identifikasi gaya rambut.

Preferensi masyarakat terhadap gaya rambut juga menunjukkan adanya variasi yang signifikan. Survei Zen Beauty Index pada tahun 2024 mengungkapkan bahwa potongan *taper cut* menjadi pilihan favorit lintas generasi pria Indonesia dengan persentase 29,5%. Temuan ini menegaskan bahwa preferensi gaya rambut sangat dipengaruhi faktor personal dan sosial, sehingga dibutuhkan pendekatan berbasis teknologi untuk memberikan rekomendasi yang lebih personal, akurat, dan relevan dengan karakteristik visual individu [7].


Urgensi penelitian semakin kuat dengan meningkatnya kebutuhan akan solusi personalisasi di industri kecantikan digital. Menurut data situs statista pada tahun 2024, pengguna platform kecantikan digital secara global diperkirakan mencapai 1,5 miliar orang. Tren perawatan diri yang semakin berkembang juga menunjukkan bahwa rambut memiliki peran penting dalam membangun rasa percaya diri. Oleh karena itu, penelitian ini menawarkan pendekatan berbasis deep learning untuk memberikan solusi praktis bagi masyarakat yang membutuhkan personalisasi gaya rambut berbasis data [8].

Penelitian ini berfokus pada pengembangan arsitektur CNN yang optimal untuk klasifikasi bentuk wajah dan tipe rambut dalam identifikasi gaya rambut. Pendekatan ini menggabungkan arsitektur *EfficientNet* yang unggul dalam efisiensi model dan akurasi melalui *compound scaling* [9], serta *ResNet* yang dirancang dengan *skip connections* untuk menjaga kestabilan distribusi informasi antar-layer, sehingga menghasilkan performa konsisten pada tugas klasifikasi

gambar [10]. Dengan kombinasi tersebut, sistem diharapkan mampu memberikan hasil identifikasi yang lebih akurat dan relevan.

Berdasarkan latar belakang tersebut, penelitian ini dirumuskan dengan fokus pada dua permasalahan utama, yaitu bagaimana arsitektur CNN dapat digunakan untuk menentukan gaya rambut yang sesuai melalui klasifikasi gambar berdasarkan bentuk wajah dan tipe rambut, serta bagaimana hasil identifikasi tersebut dapat divisualisasikan kepada pengguna melalui antarmuka website interaktif. Tujuan penelitian ini adalah mengembangkan dan mengevaluasi arsitektur CNN untuk klasifikasi gaya rambut, serta menyajikan hasil identifikasi melalui website berbasis Flask. Penelitian ini diharapkan memberikan manfaat akademis berupa kontribusi pada literatur di bidang machine learning, khususnya penerapan CNN dalam klasifikasi gambar, sekaligus manfaat praktis dengan menyediakan solusi berbasis computer vision untuk membantu individu memilih gaya rambut sesuai karakteristik personal [11]. Adapun batasan penelitian ditetapkan pada penggunaan arsitektur EfficientNet dan ResNet, dengan klasifikasi terbatas pada bentuk wajah dan tipe rambut tertentu, serta pengembangan aplikasi berbasis website.

II. METODE PENELITIAN



Gambar 1 Alur Penelitian

Penelitian ini menggunakan pendekatan kuantitatif dengan model klasifikasi gambar. Mengacu pada kerangka kerja CRISP-DM, penelitian berfokus pada identifikasi bentuk wajah dan jenis rambut, bukan pada pemberian identifikasi secara eksplisit. Hal ini untuk menyesuaikan fokus penelitian agar lebih terarah pada identifikasi visual berbasis CNN.

