

## Implementasi *Convolutional Neural Network* pada *Multi-label Classification* Wajah Manusia Berdasarkan Usia, Gender, dan Ras

Maulana Surya Negara<sup>1</sup>, Muhammad Irzan<sup>1</sup>, Ahmad Dia'ul Haqqi<sup>1</sup>, Fitri Bimantoro<sup>1</sup>

<sup>1</sup>Jurusan Teknik Informatika, Fakultas Teknik Universitas Mataram, Jl. Majapahit No. 62, Mataram, 83115 Indonesia

### ARTICLE INFO

#### Article history:

Received July 20, 2024  
Revised August 31, 2024  
Accepted August 31, 2024

#### Keywords:

*Human Face ;  
Classification;  
Convolutional Neural Network;  
Augmentasi;  
Multi-label*

### ABSTRACT

Klasifikasi wajah manusia merupakan bidang penelitian penting dalam pengenalan pola dan *computer vision*, dengan fokus pada informasi seperti jenis kelamin, usia, ras, dan ekspresi wajah. Penelitian ini bertujuan untuk meningkatkan klasifikasi *multi-label* wajah manusia menggunakan *convolutional neural network* (CNN). Metode tradisional seperti *Local Binary Pattern* (LBP) dan *Random K-Nearest Neighbor* (KNN) menunjukkan keterbatasan dalam akurasi dan ketergantungan pada ekstraksi fitur manual, sementara metode CNN yang lebih modern menunjukkan peningkatan akurasi yang signifikan. Penelitian ini bertujuan meningkatkan klasifikasi *multi-label* wajah manusia berdasarkan usia, gender, dan ras menggunakan *convolutional neural network* (CNN). Menggunakan *dataset* UTKFace, model CNN diuji dengan berbagai arsitektur dan teknik *augmentasi* data. Hasil terbaik menunjukkan akurasi 82.98% untuk usia, 90.36% untuk gender, dan 79.48% untuk ras. Penggunaan *augmentasi* data dan peningkatan jumlah filter CNN secara signifikan meningkatkan akurasi model. Meskipun ada tantangan dalam mengklasifikasikan usia "teenager" dan ras "Indian" serta "Others" akibat distribusi data yang tidak seimbang, hasil ini menunjukkan potensi besar CNN dalam klasifikasi *multi-label* wajah manusia. Pengembangan lebih lanjut direkomendasikan dengan *fine-tuning* arsitektur CNN dan eksplorasi metode *augmentasi* data serta *transfer learning*.

*Human face classification is an important research area in pattern recognition and computer vision, focusing on information such as gender, age, race, and facial expressions. This research aims to improve multi-label classification of human faces using convolutional neural networks (CNN). Traditional methods such as Local Binary Pattern (LBP) and Random K-Nearest Neighbor (KNN) show limitations in accuracy and dependence on manual feature extraction, while more modern CNN methods show significant improvements in accuracy. This research aims to improve multi-label classification of human faces based on age, gender and race using convolutional neural networks (CNN). Using the UTKFace dataset, the CNN model is tested with various architectures and data augmentation techniques. The best results showed an accuracy of 82.98% for age, 90.36% for gender, and 79.48% for race. The use of data augmentation and increasing the number of CNN filters significantly improves the model accuracy. Although there are challenges in classifying age "teenager" and race "Indian" and "Others" due to unequal data distribution, these results demonstrate the great potential of CNN in multi-label classification of human faces. Further development is recommended by fine-tuning the CNN architecture and exploring data augmentation and transfer learning methods.*

---

**Corresponding Author:**

Maulana Surya Negara, Jurusan Teknik Informatika Fakultas Teknik Universitas Mataram, Jl. Majapahit No. 62, Mataram, 83115, Indonesia

Email: [f1d021110@student.unram.ac.id](mailto:f1d021110@student.unram.ac.id)

---

**1. PENDAHULUAN**

Klasifikasi wajah manusia adalah salah satu bidang penelitian yang penting dalam pengenalan pola dan *computer vision* [1]. Citra sangat dibutuhkan dalam melakukan klasifikasi wajah salah satunya adalah informasi tentang jenis kelamin, usia, ras, dan ekspresi [2]. Klasifikasi wajah menjadi tantangan sendiri mengingat ragamnya bentuk wajah manusia. Tingkat akurasi dalam klasifikasi menjadi tolak ukur terhadap kesuksesan dalam identifikasi wajah. Selain itu, objek citra menjadi salah satu problem dalam *computer vision* [3]. Terlebih, dalam klasifikasi wajah sejauh ini hanya mampu mendeteksi beberapa deteksi saja, artinya dalam satu sistem belum mampu mendeteksi wajah dengan klasifikasi berbeda yang lebih kompleks.

Penelitian sebelumnya telah banyak menggunakan metode ekstraksi fitur tradisional seperti *Local Binary Pattern* (LBP) dan algoritma klasifikasi seperti *Random K-Nearest Neighbor* (KNN) untuk klasifikasi wajah. Metode LBP dan *Random KNN* memiliki beberapa keunggulan, seperti kesederhanaan komputasi dan kemampuan diskriminatif [4]. Namun, hasil yang diperoleh masih memiliki beberapa keterbatasan yang signifikan. Hasil klasifikasi gender berbasis wajah menggunakan LBP dan *Random KNN* menunjukkan akurasi rata-rata sebesar 72,5%, yang dianggap kurang memadai untuk aplikasi yang memerlukan keakuratan tinggi. Selain itu, metode ini sangat bergantung pada proses ekstraksi fitur manual, yang sering kali tidak mampu menangkap informasi penting dari citra wajah, terutama pada kondisi pencahayaan dan pose yang bervariasi [5].

