

SISTEM PENGENALAN GENDER OTOMATIS MELALUI ANALISIS CITRA MATA: MENGGUNAKAN HYBRID PRE- TRAINED CONVOLUTIONAL NEURAL NETWORK- HAAR CASCADE CLASSIFIER

AUTOMATIC GENDER RECOGNITION SYSTEM THROUGH EYE IMAGE ANALYSIS: USING A HYBRID PRE-TRAINED CONVOLUTIONAL NEURAL NETWORK- HAAR CASCADE CLASSIFIER

¹Arvian Sofyan Majid, ² Hanif Al Fatta

^{1,2} Teknik Informatika, Universitas Amikom Yogyakarta, Indonesia

^{1*}arvian@students.amikom.ac.id, ²hanif.a@amikom.ac.id

Received:
27 January 2026

Revised:
2 February 2026

Accepted:
31 July 2026

Published:
4 August 2026

ABSTRAK

Perkembangan sistem cerdas berbasis pengolahan citra digital telah mendorong penerapan identifikasi jenis kelamin secara *automatic* pada berbagai bidang, seperti pada keamanan dan pengawasan. Namun, pada kondisi dunia nyata seperti rekaman CCTV atau penggunaan alat pelindung diri, wajah seseorang sering tertutup sebagian sehingga metode identifikasi berbasis wajah penuh menjadi kurang efektif. Pada penelitian ini, mengusulkan sebuah sistem pengenalan gender secara otomatis berbasis analisis citra mata dengan mengombinasikan *pretrained Convolutional Neural Network* (CNN) dan *Haar Cascade Classifier*. CNN digunakan dalam melakukan klasifikasi gender, sedangkan *Haar Cascade* digunakan dalam melakukan deteksi dan ekstraksi area mata sebagai *Region of Interest* (ROI). Dua arsitektur CNN yang menjadi rekomendasi yaitu VGG16 dan MobileNetV2, dibandingkan untuk mengevaluasi performa dari sistem. Adapun proses *preprocessing* meliputi perubahan ukuran citra (*resize*), normalisasi nilai piksel, serta augmentasi data untuk meningkatkan generalisasi suatu model. Evaluasi dilakukan dengan menggunakan metrik *accuracy*, *precision*, *recall*, dan *f1-score*. Hasil pengujian menunjukkan bahwa VGG16 memberikan performa terbaik dengan akurasi sebesar 96%, sedangkan MobileNetV2 mencapai akurasi 94%. Selain itu, VGG16 juga menunjukkan kemampuan yang lebih baik dalam mengenali kelas minoritas. Hasil implementasi pada sistem membuktikan bahwa pendekatan yang diusulkan mampu bekerja secara efektif pada kondisi wajah tertutup sebagian, sehingga berpotensi diterapkan pada sistem pengawasan berbasis kamera dengan keterbatasan visual.

Kata Kunci : Citra Mata, Convolutional Neural Network, Haar Cascade Classifier, Pengenalan Gender.

ABSTRACT

The development of intelligent systems based on digital image processing has encouraged the application of automatic gender identification in various fields, such as security and surveillance. However, in real-world conditions such as CCTV footage or the use of personal protective equipment, a person's face is often partially covered, making full-face identification methods less effective. In this study, we propose an automatic gender recognition system based on eye image analysis by combining a pretrained Convolutional Neural Network (CNN) and a Haar Cascade Classifier. CNN is used to perform gender classification, while Haar Cascade is used to detect and extract the eye area as a Region of Interest (ROI). Two recommended CNN architectures, VGG16 and MobileNetV2, are compared to evaluate the system's performance. The preprocessing process includes image resizing, pixel value normalization, and data augmentation to improve the generalization of a model. Evaluation is carried out using accuracy, precision, recall, and f1-score metrics. The test results show that VGG16 provides the best performance with an accuracy of 96%, while MobileNetV2 achieves an accuracy of 94%. Furthermore, VGG16 also demonstrated superior recognition capabilities for minority classes. Implementation results demonstrate that the proposed

approach works effectively under partially obscured face conditions, potentially making it applicable to camera-based surveillance systems with visual impairments.

Keywords : *Eye Image, Convolutional Neural Network, Haar Cascade Classifier, Gender Recognition.*

PENDAHULUAN

Perkembangan pesat Teknologi Informasi dan Komunikasi telah mendorong pemanfaatan sistem cerdas berbasis *machine learning* dan *deep learning* dalam berbagai bidang, khususnya pada pengolahan citra digital (Pandimurugan, Jain, & Sinha, 2020). Salah satu penerapan yang banyak dikembangkan adalah sistem identifikasi otomatis, seperti pengenalan wajah dan pengenalan jenis kelamin (Jung, An, Kwak, Salminen, & Jansen, 2018). Identifikasi jenis kelamin memiliki peran penting dalam berbagai aplikasi, antara lain sistem keamanan, pengawasan berbasis kamera, analisis perilaku, serta sistem interaksi manusia dan komputer (Vani, Raajan, Haretha Winnmalar., & Sudharsan, 2020).