A. Business Understanding

Penelitian ini dilatarbelakangi oleh kebutuhan pasar akan personalisasi dalam industri kecantikan, khususnya dalam

pemilihan gaya rambut yang sesuai dengan karakteristik individu. Banyak pengguna mengalami kesulitan menemukan potongan rambut yang tepat karena pemilihan masih bersifat subjektif dan bergantung pada intuisi penata rambut atau tren umum. Oleh karena itu, penelitian ini berfokus pada pengembangan sistem berbasis deep learning yang mampu mengidentifikasi bentuk wajah dan tipe rambut pengguna secara akurat. Dengan menggabungkan arsitektur CNN, yaitu EfficientNet dan ResNet, sistem diharapkan dapat memberikan rekomendasi gaya rambut yang lebih relevan dan personal, sekaligus meningkatkan kepercayaan diri pengguna [12]. Implementasi sistem dalam platform berbasis website juga memberikan nilai tambah berupa kemudahan akses dan potensi adopsi yang lebih luas di kalangan masyarakat maupun praktisi industri kecantikan.

B. Data Understanding

Dataset yang digunakan dalam penelitian ini terdiri dari dua dataset sekunder Kaggle yaitu, *Face Shape Dataset* dan *Hair Type Dataset*, yang berisi citra wajah dan rambut dengan label sesuai kategori. *Face Shape Dataset* terdiri dari lima kelas bentuk wajah.

Tabel 1 Face Shape Dataset

Bentuk Wajah	Jumlah
Oval	1.000
Bulat	1.000
Persegi	1.000
Hati	1.000
Oblong	1.000

Sedangkan *Hair Type Dataset* mencakup empat kelas tipe rambut.

Tabel 2 Hair Type Dataset

Jenis Rambut	Jumlah
Lurus	1.000
Bergelombang	1.000
Keriting	1.000
Gimbal	1.000

Sebelum digunakan dalam pelatihan model, seluruh citra diseragamkan ukurannya menjadi 224×224 piksel, dilakukan normalisasi, augmentasi untuk variasi pencahayaan, serta deteksi wajah agar objek berada di tengah gambar. Proses pelabelan data bentuk wajah disusun ulang menjadi seperti tabel di bawah ini.

Tabel 3 Label Berdasarkan Data Kategori Bentuk Wajah

Label	Bentuk Wajah
Kelas 0	Bulat
Kelas 1	Ova;
Kelas 2	Persegi
Kelas 3	Hati
Kelas 4	Oblong

Sementara untuk label kategori jenis rambut disusun ulang menjadi seperti di bawah tabel di bawah ini.

Tabel 4 Label Berdasarkan Data Kategori Jenis Rambut


Jenis Rambut	Jumlah
Kelas 0	Lurus
Kelas 1	Bergelombang
Kelas 2	Keriting
Kelas 3	Gimbal

Penelitian terdahulu menunjukkan Face Shape Dataset telah digunakan dengan berbagai arsitektur CNN seperti InceptionV3, Xception, Swin Transformer, dan EfficientNetV2S, dengan akurasi berkisar 84–87%. Namun, sebagian besar studi hanya berfokus pada klasifikasi bentuk wajah secara tunggal tanpa mengintegrasikan tipe rambut. Sementara itu, penelitian terkait Hair Type Dataset masih terbatas, salah satunya menggunakan VGG16 dengan akurasi 59,61%, menunjukkan adanya peluang peningkatan performa dengan pendekatan arsitektur CNN yang lebih efisien.

C. Data Preparation

Proses ini dimulai dari pembersihan data dengan menghapus gambar rusak, sehingga dilakukan resizing seluruh citra menjadi 224×224 piksel, normalisasi nilai piksel sesuai kebutuhan arsitektur EfficientNet, serta pemberian label yang konsisten pada setiap kategori bentuk wajah dan jenis rambut.

Selanjutnya, dataset dibagi menjadi data latih, validasi, dan uji dengan beberapa skema perbandingan (90:10, 80:20, dan 70:30) guna mengevaluasi pengaruh proporsi data terhadap performa model. Untuk meningkatkan generalisasi, dilakukan augmentasi data berupa rotasi, zoom, pergeseran, flip horizontal, dan penyesuaian intensitas warna menggunakan ImageDataGenerator. Langkah ini memastikan distribusi data lebih beragam sekaligus mengurangi risiko overfitting pada model CNN yang digunakan.




