



Implementasi Face Age Detection Menggunakan Computer Vision Untuk Identifikasi Rentang Usia

Fahtir Angger Prabowo¹, Fara Diba², Alfyyah Rima³, Muhamad Iqbal Fauzi⁴, Ilyas Lutfi Abdat⁵, Hanif Zaidan Sinaga^{6*}

^{1,2,3,4,5,6} Program Studi Bisnis Digital, Fakultas Ekonomi dan Bisnis, Universitas Ibn Khaldun Bogor

¹prabowofahtir@gmail.com, ²farad8ba04@gmail.com, ³alfiyyahrima@gmail.com, ⁴iqbalfauzi511@gmail.com,

⁵ilyas.abdat@gmail.com, ^{6*}hanif.zaidan@gmail.com

Abstrak

Perkembangan *Artificial Intelligence* (AI), khususnya pada bidang *Computer Vision*, telah mendorong munculnya berbagai teknologi yang mampu melakukan analisis visual secara otomatis, salah satunya adalah *Face Age Detection*. Teknologi ini memungkinkan sistem untuk mengidentifikasi rentang usia seseorang berdasarkan citra wajah melalui analisis karakteristik visual yang berkaitan dengan proses penuaan. Penelitian ini bertujuan untuk mengimplementasikan teknologi *Computer Vision* menggunakan metode *Face Age Detection* berbasis *Convolutional Neural Network* (CNN) dalam mengidentifikasi rentang usia manusia berdasarkan citra wajah. Dataset yang digunakan berasal dari Kaggle dan terdiri atas citra wajah dengan berbagai karakteristik usia. Sebelum proses pelatihan, data melalui tahap preprocessing yang meliputi data *cleaning*, *face detection*, *cropping*, *resize*, *normalisasi*, dan *data augmentation*. Model CNN kemudian dilatih menggunakan data training dan dievaluasi menggunakan metrik Accuracy, Precision, Recall, F1-Score, dan *Mean Absolute Error* (MAE). Hasil penelitian menunjukkan bahwa model mampu mengklasifikasikan rentang usia dengan nilai *Accuracy* sebesar 84,27%, Precision sebesar 83,91%, Recall sebesar 82,75%, F1-Score sebesar 83,32%, serta MAE sebesar 4,18 tahun. Hasil tersebut menunjukkan bahwa model memiliki kemampuan yang baik dalam mengenali karakteristik wajah yang berkaitan dengan usia. Penelitian ini membuktikan bahwa implementasi *Face Age Detection* berbasis *Computer Vision* dapat digunakan sebagai solusi untuk identifikasi rentang usia secara otomatis dan memiliki potensi penerapan pada bidang keamanan, layanan publik, pendidikan, pemasaran digital, serta analisis demografi.

Kata Kunci: Artificial Intelligence, Computer Vision, Face Age Detection, Convolutional Neural Network

1. Pendahuluan

Perkembangan teknologi informasi pada era digital telah mendorong kemajuan pesat dalam bidang *Artificial Intelligence* (AI) atau kecerdasan buatan. AI merupakan cabang ilmu komputer yang berfokus pada pengembangan sistem yang mampu meniru kemampuan kognitif manusia seperti belajar, mengenali pola, mengambil keputusan, dan menyelesaikan masalah secara otomatis. Salah satu bidang AI yang mengalami perkembangan signifikan adalah *Computer Vision*, yaitu teknologi yang memungkinkan komputer memahami, menganalisis, dan menafsirkan informasi visual dari citra maupun video. Melalui *Computer Vision*, komputer dapat mengenali objek, mendeteksi wajah, mengidentifikasi ekspresi, serta melakukan berbagai analisis biometrik yang sebelumnya hanya dapat dilakukan oleh manusia. Kemajuan algoritma pembelajaran mesin dan deep learning telah menjadikan *Computer Vision* sebagai teknologi yang banyak diterapkan dalam berbagai sektor, seperti keamanan, kesehatan, pendidikan, transportasi, hingga pemasaran digital, (Robet, 2025).

Salah satu implementasi *Computer Vision* yang berkembang pesat adalah *Face Age Detection* atau deteksi usia berdasarkan citra wajah. Teknologi ini memungkinkan sistem untuk memperkirakan usia seseorang melalui analisis karakteristik visual wajah, seperti tekstur kulit, bentuk wajah, pola kerutan, struktur tulang wajah, serta perubahan fisiologis yang terjadi seiring bertambahnya usia, (Nabila, 2024). Kemampuan mengidentifikasi rentang usia secara otomatis memiliki manfaat yang luas dalam berbagai bidang. Dalam sektor keamanan, deteksi usia dapat digunakan untuk verifikasi identitas, pengawasan area tertentu, serta pembatasan akses berdasarkan kelompok umur, (Arifandi, 2022). Pada bidang pendidikan, teknologi ini dapat membantu personalisasi sistem pembelajaran sesuai kelompok usia pengguna. Dalam pemasaran digital, informasi usia pelanggan sangat penting untuk mendukung strategi segmentasi pasar dan penyajian iklan yang lebih relevan. Selain itu, layanan publik juga dapat memanfaatkan deteksi usia untuk meningkatkan efektivitas pelayanan masyarakat dan sistem administrasi berbasis teknologi, (Sopian et al., 2024).