Berbagai penelitian terdahulu menunjukkan bahwa identifikasi jenis kelamin dapat dilakukan melalui beragam pendekatan, seperti analisis citra wajah (Serna, Pena, Morales, & Fierrez, 2020), tulisan tangan (Topaloglu & Ekmekci, 2017) (Gumilang & Avianto, 2023), suara (Mamyrbayev, Toleu, Tolegen, Mekebayev, & Pham, 2020), bahkan pada sidik jari (Narayanan & K, 2019). Di antara pendekatan tersebut, metode berbasis citra wajah dengan memanfaatkan *Convolutional Neural Network* (CNN) menunjukkan performa yang sangat baik karena kemampuannya dalam mengekstraksi fitur visual secara otomatis. Model CNN, baik arsitektur standar maupun *pretrained* model seperti VGG, ResNet, dan MobileNet, telah banyak digunakan untuk meningkatkan akurasi klasifikasi, terutama pada dataset berukuran besar maupun terbatas.

Meskipun demikian, dalam kondisi dunia nyata sering ditemukan keterbatasan yang membuat metode identifikasi berbasis wajah penuh menjadi kurang efektif. Pada rekaman CCTV, kejadian kriminal, atau lingkungan kerja dan kesehatan, wajah subjek kerap tertutup oleh masker, helm, cadar atau alat pelindung diri lainnya. Selain itu, faktor pencahayaan yang rendah, sudut pengambilan gambar yang tidak ideal, serta resolusi citra yang rendah semakin memperumit proses identifikasi wajah secara utuh. Kondisi ini menyebabkan sebagian besar fitur wajah tidak dapat dimanfaatkan, sehingga sistem identifikasi konvensional mengalami penurunan performa.

Dalam situasi tersebut, area mata menjadi salah satu bagian wajah yang paling sering terekam dengan jelas. Mata dan area sekitarnya memiliki karakteristik morfologis tertentu, seperti bentuk mata, lipatan kelopak, tekstur kulit, dan pola alis yang dapat digunakan sebagai fitur visual untuk membedakan jenis kelamin (Cimtay & Yilmaz, 2021). Beberapa penelitian sebelumnya, telah membuktikan bahwa citra mata sudah cukup informatif untuk melakukan klasifikasi jenis kelamin dengan tingkat akurasi yang kompetitif, terutama ketika diproses menggunakan model CNN berbasis *transfer learning* (Abdalrady & Aly, 2020) (Cimtay & Yilmaz, 2021) (Greco, Saggese, Vento, & Vigilante, 2020).


Selain metode klasifikasi, tahap deteksi objek juga memiliki peran penting dalam sistem pengenalan berbasis citra. Metode deteksi seperti *Haar Cascade Classifier* dikenal memiliki keunggulan dalam hal kecepatan dan efisiensi komputasi, sehingga masih relevan untuk aplikasi *realtime* dan perangkat dengan sumber daya yang terbatas (C, Sankar, & Reddy, 2025) (Andrean, et al., 2024) (Naser, et al., 2025) (Rastogi & Ryuh, 2019). Penggunaan *Haar Cascade* untuk mendeteksi area mata memungkinkan sistem untuk melakukan ekstraksi *Region of Interest* (ROI) secara cepat sebelum dilakukan proses klasifikasi dengan menggunakan CNN.

Berdasarkan permasalahan tersebut, penelitian ini mengusulkan sebuah sistem pengenalan jenis kelamin secara otomatis melalui analisis citra mata dengan pendekatan *hybrid* antara *Convolutional Neural Network* dan *Haar Cascade Classifier*. *Haar Cascade* digunakan pada tahap awal guna mendeteksi dan mengekstraksi area mata, sedangkan CNN berbasis *pretrained model* digunakan dalam melakukan klasifikasi jenis kelamin. Dalam penelitian ini, dua arsitektur CNN yaitu VGG16 dan MobileNetV2, dibandingkan untuk mengevaluasi performa sistem dari segi akurasi dan kemampuan mengenali kelas minoritas. Pendekatan diharapkan mampu menghasilkan sistem pengenalan jenis kelamin yang tidak hanya akurat, namun juga *robust* terhadap kondisi wajah tertutup sebagian serta layak diterapkan pada skenario dunia nyata.

METODE

Tahapan Penelitian

Penelitian ini dilakukan melalui beberapa tahapan utama yang mencakup pengumpulan data, *preprocessing* citra, deteksi area mata, klasifikasi jenis kelamin menggunakan *Convolutional Neural Network* (CNN), serta evaluasi performa sistem. Alur umum sistem dimulai dari citra masukan, dilanjutkan dengan deteksi area mata menggunakan *Haar Cascade Classifier*, *preprocessing* citra mata, proses klasifikasi jenis kelamin menggunakan CNN dan diakhiri dengan evaluasi hasil prediksi.