Gambar 2 Alur Data Preparation

D. Modelling

Penelitian ini menggunakan dua arsitektur CNN yang berbeda sesuai dengan karakteristik data. EfficientNetB0 digunakan untuk klasifikasi bentuk wajah karena efisien secara komputasi namun tetap mampu menangkap pola global kontur wajah [13]. Sedangkan ResNet50 digunakan untuk klasifikasi jenis rambut karena keunggulannya dalam mengenali detail tekstur melalui residual connection [14].

Model dibangun menggunakan framework PyTorch dengan optimizer Adam yang adaptif, serta memanfaatkan GPU melalui CUDA untuk mempercepat pelatihan. Proses training dilakukan dengan membagi dataset menjadi training set dan validation set, serta melakukan optimasi hyperparameter seperti epoch, batch size, dan learning rate untuk mencapai keseimbangan antara akurasi dan stabilitas.


Untuk mencegah overfitting, diterapkan strategi early stopping, dropout, dan L2 regularization (weight decay). Model terbaik kemudian disimpan dalam format .pth untuk mendukung tahap deployment pada aplikasi berbasis website. Dengan pendekatan ini, sistem diharapkan mampu memberikan klasifikasi bentuk wajah dan tipe rambut secara akurat, serta mendukung rekomendasi gaya rambut yang lebih personal



Gambar 3 Diagram Modelling Data

1) Modeling dengan EfficientNetB0 (Klasifikasi Bentuk Wajah)


Flowchart pemodelan bentuk wajah menggunakan EfficientNetB0 diawali dengan *preprocessing* citra berupa *resize* ke ukuran 224×224 piksel dan normalisasi, kemudian



Gambar 4 Flowchart Modelling Bentuk Wajah

model EfficientNetB0 digunakan sebagai *base model* tanpa lapisan output yang ditambahkan lapisan klasifikasi sesuai jumlah kelas, dan tahap akhir dilakukan kompilasi menggunakan Adam optimizer dengan *loss function categorical crossentropy* serta metrik evaluasi akurasi, presisi, dan recall.

2) Modeling dengan ResNet50 (Klasifikasi Jenis Rambut)



Gambar 5 Flowchart Modelling Jenis Rambut

Flowchart pemodelan jenis rambut menggunakan ResNet50 diawali dengan *preprocessing* citra berupa *resize* ke ukuran 224×224 piksel dan normalisasi menggunakan *resnet50.preprocess_input*, kemudian ResNet50 dijadikan base model dengan penambahan lapisan klasifikasi sesuai jumlah kelas. Model dikompilasi menggunakan Adam optimizer dengan *loss function categorical crossentropy*, serta dievaluasi dengan metrik akurasi, presisi, recall, F1-score, dan MSE. Pemilihan ResNet50 didasarkan pada kompleksitas visual rambut yang lebih tinggi dibanding bentuk wajah, karena tekstur, volume, dan arah pertumbuhan rambut memerlukan arsitektur dalam dengan *residual connections* untuk mempertahankan informasi fitur penting dan mencegah masalah *vanishing gradient*.

E. Tuning Hyperparameter

Setelah pemodelan CNN berbasis EfficientNetB0 dan ResNet50, dilakukan *tuning hyperparameter* melalui pendekatan *grid search* dan *experimental tuning* untuk mengoptimalkan performa klasifikasi bentuk wajah dan jenis rambut. Parameter yang diuji meliputi *learning rate* (0.1, 0.01, 0.001, 0.0001), *batch size* (16, 32, 64), serta dropout rate pada *fully connected layer* (0.2, 0.3, 0.5), dengan Adam optimizer sebagai pilihan utama. Proses ini bertujuan memperoleh akurasi tertinggi dengan stabilitas *loss function* yang baik, sekaligus meminimalkan risiko *overfitting*.

F. Evaluasi Model

Tahap evaluasi dilakukan dengan membandingkan performa EfficientNet (klasifikasi bentuk wajah) dan ResNet (klasifikasi jenis rambut) menggunakan metrik Confusion Matrix, Akurasi, Presisi, Recall, F1-Score, serta MSE.