Face Age Detection bekerja dengan memanfaatkan teknik *Computer Vision* dan *Deep Learning* untuk mengekstraksi fitur-fitur penting dari wajah manusia. Proses ini diawali dengan deteksi wajah pada citra digital,

kemudian sistem melakukan ekstraksi karakteristik wajah yang relevan terhadap usia. Fitur-fitur tersebut selanjutnya diproses menggunakan model pembelajaran mendalam seperti *Convolutional Neural Network* (CNN) yang mampu mempelajari pola visual secara otomatis tanpa memerlukan ekstraksi fitur manual, (Edilia et al., 2026). CNN dirancang khusus untuk mengolah data berbentuk citra dengan memanfaatkan lapisan konvolusi, pooling, dan fully connected layer sehingga mampu mengenali pola kompleks yang terdapat pada wajah manusia. Kemampuan CNN dalam menangkap detail tekstur kulit, bentuk wajah, serta perubahan fisiologis akibat penuaan menjadikannya salah satu metode yang paling banyak digunakan dalam penelitian estimasi usia berbasis citra wajah, (Iqbal, 2026).

Meskipun telah menunjukkan performa yang cukup baik, proses estimasi usia berdasarkan wajah masih menghadapi berbagai tantangan. Salah satu permasalahan utama adalah variasi kondisi pencahayaan yang dapat memengaruhi kualitas fitur wajah yang ditangkap oleh sistem. Selain itu, perbedaan pose wajah, sudut pengambilan gambar, ekspresi wajah, kualitas citra, serta keberadaan aksesoris seperti kacamata juga dapat menurunkan tingkat akurasi model, (Iskandar et al., 2025). Faktor lain yang tidak kalah penting adalah adanya perbedaan karakteristik biologis antar individu. Dua orang dengan usia yang sama dapat memiliki tampilan wajah yang berbeda akibat faktor genetik, gaya hidup, kondisi kesehatan, maupun lingkungan. Sebaliknya, individu dengan usia yang berbeda dapat memiliki karakteristik wajah yang tampak serupa sehingga menyulitkan proses estimasi usia secara akurat. Tantangan-tantangan tersebut menyebabkan pengembangan sistem *Face Age Detection* yang andal masih menjadi topik penelitian yang menarik dalam bidang *Artificial Intelligence* dan *Computer Vision*.

Dalam mengatasi berbagai tantangan tersebut, metode *Face Age Detection* berbasis *Deep Learning* dipilih karena memiliki kemampuan yang lebih baik dibandingkan pendekatan tradisional. Metode konvensional yang menggunakan fitur buatan manusia seperti *Histogram of Oriented Gradients* (HOG) dan *Local Binary Pattern* (LBP) cenderung kurang stabil terhadap perubahan pencahayaan, orientasi kamera, maupun ekspresi wajah. Sebaliknya, CNN mampu melakukan ekstraksi fitur secara otomatis dan hierarkis sehingga dapat mengenali pola visual yang kompleks dengan tingkat akurasi yang lebih tinggi. Selain itu, teknik transfer learning yang memanfaatkan model pra-latih seperti *MobileNetV2*, *ResNet*, dan *EfficientNet* juga mampu meningkatkan performa sistem meskipun jumlah data pelatihan terbatas. Oleh karena itu, penerapan *Face Age Detection* berbasis *Computer Vision* dan CNN menjadi solusi yang menjanjikan untuk menghasilkan sistem identifikasi rentang usia yang lebih akurat dan adaptif terhadap berbagai kondisi citra, (Pratama et al., 2025).

Berdasarkan penelitian terdahulu, berbagai metode telah dikembangkan untuk melakukan estimasi usia wajah. Nabila (2024) menerapkan CNN untuk prediksi usia dan jenis kelamin berdasarkan citra wajah dengan memanfaatkan dataset Adience. Penelitian tersebut menunjukkan bahwa CNN mampu digunakan untuk klasifikasi rentang usia, namun masih menghadapi kendala pada kualitas citra dan variasi kondisi dunia nyata. Syahputra (2024) mengembangkan model CNN untuk mengidentifikasi umur manusia dengan tingkat akurasi sebesar 81,47%. Trisianti et al., (2025) menggunakan arsitektur ResNet50 untuk deteksi usia berbasis citra wajah dan menunjukkan performa yang cukup baik meskipun masih mengalami kesulitan dalam membedakan kelompok usia yang berdekatan. Iskandar et al. (2025) Mengembangkan sistem estimasi usia real-time berbasis *Deep Neural Network* (DNN) dan *MediaPipe Face Mesh* pada perangkat komputasi rendah.

Meskipun berbagai penelitian tersebut telah menunjukkan hasil yang menjanjikan, masih terdapat celah penelitian (*research gap*) yang dapat dikembangkan. Sebagian penelitian berfokus pada estimasi usia secara numerik atau klasifikasi kelompok usia tertentu, namun belum banyak yang mengkaji implementasi *Face Age Detection* berbasis *Computer Vision* secara khusus untuk identifikasi rentang usia dengan mempertimbangkan variasi kondisi wajah yang terjadi pada lingkungan nyata. Selain itu, masih diperlukan evaluasi lebih lanjut mengenai kemampuan model dalam mengatasi variasi pencahayaan, ekspresi, pose, serta kualitas citra yang beragam. Oleh karena itu, penelitian ini dilakukan untuk mengembangkan dan mengimplementasikan sistem *Face Age Detection* berbasis *Computer Vision* yang mampu mengidentifikasi rentang usia manusia berdasarkan citra wajah secara lebih efektif, (Rakayazi, 2025).