Pada penelitian lain yang dilakukan oleh Putra, 2023, melakukan klasifikasi ras dan gender dengan metode *convolutional neural network* mendapatkan akurasi masing-masing sebesar 82% dan 94%. Akan tetapi ia menggunakan dua model yang berbeda untuk melakukan klasifikasi jenis kelamin dan ras [6]. Hal ini menunjukkan bahwa pembuatan model yang dapat melakukan *multi-label* klasifikasi bukanlah suatu hal yang mudah. Untuk mengatasi tantangan ini, diperlukan metode yang mampu menangkap berbagai fitur yang ada dalam gambar wajah dan memprediksi beberapa label secara simultan.

*Convolutional neural network* telah terbukti sangat efektif dalam menangani masalah pengenalan gambar. Dari penelitian Weni, 2020 dalam penelitian Soni mendapatkan hasil akurasi sebesar 95% dengan menggunakan metode *convolutional neural network* untuk melakukan pendeteksian katarak pada citra wajah [7]. Pada penelitian sebelumnya yang menggunakan UTKFace *dataset*, terdapat dua jenis hasil akurasi pada data usia dan gender dengan hasil akurasi masing-masing 60% dan 80%. Akan tetapi pada penelitian ini, penulis menggunakan *pretrained* model ResNet50 yang walaupun *powerfull*, namun berat secara komputasi dan mungkin tidak cocok untuk aplikasi *real-time* atau lingkungan dengan sumber daya komputasi terbatas [8].

Klasifikasi *multi-label* berbeda dari klasifikasi biasa yang hanya memiliki satu label untuk setiap data. Dalam klasifikasi *multi-label*, setiap data dapat terkait dengan beberapa label sekaligus. Sebagai contoh, pada penelitian yang dilakukan oleh Wu, 2022, menggunakan model *multi-label* yang menggabungkan CNN dan *transformer* telah digunakan untuk identifikasi mineral dalam gambar, mencapai rata-rata *precision* sebesar 85.26% [9].

Penelitian ini bertujuan untuk mengeksplorasi penggunaan *convolutional neural network* dalam klasifikasi *multi-label* wajah manusia. Kami berfokus pada bagaimana arsitektur *deep learning* dapat diadaptasi untuk menangani keluaran *multi-label* dan bagaimana mengoptimalkan kinerja model dalam kondisi data yang kompleks. Pendekatan ini melibatkan eksperimen dengan berbagai arsitektur *deep learning*, teknik *augmentasi* data, dan strategi pelatihan untuk meningkatkan akurasi dan efisiensi model.

Dengan menggunakan *convolutional neural network*, diharapkan dapat diperoleh model yang robust dan akurat untuk klasifikasi *multi-label* pada wajah manusia. Hal ini tidak hanya akan meningkatkan kemampuan sistem pengenalan wajah tetapi juga membuka peluang untuk aplikasi yang lebih canggih dalam analisis wajah, seperti pemantauan emosi, interaksi sosial, dan analisis demografi.

**1.1. Deteksi Wajah**

Perkembangan teknologi komputer selalu diikuti oleh perkembangan deteksi wajah. Hal ini dibuktikan dengan banyaknya algoritma pendeteksian wajah yang digunakan aplikasi komersial. Algoritma ini dijadikan

sebagai pemodelan wajah, *face relighting*, pengenalan wajah, verifikasi atau otektikasi wajah, *head pose tracking*, pelacakan atau pengenalan ekspresi wajah, pengenalan jenis kelamin atau usia dan masih banyak lagi [10].

### 1.2. Pengenalan Wajah

Pengenalan wajah adalah sistem yang memanfaatkan fitur wajah seseorang yang kemudian diidentifikasi. Untuk mengetahui segala bentuk informasi terkait dengan gambar wajah [7]. Pengenalan wajah banyak digunakan sebagai sistem keamanan selain dari pengenalan retina mata, pengenalan sidik jari, dan iris mata [11].

Disisi lain, mengidentifikasi postur wajah, karakteristik wajah, dan emosi wajah masih menjadi kendala saat ini. Salah satu masalah dengan sistem pengenalan wajah misalnya, ketika foto wajah diambil, lokasi wajah terlihat samping, dengan karakteristik wajah yang hanya terlihat sebagian. Salah satu pendekatan ekstraksi wajah saat ini adalah CNN (*Convolutional Neural Network*) dari beberapa penelitian yang ada [7]

### 1.3. Image Augmentation

*Augmentasi* adalah memodifikasi citra dengan proses pengolahan data citra [2] Menambahkan data citra sangat diperlukan untuk menyeimbangkan data citra antar kelas [12]. Berbagai teknik *augmentasi* gambar yang berhasil untuk mengatasi *overfitting* telah dikembangkan dalam visi komputer. Teknik ini menerapkan transformasi pada gambar *input* di mana label tugas tidak berubah [13].

*Augmentasi* data banyak digunakan untuk mengatasi masalah kekurangan data. Secara umum, *augmentasi* data berarti menciptakan sampel data tambahan secara artifisial untuk memperbesar ukuran data pelatihan. Dalam bidang pencitraan, hal ini biasanya dilakukan dengan menerapkan berbagai transformasi gambar, seperti translasi, rotasi, atau pembalikan [14]

### 1.4. Convolutional Neural Network

*Convolutional Neural Network* (CNN) merupakan salah satu jenis *deep feed-forward artificial neural network* yang sering digunakan dalam analisis citra. Struktur CNN terdiri dari satu lapisan masukan (*input layer*), satu lapisan keluaran (*output layer*), dan beberapa lapisan tersembunyi (*hidden layer*) [15].