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

Gambar 6 Confusion Matrix


Confusion Matrix digunakan untuk melihat distribusi prediksi benar dan salah pada tiap kelas, sementara akurasi mengukur kebenaran klasifikasi secara keseluruhan. Presisi dan recall menilai ketepatan serta kemampuan model mengenali tiap kelas, dan F1-Score mengukur keseimbangan keduanya. Hasil evaluasi menunjukkan bahwa kombinasi EfficientNet dan ResNet memberikan performa klasifikasi yang baik, dengan MSE membantu mengidentifikasi deviasi yang perlu diperbaiki pada iterasi selanjutnya.

G. Validasi Model

Untuk memastikan generalisasi model, penelitian ini menggunakan *k-fold cross-validation* pada arsitektur EfficientNet (bentuk wajah) dan ResNet (jenis rambut) dengan variasi 3, 5, dan 10 lipatan. Teknik ini membagi dataset menjadi beberapa fold, di mana setiap fold bergantian digunakan sebagai data uji dan sisanya sebagai data latih, sehingga seluruh data dapat dievaluasi secara menyeluruh. Pendekatan ini bertujuan menghasilkan evaluasi performa yang lebih akurat, stabil, dan tidak bergantung pada pembagian data tertentu, sekaligus mengurangi risiko overfitting. Evaluasi pada tiap fold dilakukan menggunakan metrik akurasi, presisi, *recall*, dan *f1-score*.

H. Deployment

Tahap deployment dalam penelitian ini menggunakan pendekatan *Rapid Application Development* (RAD) yang menekankan kecepatan dan iterasi melalui prototipe, sehingga sistem dapat divalidasi dan disesuaikan secara berkelanjutan.



Gambar 7 Framework Rapid Application Development

Proses RAD dibagi menjadi empat tahap, yaitu:

1) Requirement Planning (Perencanaan Kebutuhan)

Tahap ini mencakup identifikasi kebutuhan fungsional dan non-fungsional sistem. Kebutuhan fungsional meliputi fitur unggah gambar wajah, klasifikasi bentuk wajah dan jenis rambut, serta rekomendasi gaya rambut berbasis hasil klasifikasi dan *expert system*. Kebutuhan non-fungsional difokuskan pada atribut kualitas dan batasan teknis untuk menjamin performa sistem. Mekanisme klasifikasi juga dibatasi dengan nilai *confidence score* $\geq 50\%$ untuk menjaga keandalan hasil prediksi.

2) User Design (Desain Pengguna)

Antarmuka website dirancang sederhana namun informatif, terdiri dari tiga komponen utama: (a) halaman unggah foto, (b) tampilan hasil klasifikasi bentuk wajah dan jenis rambut beserta *confidence score*, serta (c) daftar rekomendasi gaya rambut yang dihasilkan melalui *rule engine* berbasis kombinasi hasil klasifikasi. Prototipe antarmuka dibangun menggunakan HTML dan CSS untuk memudahkan interaksi pengguna.

3) Construction (Konstruksi Sistem)

Tahap ini melibatkan integrasi *frontend*, *backend*, model deep learning, dan *expert system*. Bagian *frontend* dibangun dengan HTML dan CSS untuk menampilkan input gambar serta hasil klasifikasi. *Backend* menggunakan Flask sebagai server yang mengatur komunikasi dengan model CNN, yaitu EfficientNetB0 untuk klasifikasi bentuk wajah dan ResNet50 untuk klasifikasi jenis rambut. Setelah kedua hasil klasifikasi diperoleh, sistem rekomendasi dijalankan menggunakan *expert system* yang dibangun berdasarkan wawancara dengan pemilik barbershop (rambut pria) dan salon (rambut wanita), sehingga sistem menghasilkan saran gaya rambut yang relevan sesuai kombinasi bentuk wajah dan jenis rambut.

4) Cutover (Implementasi)

Tahap akhir berupa transisi sistem dari pengembangan menuju penggunaan nyata. Sebelum dioperasikan penuh, dilakukan pengujian menggunakan metode *Black-Box Testing* untuk memastikan fungsionalitas utama berjalan sesuai spesifikasi, khususnya pada fitur unggah gambar, proses klasifikasi, serta keluaran rekomendasi gaya rambut.