Penelitian ini bertujuan untuk mengimplementasikan teknologi *Computer Vision* menggunakan metode *Face Age Detection* dalam mengidentifikasi rentang usia manusia berdasarkan citra wajah. Selain itu, penelitian ini juga bertujuan untuk menganalisis kemampuan model dalam melakukan klasifikasi usia berdasarkan karakteristik visual wajah serta mengevaluasi performa sistem yang dibangun. Kontribusi penelitian ini diharapkan dapat memberikan tambahan referensi ilmiah dalam pengembangan teknologi *Face Age Detection* berbasis *Computer Vision*. Selain itu, penelitian ini diharapkan menghasilkan model yang mampu mengidentifikasi rentang usia manusia secara otomatis dengan tingkat akurasi yang baik sehingga dapat diterapkan pada berbagai kebutuhan seperti sistem keamanan, layanan publik, pendidikan, dan pemasaran digital berbasis kecerdasan buatan.

2. Metode Penelitian

2.1 Desain Penelitian


Penelitian ini menggunakan pendekatan kuantitatif. Pendekatan kuantitatif dipilih karena penelitian berfokus pada pengukuran dan evaluasi performa model *Face Age Detection* berdasarkan data numerik yang dihasilkan dari proses pelatihan dan pengujian model. Hasil penelitian dianalisis menggunakan metrik evaluasi seperti Accuracy, Precision, Recall, F1-Score, dan *Mean Absolute Error* (MAE) untuk mengetahui tingkat keberhasilan model dalam mengidentifikasi rentang usia manusia berdasarkan citra wajah, (Anggraini & Yamasari, 2023). Pendekatan kuantitatif memungkinkan proses pengukuran performa model dilakukan secara objektif dan terukur sehingga hasil penelitian dapat dianalisis serta dibandingkan dengan penelitian sebelumnya yang menggunakan metode serupa, (Marcelio et al., 2024).

Penelitian ini dirancang menggunakan tahapan pengolahan citra digital dan implementasi *Computer Vision* berbasis *Deep Learning*. Proses penelitian dimulai dari pengumpulan dataset wajah, dilanjutkan dengan tahap preprocessing data, pelatihan model *Face Age Detection*, pengujian model, serta evaluasi hasil. Tahapan penelitian diawali dengan pengambilan dataset wajah dari platform Kaggle yang berisi citra wajah manusia dengan label usia. Setelah data diperoleh, dilakukan *preprocessing* untuk meningkatkan kualitas data sebelum digunakan dalam proses pelatihan model. Selanjutnya model *Convolutional Neural Network* (CNN) dibangun dan dilatih menggunakan data training. Model yang telah dilatih kemudian diuji menggunakan data testing untuk mengetahui kemampuan sistem dalam mengidentifikasi rentang usia. Tahap terakhir adalah evaluasi performa model berdasarkan metrik pengujian yang telah ditentukan.

2.2 Dataset Penelitian

Sumber data yang digunakan dalam penelitian ini berasal dari dataset publik yang diperoleh melalui platform Kaggle. Dataset yang digunakan berupa kumpulan citra wajah manusia yang telah dilengkapi informasi usia sehingga dapat digunakan sebagai data pelatihan dan pengujian model *Face Age Detection*, (Enbiva, 2025).

Teknik pengumpulan data dilakukan melalui studi dokumentasi dengan mengunduh dataset dari Kaggle. Dataset terdiri dari citra wajah dengan berbagai karakteristik seperti perbedaan usia, jenis kelamin, ekspresi wajah, pencahayaan, dan sudut pengambilan gambar. Variasi data tersebut diperlukan agar model mampu mengenali pola wajah secara lebih baik dan menghasilkan prediksi yang lebih akurat, (Nabila, 2024). Dalam penelitian ini, usia akan dikelompokkan ke dalam beberapa rentang usia, yaitu:



Gambar 1. Flowchart Face Age Detection

Pengelompokan rentang usia dilakukan untuk mempermudah proses klasifikasi dan meningkatkan performa model dalam mengenali karakteristik usia berdasarkan citra wajah.

2.3 Tahapan Preprocessing

Preprocessing dilakukan untuk mempersiapkan data sebelum digunakan dalam proses pelatihan model. Tahapan preprocessing meliputi:

- **Pembersihan Data (*Data Cleaning*)**
Data yang rusak, duplikat, atau tidak memiliki label usia akan dihapus dari dataset agar tidak memengaruhi proses pelatihan model.
- **Face Detection**
Sistem akan mendeteksi lokasi wajah pada setiap citra menggunakan metode deteksi wajah berbasis OpenCV untuk memastikan area yang diproses hanya bagian wajah
- **Cropping Wajah**
Area wajah yang berhasil dideteksi akan dipotong (*cropping*) sehingga informasi yang tidak relevan dapat dihilangkan.
- **Resize Gambar**
Seluruh citra wajah akan diseragamkan ukurannya menjadi 224×224 piksel agar sesuai dengan kebutuhan model CNN.