Metode CNN biasanya dilatih dengan berbagai macam metode *backpropagation* yang berbasis gradien. Semua pola pelatihan dan juga *output* yang juga diharapkan dimasukkan ke dalam jaringan. Setelah itu network error (perbedaan antara *output* sebenarnya dan yang di harapkan) dipropagasi lagi melalui jaringan dan digunakan untuk menghitung gradien dari *network error* dengan bobot. Gradien kemudian akan digunakan untuk mengupdate nilai bobot sesuai dengan aturan tertentu (misalnya, stokastik, momentum, dll) [7]

### 1.5. Deep Learning

*Deep Learning* adalah bagian dari kecerdasan buatan dan pembelajaran mesin yang melibatkan pembuatan jaringan saraf berlapis untuk melakukan tugas-tugas yang tepat seperti deteksi objek, pengenalan suara, terjemahan bahasa, dan sebagainya. *Deep Learning* bervariasi dari pendekatan pembelajaran mesin biasa yang mengeksekusi representasi data seperti foto, video, atau teks secara otomatis tanpa memerlukan penulisan kode atau keahlian manusia [7].

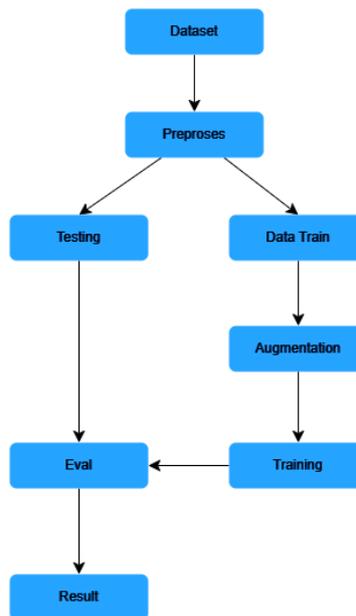
### 1.6. Hyperparameter Tuning

Meskipun model *Convolutional Neural Network* (CNN) menghasilkan kinerja yang cukup baik, kinerjanya masih dapat ditingkatkan untuk mendapatkan model yang lebih optimal melalui *hyperparameter tuning*. *Hyperparameter tuning* memiliki peran penting dalam mengoptimalkan dan meningkatkan kinerja CNN. Beberapa *hyperparameter tuning* yang sering disesuaikan untuk mengoptimalkan kinerja model CNN antara lain *epoch*, *batch size*, *learning rate*, dan *optimizer* [16].

Penelitian sebelumnya mengenai *hyperparameter tuning* telah dilakukan oleh Kristina, dkk (2022). Pada penelitian tersebut, model CNN digunakan untuk mengklasifikasikan penyakit tumor otak pada citra MRI. [14]. *Dataset* yang digunakan terdiri dari 6484 citra yang dibagi menjadi 4 kelas, yaitu *glioma*, *meningioma*, *hipofisis*, dan tanpa tumor. Penggunaan CNN yang dikombinasikan dengan *hyperparameter tuning* terbukti memberikan hasil yang optimal dalam klasifikasi tumor otak. Dari percobaan yang dilakukan, didapatkan akurasi sebesar 98,84%. Hal ini menunjukkan bahwa dengan melakukan penyesuaian pada *hyperparameter* seperti *epoch*, *batch size*, *learning rate*, dan *optimizer*, kinerja model CNN dapat ditingkatkan secara signifikan [17].

Implementasi teknik *hyperparameter tuning* pada CNN diharapkan dapat memberikan hasil yang lebih optimal dalam penelitian ini, yang berfokus pada *multi-label classification* wajah manusia berdasarkan umur, gender, dan ras. Dengan demikian, diharapkan akurasi dan efisiensi model dalam mengklasifikasikan wajah manusia dapat meningkat.

## 2. METODOLOGI

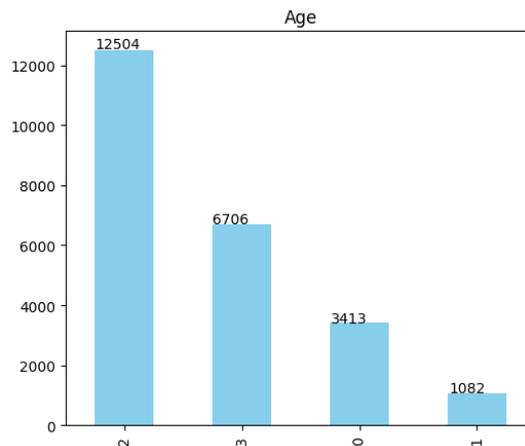


**Gambar 1.** Bagan Alur Penelitian

Adapun alur penelitian kami dimulai dari *dataset*, selanjutnya terdapat *preprocessing* yang di mana terbagi menjadi dua yaitu data *train* dan *testing*. Selanjutnya data *train* akan melalui teknik *augmentation* dan terakhir ada *training* yang di akhiri oleh evaluasi dan hasil.

### 2.1. Dataset

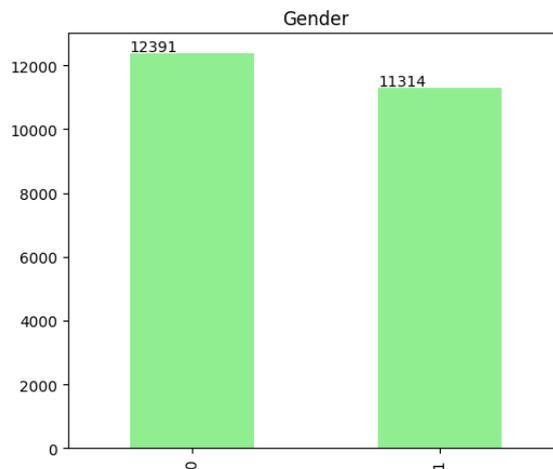
Pada penelitian ini, *dataset* yang digunakan adalah UTKFace *dataset* (Zhang, Song, & Qi 2017). *Dataset* ini mencakup label usia dari rentang 0-116, jenis kelamin, serta lima kategori ras, yaitu ras *Kaukasia*, ras *Ethiopia*, ras *India*, ras *Latin*, dan ras *Asia*.