III. HASIL DAN PEMBAHASAN

Subbab ini menjelaskan hasil dari setiap proses implementasi yang sudah dijabarkan peneliti pada bab 2 sebelumnya.

A. Preprocessing Data

Tahap preprocessing data dilakukan untuk memastikan kualitas dan konsistensi dataset sebelum pelatihan model deep learning. Proses ini meliputi:

1. Penghapusan gambar buram. Gambar yang tidak jelas dihilangkan karena berpotensi mengganggu ekstraksi fitur oleh CNN.
2. Penghapusan gambar tidak terfokus atau terpotong. Gambar dengan detail terbatas yang menyulitkan model dalam mengenali objek dihapus dari dataset.
3. Penghapusan gambar tidak relevan. Gambar yang tidak sesuai dengan kategori penelitian, seperti brosur atau iklan, dibuang.
4. Penghapusan gambar dengan teks berlebihan. Gambar yang mengandung tulisan atau elemen visual mengganggu dikeluarkan dari dataset.
5. Resizing citra – seluruh gambar diseragamkan ke ukuran 224x224 piksel agar sesuai dengan dimensi input model CNN dan menjaga keseimbangan antara detail visual serta efisiensi komputasi.

B. Pengolahan Data

Pada tahap pemodelan, digunakan dua arsitektur CNN secara paralel untuk tugas klasifikasi spesifik, yaitu EfficientNetB0 untuk klasifikasi bentuk wajah dan ResNet50 untuk klasifikasi jenis rambut.

1) Modeling dengan EfficientNetB0 (Klasifikasi Bentuk Wajah)

Model klasifikasi bentuk wajah dibangun dengan pendekatan transfer learning menggunakan bobot EfficientNetB0 yang telah dilatih pada dataset ImageNet.

- Base Model: EfficientNetB0 dimuat tanpa lapisan klasifikasi teratas (*include_top=False*) sehingga lapisan konvolusinya berfungsi sebagai *feature extractor*.
- Custom Layers: Ditambahkan beberapa lapisan penyesuaian, yaitu *GlobalAveragePooling2D* untuk mereduksi *feature map* menjadi vektor satu dimensi, *dropout* dengan tingkat 0.3 untuk mencegah *overfitting*, *dense layer* dengan aktivasi *Softmax* dan 5 unit output sesuai jumlah kelas bentuk wajah (oval, bulat, persegi, hati, dan oblong).
- Kompilasi Model: Proses pelatihan dikonfigurasi dengan *optimizer* Adam, fungsi kerugian *categorical_crossentropy*, serta metrik evaluasi berupa akurasi, presisi, dan recall.

Tabel 5 Nilai Akurasi Berdasarkan Split Data EfficientNet

Epoch	70:30	80:20	90:10
5	32.15%	34.85%	36.44%
10	44.71%	47.88%	49.56%
15	52.14%	54.73%	57.33%
20	53.98%	56.15%	58.00%
25	67.93%	70.81%	72.44%

2) Modeling dengan ResNet50 (Klasifikasi Jenis Rambut)

Arsitektur ResNet50 dipilih untuk klasifikasi jenis rambut karena kemampuannya dalam mengatasi masalah *vanishing gradient* melalui mekanisme *skip connections*. Dengan karakteristik tersebut, ResNet50 memungkinkan pembangunan model yang sangat dalam (*deep*) dan efektif dalam mempelajari fitur kompleks, termasuk tekstur dan pola rambut yang bervariasi.

- Base Model: ResNet50 dimanfaatkan sebagai model dasar tanpa lapisan klasifikasi teratas (*include_top=False*), sehingga berfungsi sebagai *feature extractor*.
- Custom Layers: Ditambahkan beberapa lapisan penyesuaian, yaitu: *GlobalAveragePooling2D* untuk merangkum *feature map*, *dropout* dengan tingkat 0.3 sebagai regularisasi untuk mencegah *overfitting*, *dense layer* dengan aktivasi *Softmax* dan 5 unit output sesuai jumlah kelas jenis rambut (lurus, keriting, gelombang, dan gimbal).
- Kompilasi Model: Proses pelatihan dikonfigurasi dengan *optimizer* Adam, fungsi kerugian *categorical_crossentropy*, serta metrik evaluasi berupa akurasi, presisi, recall, dan f1-score.