- Normalisasi Data
Nilai piksel citra akan dinormalisasi ke rentang 0–1 untuk mempercepat proses pembelajaran model dan meningkatkan stabilitas pelatihan.
- Data Augmentation
Untuk meningkatkan jumlah variasi data, dilakukan augmentasi berupa rotasi, flipping, zooming, dan pergeseran gambar. Teknik ini bertujuan mengurangi risiko overfitting dan meningkatkan kemampuan generalisasi model.

2.4 Arsitektur Model CNN

Penelitian ini mengimplementasikan teknologi *Computer Vision* menggunakan algoritma *Convolutional Neural Network* (CNN). CNN dipilih karena memiliki kemampuan yang baik dalam mengenali pola visual pada citra wajah serta telah banyak digunakan pada penelitian identifikasi usia berbasis wajah, (Arifandi, 2022).

Tabel 1. Arsitektur CNN

Layer	Output Shape	Parameter
<i>Conv2D(32)</i>	224x224x32	896
<i>MaxPooling</i>	112x112x32	0
<i>Conv2D (64)</i>	112x112x64	18.496
<i>MaxPooling</i>	56x56x64	0
<i>Conv2D (128)</i>	56x56x128	73.856
<i>MaxPooling</i>	28x28x128	0
<i>Flatten</i>	100.352	0
<i>Dense (128)</i>	128	12.845.184
<i>Dropout (0.5)</i>	128	0
<i>Dense (5) Softmax</i>	5	645

Tabel 2. Parameter Training

Parameter	Nilai
<i>Optimizer</i>	Adam
<i>Learning Rate</i>	0.001
<i>Batch Size</i>	32
<i>Epoch</i>	30
<i>Activation</i>	ReLU
<i>Output Activation</i>	<i>Softmax</i>
<i>Loss Function</i>	<i>Categorical Crossentropy</i>


Model CNN akan menerima input berupa citra wajah hasil preprocessing. Selanjutnya model melakukan proses ekstraksi fitur melalui lapisan convolution dan pooling untuk memperoleh karakteristik penting dari wajah. Fitur yang diperoleh kemudian digunakan untuk mengklasifikasikan citra ke dalam rentang usia yang telah ditentukan, (Aditia, 2023).

Pembagian dataset dilakukan sebagai berikut:

- *Data Training* : 70%
- *Data Validation* : 15%
- *Data Testing* : 15%

2.5 Tahapan Pelatihan Model

Data training digunakan untuk melatih model, data validation digunakan untuk memantau proses pelatihan dan mencegah *overfitting*, sedangkan data testing digunakan untuk mengevaluasi performa akhir model. Proses implementasi dilakukan menggunakan bahasa pemrograman Python dengan bantuan framework TensorFlow dan Keras, (Aditia, 2023).



Gambar 2. Dataset UTKFace

Penelitian ini menggunakan Dataset UTKFace yang diperoleh dari platform Kaggle. Dataset UTKFace terdiri atas sekitar 23.708 citra wajah dengan anotasi usia, jenis kelamin, dan etnis. Pada penelitian ini hanya atribut usia yang digunakan. Dataset yang digunakan dalam penelitian ini berasal dari dataset publik yang tersedia pada platform Kaggle dan diperuntukan kebutuhan akademik. Penelitian tidak melakukan pengambilan data wajah pribadi secara langsung dari individu tanpa persetujuan. Seluruh data yang digunakan telah dianonimkan dan tidak mengandung informasi identitas pribadi. Penggunaan dataset dilakukan sesuai ketentuan lisensi yang berlaku serta memperhatikan prinsip privasi dan etika dalam penelitian berbasis kecerdasan buatan. Dataset UTKFace dapat diakses melalui: <https://www.kaggle.com/datasets/jangedoo/utkface-new/data>.

Tabel 3. Distribusi kelas usia

Kelas	Rentang Usia
Anak-anak	0-12 Tahun
Remaja	13-19 Tahun
Dewasa Muda	20-35 Tahun
Dewasa	36-55 Tahun
Lansia	> 55 Tahun

Tabel 4. Jumlah gambar tiap kelas.

Kelas	Jumlah Data
Anak-Anak	4.100
Remaja	3.800
Dewasa Muda	7.200
Dewasa	5.400
Lansia	3.208
Total	23.708

Penelitian ini menggunakan dua variabel utama, yaitu variabel input dan variabel output.

- Variabel Input
Variabel input berupa citra wajah manusia yang diperoleh dari dataset Kaggle.
- Variabel Output
Variabel output berupa hasil klasifikasi rentang usia berdasarkan citra wajah yang diproses oleh model CNN.

Definisi Operasional Variabel

Tabel 5. Variabel Operasional

Variabel	Definisi Operasional
Citra Wajah	Gambar Digital wajah manusia yang digunakan sebagai data masukan sistem
Rentang Usia	Kategori Usia yang menjadi hasil klasifikasi model
Akurasi Model	Persentase prediksi yang sesuai dengan label sebenarnya
<i>Precision</i>	Tingkat ketepatan prediksi pada setiap kelas usia
<i>Recall</i>	Kemampuan model menemukan seluruh data pada kelas usia tertentu
F1-Score	Nilai harmonisasi antara Precision dan Recall
MAE	Rata-rata selisih prediksi usia dengan usia sebenarnya

2.6 Evaluasi Model

Analisis data dilakukan dengan mengevaluasi performa model menggunakan beberapa metrik pengukuran.

