

**PENERAPAN ARSITEKTUR *CONVOLUTIONAL NEURAL NETWORK*  
(CNN) *MOBILENETV1* DAN *DENSENET-121* UNTUK KLASIFIKASI  
JENIS KELAMIN BERDASARKAN CITRA MATA MANUSIA**

**(Skripsi)**

**Oleh**

**SINTA NURHALIFAH  
NPM 2117051015**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS LAMPUNG  
BANDAR LAMPUNG**

**2025**

**PENERAPAN ARSITEKTUR *CONVOLUTIONAL NEURAL NETWORK*  
(CNN) *MOBILENETV1* DAN *DENSENET-121* UNTUK KLASIFIKASI  
JENIS KELAMIN BERDASARKAN CITRA MATA MANUSIA**

**Oleh**

**SINTA NURHALIFAH**

**Skripsi**

**Sebagai Salah Satu Syarat Untuk Mencapai Gelar  
SARJANA ILMU KOMPUTER (S.Kom)**

**Pada**

**Jurusan Ilmu Komputer  
Fakultas Matematika Dan Ilmu Pengetahuan Alam  
Universitas Lampung**



**PROGRAM STUDI ILMU KOMPUTER  
FAKULTAS MATEMATIKA DAN ILMU PENEGTAHUAN ALAM  
UNIVERSITAS LAMPUNG**

**2025**

## ABSTRAK

### **PENERAPAN ARSITEKTUR *CONVOLUTIONAL NEURAL NETWORK* (CNN) *MOBILENETV1* DAN *DENSENET-121* UNTUK KLASIFIKASI JENIS KELAMIN BERDASARKAN CITRA MATA MANUSIA**

Oleh

**SINTA NURHALIFAH**

Klasifikasi jenis kelamin merupakan salah satu bidang penting dalam sistem identifikasi biometrik yang berperan dalam keamanan, forensik, dan interaksi manusia-komputer. Citra mata manusia menjadi salah satu objek visual yang potensial untuk digunakan dalam klasifikasi jenis kelamin karena mengandung ciri khas anatomi yang berbeda antara laki-laki dan perempuan. Penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi dua arsitektur *Convolutional Neural Network* (CNN), yaitu *MobileNetV1* dan *DenseNet-121*, dalam proses klasifikasi jenis kelamin berdasarkan citra mata manusia. Dataset yang digunakan diperoleh dari platform *Kaggle* dengan total 11.525 citra mata, terdiri atas 6.323 citra mata laki-laki dan 5.202 citra mata perempuan. Proses penelitian meliputi tahap *pre-processing*, pembagian data, augmentasi menggunakan transformasi *Affine* (rotasi dan translasi), serta pelatihan dan evaluasi model. Evaluasi dilakukan menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*. Hasil penelitian menunjukkan bahwa kedua arsitektur mampu melakukan klasifikasi dengan baik, namun terdapat perbedaan performa di antara keduanya. Klasifikasi pada penelitian ini mendapatkan akurasi terbaik untuk *MobileNetV1* dengan menggunakan skenario rotasi sebesar 92,49%, dan arsitektur *DenseNet-121* dengan menggunakan skenario gabungan rotasi dan translasi sebesar 86.84%. Penelitian ini diharapkan dapat memberikan kontribusi terhadap pengembangan sistem klasifikasi berbasis citra mata yang efisien dan akurat menggunakan pendekatan *deep learning*.

**Kata kunci:** *Convolutional Neural Network*, *MobileNetV1*, *DenseNet-121*, Klasifikasi Jenis Kelamin, Citra Mata.

## ***ABSTRACT***

### ***IMPLEMENTATION OF CONVOLUTIONAL NEURAL NETWORK ARCHITECTURES MOBILENETV1 AND DENSENET-121 FOR GENDER CLASSIFICATION BASED ON HUMAN EYE IMAGES***

***By***

**SINTA NURHALIFAH**

*Gender classification is an important field in biometric identification systems that plays a vital role in security, forensics, and human–computer interaction. Human eye images are a promising visual object for gender classification because they contain distinct anatomical features that differ between males and females. This study aims to implement and evaluate two Convolutional Neural Network (CNN) architectures, namely MobileNetV1 and DenseNet-121, for gender classification based on human eye images. The dataset used was obtained from the Kaggle platform, consisting of 11,525 eye images, with 6,323 male and 5,202 female samples. The research process involved several stages, including pre-processing, data splitting, augmentation using Affine transformations (rotation and translation), as well as model training and evaluation. The evaluation was conducted using accuracy, precision, recall, and F1-score metrics. The results showed that both architectures were capable of performing gender classification effectively, although differences in performance were observed. The best accuracy was achieved by MobileNetV1 with a rotation scenario of 92.49%, while DenseNet-121 obtained 86.84% with a combined rotation and translation scenario. This research is expected to contribute to the development of efficient and accurate eye image–based gender classification systems using deep learning approaches.*

***Key words:*** Convolutional Neural Network, MobileNetV1, DenseNet-121, Gender Classification, Eye Image.

Judul Skripsi : **PENERAPAN ARSITEKTUR  
CONVOLUTIONAL NEURAL NETWORK  
(CNN) MOBILENETV1 DAN DENSENET-121  
UNTUK KLASIFIKASI JENIS KELAMIN  
BERDASARKAN CITRA MATA MANUSIA.**

Nama Mahasiswa : **Sinta Nurhalifah**

Nomor Pokok Mahasiswa : 2117051015

Jurusan : Ilmu Komputer

Fakultas : Matematika dan Ilmu Pengetahuan Alam



1. Komisi Pembimbing

A handwritten signature in black ink, belonging to Dr. rer. nat. Akmal Junaidi, M.Sc.

Dr. rer. nat. Akmal Junaidi, M.Sc.  
NIP. 197101291997021001

2. Mengetahui

Ketua Jurusan Ilmu Komputer

A handwritten signature in blue ink, belonging to Dwi Sakethi, S.Si., M.kom.  
Dwi Sakethi, S.Si., M.kom.  
NIP. 196806111998021001

Ketua Prodi Ilmu Komputer

A handwritten signature in blue ink, belonging to Tristiyanto, M.I.S., Ph.D.  
Tristiyanto, M.I.S., Ph.D.  
NIP. 198104142005011001

## MENGESAHKAN


### 1. Tim Penguji

Ketua : Dr. rer. nat. Akmal Junaidi, M.Se.