Gambar 1 Diagram Alur Sistem

Dataset

Dataset yang digunakan dalam penelitian ini berupa citra mata yang telah dipisahkan berdasarkan jenis kelamin, yaitu kelas laki-laki dan perempuan. Dataset yang digunakan bersumber dari dua platform terpercaya. Sumber pertama berasal dari Website *Kaggle* yang dikontribusikan oleh PAVELBIZ, menyediakan 11.525 citra mata. Sementara itu, sumber kedua diperoleh dari Website *MRL Eye Dataset* yang dikembangkan oleh Radovan Fusek, dengan menyediakan 25.770 citra mata. Total keseluruhan dataset yaitu 37.295 citra mata, dengan distribusi 25.952 citra laki-laki dan 11.343 citra perempuan. Dataset ini mencerminkan kondisi *class imbalance* yang umum ditemukan pada data dunia nyata.


Data dibagi menjadi dua bagian, yaitu 70% data latih dan 30% data uji, dengan pembagian dilakukan secara *stratified* untuk menjaga proporsi kelas pada masing-masing subset. Pembagian bertujuan untuk memastikan proses pelatihan dan evaluasi model dilakukan secara adil dan representatif.

Table 1 Distribusi Dataset Citra Mata Berdasarkan Kelas Gender

Label	Count
maleeyes	25952
femaleeyes	11343

Preprocessing Citra

Tahap *preprocessing* dilakukan untuk memastikan keseragaman dan kualitas data sebelum diproses oleh model CNN. Setiap citra mata diubah ukurannya menjadi 64x64 piksel, kemudian dilakukan normalisasi nilai piksel ke rentang 0-1. Karena model CNN yang digunakan merupakan *pretrained model* yang dilatih pada citra RGB, citra mata *grayscale* dikonversi menjadi tiga kanal tanpa mengubah informasi visual utama.



Gambar 2 Grayscale Citra Mata

Dataset dibagi menjadi 70% untuk *training data*, dan 30% untuk *testing data* menggunakan teknik *stratified sampling* untuk menjaga distribusi kelas antara data latih dan data uji. Label kelas direpresentasikan dalam bentuk *one-hot encoding* untuk mendukung proses pelatihan model CNN. Proses ini menghasilkan 26.106 citra mata pada data pelatihan, dan 11.189 citra mata pada data pengujian.

Table 2 Split Data Pelatihan dan Pengujian

Subset	Jumlah Citra
Training (70%)	26.106
Testing (30%)	11.189

Selain itu, untuk meningkatkan kemampuan generalisasi model dan mengurangi risiko *overfitting*, diterapkan teknik *data augmentation* yang meliputi rotasi ringan pada citra hingga $\pm 10^\circ$ dan *zooming* sebesar 10%. Pendekatan ini membantu model untuk mengenali variasi citra mata yang mungkin muncul pada kondisi dunia nyata. Mengingat distribusi dataset yang tidak seimbang atau *imbalanced data* antara kelas laki-laki dan perempuan, penelitian ini menerapkan pendekatan *class weighting* pada proses pelatihan. Bobot kelas dihitung berdasarkan proporsi masing-masing kelas pada data pelatihan, sehingga model tidak akan bias terhadap kelas mayoritas dan mampu meningkatkan sensitivitas terhadap kelas minoritas.

Arsitektur VGG16

Pada penelitian ini, memanfaatkan pendekatan *transfer learning* dengan menggunakan arsitektur VGG16 yang telah dilatih sebelumnya pada dataset *ImageNet* sebagai *feature extractor* (Yilmaz, Demircali, Kocaman, & Uvet, 2020). Lapisan klasifikasi bawaan VGG16 dihilangkan (*include_top = false*), dan seluruh lapisan konvolusi dibekukan untuk mempertahankan representasi fitur visual yang telah dipelajari. Pendekatan ini bertujuan untuk meningkatkan efisiensi pelatihan serta mengurangi risiko terhadap *overfitting*, mengingat keterbatasan dan kompleksitas visual yang ada pada dataset citra mata. VGG16 dipilih karena terbukti memiliki ketahanan yang baik terhadap gangguan visual seperti *noise* dan *blur* pada berbagai penelitian sebelumnya (Cimtay & Yilmaz, 2021).

Setelah proses ekstraksi fitur menggunakan VGG16, ditambahkan lapisan klasifikasi (*classifier head*) berupa *Flatten layer* yang diikuti oleh dua *fully connected layer* dengan masing-masing 1024 dan 512 *neuron* menggunakan fungsi aktivasi SELU. Penggunaan fungsi aktivasi SELU bertujuan untuk menjaga stabilitas distribusi aktivasi dan mempercepat konvergensi selama proses pelatihan. Lapisan keluaran menggunakan fungsi aktivasi *Softmax* untuk melakukan klasifikasi ke dalam dua kelas jenis kelamin. Seluruh lapisan pada VGG16 dibekukan, sehingga hanya lapisan klasifikasi yang dilatih selama proses pembelajaran.