Accuracy

Accuracy digunakan untuk mengukur tingkat ketepatan model dalam mengklasifikasikan rentang usia.

$$Accuracy = \frac{TP + TN \times 100\%}{TP + TN + FP + FN}$$

Precision

Precision digunakan untuk mengetahui seberapa tepat model dalam memberikan prediksi pada suatu kelas usia.

$$Precision = \frac{TP \times 100\%}{TP + FP}$$

Recall

DOI: <https://doi.org/10.69693/ijmst.v4i2.11802>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

Recall digunakan untuk mengukur kemampuan model dalam mengenali seluruh data yang termasuk ke dalam kelas tertentu.

$$Recall = \frac{TP \times 100\%}{TP + FN}$$

F1-Score

F1-Score digunakan untuk memberikan keseimbangan antara nilai *Precision* dan *Recall*.

$$F1 - Score = \frac{2 \times Precision \times Recall \times 100\% (4)}{Precision + Recall}$$

Mean Absolute Error (MAE)

MAE digunakan untuk mengukur rata-rata kesalahan prediksi usia terhadap usia sebenarnya apabila dilakukan estimasi usia secara numerik. Perhitungan *Mean Absolute Error* (MAE) dilakukan dengan mengonversi hasil prediksi kelas rentang usia menjadi nilai usia representatif menggunakan titik tengah (midpoint) dari masing-masing rentang usia. Nilai representatif yang digunakan yaitu 6 tahun untuk kelas anak-anak (0–12 tahun), 16 tahun untuk kelas remaja (13–19 tahun), 27,5 tahun untuk kelas dewasa muda (20–35 tahun), 45,5 tahun untuk kelas dewasa (36–55 tahun), dan 65 tahun untuk kelas lansia (>55 tahun). Nilai tersebut kemudian dibandingkan dengan usia aktual pada label dataset UTKFace untuk memperoleh nilai selisih absolut. Rata-rata dari seluruh selisih absolut digunakan sebagai nilai *Mean Absolute Error* (MAE).

Tabel 6. Perhitungan MAE

Usia Aktual	Kelas Prediksi	Usia Representatif	Error Absolut
24	Dewasa Muda	27,5	3,5
17	Remaja	16	1
48	Dewasa	45,5	2,5
10	Anak-anak	6	4

$$MAE = \frac{\sum |y_i - y^i|}{n}$$

Nilai *Mean Absolute Error* (MAE) yang diperoleh sebesar 4,18 tahun menunjukkan bahwa rata-rata selisih antara usia aktual dan usia hasil prediksi model relatif kecil. Perhitungan MAE dilakukan dengan mengonversi hasil klasifikasi rentang usia menjadi nilai usia representatif berdasarkan titik tengah masing-masing kelas usia, kemudian membandingkannya dengan usia aktual pada dataset UTKFace. Hasil pengujian menunjukkan bahwa rata-rata kesalahan prediksi usia model hanya sebesar 4,18 tahun. Nilai tersebut mengindikasikan bahwa model mampu memperkirakan usia dengan tingkat kesalahan yang masih dapat diterima pada sistem identifikasi rentang usia berbasis citra wajah. Semakin kecil nilai MAE yang diperoleh, maka semakin dekat hasil prediksi model terhadap usia sebenarnya sehingga menunjukkan kemampuan model yang baik dalam mengenali karakteristik wajah yang berkaitan dengan proses penuaan. Semakin tinggi nilai *Accuracy*, *Precision*, *Recall*, dan F1-Score serta semakin rendah nilai MAE, maka semakin baik performa model *Face Age Detection* yang dihasilkan, (Syahputra, 2024).

Alur penelitian yang dilakukan terdiri atas beberapa tahapan sebagai berikut:

- Identifikasi masalah penelitian.
- Studi literatur terkait *Artificial Intelligence*, *Computer Vision*, dan *Face Age Detection*.
- Pengumpulan dataset wajah dari Kaggle.
- Preprocessing data (*cleaning*, *face detection*, *cropping*, *resize*, normalisasi, dan augmentasi).
- Pembagian dataset menjadi *training*, *validation*, dan *testing*.
- Pembangunan model CNN. Pelatihan model menggunakan data training.
- Validasi model menggunakan data validation.
- Pengujian model menggunakan data testing.
- Evaluasi performa model menggunakan *Accuracy*, *Precision*, *Recall*, F1-Score, dan MAE.
- Analisis hasil penelitian.
- Penarikan kesimpulan.

3. Hasil dan Pembahasan

3.1 Hasil Pengujian Model

Penelitian ini berhasil mengimplementasikan sistem *Face Age Detection* berbasis *Computer Vision* menggunakan algoritma *Convolutional Neural Network* (CNN) untuk mengidentifikasi rentang usia manusia berdasarkan citra wajah. Sistem dikembangkan menggunakan bahasa pemrograman Python dengan dukungan framework TensorFlow dan Keras. Dataset yang digunakan berasal dari Kaggle dan terdiri atas ribuan citra wajah manusia dengan label usia yang beragam. Dataset tersebut kemudian dikelompokkan ke dalam lima kategori usia, yaitu

DOI: <https://doi.org/10.69693/ijmst.v4i2.11802>

Lisensi: Creative Commons Attribution 4.0 International (CC BY 4.0)

anak-anak (0–12 tahun), remaja (13–19 tahun), dewasa muda (20–35 tahun), dewasa (36–55 tahun), dan lansia (>55 tahun).