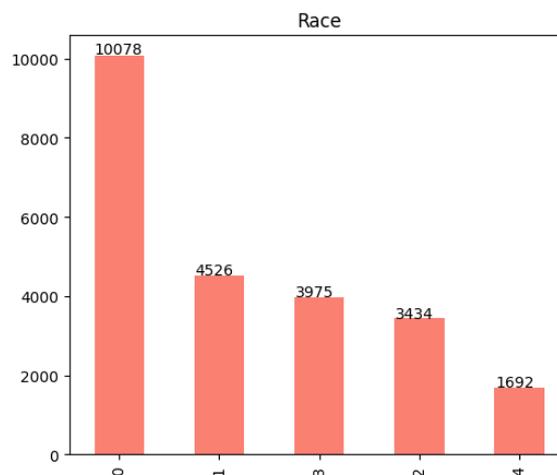
**Gambar 2.** Grafik Distribusi Data Label Age

Gambar 2 merupakan grafik yang menampilkan distribusi usia dengan label Age, terlihat bahwa kelompok *adult* dengan indeks 2 memiliki hasil tertinggi yaitu 12504 data. Diikuti oleh indeks 3 yaitu kelompok *old* dengan 6706 data, indeks 0 yaitu kelompok *child* yang berjumlah 3413 data dan paling sedikit adalah indeks 1 atau kelompok *teenager* yang berjumlah 1082 data. Data ini menunjukkan adanya sebuah kesenjangan yang signifikan antara keempat data.

Gambar 3 adalah grafik hasil distribusi data berdasarkan label gender yang menunjukkan bahwa kelompok *male* dengan indeks 0 memiliki jumlah data sebanyak 12391, sedangkan kelompok *female* dengan indeks 1 memiliki jumlah data sebanyak 11314. Dari data tersebut yang meskipun memiliki perbedaan antara kedua kelompok, namun selisih keduanya memiliki kesenjangan yang tidak terlalu tinggi.



**Gambar 3.** Grafik Distribusi Data Label Gender



**Gambar 4.** Grafik distribusi data Label Race

Gambar 4 merupakan sebuah grafik yang menunjukkan hasil distribusi data dengan label *race*, grafik di atas menunjukkan hasil sebagai berikut: kelompok *white* dengan indeks 0 memiliki jumlah data sebanyak 10078, kelompok *black* dengan indeks 1 menghasilkan jumlah data sebanyak 4526, kelompok *asian* dengan indeks 2 menampilkan jumlah data sebanyak 3434, kelompok *indian* dengan indeks 3 memiliki jumlah data sebanyak 3975, dan yang terakhir kelompok *others* dengan indeks 4 mempunyai jumlah data sebanyak 1692. Data tersebut menunjukkan indeks tertinggi adalah 0 yaitu kelompok *white* di ikuti oleh indeks 1, 3, 2, dan terakhir 4. Kesenjangan tertinggi di miliki oleh indeks 0, namun data lain menunjukkan kesenjangan yang tidak terlalu tinggi.

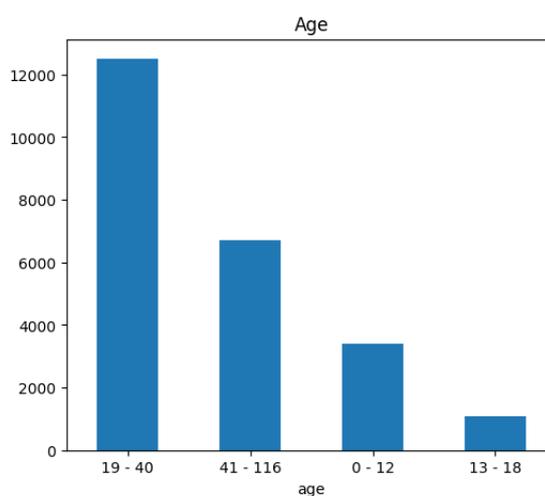
## 2.2. Preprocessing Dataset

Setelah proses pengumpulan data, langkah selanjutnya yaitu melakukan data *preprocessing* yang bertujuan untuk mempersiapkan data sebelum diolah oleh model. Pada tahap ini dilakukan penghapusan gambar yang memiliki ketidaksesuaian pada label. Selain itu juga, akan dilakukan *grouping* pada label *age*. Label *age* akan dibagi menjadi menjadi grup usia *child*, *teenager*, *adult*, dan *old*.

Selanjutnya dilakukan penyeragaman ukuran dari gambar karena model yang digunakan mengharuskan untuk memiliki ukuran yang gambar seragam. Pada percobaan ini ukuran gambar yang akan digunakan yaitu 150x150. Setelah itu akan dilakukan *encoding* dengan menggunakan metode *one hot* pada label *age* dan *race*. Sehingga hasil dari *preprocessing* menjadi seperti berikut.

## 2.3. Splitting Dataset

Setelah data melalui tahapan *preprocessing*, selanjutnya akan dilakukan *splitting* data menjadi data *train* dan data *test* dengan ukuran masing-masing 80% dan 20%.