Penguji

Bukan Pembimbing : Didik Kurniawan, S.Si., M.T.



Penguji

Bukan Pembimbing : M. Iqbal Parabi, S.Si., M.T.



### 2. Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam



Dr. Eng. Heri Satria, S.Si., M.Si.  
NIP. 197110012005011002

Tanggal Lulus Ujian Skripsi : 15 Agustus 2025

## PERNYATAAN

Saya yang bertanda tangan di bawah ini:

Nama : Sinta Nurhalifah

NPM : 2117051015

Dengan ini menyatakan bahwa skripsi yang berjudul **“PENERAPAN ARSITEKTUR *CONVOLUTIONAL NEURAL NETWORK* (CNN) *MOBILENETV1* DAN *DENSENET-121* UNTUK KLASIFIKASI JENIS KELAMIN BERDASARKAN CITRA MATA MANUSIA”** adalah benar hasil karya sendiri dan bukan orang lain. Seluruh tulisan yang tertuang dalam skripsi ini telah mengikuti kaidah penulisan karya ilmiah Universitas Lampung. Jika di kemudian hari terbukti skripsi penulisan adalah hasil penjiplakan atau dibuat oleh orang lain, maka penulis bersedia menerima sanksi sesuai dengan peraturan yang berlaku.

Bandar Lampung, 27 Agustus 2025



Sinta Nurhalifah  
NPM. 2117051015

## RIWAYAT HIDUP



Penulis yang bernama Sinta Nurhalifah lahir di Bumi Ratu Nuban, Lampung Tengah pada tanggal 08 April 2003. Penulis merupakan anak kedua dari dua bersaudara, putri dari pasangan Bapak Alex Reza dan Ibu Sri Aminah. Penulis memulai pendidikan formal di PAUD Bhakti Mulia dan menyelesaikannya pada Tahun 2009. Pendidikan dasar dilanjutkan di SD Negeri 1 Bumi Ratu Nuban dan lulus pada Tahun 2015, kemudian melanjutkan ke SMP Negeri 2 Bumi Ratu Nuban dan lulus pada tahun 2018. Selanjutnya, penulis menyelesaikan pendidikan menengah atas di SMA Negeri 1 Trimurjo pada Tahun 2021. Pada Tahun 2021, penulis diterima sebagai mahasiswa Program Studi Ilmu Komputer FMIPA Universitas Lampung melalui jalur Seleksi Nasional Masuk Perguruan Tinggi Negeri (SNMPTN). Selama menjalani masa perkuliahan, penulis aktif dalam berbagai kegiatan organisasi dan pengembangan diri antara lain:

1. Pada periode 2021/2022 penulis menjadi anggota ADAPTER Himpunan Mahasiswa Jurusan Ilmu Komputer (HIMAKOM).
2. Pada periode 2021/2022 penulis menjadi pengurus di bidang Kesekretariatan Himpunan Mahasiswa Ilmu Komputer (HIMAKOM).
3. Pada periode 2023/2024 penulis menjabat sebagai Sekretaris Biro Kewirausahaan Himpunan Mahasiswa Ilmu Komputer (HIMAKOM).

Selain aktif dalam organisasi, penulis juga melaksanakan kegiatan akademik di luar kampus yaitu :

1. Kerja Praktik di RSUD Dr. H. Abdul Moeloek (RSUDAM) pada Tahun 2023.
2. Kuliah Kerja Nyata (KKN) periode II Tahun ajaran 2023/2024 yang dilaksanakan di Desa Gunung Mekar, Kabupaten Lampung Timur.

## **PERSEMBAHAN**

*Alhamdulillahirobbilalamin*

Segala puji syukur kepada Allah SWT yang telah memberikan rahmat dan hidayah-Nya sehingga dapat menyelesaikan penulisan skripsi ini. Sholawat dan salam saya sanjungkan kepada Nabi Muhammad SAW.

Saya persembahkan karya ini kepada:

### **Orang Tuaku Tercinta**

Ayahanda tercinta Alex Reza, dan Ibunda tersayang Sri Aminah, yang senantiasa mengiringi langkahku dengan doa yang tak pernah putus, cinta yang tulus, serta pengorbanan yang tak ternilai. Terima kasih telah menjadi cahaya dalam setiap gelapku, tempat berpulang dalam setiap lelahku, dan alasan terbesarku untuk terus berjuang. Skripsi ini selesai bukan karena usahaku, melainkan karena doa dan ridho dari Bapak dan Ibu. Terima kasih sudah mengantarkanku menjadi seorang Sarjana, gelar ini bukti bahwa kedua orang tuaku selalu mengusahakan pendidikan yang terbaik agar masa depanku jauh lebih baik dari mereka. Semoga Allah membalas setiap tetes peluh, lelah dan doa yang kalian panjatkan dengan keberkahan tanpa batas di dunia dan akhirat.

Seluruh Keluarga Besar, Sahabat dan Teman – Teman.

Almamater Tercinta “**Universitas Lampung**”.

## SANWACANA

Segala puji dan syukur penulis panjatkan ke hadirat Allah Subhanahu wa Ta'ala atas limpahan rahmat, hidayah, dan inayah-Nya sehingga penulis dapat menyelesaikan penyusunan skripsi ini dengan judul: **“Penerapan Arsitektur *Convolutional Neural Network (CNN) MobileNetV1 dan DenseNet-121* untuk Klasifikasi Jenis Kelamin Berdasarkan Citra Mata Manusia”**