Aristektur MobileNetV2


Sebagai model pembanding, penelitian ini menggunakan arsitektur MobileNetV2 yang telah dilatih sebelumnya pada dataset *ImageNet*. Lapisan klasifikasi bawaan dihilangkan, dan seluruh lapisan konvolusi dibekukan untuk mempertahankan representasi fitur awal. MobileNetV2 dipilih karena arsitekturnya yang ringan dan efisien, sehingga umum digunakan pada aplikasi *realtime* dan perangkat

dengan sumber daya terbatas. Meskipun MobileNetV2 secara default dilatih pada citra berukuran 224x224 piksel, pada penelitian ini model digunakan dengan ukuran input 64x64 piksel agar konsisten dengan skenario citra mata dan efisiensi komputasi. Penyesuaian ini berpotensi mempengaruhi kemampuan ekstraksi fitur global, namun tetap memungkinkan evaluasi kinerja MobileNetV2 dalam citra dengan resolusi rendah.

Pada arsitektur MobileNetV2, ditambahkan lapisan klasifikasi yang sama dengan model VGG16 untuk menjaga konsistensi eksperimen. *Classifier head* terdiri dari *Flatten layer* yang diikuti oleh dua *fully connected layer* dengan masing-masing berukuran 1024 dan 512 *neuron* dengan fungsi aktivasi SELU, serta lapisan keluaran *Softmax* untuk klasifikasi dua kelas jenis kelamin. Seluruh lapisan konvolusi MobileNetV2 dibekukan sehingga hanya lapisan klasifikasi yang dilatih. Pendekatan ini bertujuan guna memastikan bahwa perbedaan performa yang dihasilkan merefleksikan kemampuan ekstraksi fitur dari masing-masing arsitektur CNN.

Pelatihan Model CNN

Penelitian ini menggunakan pendekatan *transfer learning* dengan dua arsitektur CNN, yaitu VGG16 dan MobileNetV2. Kedua model menggunakan bobot awal dari dataset ImageNet dan dimanfaatkan sebagai *feature extractor* dengan membekukan seluruh lapisan konvolusi. Lapisan tambahan berupa *fully connected layer* ditambahkan pada bagian akhir model untuk melakukan klasifikasi dua kelas jenis kelamin.




Gambar 3 Fully Connected Layer

Proses pelatihan dilakukan menggunakan optimizer Adam dengan *learning rate* sebesar 1×10^{-4} dan fungsi *loss categorical cross-entropy*. Untuk mengatasi ketidakseimbangan jumlah data antar kelas, diterapkan *class weighting* pada proses pelatihan. Setiap model dilatih selama 20 *epoch* dengan ukuran *batch* yang sama agar perbandingan performa antar model bersifat adil.

Deteksi Area Mata Menggunakan Haar Cascade

Pada tahap implementasi sistem, digunakan *Haar Cascade Classifier* untuk mendeteksi area mata dari citra masukan. Metode ini dipilih karena memiliki keunggulan dalam kecepatan dan efisiensi komputasi, sehingga sesuai untuk aplikasi real-time. Proses diawali dengan melakukan konversi citra ke *grayscale* untuk meningkatkan efisiensi komputasi. Area mata yang terdeteksi kemudian diseleksi berdasarkan ukuran untuk memastikan hanya *Region of Interest (ROI)* yang valid digunakan.

ROI mata yang terpilih selanjutnya diekstraksi dan dilakukan peningkatan kualitas citra menggunakan teknik *histogram equalization*. Tahap ini bertujuan untuk meningkatkan kontras citra mata sehingga fitur visual lebih mudah dikenali oleh model CNN.




Gambar 4 Hasil Deteksi dan Ekstraksi Area Mata dengan Haar Cascade Classifier

Proses Inferensi dan Penentuan Gender

Pada tahap inferensi, citra masukan diproses melalui deteksi mata menggunakan *Haar Cascade*, kemudian dilakukan *preprocessing* agar sesuai dengan format input CNN. Model CNN menghasilkan prediksi berupa probabilitas untuk setiap kelas gender. Kelas dengan probabilitas tertinggi dipilih sebagai hasil dari prediksi.

Untuk meningkatkan keandalan sistem, diterapkan mekanisme *confidence-based decision*, di mana prediksi dengan tingkat keyakinan rendah akan dikategorikan sebagai *uncertain*. Pendekatan ini bertujuan untuk mengurangi risiko kesalahan klasifikasi pada citra dengan kualitas rendah atau kondisi visual yang tidak ideal.