3) Turning Hyperparameter

Proses tuning dilakukan dengan pendekatan manual (manual tuning) dan eksperimen bertahap dengan memvariasikan kombinasi parameter utama. Tabel 2 berikut menunjukkan kombinasi *hyperparameter* yang digunakan selama eksperimen:

Tabel 6 Turning Hyperparameter


No	Model	Learning Rate	Optimizer	Dropout	Batch Size
1	EfficientNet	0.1	Adam	0.2	16
2	EfficientNet	0.01	Adam	0.2	16
3	EfficientNet	0.001	Adam	0.2	16
4	EfficientNet	0.0001	Adam	0.2	16
5	ResNet50	0.0001	Adam	0.3	32
6	ResNet50	0.0005	Adam	0.2	32
7	ResNet50	0.0001	Adam	0.4	64

Berdasarkan hasil beberapa eksperimen, konfigurasi terbaik untuk masing-masing model adalah sebagai berikut

Tabel 7 Konfigurasi Terbaik


Deskripsi	EfficientNetB0 (Bentuk Wajah)	ResNet50 (Jenis Rambut)
Learning Rate	0.0001	0.0001
Optimizer	Adam	Adam
Dropout	0.3	0.3
Batch Size	32	32

Setelah proses *tuning hyperparameter*, model dilatih ulang menggunakan kombinasi parameter terbaik untuk memaksimalkan performa klasifikasi. Parameter seperti *learning rate* rendah untuk kestabilan pembelajaran, *dropout* optimal untuk mencegah *overfitting*, serta pemilihan *optimizer* adaptif seperti Adam memberikan kondisi pelatihan yang seimbang antara generalisasi dan akurasi.



Gambar 8 Confusion Matrix Model ResNet50

Hasil confusion matrix untuk model ResNet50 pada klasifikasi bentuk wajah, model menunjukkan performa yang cukup baik.



Gambar 9 Confusion Matrix Model EfficientNetB0

Sementara itu, Gambar 8 menampilkan *confusion matrix* dari model EfficientNetB0 untuk klasifikasi jenis wajah, dan memperlihatkan kinerja yang sangat optimal.

4) Evaluasi Performa

Tabel 8 Hasil Evaluasi Model ResNet50 pada Klasifikasi Jenis Rambut

Test Accuracy: 0.945

Classification Report:

	precision	recall	f1-score	support
0	1.00	0.93	0.97	60
1	0.83	0.97	0.90	36
2	0.92	0.90	0.91	39
3	1.00	0.95	0.98	44
4	0.95	1.00	0.98	21
accuracy			0.94	200
macro avg	0.94	0.95	0.95	200
weighted avg	0.95	0.94	0.95	200

Model ResNet50 mencapai akurasi lebih dari 94% dengan precision, recall, dan F1-score tinggi serta merata di seluruh kelas rambut, menunjukkan kinerja seimbang tanpa bias. Hal ini menegaskan kemampuan model dalam mengekstrak fitur tekstur rambut secara efisien sehingga layak diintegrasikan ke dalam sistem identifikasi gaya rambut berbasis website dengan performa stabil dan akurat.

Tabel 9 Hasil Evaluasi Model EfficientNetB0 pada Klasifikasi Bentuk Wajah

Precision (macro)	0.7135
Recall (macro)	0.7120
F1 Score (macro)	0.7114


Nilai F1-score secara keseluruhan menunjukkan stabilitas dan konsistensi model dalam melakukan klasifikasi. Hal ini menunjukkan bahwa EfficientNetB0 memiliki potensi sebagai arsitektur dasar dalam proses klasifikasi wajah yang kompleks, terutama jika dikombinasikan dengan teknik augmentasi data atau transfer learning lanjutan.