Dalam proses penyusunan skripsi ini, penulis menyadari sepenuhnya bahwa tanpa bantuan, bimbingan, dan doa dari berbagai pihak, tugas ini tidak mungkin terselesaikan dengan baik. Oleh karena itu, dengan segala kerendahan hati, penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Allah SWT, yang telah melimpahkan rahmat, taufik, dan hidayah-Nya sehingga saya dapat menyelesaikan tugas ini dengan baik
2. Kedua orang tua saya, yang telah memberikan doa, kasih sayang, serta dukungan yang tiada henti menjadi kekuatan terbesar dalam setiap langkah.
3. Bapak Dr. Eng. Heri Satria, S.Si., M.Si. Selaku Dekan FMIPA Universitas Lampung.
4. Bapak Dwi Sakethi, S.Si., M.Kom. Selaku Ketua Jurusan Ilmu Komputer Universitas Lampung.
5. Ibu Yunda Heningtyas, M.Kom. Selaku Sekretaris Jurusan Ilmu Komputer Universitas Lampung.
6. Bapak Bambang Hermanto, S.Kom., M.Cs. selaku Dosen Pembimbing Akademik, yang telah membimbing penulis sejak awal masa perkuliahan. Terima kasih atas segala arahan, perhatian, dan dukungan yang diberikan selama penulis menempuh studi.
7. Bapak Dr. rer. nat. Akmal Junaidi, M.Sc. Selaku Dosen Pembimbing yang telah dengan penuh kesabaran dan dedikasi membimbing, mengarahkan, serta memberikan masukan berharga selama proses penulisan skripsi ini.

Terima kasih atas waktu, ilmu dan kesediaannya menjadi penopang utama dalam perjalanan akademik ini.

8. Bapak Didik Kurniawan, S.Si., M.T dan Bapak M. Iqbal Parabi, S.Si., M.T. Selaku Dosen Pembahas, yang telah memberikan kritik, saran, serta pandangan yang membangun demi kesempurnaan skripsi.
9. Bapak dan Ibu Dosen Jurusan Ilmu Komputer FMIPA Universitas Lampung, atas ilmu, wawasan, dan nilai-nilai yang telah ditanamkan selama perkuliahan. Setiap pembelajaran yang diberikan menjadi pondasi penting dalam proses penyusunan skripsi dan pengembangan diri penulis.
10. Yola Okta Vina, Selaku sahabat yang selalu hadir dalam suka dan duka, menjadi tempat berbagi cerita dan sumber semangat dalam setiap proses yang penulis jalani. Terima kasih telah menjadi bagian penting dalam perjalanan ini.
11. Teman-teman Ilmu Komputer angkatan 2021, yang telah menjadi rekan seperjuangan sejak awal langkah di bangku kuliah. Kebersamaan, kerja sama, dan kenangan selama bertahun-tahun ini akan selalu menjadi bagian berharga dalam hidup penulis.

Dalam penyusunan skripsi ini, penulis menyadari masih terdapat banyak kekurangan, baik dari segi isi maupun penyajiannya. Hal ini tidak terlepas dari keterbatasan pengalaman, wawasan, dan kemampuan penulis. Oleh karena itu, penulis sangat mengharapkan adanya kritik dan saran yang membangun dari para pembaca guna perbaikan di masa yang akan datang. Penulis berharap, semoga isi dari skripsi ini dapat memberikan manfaat serta menjadi bahan referensi yang berguna bagi siapa pun yang membacanya.

Bandar Lampung, 27 Agustus 2025

Sinta Nurhalifah  
NPM. 2117051015

## DAFTAR ISI

### Halaman

|                                    |             |
|------------------------------------|-------------|
| <b>DAFTAR ISI.....</b>             | <b>iv</b>   |
| <b>DAFTAR TABEL.....</b>           | <b>vii</b>  |
| <b>DAFTAR GAMBAR.....</b>          | <b>viii</b> |
| <b>DAFTAR PSEUDOCODE .....</b>     | <b>x</b>    |
| <b>I. PENDAHULUAN.....</b>         | <b>1</b>    |
| 1.1 Latar Belakang .....           | 1           |
| 1.2 Rumusan Masalah .....          | 3           |
| 1.3 Batasan Masalah.....           | 3           |
| 1.4 Tujuan.....                    | 3           |
| 1.5 Manfaat.....                   | 4           |
| <b>II. TINJAUAN PUSTAKA .....</b>  | <b>5</b>    |
| 2.1 Penelitian Terdahulu.....      | 5           |
| 2.2 Klasifikasi Jenis Kelamin..... | 10          |
| 2.3 Mata.....                      | 10          |
| 2.4 Citra Digital.....             | 11          |
| 2.5 <i>Machine Learning</i> .....  | 11          |
| 2.6 Klasifikasi Citra.....         | 12          |

|             |                                                                   |           |
|-------------|-------------------------------------------------------------------|-----------|
| 2.7         | <i>Deep Learning</i> .....                                        | 12        |
| 2.7.1       | <i>Convolutional Neural Network (CNN)</i> .....                   | 12        |
| 2.7.2       | Arsitektur <i>DenseNet-121</i> .....                              | 14        |
| 2.7.3       | Arsitektur <i>MobileNetV1</i> .....                               | 15        |
| 2.8         | Evaluasi Kinerja Klasifikasi .....                                | 16        |
| 2.9         | Transformasi <i>Affine</i> .....                                  | 18        |
| <b>III.</b> | <b>METODE PENELITIAN</b> .....                                    | <b>20</b> |
| 3.1         | Tempat dan Waktu Penelitian .....                                 | 20        |
| 3.1.1       | Tempat Penelitian .....                                           | 20        |
| 3.1.2       | Waktu Penelitian.....                                             | 20        |
| 3.2         | Data dan Alat.....                                                | 21        |
| 3.2.1       | Data.....                                                         | 21        |
| 3.2.2       | Alat.....                                                         | 21        |
| 3.3         | Alur Pengerjaan Penelitian.....                                   | 23        |
| 3.3.1       | Pengumpulan Dataset.....                                          | 23        |
| 3.3.2       | <i>Pre-Processing</i> .....                                       | 24        |
| 3.3.3       | Pembagian Data.....                                               | 24        |
| 3.3.4       | Augmentasi Data.....                                              | 24        |
| 3.3.5       | Perancangan Model <i>Convolutional Neural Network (CNN)</i> ..... | 25        |
| 3.3.6       | Pelatihan Model <i>Convolutional Neural Network (CNN)</i> .....   | 25        |
| 3.3.7       | Evaluasi Model <i>Convolutional Neural Network (CNN)</i> .....    | 25        |
| 3.3.8       | Evaluasi Hasil.....                                               | 26        |
| <b>IV.</b>  | <b>HASIL DAN PEMBAHASAN</b> .....                                 | <b>27</b> |