Gambar 5 Convolutional Neural Network


Metode Evaluasi

Evaluasi performa sistem dilakukan menggunakan data uji dengan metrik *accuracy*, *precision*, *recall*, dan *f1-score*. Selain itu, digunakan *confusion matrix* untuk menganalisis kesalahan klasifikasi pada masing-masing kelas jenis kelamin. Evaluasi ini bertujuan untuk membandingkan performa antara model VGG16 dan MobileNetV2 serta menilai kemampuan model dalam mengenali kelas minoritas.

HASIL DAN PEMBAHASAN

Hasil Pelatihan Model

Proses pelatihan dilakukan terhadap dua model CNN berbasis *transfer learning*, yaitu VGG16 dan MobileNetV2, menggunakan dataset citra mata yang telah melalui tahap *preprocessing* dan *data augmentation*. Kedua model dilatih dengan konfigurasi yang sama untuk memastikan perbandingan performa yang adil. Selama proses pelatihan, kedua model menunjukkan tren peningkatan akurasi dan penurunan nilai *loss* yang stabil. Model VGG16 mencapai konvergensi yang lebih konsisten dibandingkan MobileNetV2, terutama pada tahap validasi, yang mengindikasikan kemampuan generalisasi yang lebih baik terhadap data uji.



Gambar 6 Grafik Akurasi Model VGG16 dan MobileNetV2

Pada model VGG16, akurasi pelatihan meningkat secara konsisten seiring bertambahnya *epoch* dan mencapai nilai di atas 0.96 pada akhir pelatihan. Akurasi validasi juga menunjukkan tren peningkatan yang sejalan dengan akurasi pelatihan, meskipun terdapat beberapa fluktuasi pada *epoch* awal hingga pertengahan. Selisih antara akurasi pelatihan dan validasi relatif kecil, yang mengindikasikan bahwa model VGG16 memiliki kemampuan generalisasi yang baik dan tidak mengalami *overfitting* yang signifikan.

Sementara itu, pada model MobileNetV2, akurasi pelatihan juga meningkat secara stabil hingga mendekati 0,97. Namun, akurasi dari validasi menunjukkan nilai yang lebih rendah dibandingkan akurasi

pelatihan serta mengalami fluktuasi yang lebih jelas pada beberapa *epoch*. Perbedaan yang lebih besar antara akurasi pelatihan dan validasi ini mengindikasikan bahwa MobileNetV2 memiliki kemampuan generalisasi yang lebih rendah dibandingkan VGG16 pada dataset citra mata yang digunakan.



Gambar 7 Grafik Loss Model VGG16 dan MobileNetV2

Pada model VGG16, *training loss* menunjukkan penurunan yang tajam pada *epoch* awal dan terus menurun secara bertahap hingga mencapai nilai rendah pada akhir pelatihan. *Validation loss* juga memperlihatkan tren penurunan yang sejalan, meskipun mengalami fluktuasi pada beberapa *epoch* awal dan pertengahan. Namun, fluktuasi tersebut cenderung mengecil pada *epoch* akhir, yang menandakan bahwa model mulai mencapai kondisi konvergen. Kedekatan antara *training loss* dan *validation loss* pada akhir pelatihan mengindikasikan bahwa model VGG16 mampu belajar secara stabil tanpa gejala *overfitting* yang berarti.

Sebaliknya, pada model MobileNetV2, *training loss* juga menurun secara konsisten, menunjukkan bahwa model mampu mempelajari pola data pelatihan dengan baik. Namun, *validation loss* cenderung lebih tinggi dibandingkan *training loss* dan menunjukkan fluktuasi yang lebih sering di sepanjang *epoch*. Pola ini mengindikasikan bahwa meskipun MobileNetV2 memiliki kemampuan pembelajaran yang baik, model ini lebih sensitif terhadap variasi data validasi, sehingga generalisasi model tidak sebaik VGG16 pada dataset yang digunakan.

Evaluasi Kinerja Model

Evaluasi performa dilakukan menggunakan data uji dengan metrik *accuracy*, *precision*, *recall*, dan *f1-score*. Metrik-metrik ini digunakan untuk menilai kemampuan model dalam mengenali setiap kelas secara lebih komprehensif. Secara matematis, metrik evaluasi tersebut dirumuskan sebagai berikut:

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

$$F1 - Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (3)$$

Di mana TP (*True Positive*) menyatakan jumlah data yang diklasifikasikan dengan benar sebagai kelas positif, FP (*False Positive*) menyatakan jumlah data yang salah diklasifikasikan sebagai kelas positif, dan FN (*False Negative*) menyatakan jumlah data positif yang salah diklasifikasikan sebagai kelas negatif. Nilai *f1-score* merupakan rata-rata harmonis dari *precision* dan *recall*, sehingga mampu merepresentasikan kinerja model secara lebih seimbang, terutama pada dataset dengan ketidakseimbangan kelas. Tabel evaluasi menunjukkan bahwa model VGG16 menghasilkan performa yang lebih tinggi dibandingkan MobileNetV2 pada seluruh metrik yang digunakan.