C. Deployment (Implementasi)

Setelah model dievaluasi dan terbukti memiliki performa yang optimal, langkah terakhir adalah implementasi


(deployment) model ke dalam sebuah aplikasi yang dapat diakses oleh pengguna akhir.

1) Tampilan Website



Gambar 10 Tampilan Halaman Utama

. Halaman utama menampilkan judul “Hair Style Identification” secara menonjol, disertai deskripsi singkat yang mengarahkan pengguna mengunggah foto wajah melalui kotak unggah minimalis dengan ikon dan teks petunjuk “Pilih atau seret gambar ke sini”, serta tombol biru “Prediksi Sekarang” di bawahnya yang memberikan kontras jelas sekaligus menandai langkah aksi berikutnya.



Gambar 11 Tampilan Halaman Prediksi

Setelah pengguna mengunggah foto, sistem menampilkan halaman hasil prediksi dengan foto yang diunggah ditampilkan menonjol di bagian tengah sebagai verifikasi input, diikuti ringkasan hasil berupa bentuk wajah dan tipe rambut dengan tipografi jelas. Aplikasi kemudian menyajikan daftar rekomendasi gaya rambut dalam format poin yang ringkas dan mudah dibaca.

2) Tampilan Website

Pengujian sistem dilakukan menggunakan pendekatan *black-box testing*, yaitu metode uji fungsional yang menilai kinerja aplikasi berdasarkan interaksi input dan output tanpa memeriksa logika internal atau kode program. Pengujian ini berfokus pada evaluasi dari perspektif pengguna akhir untuk memastikan integritas dan reliabilitas fungsionalitas sistem. Tujuannya adalah:

- Setiap fitur berjalan sesuai dengan yang diharapkan.

- b) Aplikasi menghasilkan output yang benar dan relevan untuk setiap input.
- c) Antarmuka pengguna responsif serta bebas dari bug atau kesalahan.

Hasil pengujian dengan metode ini disajikan pada tabel berikut.

Tabel 10 Hasil Pengujian Black-box Testing

Halaman Pengujian	Test Case	Hasil yang Diharapkan	Berjalan
Halaman Utama	User memilih gambar wajah lalu menekan tombol Upload.	Sistem menerima file gambar dalam format .jpg/.png dan menampilkannya pada halaman utama sebagai input.	✓
Halaman Prediksi	User menekan tombol Prediksi setelah gambar berhasil diunggah.	Sistem memproses gambar, melakukan klasifikasi bentuk wajah dengan model EfficientNetB0, klasifikasi jenis rambut dengan model ResNet50, dan menampilkan hasil di halaman utama.	✓
Halaman Utama	Setelah proses klasifikasi selesai, sistem menampilkan hasil prediksi.	Website menampilkan bentuk wajah, jenis rambut, serta daftar rekomendasi gaya rambut yang sesuai, di bawah tombol prediksi.	✓

Selain pengujian black-box untuk memastikan seluruh fitur website berfungsi dengan baik, dilakukan juga pengujian model menggunakan data uji yang belum pernah digunakan dalam pelatihan. Data ini berupa citra nyata dengan variasi bentuk, pencahayaan, dan latar belakang, bertujuan menilai kemampuan model dalam melakukan generalisasi terhadap data baru.

IV. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian dan implementasi yang dilakukan, diperoleh beberapa kesimpulan sebagai berikut:

1. Penelitian berhasil menerapkan alur kerja CRISP-DM secara menyeluruh, mulai dari business understanding, data understanding, data preparation (termasuk augmentasi), modeling berbasis transfer learning, evaluasi, hingga implementasi dalam aplikasi berbasis web.
2. Dua arsitektur CNN, yaitu EfficientNetB0 untuk klasifikasi bentuk wajah dan ResNet50 untuk klasifikasi jenis rambut, berhasil diintegrasikan ke dalam satu sistem identifikasi. Model EfficientNetB0

mencapai akurasi validasi 72,44%, sedangkan ResNet50 mencapai akurasi validasi 92,96%.