|           |                                                                 |           |
|-----------|-----------------------------------------------------------------|-----------|
| 4.1       | Pengumpulan Data .....                                          | 27        |
| 4.2       | <i>Pre-Proceesing</i> Data.....                                 | 28        |
| 4.3       | Pembagian Dataset .....                                         | 29        |
| 4.4       | Augmentasi Data .....                                           | 29        |
| 4.5       | Perancangan Model CNN .....                                     | 33        |
| 4.5.1     | Arsitektur <i>MobileNetV1</i> .....                             | 34        |
| 4.5.2     | Arsitektur <i>DenseNet-121</i> .....                            | 37        |
| 4.6       | Pelatihan Model CNN .....                                       | 41        |
| 4.7       | Evaluasi Model CNN .....                                        | 47        |
| 4.7.1     | <i>Accuracy</i> .....                                           | 47        |
| 4.7.2     | <i>Confusion Matrix</i> .....                                   | 48        |
| 4.8       | Perbandingan Hasil Penelitian Dengan Penelitian Terdahulu ..... | 54        |
| 4.8.1     | Tabel Perbandingan Model.....                                   | 55        |
| 4.9       | Analisis <i>Misclassification</i> .....                         | 57        |
| <b>V.</b> | <b>PENUTUP .....</b>                                            | <b>60</b> |
| 5.1       | Simpulan .....                                                  | 60        |
| 5.2       | Saran .....                                                     | 61        |
|           | <b>DAFTAR PUSTAKA.....</b>                                      | <b>62</b> |

## DAFTAR TABEL

| <b>Tabel</b>                                           | <b>Halaman</b> |
|--------------------------------------------------------|----------------|
| 1. Kajian Jurnal Penelitian Terdahulu.....             | 5              |
| 2. <i>Confusion Matrix</i> (Rahman et al., 2017).....  | 17             |
| 3. Rincian Dataset.....                                | 28             |
| 4. Jumlah Pembagian Dataset.....                       | 29             |
| 5. Pembagian Data Setelah Augmentasi.....              | 33             |
| 6. Hasil <i>Training</i> Model.....                    | 46             |
| 7. Hasil Akurasi Model.....                            | 47             |
| 8. Perbandingan Model Dengan Penelitian Terdahulu..... | 55             |

## DAFTAR GAMBAR

| Gambar                                                                         | Halaman |
|--------------------------------------------------------------------------------|---------|
| 1. Mata wanita dan Pria (Sumber: <i>Pavelbiz/Eyes-rtte/Kaggle</i> ).....       | 11      |
| 2. <i>Convolutional Neural Network</i> (Alwanda et al., 2020) .....            | 13      |
| 3. <i>Fully Connected Layer</i> (Santoso & Ariyanto, 2018). ....               | 14      |
| 4. Arsitektur <i>DenseNet121</i> (License & Rizwee, 2023).....                 | 15      |
| 5. Arsitektur <i>MobileNet</i> (Howard et al., 2017) .....                     | 16      |
| 6. Sampel Dataset (Sumber: <i>Kaggle</i> ) .....                               | 21      |
| 7. Alur Pengerjaan Penelitian .....                                            | 23      |
| 8. Contoh Citra Mata .....                                                     | 28      |
| 9. Contoh Hasil Augmentasi .....                                               | 32      |
| 10. Arsitektur <i>MobileNet</i> Dengan Penyesuaian <i>Layer</i> Tambahan ..... | 34      |
| 11. Arsitektur <i>DenseNet</i> Dengan Penyesuaian <i>Layer</i> Tambahan .....  | 38      |
| 12. Grafik <i>Training MobileNet</i> Tanpa Augmentasi .....                    | 43      |
| 13. Grafik <i>Training DenseNet</i> Tanpa Augmentasi .....                     | 43      |
| 14. Grafik <i>Training MobileNet</i> Augmentasi <i>Rotasi</i> .....            | 43      |
| 15. Grafik <i>Training DenseNet</i> Augmentasi <i>Rotasi</i> .....             | 44      |
| 16. Grafik <i>Training MobileNet</i> Augmentasi <i>Translasi</i> .....         | 44      |
| 17. Grafik <i>Training DenseNet</i> Augmentasi <i>Translasi</i> .....          | 44      |
| 18. Grafik <i>Training MobileNet</i> <i>Rotasi</i> Dan <i>Translasi</i> .....  | 45      |
| 19. Grafik <i>Training DenseNet</i> <i>Rotasi</i> Dan <i>Translasi</i> .....   | 45      |

|                                                                  |    |
|------------------------------------------------------------------|----|
| 20. <i>Confusion Matrix MobileNet Tanpa Augmentasi</i> .....     | 49 |
| 21. <i>Confusion Matrix DenseNet Tanpa Augmentasi</i> .....      | 49 |
| 22. <i>Confusion Matrix MobileNet Augmentasi Rotasi</i> .....    | 50 |
| 23. <i>Confusion Matrix DenseNet Augmentasi Rotasi</i> .....     | 51 |
| 24. <i>Confusion Matrix MobileNet Augmentasi Translasi</i> ..... | 51 |
| 25. <i>Confusion Matrix DenseNet Augmentasi Translasi</i> .....  | 52 |
| 26. <i>Confusion Matrix MobileNet Rotasi Dan Translasi</i> ..... | 53 |
| 27. <i>Confusion Matrix DenseNet Rotasi Dan Translasi</i> .....  | 53 |
| 28. <i>Contoh Gambar Missclassification</i> .....                | 59 |