Gambar 5. Age Group

#### 2.4. Augmentation Dataset

Selanjutnya akan dilakukan tahapan *balancing* data dengan *image augmentation*. Proses ini memiliki peran penting dalam mengatasi masalah data yang tidak seimbang dan dapat meningkatkan generalisasi dan kinerja model [18]. *Augmentasi* dilakukan dengan membuat salinan dari gambar asli dengan jumlah tertentu. Lalu pada salinan tersebut akan diimplementasikan operasi *rotation* dengan nilai 10, *zoom* dengan nilai 0,1, *width shift* dengan nilai 0,1, *height shift* dengan nilai 0,1, *horizontal flip*, *brightness* dengan nilai dari 0,9 – 1,1, *shear* dengan nilai 0,1, dan *channel shift* dengan nilai 0,1.

#### 2.5. Training

Pada proses *training* model, terdapat lima skenario model dengan arsitektur yang serupa namun memiliki variasi dalam beberapa parameter kunci telah diuji. Berikut ini adalah rangkuman dari kelima skenario tersebut:

1. Arsitektur Model: Semua model memiliki arsitektur dasar yang sama, terdiri dari:
  - a. 1 blok *input*
  - b. 1 blok CNN dengan beberapa *filter*
  - c. 3 blok Dense (*Fully Connected Layer*)
2. Parameter Model:
  - a. Filter CNN dan ukuran *kernel*: Setiap model menggunakan filter dengan ukuran 32, 32, 64, dan 64 (model 1-4) atau 32, 64, 64, dan 128 (model 5) dengan ukuran *kernel* 3x3.
  - b. *Pooling*: Semua model menggunakan MaxPooling dengan parameter *padding*='same' dan *regularizer*=0.001.
  - c. Dropout: Tingkat dropout pada blok CNN adalah 0.2 untuk model 1 dan 2, dan 0.5 untuk model 3, 4, dan 5. Tingkat *dropout* pada blok Dense adalah 0.2 untuk semua model.
  - d. Dense *Regularizer*: *Regularizer* untuk blok Dense adalah 0.0001 untuk semua model.
3. Batch Size: Model 1 hingga 3 menggunakan *batch size* 64, sementara model 4 dan 5 menggunakan *batch size* 256.
4. Optimizer dan Epoch: Semua model menggunakan *optimizer* Adam dengan jumlah *epoch* yang bervariasi: 20 *epoch* untuk model 1 dan 2, dan 50 *epoch* untuk model 3, 4, dan 5.

#### 2.6. Evaluasi

Evaluasi performa model CNN dilakukan menggunakan beberapa metrik evaluasi yang umum digunakan dalam tugas klasifikasi, yaitu akurasi, *precision*, *recall*, dan *confusion matrix*. Berikut penjelasan setiap metrik dan bagaimana mereka diaplikasikan dalam penelitian ini:

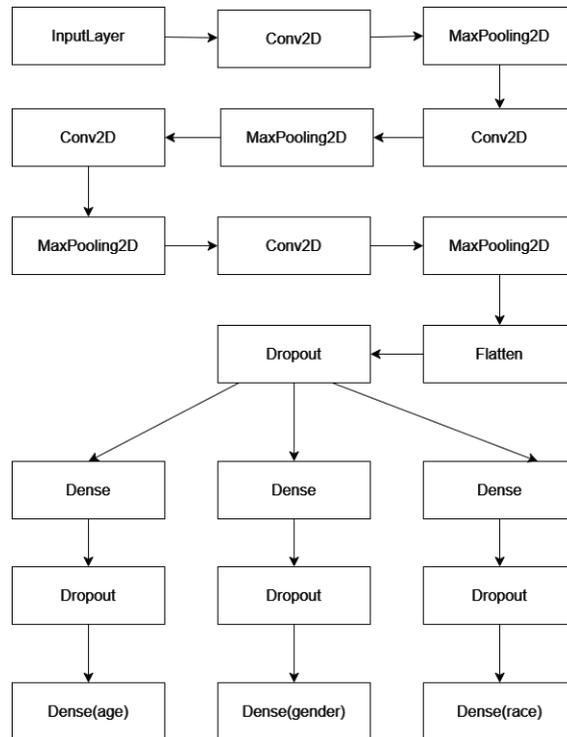
1. Akurasi (Accuracy)

Akurasi adalah salah satu metrik evaluasi yang paling sederhana dan paling umum digunakan untuk mengukur kinerja model klasifikasi. Akurasi menghitung persentase prediksi yang benar dibandingkan dengan total prediksi yang dibuat oleh model. Rumus untuk menghitung akurasi dalam persamaan (1).

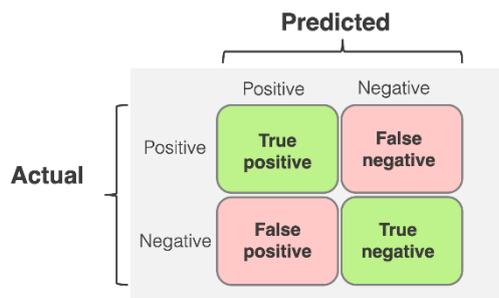
$$Akurasi = \frac{Jumlah\ prediksi}{Total\ prediksi} \quad (1)$$

2. Confusion Matrix

*Confusion matrix* adalah alat yang sangat berguna untuk menganalisis kinerja model klasifikasi. Matriks ini memberikan gambaran yang lebih detail tentang bagaimana model membuat prediksi, dengan menunjukkan jumlah prediksi benar dan salah yang dibuat oleh model untuk setiap kelas. Berikut merupakan ilustrasi dari arsitektur model yang akan digunakan.