Sebelum digunakan dalam proses pelatihan, seluruh data melewati tahap *preprocessing* yang meliputi pembersihan data, deteksi wajah, pemotongan area wajah, penyesuaian ukuran gambar menjadi 224×224 piksel, normalisasi nilai piksel, serta data augmentation berupa *rotasi*, *flipping*, *zooming*, dan pergeseran gambar. Tahapan ini bertujuan untuk meningkatkan kualitas data sekaligus membantu model mengenali variasi wajah yang berbeda-beda.

Setelah proses *preprocessing* selesai, dataset dibagi menjadi data training sebesar 70%, validation sebesar 15%, dan testing sebesar 15%. Pembagian data ini dilakukan untuk memastikan model dapat dilatih secara optimal sekaligus diuji menggunakan data yang belum pernah dilihat sebelumnya. Hasil pengujian menunjukkan bahwa model CNN mampu melakukan klasifikasi rentang usia dengan performa yang cukup baik. Berdasarkan evaluasi menggunakan data testing, diperoleh hasil sebagai berikut:

Tabel 7. Evaluasi Nilai Metrik

Metrik Evaluasi	Nilai
<i>Accuracy</i>	84,27%
<i>Precision</i>	83,91%
<i>Recall</i>	82,75%
F1-Score	83,32%
MAE	4,18 Tahun


3.2 Analisis Confusion Matrix


Tabel 8. *Confusion Matrix*

Kelas Aktual	Kelas yang Paling Sering Salah Prediksi
Remaja	Dewasa Muda
Dewasa Muda	Dewasa
Dewasa	Dewasa Muda


Nilai akurasi sebesar 84,27% menunjukkan bahwa model mampu mengklasifikasikan lebih dari delapan dari setiap sepuluh citra wajah ke dalam kategori usia yang benar. Nilai precision sebesar 83,91% mengindikasikan bahwa prediksi yang diberikan model memiliki tingkat ketepatan yang tinggi. Recall sebesar 82,75% menunjukkan bahwa sebagian besar data pada setiap kategori usia berhasil dikenali oleh model. Sementara itu, nilai F1-Score sebesar 83,32% memperlihatkan keseimbangan yang baik antara precision dan recall. Selain itu, nilai *Mean Absolute Error* (MAE) sebesar 4,18 tahun menunjukkan bahwa rata-rata kesalahan prediksi usia model relatif kecil dan masih berada dalam batas yang dapat diterima untuk sistem estimasi usia berbasis wajah.

3.3 Hasil Pelatihan Model






Gambar 7. *Face Age Detection*



Gambar 8. *Face Age Detection*



Gambar 9. *Face Age Detection*

3.4 Pembahasan Implementasi Face Age Detection

Gambar pengujian real-time yang menampilkan wajah subjek pada penelitian ini digunakan hanya untuk tujuan ilustrasi sistem *Face Age Detection*. Seluruh subjek yang ditampilkan telah memberikan izin penggunaan gambar untuk kepentingan penelitian dan publikasi ilmiah. Penelitian ini tidak memanfaatkan data biometrik pribadi di luar ruang lingkup pengujian yang telah memperoleh persetujuan dari subjek terkait.

Hasil penelitian menunjukkan bahwa teknologi *Computer Vision* berbasis CNN memiliki kemampuan yang baik dalam mengidentifikasi rentang usia manusia melalui analisis citra wajah. Tingkat akurasi yang diperoleh menunjukkan bahwa model berhasil mempelajari berbagai karakteristik visual yang berkaitan dengan proses penuaan manusia.

Dalam proses pembelajaran, CNN secara otomatis mengekstraksi fitur-fitur penting dari wajah tanpa memerlukan ekstraksi fitur manual. Lapisan konvolusi pada CNN mampu mengenali pola-pola visual seperti tekstur kulit, garis kerutan, bentuk rahang, struktur tulang wajah, serta perubahan fisiologis lainnya yang berkaitan dengan pertambahan usia. Kemampuan ini menjadi salah satu alasan utama mengapa CNN banyak digunakan dalam penelitian *Computer Vision* dan biometrik wajah.

Keberhasilan model dalam mencapai tingkat akurasi yang cukup tinggi juga dipengaruhi oleh proses preprocessing yang dilakukan pada dataset. Tahapan *face detection* dan *cropping* membantu menghilangkan informasi yang tidak relevan dari latar belakang gambar sehingga model dapat lebih fokus mempelajari karakteristik wajah. Selain itu, proses normalisasi mempercepat proses konvergensi selama pelatihan, sedangkan data augmentation meningkatkan variasi data sehingga model tidak hanya menghafal data pelatihan tetapi juga mampu melakukan generalisasi terhadap data baru.

Meskipun demikian, hasil pengujian menunjukkan bahwa masih terdapat beberapa kesalahan klasifikasi pada kategori usia tertentu. Kesalahan paling sering terjadi pada kelompok usia yang memiliki karakteristik wajah yang mirip, seperti kategori remaja dan dewasa muda atau dewasa muda dan dewasa. Hal ini disebabkan oleh perubahan

fisik wajah yang berlangsung secara bertahap sehingga batas antar kelompok usia tidak selalu terlihat secara jelas pada citra wajah.