## DAFTAR SOURCE CODE

| <i>Source Code</i>                                                                        | <b>Halaman</b> |
|-------------------------------------------------------------------------------------------|----------------|
| 1. Kode Program Augmentasi Data .....                                                     | 30             |
| 2. Kode Program Menampilkan Augmentasi .....                                              | 31             |
| 3. Kode Program Inisialisasi dan <i>Import Library MobileNetV1</i> .....                  | 35             |
| 4. Kode Program <i>Input</i> Citra <i>MobileNetV1</i> .....                               | 35             |
| 5. Kode Program Pemanggilan Arsitektur Dasar <i>MobileNetV1</i> .....                     | 35             |
| 6. Kode Program Membekukan Seluruh <i>Layer</i> Base Model <i>MobileNet V1</i> .....      | 36             |
| 7. Kode Program Penambahan Lapisan <i>Fully Connected</i> Pada <i>MobileNetV1</i> .....   | 36             |
| 8. Kode Program Lapisan <i>Output MobileNetV1</i> .....                                   | 36             |
| 9. Kode Program Pembuatan Objek Model Akhir <i>MobileNetV1</i> .....                      | 36             |
| 10. Kode Program Proses Kompilasi Model <i>MobileNetV1</i> .....                          | 37             |
| 11. Kode Program Inisialisasi dan <i>Import Library DenseNet-121</i> .....                | 39             |
| 12. Kode Program <i>Input</i> Citra <i>DenseNet-121</i> .....                             | 39             |
| 13. Kode Program Pemanggilan Arsitektur Dasar <i>DenseNet-121</i> .....                   | 39             |
| 14. Kode Program Membekukan Seluruh <i>Layer</i> Base Model <i>DenseNet-121</i> .....     | 40             |
| 15. Kode Program <i>Output GlobalAveragePooling2D</i> .....                               | 40             |
| 16. Kode Program Penambahan Lapisan <i>Fully Connected</i> Pada <i>DenseNet-121</i> ..... | 40             |
| 17. Kode Program Lapisan <i>Output DenseNet-121</i> .....                                 | 40             |
| 18. Kode Program Pembuatan Objek Model Akhir <i>DenseNet-121</i> .....                    | 41             |

|                                                                    |    |
|--------------------------------------------------------------------|----|
| 19. Kode Program Proses Kompilasi Model <i>DenseNet</i> -121 ..... | 41 |
| 20. Kode Program Proses <i>Training</i> Model .....                | 42 |

## I. PENDAHULUAN

### 1.1 Latar Belakang

Mata merupakan organ kompleks dan fungsional yang berperan dalam menangkap cahaya dan merubahnya menjadi sinyal-sinyal yang dikirimkan ke otak untuk menghasilkan persepsi visual. Selain itu, mata juga berfungsi untuk memberikan pandangan warna, kedalaman, serta gerakan. Objek penelitian yang satu ini sangat relevan dalam penelitian dan klasifikasi karena selain sebagai organ vital dalam tubuh manusia, mata juga mencerminkan aspek demografis yaitu jenis kelamin. Jenis kelamin adalah salah satu hal pembeda antara individu yang satu dengan yang lainnya.

Klasifikasi jenis kelamin berdasarkan mata atau bagian wajah umumnya dilakukan melalui observasi visual oleh manusia, seperti tenaga medis, psikolog, atau pakar forensik, dengan berfokus pada ciri-ciri anatomi dan fisiologis. Misalnya, ciri-ciri seperti ketebalan alis, ukuran dan bentuk kelopak mata, jarak antar mata, atau kontur wajah sering digunakan sebagai indikator untuk membedakan jenis kelamin. Namun, teknik ini bergantung pada keterampilan subjektif dan pengalaman pengamat, sehingga rentan terhadap bias dan kurang akurat pada kondisi tertentu, misalnya jika ada pencahayaan buruk, wajah tertutupi, atau bentuk mata yang sulit dibedakan, sehingga memunculkan kebutuhan akan pendekatan berbasis teknologi yang lebih akurat dan efisien.

Saat ini kecerdasan buatan (*Artificial Intelligence*) merupakan teknologi berbasis komputer yang tengah populer dan banyak dibahas. Kecerdasan buatan (*Artificial Intelligence*) dapat diartikan sebagai kemampuan tertentu seperti manusia yang dirancang untuk berinteraksi dengan dunia dalam bentuk sistem komputer (Salamah et al., 2022). Kehadiran kecerdasan buatan (AI) dan

pembelajaran mendalam (*deep learning*) telah menawarkan solusi baru dalam klasifikasi jenis kelamin melalui analisis citra, khususnya dengan model *Convolutional Neural Network* (CNN). *Convolutional Neural Network* (CNN) salah satu jenis *neural network* dimana metode ini dapat menggunakan gambar, *Convolutional Neural Network* (CNN) memiliki kemampuan untuk mengenali objek pada sebuah gambar (Online, 2020). CNN dapat mengenali pola rumit dari gambar, termasuk citra mata, dan telah terbukti lebih handal dibandingkan teknik tradisional. Sebagai solusi atas keterbatasan ini, teknologi *deep learning* seperti CNN kini digunakan karena mampu secara otomatis mengekstrak fitur-fitur penting dari gambar tanpa perlu intervensi manual, dan menghasilkan akurasi tinggi meskipun dalam kondisi gambar tidak ideal.

Pengenalan jenis kelamin melalui citra mata menawarkan solusi praktis dan efektif dalam berbagai situasi di mana wajah tidak sepenuhnya terlihat atau tertutup, seperti penggunaan masker, kacamata besar, atau kondisi pencahayaan buruk. Pemrosesan gambar berkaitan dengan pemrosesan fitur yang melibatkan representasi terperinci seperti mata, mulut, dan bentuk wajah (Triwijoyo, 2019). Klasifikasi jenis kelamin ini menggunakan *Python*, *keras* dan *Tensorflow* sebagai *library machine learning open source* untuk *neural network*. Dataset yang akan digunakan sebagai sumber data utama adalah dari *kaggle* yaitu *female and male eyes*, yang menyediakan belasan ribu gambar mata laki-laki dan perempuan.

Pada penelitian sebelumnya klasifikasi jenis kelamin manusia telah dilakukan menggunakan metode seperti *K-Nearest Neighbor* dan *Naive Bayes* (Kurniawan & Irsyad 2022). Studi lain membandingkan model *Convolutional Neural network* (CNN) dan *Haar Cascade Classifier* dalam klasifikasi gender dari citra mata (Pradana & Wijiyanto 2024).