Gambar 6. Arsitektur Model



Gambar 7. Confusion Matrix

3. HASIL DAN PEMBAHASAN



Gambar 8. Hasil Preprocessing

Gambar 8 merupakan hasil preprocessing yang bertujuan untuk mempersiapkan data sebelum diolah dan melakukan penghapusan gambar yang tidak sesuai pada label.

Pada penelitian ini, kami melakukan eksperimen beberapa model yang memiliki variasi arsitektur, *augmentasi* data, dan *hyperparameter*. Berikut adalah hasil eksperimen dengan lima model yang berbeda.

1. Pada eksperimen awal model menggunakan konfigurasi sederhana untuk mengukur *baseline* metrik *accuracy*. Berikut merupakan konfigurasi yang dimiliki model *baseline*.
  - a. CNN filter: 32, 32, 64, 64
  - b. CNN *dropout*: 0,2
  - c. *Kernel size*: 3x3
  - d. *Pooling*: *MaxPooling* dengan *padding* “same” dan nilai *regularizer* 0,001.
  - e. *Dense*: 128 dengan *dropout* 0,2 dan nilai *regularizer* 0,001.
  - f. *Batch size*: 64
  - g. *Optimizer*: Adam
  - h. *Epoch*: 20
2. Pada eksperimen kedua akan diterapkan teknik *augmentasi* pada data *train*.
3. Selanjutnya bereksperimen melatih model lebih lama dengan meningkatkan jumlah *epoch* menjadi 50 dan menambahkan jumlah *dropout* pada CNN menjadi 0,5.
4. Pada eksperimen keempat, unit dari *dense layer* akan ditingkatkan menjadi 256.
5. Pada eksperimen terakhir, akan dilakukan peningkatan *filter* dari CNN menjadi 32, 64, 64, dan 128. Karena tidak ada peningkatan yang signifikan ketika unit *dense layer* ditingkatkan, maka pada eksperimen ini unit dari *dense layer* akan menggunakan 128 kembali.

**Tabel 1.** Perbandingan Hasil Eksperimen

Eksperimen	Total Params	Age Accuracy	Gender Accuracy	Race Accuracy
1	2,057,898	0.8146	0.884	0.7697
2	2,057,898	0.8207	0.8971	0.7844
3	2,057,898	0.8329	0.9091	0.7855
4	4,050,218	0.8338	0.8998	0.7863
5	4,113,162	0.8298	0.9036	0.7948

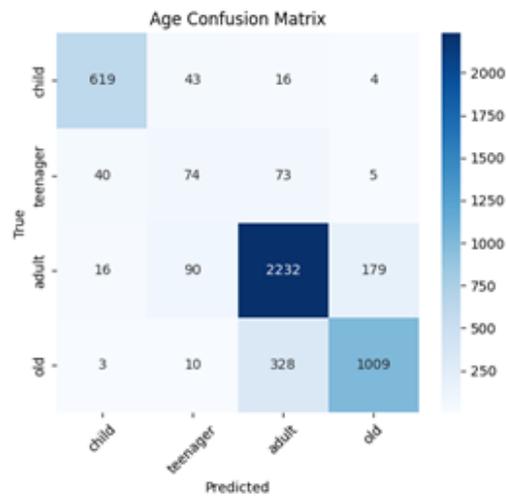
Hasil eksperimen menunjukkan bahwa penggunaan *augmentasi* data dan proses *training* yang lebih lama, disertai dengan penambahan jumlah *dropout*, dapat secara signifikan meningkatkan akurasi model. Model dengan 256 *neuron* pada *dense layer* hanya menunjukkan peningkatan kinerja pada label gender. Dengan pertimbangan bahwa peningkatan akurasi hanya terjadi pada label gender disertai dengan peningkatan total parameter hampir dua kali lipat, maka jumlah *neuron* akan dikembalikan menjadi 128. Peningkatan jumlah *filter* CNN menghasilkan hasil terbaik pada studi kasus ini, dengan ketiga label mengalami peningkatan akurasi. Dengan jumlah total parameter yang serupa, peningkatan jumlah *filter* CNN lebih menjanjikan dibandingkan dengan meningkatkan unit pada *dense layer*.

Sehingga dari eksperimen terakhir didapatkan hasil evaluasi menggunakan *confusion matrix* sebagai berikut.

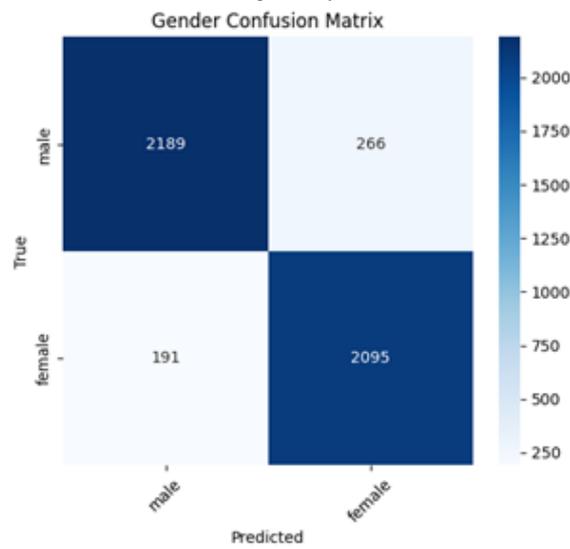
Pada Gambar 8 terlihat dalam mengklasifikasikan wajah ke dalam kategori usia seperti 'child', 'teenager', 'adult', dan 'old'. Dari hasil pengujian, model lebih banyak melakukan kesalahan dalam mengklasifikasikan 'teenager' ke dalam kategori 'adult'. Hal ini tentu disebabkan karena kelas “teenager” merupakan kelas yang memiliki data paling sedikit.