Table 3 Evaluasi Performa Model VGG16

Class	Precision	Recall	F1-Score	Support
Male	0.97	0.97	0.97	7786
Female	0.94	0.94	0.94	3403
Accuracy				0.96

Berdasarkan hasil pengujian, model VGG16 mencapai akurasi sebesar 96,3%, dengan nilai *f1-score* 0,97 untuk kelas laki-laki dan 0,94 untuk kelas perempuan.


Table 4 Evaluasi Performa Model MobileNetV2

<i>Class</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Male	0.94	0.97	0.96	7786
Female	0.93	0.87	0.90	3403
Accuracy	0.94			

Sedangkan MobileNetV2 mencapai akurasi 94%, dengan *f1-score* 0,96 pada kelas laki-laki dan 0,90 pada kelas perempuan. Nilai *precision*, *recall*, dan *f1-score* pada VGG16 juga menunjukkan keseimbangan yang lebih baik, menandakan bahwa model ini tidak hanya akurat secara keseluruhan, tetapi juga stabil dalam mengenali kedua kelas jenis kelamin.

Analisis Confusion Matrix

Analisis lebih lanjut dilakukan menggunakan *confusion matrix* untuk melihat distribusi kesalahan klasifikasi pada masing-masing kelas. Hasil dari *confusion matrix* menunjukkan bahwa model VGG16 menghasilkan jumlah kesalahan klasifikasi yang lebih sedikit dibandingkan MobileNetV2. Pada kelas laki-laki, VGG16 hanya salah mengklasifikasikan 207 citra, sedangkan MobileNetV2 menghasilkan 221 kesalahan. Pada kelas perempuan, VGG16 juga menunjukkan performa yang lebih baik dengan 202 kesalahan, dibandingkan 458 kesalahan pada MobileNetV2.



Gambar 8 Confusion Matrix Hasil Klasifikasi Model VGG16 dan MobileNetV2

Perbedaan kesalahan pada klasifikasi paling signifikan terlihat pada kelas perempuan yang merupakan kelas minoritas. Model VGG16 mampu mengklasifikasikan kelas perempuan dengan tingkat kesalahan yang lebih rendah dibandingkan MobileNetV2. Hal ini menunjukkan bahwa arsitektur VGG16 lebih efektif dalam memungkinkan ekstraksi fitur tekstur dan bentuk mata yang lebih stabil pada citra beresolusi rendah, sehingga menghasilkan tingkat kesalahan klasifikasi yang lebih rendah dibandingkan MobileNetV2. Kemampuan ini menjadi penting dalam skenario dunia nyata seperti rekaman CCTV, dimana kualitas citra sering kali rendah dan hanya area mata yang dapat teramati secara jelas.


Pembahasan Perbandingan Model

Hasil eksperimen menunjukkan bahwa kompleksitas arsitektur dari VGG16 berkontribusi terhadap kemampuannya dalam menghasilkan representasi fitur yang lebih kaya. Hal ini berdampak pada peningkatan performa klasifikasi, khususnya dalam mengenali kelas minoritas. Sebaliknya, MobileNetV2 yang dirancang dengan fokus pada efisiensi komputasi menunjukkan performa yang kompetitif, namun dengan kompromi pada tingkat akurasi dan *f1-score*.

Meskipun MobileNetV2 memiliki performa yang lebih rendah dibandingkan VGG16, model ini tetap relevan untuk aplikasi yang membutuhkan pemrosesan cepat dan penggunaan sumber daya yang terbatas. Dengan demikian, pemilihan model dapat disesuaikan dengan kebutuhan aplikasi, apakah lebih mengutamakan akurasi atau efisiensi komputasi.

Hasil Implementasi Sistem

Selain evaluasi berbasis dataset statis, sistem juga diuji pada skenario implementasi nyata dengan citra wajah yang tertutup sebagian. Hasil pengujian menunjukkan bahwa sistem mampu mendeteksi area mata menggunakan *Haar Cascade Classifier* dan melakukan klasifikasi jenis kelamin secara akurat menggunakan model CNN.



Gambar 9 Contoh Hasil Implementasi Sistem Pengenalan Gender Berbasis Citra Mata

Pada Gambar 9 menunjukkan contoh hasil implementasi sistem pada citra dengan kondisi wajah tertutup sebagian. Sistem berhasil mendeteksi area mata menggunakan *Haar Cascade Classifier* dan melakukan klasifikasi jenis kelamin menggunakan CNN berbasis VGG16. Tingkat keyakinan prediksi yang tinggi menunjukkan bahwa fitur visual pada area mata memiliki karakteristik yang cukup kuat untuk membedakan jenis kelamin, meskipun citra mengalami keterbatasan visual akibat penutup wajah. Hal ini memperkuat potensi penggunaan sistem dalam aplikasi pengawasan atau keamanan berbasis kamera. Hasil implementasi ini membuktikan bahwa pendekatan *hybrid CNN-Haar Cascade* yang diusulkan tidak hanya efektif pada data uji, tetapi juga dapat diterapkan pada kondisi dunia nyata dengan keterbatasan visual, seperti penggunaan masker atau penutup wajah.