Sementara itu, CNN telah terbukti meningkatkan performa dalam berbagai aplikasi klasifikasi. Dalam klasifikasi tanaman pada citra resolusi tinggi, CNN mencapai akurasi sebesar 82% (Arrofiqoh & Harintaka, 2018).

Berdasarkan permasalahan yang telah dijelaskan dan penelitian sebelumnya, Model CNN dikenal mampu memberikan akurasi tinggi saat diterapkan pada

objek kecil dan beragam. Jika penelitian sebelumnya menunjukkan hasil baik dengan objek serupa, maka penerapannya dalam klasifikasi jenis kelamin berdasarkan citra mata diharapkan memberikan performa yang lebih unggul. Pada penelitian ini pengusulan metode CNN akan dievaluasi menggunakan metrik akurasi, *precision*, *recall*, dan *F1-score*.

## 1.2 Rumusan Masalah

Berdasarkan uraian pada latar belakang, maka rumusan masalah yang didapat yaitu:

- a. Bagaimana proses klasifikasi jenis kelamin manusia dapat dilakukan dengan memanfaatkan arsitektur *MobileNetV1* dan DenseNet-121 melalui analisis visual terhadap citra mata manusia?
- b. Bagaimana arsitektur *MobileNetV1* dan DenseNet-121 dalam memberikan akurasi dari hasil klasifikasi jenis kelamin manusia berdasarkan data mata manusia?

## 1.3 Batasan Masalah

Batasan masalah dari penelitian ini yaitu:

- a. Penelitian ini hanya berfokus pada klasifikasi jenis kelamin berdasarkan citra mata manusia.
- b. Dataset yang digunakan terdiri dari citra mata yang mewakili laki-laki dan perempuan, sehingga tidak mencakup *gender non-biner*.

## 1.4 Tujuan Penelitian

Adapun tujuan yang ingin dicapai dari penelitian ini adalah sebagai berikut:

- a. Menerapkan arsitektur *MobileNetV1* dan DenseNet-121 untuk melakukan klasifikasi jenis kelamin manusia melalui analisis citra mata manusia.
- b. Mengetahui hasil tingkat akurasi dalam klasifikasi jenis kelamin manusia berdasarkan data citra mata manusia.

## 1.5 Manfaat

Manfaat dari penelitian ini yaitu:

- a. Menghasilkan implementasi arsitektur *MobileNetV1* dan DenseNet-121 untuk klasifikasi jenis kelamin berdasarkan citra mata manusia.
- b. Memperoleh evaluasi performa metode arsitektur *MobileNetV1* dan DenseNet-121 dalam mengklasifikasikan jenis kelamin dari citra mata manusia.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian ini tidak lepas dari penelitian sebelumnya yang telah dilakukan. Ringkasan dari penelitian terdahulu dapat dilihat pada Tabel 1.

Tabel 1. Kajian Jurnal Penelitian Terdahulu.

| Penelitian                                                                                                                                                                        | Data                                                                              | Metode                                                                                                                            | Hasil                                                                                                                |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------------------------------|
| <i>Pre-trained Convolutional Neural Networks for Gender Classification</i> (Patil, B., & Hangarge, M 2023).                                                                       | 11.525 data, 6.323 data citra mata laki-laki dan 5.202 data citra mata perempuan. | Metode <i>Convolutional Neural Network</i> , VGG16, <i>ResNet</i> 152 V2, <i>InceptionResNet</i> V2, dan <i>EfficientNet</i> V2L. | CNN:93.08, VGG16: 84.05, <i>ResNet</i> 152V2:80.10, <i>InceptionResNet</i> V2:82.43, <i>EfficientNet</i> V2L: 84.19. |
| <i>Comparison of KNN and CNN Algorithms for Gender Classification Based on Eye Images</i> (Wicaksono, R. D., & Shidiq, G. F 2024).                                                | 11.525 data, 6.323 data citra mata laki-laki dan 5.202 data citra mata perempuan. | Metode <i>K-Nearest Neighbors</i> (KNN) dan <i>Convolutional Neural Network</i> (CNN).                                            | Nilai akurasi yang untuk KNN: 81% dan CNN:93%                                                                        |
| Identifikasi Jenis Kelamin Otomatis Berdasarkan Mata Manusia Menggunakan <i>Convolutional Neural Network</i> (CNN) dan <i>Haar Cascade Classifier</i> (Pradana & Wijiyanto 2024). | 11.525 data, 6.323 data citra mata laki-laki dan 5.202 data citra mata perempuan. | Metode <i>Convolutional Neural Network</i> dan <i>Haar Cascade Classifier</i> .                                                   | Nilai akurasi yang didapatkan yaitu 92%.                                                                             |

|                                                                                                                                                  |                                                                                   |                                                           |                                                                                                  |
|--------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------------------------------|-----------------------------------------------------------|--------------------------------------------------------------------------------------------------|
| <i>Performance of Deep Learning Inception Model and MobileNet Model on gender Prediction Through Eye Image</i> (Listio, 2022).                   | 2.681 data, 1.251 data citra mata laki-laki dan 1.430 data citra mata perempuan.  | Metode <i>Inception-V3</i> dan <i>MobileNet</i> .         | Nilai akurasi yang dihasilkan untuk <i>Inception-V3</i> 91,82% dan untuk <i>MobileNet</i> 89,3%. |
| Perbandingan metode <i>K-Nearest Neighbor</i> Dan <i>Naive Bayes</i> untuk Klasifikasi <i>Gender</i> Berdasarkan Mata (Kurniawan & Irsyad 2022). | 15.060 data, 8.090 data citra mata laki-laki dan 6.969 data citra mata perempuan. | Metode <i>K-Nearest Neighbor</i> dan <i>Naive Bayes</i> . | Nilai akurasi untuk KNN 68,81% dan untuk <i>Naive Bayes</i> 62,58%.                              |

Penelitian terdahulu digunakan sebagai acuan dan perbandingan dalam melakukan penelitian ini. Penjelasan mengenai penelitian terdahulu yang digunakan adalah sebagai berikut:

### 2.1.1 *Pre-trained Convolutional Neural Networks for Gender Classification* (Patil, B., & Hangarge, M 2023).

Penelitian ini bertujuan untuk mengevaluasi performa berbagai model *deep learning* dalam klasifikasi jenis kelamin berdasarkan citra mata. Dataset yang digunakan adalah dataset “*Female and Male Eyes*” yang tersedia di *Kaggle* (Eyes-rtte, 2021), terdiri atas 11.525 gambar mata yang mencakup 6.323 citra mata pria dan 5.202 citra mata wanita. Dataset ini dipotong menjadi bagian mata dari wajah menggunakan citra dari *UKTFace*, lalu diubah ukurannya menjadi  $75 \times 75$  piksel. Data dibagi menjadi 70% untuk pelatihan dan 30% untuk pengujian. Penelitian ini membandingkan beberapa model CNN pra-latih (*pre-trained*), yaitu *VGG16*, *ResNet152V2*, *InceptionResNetV2*, dan *EfficientNetV2L*, serta satu arsitektur CNN kustom. Seluruh model dilatih selama 30 *epoch* dengan menggunakan *optimizer Adam*, fungsi *loss categorical cross-entropy*, dan *batch size* sebesar 32. Untuk mencegah *overfitting*, digunakan *dropout layer*. Hasil penelitian menunjukkan bahwa model *EfficientNetV2L* memberikan

akurasi tertinggi di antara model *pre-trained* sebesar 84,19%, sedangkan model CNN kustom mencapai akurasi tertinggi sebesar 93,08%. Arsitektur CNN kustom terdiri dari dua lapisan konvolusi, dua lapisan *max pooling*, dan dua lapisan dense, serta total parameter sebanyak 272.545. Penelitian ini menyimpulkan bahwa CNN kustom lebih unggul dalam akurasi dibanding model pra-latih meskipun memiliki jumlah parameter yang lebih kecil, dan cocok digunakan jika sumber daya komputasi terbatas.

### 2.1.2 *Comparison of KNN and CNN Algorithms for Gender Classification*

*Based on Eye Images* (Wicaksono, R. D., & Shidiq, G. F 2024).

Penelitian ini membandingkan efektivitas algoritma *K-Nearest Neighbor* (KNN) dan *Convolutional Neural Network* (CNN) dalam tugas klasifikasi jenis kelamin menggunakan citra iris mata. Dataset yang digunakan berasal dari *Kaggle* (Eyes-rtte, 2021) dengan jumlah total 11.525 gambar iris mata, terdiri dari 6.323 gambar pria dan 5.202 gambar wanita. Dataset ini dibagi menjadi 75% untuk pelatihan dan 25% untuk pengujian. Proses *preprocessing* meliputi normalisasi piksel (0–255 menjadi 0–1), *interpolasi linier* untuk penyamaan ukuran, serta augmentasi data seperti rotasi sebesar 20 derajat, pergeseran *horizontal* dan *vertikal* sebesar 10%, refleksi *horizontal* dan *vertikal*, serta transformasi geometris berupa *shearing* sebesar 0,2 pada sumbu-x dan *zooming* sebesar 10%. CNN yang digunakan terdiri dari beberapa lapisan konvolusi, *batch normalization*, *max pooling*, *dropout*, dan lapisan *dense*. CNN dilatih menggunakan *Adam optimizer* dengan *learning rate* 0.001 selama 50 *epoch* dan *batch size* 32. Hasil evaluasi menunjukkan bahwa model CNN mencapai akurasi sebesar 93%, dengan *precision* sebesar 94% untuk wanita dan 93% untuk pria, serta *recall* sebesar 91% untuk wanita dan 95% untuk pria. Sebaliknya, model KNN hanya mampu mencapai akurasi sebesar 81%, dengan *precision* 87% dan *recall* 70% untuk pria, serta *precision* 78% dan *recall* 91% untuk wanita. Hal ini menunjukkan bahwa CNN memiliki keunggulan signifikan dibanding KNN, terutama dalam mengidentifikasi pola kompleks dari citra iris mata.

### 2.1.3 Identifikasi Jenis Kelamin Otomatis Berdasarkan Mata Manusia Menggunakan *Convolutional Neural Network* (CNN) dan *Haar Cascade Classifier* (Pradana & Wijiyanto 2024).

Penelitian ini memanfaatkan dataset publik *Eyes-RTTE* dari *Kaggle*, dengan total 11.525 citra mata yang terdiri atas data latih sebanyak 7.491 citra (65%) dan data uji sebanyak 4.034 citra (35%). Pada tahapan *preprocessing*, citra diubah ukurannya menjadi  $60 \times 60$  piksel dan dikonversi dari format warna RGB ke *grayscale*. Arsitektur CNN yang digunakan memiliki tiga lapisan *convolutional*, masing-masing diikuti oleh *max pooling layer*, serta tiga *fully connected layer*, dengan fungsi aktivasi ReLU untuk setiap *hidden layer*. Lapisan CNN yang dirinci antara lain: *conv2D* pertama menghasilkan *output*  $58 \times 58 \times 32$  piksel, *max pooling* pertama menghasilkan  $29 \times 29 \times 32$ , *conv2D* kedua  $27 \times 27 \times 64$ , dan *max pooling* kedua  $13 \times 13 \times 64$  piksel, kemudian di-*flatten* menjadi vektor berdimensi 10.816 dan diteruskan ke *dense layer* 50 *neuron*, kemudian *dense layer* terakhir dua *neuron* sebagai *output*. *Haar Cascade Classifier* digunakan untuk mendeteksi area mata pada gambar sebelum dimasukkan ke CNN, dan proses training menggunakan *optimizer Adam* dengan *learning rate* 0,9 selama 20 *epoch*. Evaluasi menggunakan *confusion matrix* menunjukkan bahwa akurasi sistem sebesar 92%, dengan nilai *F1-score* keseluruhan mencapai 93%. Rata-rata *precision* dan *recall* masing-masing sebesar 0,93, menunjukkan performa sistem yang cukup stabil dalam mendeteksi jenis kelamin berbasis citra mata, meskipun masih terdapat sejumlah kesalahan klasifikasi sebesar 210 gambar salah prediksi pada kelas perempuan dan 89 gambar salah prediksi pada kelas laki-laki.

### 2.1.4 *Performance of Deep Learning Inception Model and MobileNet Model on gender Prediction Through Eye Image* (Listio, 2022).