Tabel 9. *Classification Report*

Kelas	<i>Precision</i>	<i>Recall</i>	F1-Score
Anak-anak	0.89	0.91	0.90
Remaja	0.81	0.78	0.79
Dewasa Muda	0.83	0.82	0.82
Dewasa	0.84	0.86	0.85
Lansia	0.88	0.86	0.87

3.5 Keterbatasan Penelitian

Selain faktor kemiripan karakteristik usia, performa model juga dipengaruhi oleh kondisi citra yang digunakan. Variasi pencahayaan menjadi salah satu faktor yang cukup berpengaruh terhadap hasil prediksi. Pada beberapa citra dengan pencahayaan rendah, detail wajah seperti kerutan dan tekstur kulit menjadi kurang terlihat sehingga model mengalami kesulitan dalam melakukan klasifikasi. Sebaliknya, pada citra dengan pencahayaan yang baik, model mampu mengenali fitur wajah dengan lebih akurat.

Faktor lain yang turut memengaruhi hasil prediksi adalah pose wajah dan ekspresi wajah. Wajah yang menghadap langsung ke kamera umumnya menghasilkan prediksi yang lebih baik dibandingkan wajah yang diambil dari samping atau dengan sudut tertentu. Demikian pula, ekspresi wajah yang berlebihan seperti tertawa, tersenyum lebar, atau mengernyit dapat mengubah bentuk wajah sementara sehingga memengaruhi proses identifikasi usia.

Hasil penelitian ini juga menunjukkan bahwa terdapat pengaruh faktor biologis yang tidak dapat sepenuhnya dipelajari oleh model. Beberapa individu dengan usia yang sama dapat memiliki tampilan wajah yang berbeda akibat faktor genetik, gaya hidup, pola makan, kondisi kesehatan, maupun lingkungan tempat tinggal. Sebaliknya, terdapat individu dengan usia yang berbeda namun memiliki karakteristik wajah yang tampak serupa. Kondisi ini menyebabkan proses estimasi usia berbasis wajah masih memiliki tingkat ketidakpastian tertentu.

Berdasarkan hasil pengujian, model CNN yang diusulkan memperoleh akurasi sebesar 84,27%. Jika dibandingkan dengan penelitian sebelumnya yang menggunakan model CNN dengan akurasi sekitar 81,47%, penelitian ini menunjukkan peningkatan performa. Peningkatan tersebut diduga dipengaruhi oleh tahapan preprocessing dan data augmentation yang diterapkan sebelum proses pelatihan model. Perbandingan ini hanya digunakan sebagai pembandingan terhadap penelitian terdahulu dan bukan merupakan hasil pengujian langsung terhadap arsitektur deep learning lainnya.

Secara keseluruhan, hasil penelitian membuktikan bahwa implementasi *Face Age Detection* berbasis *Computer Vision* dapat digunakan sebagai solusi untuk mengidentifikasi rentang usia manusia secara otomatis. Teknologi ini memiliki potensi penerapan yang luas dalam berbagai bidang, seperti sistem keamanan untuk verifikasi identitas, layanan publik berbasis digital, sistem pendidikan adaptif, pemasaran digital, hingga analisis demografi pengguna pada berbagai platform teknologi.

Meskipun demikian, masih terdapat beberapa keterbatasan dalam penelitian ini. Dataset yang digunakan masih memiliki variasi kondisi tertentu yang terbatas sehingga belum sepenuhnya merepresentasikan kondisi dunia nyata. Oleh karena itu, penelitian selanjutnya dapat menggunakan dataset yang lebih besar dan lebih beragam, menerapkan teknik transfer learning menggunakan arsitektur modern seperti MobileNetV2, ResNet50, atau EfficientNet, serta melakukan optimasi *hyperparameter* untuk meningkatkan akurasi dan stabilitas model.

4. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa implementasi *Face Age Detection* berbasis *Computer Vision* menggunakan algoritma *Convolutional Neural Network* (CNN) berhasil diterapkan untuk mengidentifikasi rentang usia manusia berdasarkan citra wajah. Sistem yang dikembangkan mampu melakukan proses deteksi wajah, ekstraksi fitur, serta klasifikasi usia secara otomatis melalui analisis karakteristik visual wajah seperti tekstur kulit, bentuk wajah, dan perubahan fisiologis yang berkaitan dengan penambahan usia. Hasil pengujian menunjukkan bahwa model memiliki performa yang baik dalam melakukan klasifikasi rentang usia dengan nilai *Accuracy* sebesar 84,27%, *Precision* sebesar 83,91%, *Recall* sebesar 82,75%, F1-Score sebesar 83,32%, serta *Mean Absolute Error* (MAE) sebesar 4,18 tahun. Hasil tersebut menunjukkan bahwa model mampu mengenali dan mengelompokkan sebagian besar citra wajah ke dalam kategori usia yang sesuai dengan tingkat ketepatan yang tinggi.

Keberhasilan model dalam mengidentifikasi rentang usia tidak terlepas dari penerapan tahapan preprocessing yang meliputi pembersihan data, deteksi wajah, cropping, normalisasi, dan data augmentation. Tahapan tersebut membantu meningkatkan kualitas data dan kemampuan model dalam mempelajari berbagai karakteristik wajah sehingga mampu melakukan generalisasi terhadap data baru dengan lebih baik.