3. Sistem identifikasi gaya rambut berbasis website berhasil dikembangkan, memungkinkan pengguna untuk mengunggah foto wajah dan memperoleh hasil klasifikasi bentuk wajah serta jenis rambut secara otomatis dan cepat.
4. Hasil pengujian dengan pendekatan black-box dan data uji nyata menunjukkan bahwa sistem memiliki kemampuan generalisasi yang baik terhadap variasi kondisi dunia nyata, seperti latar belakang, pencahayaan, dan ekspresi wajah.

REFERENSI

- [1] M. Farwati, I. T. Salsabila, K. R. Navira, and T. Sutabri, "Analisa pengaruh teknologi artificial intelligence (AI) dalam kehidupan sehari-hari," *Jursima*, vol. 11, no. 1, pp. 39-45, 2023.
- [2] I. Arifin, R. F. Haidi, and M. Dzalhaqi, "Penerapan computer vision menggunakan metode deep learning pada perspektif generasi ulul albab," *Jurnal Teknologi Terpadu*, vol. 7, no. 2, pp. 98-107, 2021.
- [3] Y. Ramadhan and D. Games, "Pengaruh Kualitas Pelayanan Dan Kepercayaan Terhadap Loyalitas Pelanggan Dengan Kepuasan Pelanggan Sebagai Variabel Intervening Pada Pelanggan Pangkas Rambut Densiko Bukittinggi," *Media Manajemen Jasa*, vol. 11, no. 1, pp. 45-55, 2023.
- [4] N. A. Ulfah, "Korelasi Rambut Berwarna dengan Stigma Kecantikan Perempuan Urban: Studi Kasus Kota Semarang," *Jurnal Multidisiplin Dehasen (MUDE)*, vol. 3, no. 4, pp. 307-316, 2024.
- [5] M. Tan and Q. Le, "Efficientnetv2: Smaller models and faster training," *International Conference on Machine Learning*, PMLR, 2021, pp. 10096-10106.
- [6] C. Han and L. Shi, "ML-ResNet: A novel network to detect and locate myocardial infarction using 12 leads ECG," *Computer methods and programs in biomedicine*, vol. 185, 2020, Art. no. 105138.
- [7] A. Maghfiroh, N. A. Nurhayati, I. Atikah, N. Ifrina, 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, 2025.
- [8] F. Sulianta, *Masyarakat digital: Tren, tantangan, dan perubahan di era teknologi*. Feri Sulianta, 2025.
- [9] C. Lin, P. Yang, Q. Wang, Z. Qiu, W. Lv, and Z. Wang, "Efficient and accurate compound scaling for convolutional neural networks," *Neural Networks*, vol. 167, pp. 787-797, 2023.
- [10] C. Chen and F. Qi, "Single image super-resolution using deep CNN with dense skip connections and inception-resnet," *2018 9th International Conference on Information Technology in Medicine and Education (ITME)*, 2018, pp. 999-1003. IEEE.
- [11] R. Firmansyah, *Implementasi deep learning menggunakan convolutional neural network untuk klasifikasi bunga*, B.S. thesis, Fakultas Sains dan Teknologi, UIN Syarif Hidayatullah Jakarta, 2021.
- [12] L. I. Kesuma, "ELREI: Ensemble Learning of ResNet, EfficientNet, and Inception-v3 for Lung Disease Classification based on Chest X-Ray Image," *International Journal of Intelligent Engineering & Systems*, vol. 16, no. 5, 2023.
- [13] I. N. Alam, "Metode Transfer Learning Pada Deep Convolutional Neural Network (DCNN) untuk Pengenalan Ekspresi Wajah," *ResearchGate*, no. October, pp. 13-14, 2022.
- [14] M. I. Anshori, M. A. Z. Sidiq, R. A. Yaqin, and I. W. P. Agung, "Klasifikasi Jenis Jerawat Secara Otomatis Dengan Convolutional Neural Network Menggunakan Arsitektur Resnet-50," *Jurnal Manajemen Informatika (JAMIKA)*, vol. 15, no. 1, pp. 73-84, 2025.