KESIMPULAN

Penelitian ini telah berhasil mengembangkan sebuah sistem pengenalan jenis kelamin secara otomatis berbasis analisis citra mata dengan pendekatan *hybrid* antara *Convolutional Neural Network* dan *Haar Cascade Classifier*. CNN berbasis *pretrained* model dimanfaatkan untuk melakukan klasifikasi jenis kelamin secara akurat, sedangkan *Haar Cascade Classifier* digunakan dalam mendeteksi dan mengekstraksi area mata sebagai *Region of Interest*. Berdasarkan hasil pengujian, model VGG16 menunjukkan performa terbaik dengan akurasi sebesar 96%, serta nilai *precision*, *recall*, dan *f1-score* yang seimbang. Model ini juga terbukti lebih efektif dalam mengenali kelas minoritas dibandingkan MobileNetV2, yang meskipun memiliki performa lebih rendah, tetap menunjukkan kemampuan klasifikasi yang kompetitif dengan keunggulan pada efisiensi komputasi. Hasil evaluasi menggunakan *confusion matrix* memperkuat temuan bahwa VGG16 menghasilkan jumlah kesalahan klasifikasi yang lebih sedikit pada kedua kelas jenis kelamin.

Selain evaluasi kuantitatif, hasil implementasi sistem pada citra dengan kondisi wajah tertutup sebagian menunjukkan bahwa pendekatan yang diusulkan mampu bekerja secara efektif pada skenario dunia nyata. Sistem berhasil mendeteksi area mata dan menghasilkan prediksi jenis kelamin dengan tingkat keyakinan yang tinggi, sehingga membuktikan bahwa fitur visual pada citra mata cukup informatif untuk mendukung proses identifikasi gender. Meskipun penelitian ini menunjukkan hasil yang memuaskan, terdapat beberapa peluang pengembangan yang dapat dilakukan pada penelitian selanjutnya. Pertama, penggunaan metode deteksi mata berbasis *deep learning* seperti MTCNN atau YOLO dapat dieksplorasi untuk meningkatkan akurasi deteksi pada kondisi oklusi yang lebih kompleks. Kedua, penelitian selanjutnya dapat mempertimbangkan penggunaan arsitektur CNN lain atau melakukan *fine-tuning* pada lapisan konvolusi untuk meningkatkan performa klasifikasi. Ketiga, pengujian sistem pada dataset yang lebih beragam dan bersumber dari rekaman CCTV nyata dapat dilakukan untuk mengevaluasi ketahanan sistem terhadap variasi kualitas citra. Terakhir, integrasi sistem ke dalam aplikasi *realtime* atau perangkat dengan sumber daya terbatas dapat menjadi langkah lanjutan untuk menguji kesiapan sistem dalam implementasi praktis.