Sedangkan model dapat mengklasifikasikan gender dengan akurasi yang tinggi, dengan kesalahan yang lebih sedikit dibandingkan dengan klasifikasi usia. Faktor pendukung hal ini karena pada label gender kedua kelas memiliki distribusi data yang relatif sama.

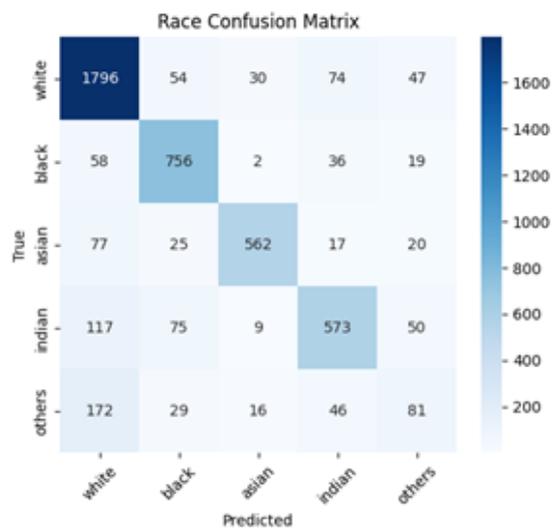
Klasifikasi ras menunjukkan hasil yang kurang baik pada kelas “indian” dan “others”. Faktor utama hal ini karena *fitur* wajah dari ras “indian” dan “others” mungkin memiliki kemiripan dengan ras “white”, menyebabkan model sulit untuk menemukan *fitur* pemisahan yang jelas. Faktor lain seperti distribusi data di mana jumlah sampel dari ras “white” jauh lebih banyak dibandingkan dengan ras “Indian” dan “others”. Ketidakseimbangan ini membuat model lebih cenderung memprediksi kelas yang dominan.



Gambar 9. Age Confusion Matrix



Gambar 10. Gender Confusion Matrix



Gambar 11. Race Confusion Matrix

#### 4. KESIMPULAN

Berdasarkan penelitian yang dilakukan, implementasi *convolutional neural network* (CNN) untuk klasifikasi *multi-label* wajah manusia berdasarkan usia, gender, dan ras telah menghasilkan model terakhir yang menjadi terbaik dengan *age accuracy*, *gender accuracy*, dan *race accuracy* berturut-turut sebesar 0,8298; 0,9036; dan 0,7948. Eksperimen menunjukkan bahwa dengan penggunaan *augmentasi* data, peningkatan jumlah *filter* CNN menjadi 32, 64, 64, 128, serta peningkatan *dropout*, akurasi klasifikasi usia, gender, dan ras dapat ditingkatkan secara signifikan dari *baseline*. Meskipun demikian, tantangan tetap ada terutama dalam klasifikasi usia, di mana kesalahan terbesar terjadi dalam mengidentifikasi “teenager” sebagai “adult”, yang dipengaruhi oleh distribusi data yang tidak seimbang. Hasil juga menunjukkan bahwa klasifikasi ras, terutama untuk kategori "Indian" dan "Others", masih memerlukan peningkatan lebih lanjut karena kesulitan dalam membedakan *fitur* wajah antara ras yang memiliki kesamaan visual.

Untuk pengembangan selanjutnya, disarankan untuk terus mengoptimalkan model dengan mempertimbangkan teknik-teknik seperti *fine-tuning* arsitektur CNN, eksplorasi metode *augmentasi* data yang lebih maju, serta penanganan secara khusus terhadap ketidakseimbangan data pada kategori usia dan ras. Selain itu, integrasi dengan metode *transfer learning* menggunakan *pre-trained* model dapat menjadi strategi yang potensial untuk meningkatkan akurasi tanpa memperbesar jumlah parameter secara signifikan. Dengan terus melakukan penelitian dan eksperimen lebih lanjut, diharapkan implementasi CNN pada klasifikasi *multi-label* wajah manusia ini dapat memberikan kontribusi yang berharga dalam pengembangan sistem pengenalan wajah yang lebih akurat dan dapat diandalkan untuk berbagai aplikasi di masa depan.