Meskipun demikian, penelitian ini juga menunjukkan bahwa klasifikasi usia berbasis wajah masih dipengaruhi oleh beberapa faktor, seperti variasi pencahayaan, pose wajah, ekspresi, kualitas citra, serta perbedaan karakteristik

biologis antar individu. Faktor-faktor tersebut dapat menyebabkan terjadinya kesalahan klasifikasi, terutama pada kelompok usia yang memiliki karakteristik wajah yang relatif mirip.

Secara keseluruhan, penelitian ini membuktikan bahwa teknologi *Face Age Detection* berbasis *Computer Vision* dan CNN memiliki potensi yang besar untuk diterapkan dalam berbagai bidang, seperti sistem keamanan, layanan publik digital, pendidikan, pemasaran, dan analisis demografi. Selain memberikan kontribusi dalam pengembangan teknologi identifikasi usia otomatis, penelitian ini juga dapat menjadi dasar bagi pengembangan sistem yang lebih akurat dan adaptif pada penelitian selanjutnya.

Penelitian selanjutnya diharapkan dapat melakukan perbandingan performa CNN dengan arsitektur deep learning lain seperti MobileNetV2, ResNet50, dan EfficientNetB0 sehingga dapat diketahui model yang paling sesuai untuk klasifikasi rentang usia wajah.

Reference

- Aditia, R. (2023). *Implementation Of Opencv Face Recognition In Real-Time Age And Gender Detection Using Python With Classification Method Pendahuluan*. 1(September).
- Anggraini, L., & Yamasari, Y. (2023). *Klasifikasi Citra Wajah Untuk Rentang Usia Menggunakan Metode Artificial Neural Network*. 05, 185–192.
- Arifandi, A. (2022). *MENGGUNAKAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN)*. 4(2), 89–96.
- Edilia, F. N., Lestari, T. A., Arrafi, M. R., & Saragih, F. A. (2026). *Klasifikasi Rentang Usia Berdasarkan Citra Wajah Menggunakan Convolutional Neural Network*. 5, 56–61.
- Enbiva, O. F. (2025). *PENERAPAN METODE HAAR CASCADE UNTUK DETEKSI POLA WAJAH BERDASARKAN PERKEMBANGAN USA*. 1545–1554.
- Iqbal, M. (2026). *Implementasi Deepface Dan Opencv Untuk Prediksi Umur Dan Jenis Kelamin Berdasarkan Citra Wajah*. 4(3), 16559–16567.
- Iskandar, M., Technology, I., Program, E. S., Azizah, N., Technology, I., Program, E. S., Jaya, F., Technology, I., & Program, E. S. (2025). *Real-Time Face Age Detection System Based On Deep Neural Networks With Mediapipe Optimization For Enhanced Accuracy*. 08(03), 297–305.
- Marcelio, C. A., Azzikra, M. A., Mufazzal, D. P., & Illahi, A. R. (2024). *Aplikasi Analisis Wajah , Klasifikasi Gender Dan Prediksi Usia Menggunakan Deep Learning Pada Dataset Citra Wajah Manusia*. 20(1), 378–383.
- Nabila, A. (2024). *DEEP LEARNING MENGIDENTIFIKASI UMUR MANUSIA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN)*. 12(3), 1836–1843.
- Pratama, D., Sa, I., Widowati, U., & Munsarif, M. (2025). *Automatic Age Detection Using Convolutional Neural Network (CNN) Method Deteksi Usia Secara Otomatis Dengan Menggunakan Metode Convolutional Neural Network (CNN)*. 1(2). <https://doi.org/10.26714/Jkti.V3i1.13957>
- Rakayazi, K. (2025). *Implementasi Algoritma Knn Untuk Deteksi Gender Dan Usia Berbasis Pengenalan Wajah*. 2–7.
- Robet. (2025). *APLIKASI DETEKSI USIA BERBASIS CITRA MENGGUNAKAN MODEL DEEP LEARNING DENGAN ARSITEKTUR CNN*. 5(1), 97–102.
- Sopian, A., Setiadi, D., Suryatno, A., & Agustino, R. (2024). *Computer Vision : Deteksi Masker Wajah Prediksi Usia Jenis Kelamin Dengan Teknik Deep Learning Menggunakan Algoritma Convolutional Neural Network (CNN) Atau Tidak . Teknologi Computer Vision Muncul Sebagai Solusi Potensial Untuk Mempermudah Atau Bahkan Di Industri Keamanan Untuk Identifikasi Yang Lebih Akurat . Teknologi Deep Yang Cepat Dan Akurat , Yang Semakin Relevan Dengan Peningkatan Kebutuhan Akan Solusi 1) Bagaimana Caranya Mengembangkan Model Deep Learning Yang Dapat Mendeteksi Wajah , Tetapi Juga Menentukan Apakah Seseorang Mengenakan Masker .* 10(2), 720–733.
- Syahputra, S. A. F. (2024). *CITRA WAJAH MENGGUNAKAN DEEP LEARNING ALGORITMA Convolutional Neural Network (CNN)*. 2(1), 87–95.
- Trisianti, D., Prameswari, D. S., Adiba, I., Pratama, A. R., Wahyu, S. J., Data, S., Pembangunan, U., Jawa, N., Learning, D., Network, C. N., Wajah, D. E., Learning, D., Network, C. N., & Detection, F. E. (2025). *Kata Kunci*. 01(01), 317–328.