DAFTAR PUSTAKA

- Abdalrady, N. A., & Aly, S. (2020). Fusion of multiple simple convolutional neural networks for gender classification. *International Conference on Innovative Trends in Communication and Computer Engineering*, 251–252.
- Arnita, Marpaung, F., Aulia, F., Suryani, N., & Nabila, R. C. (2022). *Computer vision dan pengolahan citra digital*. Pustaka Aksara.
- Bahit, M., Utami, N. P., Candra, H. K., Supit, Y., & Ramadhan, A. (2023). Validation of the Haar Cascade classification method in face detection. *Journal of Informatics and Telecommunication Engineering*, 233–243.
- Cimtay, Y., & Yilmaz, G. N. (2021). Gender classification from eye images by using pretrained convolutional neural networks. *The Eurasia Proceedings of Science, Technology, Engineering & Mathematics*, 39–44.
- Elgendy, M. (2020). *Deep learning for vision systems*. Manning Publications Co.
- Firdaus, R., Satria, J., & Baidarus. (2022). Klasifikasi jenis kelamin berdasarkan gambar mata dengan menggunakan algoritma convolutional neural network (CNN). *Computer Science and Information Technology*, 267–273.
- Ghrban, Z. S., & Abbadi, N. K. (2023). Gender classification from face and eyes images using deep learning algorithm. *Journal of Computer Science*, 345–362.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. The MIT Press.
- Gumilang, M. S., & Avianto, D. (2023). Recognition of real-time handwritten characters using convolutional neural network architecture. *Jurnal Teknik Informatika*, 1143–1150.
- Jung, S.-G., An, J., Kwak, H., Salminen, J., & Jansen, B. J. (2018). Assessing the accuracy of four popular face recognition tools for inferring gender, age, and race. *Proceedings of the Twelfth International AAAI Conference on Web and Social Media*, 624–627.
- Ke, Q., Liu, J., Bennamoun, M., An, S., Sohel, F., & Boussaid, F. (2018). Computer vision for human-machine learning. *Computer Vision for Assistive Healthcare*, 127–145.
- Lakshmi, D., Janaki, R., Subashini, V., Kumar, K. S., Aurelia, C. A., & Ananya, S. T. (2023). Prediction of age, gender, and ethnicity using Haar Cascade algorithm in convolutional neural networks. *Proceedings of World Conference on Artificial Intelligence: Advances and Applications*, 205–219.
- LeCun, Y., & Bengio, Y. (1998). *Convolutional networks for images, speech, and time series*. Association for Computing Machinery.
- Mamyrbayev, O., Toleu, A., Tolegen, G., Mekebayev, N., & Pham, D. (2020). Neural architectures for gender detection and speaker identification. *Cogent Engineering*, 1–13.
- Mohri, M., Rostamizadeh, A., & Talwalkar, A. (2018). *Foundations of machine learning*. The MIT Press.
- Mostafa, S., & Wu, F.-X. (2021). Diagnosis of autism spectrum disorder with convolutional autoencoder and structural MRI images. *Neural Engineering Techniques for Autism Spectrum Disorder*, 23–38.
- Narayanan, A., & K, S. (2019). Gender detection and classification from fingerprints using pixel count. *International Conference on System Energy and Environment*, 1–5.
- Natun, N. C., Santhia, M. A., & Kaesmetan, Y. R. (2024). Identifikasi pengenalan wajah berdasarkan jenis kelamin menggunakan metode convolutional neural network (CNN). *Journal of Technology and Informatics*, 50–57.
- Nengsih, W. (2020). CNN modelling untuk deteksi wajah berbasis gender menggunakan Python. *Jurnal Politeknik Caltex Riau*, 190–199.
- Pandimurugan, D. V., Jain, A., & Sinha, Y. (2020). IoT-based face recognition for smart applications using machine learning. *Proceedings of the Third International Conference on Intelligent Sustainable Systems*, 1263–1266.
- Pradana, A. I., & Wijiyanto. (2024). Identifikasi jenis kelamin otomatis berdasarkan mata manusia menggunakan convolutional neural network (CNN) dan Haar Cascade classifier. *Jurnal Teknologi Terapan*, 502–511.
- Ramadini, F. L., & Haryatmi, E. (2022). Penggunaan metode Haar Cascade classifier dan LBPH untuk pengenalan wajah secara realtime. *INFOTEKJAR*, 1–8.
- Salam, S., B, S., Hasnawati, & Muhaemin, M. (2020). *Pengetahuan dasar seni rupa*. Badan Penerbit Universitas Negeri Makassar.
- Saraswati, N. M., Hariyono, R. C., & Chandra, D. (2023). Face recognition menggunakan metode Haar Cascade classifier dan local binary pattern histogram. *Media Elektrik*, 6–11.
- Scendoni, R., Kelmendi, J., Ribeiro, I. L., Cingolani, M., Micco, F. D., & Cameriere, R. (2023). Anthropometric analysis of orbital and nasal parameters for sexual dimorphism: New anatomical evidences in the field of personal identification through a retrospective observational study. *National Library of Medicine*, 1–11.

- Serna, I., Pena, A., Morales, A., & Fierrez, J. (2020). InsideBias: Measuring bias in deep networks and application to face gender biometrics. *International Conference on Pattern Recognition*, 3720–3721.
- Singh, H. (2019). *Practical machine learning and image processing for facial recognition, object detection, and pattern recognition using Python*. Apress.
- Topaloglu, M., & Ekmekci, S. (2017). Gender detection and identifying one's handwriting with handwriting analysis. *Expert Systems With Applications*, 236–243.
- Vani, A., Raajan, R. N., Haretha Winmalar, D., & Sudharsan, R. (2020). Using the Keras model for accurate and rapid gender identification through detection of facial features. *Proceedings of the Fourth International Conference on Computing Methodologies and Communication*, 572–574.
- Wicaksono, R. D., Pratama, F. I., & Budianita, A. (2024). Klasifikasi gender berdasarkan citra mata manusia menggunakan algoritma convolutional neural network. *Prosiding Seminar Nasional Sains dan Teknologi*, 308–313.
- Xue, Z., Rajaraman, S., Long, R., Antani, S., & Thoma, G. R. (2018). Gender detection from spine X-ray images using deep learning. *International Symposium on Computer-Based Medical Systems*, 54–55.
- Yingge, H., Ali, I., & Lee, K.-Y. (2020). Deep neural networks on chip—A survey. *International Conference on Big Data and Smart Computing*, 589–592.
- Yulina, S. (2021). Penerapan Haar Cascade classifier dalam mendeteksi wajah dan transformasi citra grayscale menggunakan OpenCV. *Jurnal Politeknik Caltex Riau*, 100–109.
- Zeni, L. F., & Jung, C. (2018). Real-time gender detection in the wild using deep neural networks. *Conference on Graphics, Patterns and Images*, 118–125.