#### REFERENCES

- [1] R. G. Guntara, “Pemanfaatan Komputer Vision pada E-Commerce,” *Rangga Gelar Guntara) Madani: Jurnal Ilmiah Multidisiplin*, vol. 1, no. 3, pp. 2302–6219, 2023, doi: 10.5281/zenodo.7881002.
- [2] A. Antoni, T. Rohana, and A. R. Pratama, “Implementasi Algoritma Convolutional Neural Network Untuk Klasifikasi Citra Kemasan Kardus Defect dan No Defect,” *Building of Informatics, Technology and Science (BITS)*, vol. 4, no. 4, Mar. 2023, doi: 10.47065/bits.v4i4.3270.
- [3] Y. N. Yenusi, Suryasatriya Trihandaru, and A. Setiawan, “Comparison of Convolutional Neural Network (CNN) Models in Face Classification of Papuan and Other Ethnicities,” *JST (Jurnal Sains dan Teknologi)*, vol. 12, no. 1, Mar. 2023, doi: 10.23887/jstundiksha.v12i1.46861.
- [4] F. Juefei-Xu, V. N. Boddeti, and M. Savvides, “Local Binary Convolutional Neural Networks.”
- [5] R. Armandhani, R. Cahya Wihandika, and M. A. Rahman, “Klasifikasi Gender berbasis Wajah menggunakan Metode Local Binary Pattern dan Random KNN,” 2019. [Online]. Available: <http://j-ptiik.ub.ac.id>
- [6] N. S. Putra, B. F. Hutabarat, and U. Khaira, “Implementasi Algoritma Convolutional Neural Network Untuk Identifikasi Jenis Kelamin Dan Ras,” *Decode: Jurnal Pendidikan Teknologi Informasi*, vol. 3, no. 1, pp. 82–93, Feb. 2023, doi: 10.51454/decode.v3i1.123.
- [7] C. Rahmad, A. R. Syulistyo, and A. R. Wardana, “JIP (Jurnal Informatika Polinema) PENGEMBANGAN APLIKASI DEEP LEARNING PENGENALAN WAJAH PADA MEDIA ONLINE UNTUK MENGETAHUI KEHADIRAN MAHASISWA”.
- [8] A. S. Meghana, “Age and Gender prediction using Convolution, ResNet50 and Inception ResNetV2,” *International Journal of Advanced Trends in Computer Science and Engineering*, vol. 9, no. 2, pp. 1328–1334, Apr. 2020, doi: 10.30534/ijatcse/2020/65922020.
- [9] B. Wu *et al.*, “Mineral Identification Based on Multi-Label Image Classification,” *Minerals*, vol. 12, no. 11, Nov. 2022, doi: 10.3390/min12111338.
- [10] C. Rahmad, A. R. Syulistyo, and A. R. Wardana, “JIP (Jurnal Informatika Polinema) PENGEMBANGAN APLIKASI DEEP LEARNING PENGENALAN WAJAH PADA MEDIA ONLINE UNTUK MENGETAHUI KEHADIRAN MAHASISWA”.
- [11] M. Rizki Muliawan, B. Irawan, and Y. Brianorman, “IMPLEMENTASI PENGENALAN WAJAH DENGAN METODE EIGENFACE PADA SISTEM ABSENSI,” *Jurnal Coding, Sistem Komputer Untan*, vol. 03, no. 2338–493X, pp. 41–50, 2015.
- [12] M. Fikri, N. Syahbani, and G. Ramadhan, “JURNAL MEDIA INFORMATIKA BUDIDARMA Klasifikasi Gerakan Yoga dengan Model Convolutional Neural Network Menggunakan Framework Streamlit,” 2023, doi: 10.30865/mib.v7i1.5520.
- [13] M. Farid Naufal and S. Ferdiana Kusuma, “PENDETEKSI CITRA MASKER WAJAH MENGGUNAKAN CNN DAN TRANSFER LEARNING,” vol. 8, no. 6, pp. 1293–1300, 2021, doi: 10.25126/jtiik.202185201.
- [14] Z. Yang, R. O. Sinnott, J. Bailey, and Q. Ke, “A survey of automated data augmentation algorithms for deep learning-based image classification tasks,” *Knowl Inf Syst*, vol. 65, no. 7, pp. 2805–2861, Jul. 2023, doi: 10.1007/s10115-023-01853-2.
- [15] rafi Akram, S. Adinda Rachmadinasya, F. Hafidz Melvandino, and H. Ramza, “KLASIFIKASI AKTIVITAS OLAHRAGA BERDASARKAN CITRA FOTO DENGAN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK,” *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 11, no. 3, pp. 2830–7062, doi: 10.23960/jitet.v11i3%20s1.3496.

- [16] A. Julianto, A. Sunyoto, D. Ferry, and W. Wibowo, "OPTIMASI HYPERPARAMETER CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI PENYAKIT TANAMAN PADI (OPTIMIZATION OF CONVOLUTIONAL NEURAL NETWORK HYPERPARAMETERS FOR CLASSIFICATION OF RICE PLANT DISEASES)." [Online]. Available: <https://www.kaggle.com/tedisetiady/leaf-rice-dis->
- [17] D. Arsitektur Alexnet, st Kristina Amalia, K. Kunci, and T. otak, "Klasifikasi Penyakit Tumor Otak Pada Citra Mri Menggunakan Metode CNN." [Online]. Available: [www.kaggle.com](http://www.kaggle.com)

## BIOGRAPHY OF AUTHORS



**Maulana Surya Negara** ([f1d021110@student.unram.ac.id](mailto:f1d021110@student.unram.ac.id)) adalah mahasiswa angkatan 2021 di Program Studi Teknik Informatika Universitas Mataram. Melalui program Bangkit Academy memiliki minat dalam bidang *machine learning* dan tersertifikasi sebagai Tensorflow Developer.



**Muhamad Irzan** ([f1d021052@student.unram.ac.id](mailto:f1d021052@student.unram.ac.id)) adalah mahasiswa angkatan 2021 Teknik Informatika Universitas Mataram. Lahir pada tanggal 26 juli 2002.



**Ahmad Dia'ul Haqqi** ([f1d021024@student.unram.ac.id](mailto:f1d021024@student.unram.ac.id)) adalah seorang mahasiswa angkatan 2021 pada Program Studi Teknik Informatika Fakultas Teknik Universitas Mataram. Lahir pada tanggal 2003 di Aikmel Lombok Timur.



**Fitri Bimantoro** ([bimo@unram.ac.id](mailto:bimo@unram.ac.id)) adalah dosen Informatika Universitas Mataram sejak tahun 2015. Beliau memperoleh gelar Sarjana Teknik Elektro dari Jurusan Temnik Elektro Universitas Mataram pada tahun 2010 dan gelar Magister Informatika di Institut Teknologi Sepuluh Nopember pada tahun 2014. Minatnya pada bidang *computer vision*, *image processor*, *pattern recognition*, dan pengambilan gambar.