Penelitian ini bertujuan membandingkan performa dua arsitektur CNN, yaitu *Inception V3* dan *MobileNet V2*, untuk klasifikasi *gender* berbasis citra mata manusia. Dataset yang digunakan diambil dari publikasi *Celeba* dengan total 2.681 citra mata, yang terdiri dari 1.251 citra mata laki-laki dan

1.430 citra mata perempuan. Dataset ini kemudian dibagi menjadi 80% data latih, yaitu sekitar 2.144 gambar, dan 20% data uji sebanyak 537 gambar. Proses *preprocessing* mencakup konversi warna citra dari RGB (*Red Green Blue*) ke *grayscale* (1 kanal), dan *resizing* agar seragam sesuai kebutuhan input CNN. Penelitian tidak menyebutkan teknik augmentasi lain. Model CNN yang digunakan menerapkan *transfer learning* pada arsitektur *Inception V3* dan *MobileNet V2*, dengan 3 *hidden layer* di mana masing-masing *layer* terdiri dari *convolutional layer*, aktivasi ReLU, dan *max pooling*. Pengelompokan kelas ditetapkan sebagai 0 untuk perempuan dan 1 untuk laki-laki. Evaluasi dilakukan menggunakan akurasi, dengan hasil bahwa *Inception V3* mencapai nilai akurasi tertinggi sebesar 91,82%, sedangkan *MobileNet V2* memperoleh akurasi 89,3%, sehingga model *Inception V3* dinilai lebih optimal dalam klasifikasi *gender* berbasis citra mata.

#### 2.1.5 Perbandingan Metode *K-Nearest Neighbor* Dan *Naive Bayes* untuk Klasifikasi *Gender* Berdasarkan Mata (Kurniawan & Irsyad 2022).

Penelitian ini menggunakan dataset publik *Eyes-RTTE* dari *Kaggle* dengan jumlah total 15.060 citra mata, terdiri atas 8.090 citra mata laki-laki dan 6.969 citra mata perempuan. Dataset ini dibagi menjadi 4.518 citra (30%) sebagai data latih dan 10.541 citra (70%) sebagai data uji, dengan distribusi data latih 2.427 mata laki-laki dan 2.091 mata perempuan, sedangkan data uji terdiri dari 5.663 mata laki-laki dan 4.879 mata perempuan. Tahapan *preprocessing* mencakup konversi citra ke *grayscale*, transformasi HSV (*Hue Saturation Value*) untuk menangkap intensitas warna, ekstraksi fitur menggunakan *Histogram of Oriented Gradient* (HOG) untuk mendeteksi tepi dan kontur objek, serta teknik *cropping* pada citra mata untuk memfokuskan wilayah klasifikasi. Ukuran *cropping* tidak dijelaskan secara numerik, tetapi dipastikan diambil hanya area bola mata untuk mengurangi noise dari sekitar wajah. Model *K-Nearest Neighbor* menggunakan parameter  $k=3$ , dan *Naive Bayes* diterapkan tanpa parameter tuning khusus. Hasil pengujian menunjukkan metode KNN dengan *cropping* menghasilkan rata-rata akurasi 68,81%, dengan *precision* untuk kelas laki-

laki 70,87% dan *recall* 70,99%, sementara *Naive Bayes* dengan *cropping* menghasilkan rata-rata akurasi 62,58%, dengan *precision* untuk kelas laki-laki 65,63% dan *recall* 63,37%. Dari nilai tersebut, terlihat bahwa penggunaan *cropping* dengan KNN mampu meningkatkan akurasi dibanding *Naive Bayes* tanpa *cropping*, maupun *Naive Bayes* dengan *cropping*.

## 2.2 Klasifikasi Jenis Kelamin


Klasifikasi merupakan salah satu task analisis data dimana dibentuk sebuah model (*classifier*) untuk menyatakan suatu objek ke salah satu kategori atau kelas yang sudah didefinisikan sebelumnya. Klasifikasi data merupakan proses yang terdiri atas dua langkah-langkah pertama adalah tahap pelatihan (*learning*), dimana sebuah algoritma klasifikasi akan membentuk *classifier* dengan menganalisis atau belajar dari sekumpulan data latih. Pada langkah kedua, model yang terbentuk digunakan untuk mengklasifikasikan data uji. Akurasi dari sebuah *classifier* untuk sekumpulan data uji yang diberikan merupakan persentase dari data-data uji yang diklasifikasikan dengan benar oleh *classifier* (Asmara et al., 2018).

Jenis kelamin menjadi salah satu *informasi* penting yang banyak digunakan dalam berbagai macam bidang keamanan, interaksi antar manusia dengan mesin dan lain sebagainya. Hal inilah yang mendasari banyaknya sistem pengenalan jenis kelamin berdasarkan citra wajah maupun citra mata secara otomatis yang dikembangkan oleh para peneliti.

## 2.3 Mata

Mata adalah salah satu alat indra manusia yang berfungsi sebagai indra penglihat. Mata merupakan alat indra yang kompleks. Apabila kita menyebutkan mata, maka dalam pikiran kita yang muncul adalah bola mata, namun sebenarnya tidak hanya bola mata yang berperan agar kita dapat melihat, bulu mata, alis mata, dan kelopak mata juga berperan penting dalam mendukung penglihatan (Sutariawan et al., 2018).

Selain sebagai indra penglihat, mata berperan krusial dalam berbagai aktivitas sehari-hari, termasuk dalam mengenali perbedaan *gender*. Mata mencerminkan variasi fisik antara pria dan wanita, meskipun perbedaan ini tidak selalu tampak secara jelas. Contohnya, ukuran pupil dapat bervariasi antara keduanya, begitu pula dengan distribusi pigmen pada iris yang dapat memengaruhi tampilan mata. Untuk contoh gambar mata pria dan wanita dapat dilihat pada gambar 1.



Gambar 1. Mata Wanita dan Pria (Sumber: *Pavelbiz/Eyes-rtte/Kaggle*).

## 2.4 Citra Digital

Citra digital adalah citra elektronik yang dapat diambil dari beberapa jenis dokumen, dapat berupa foto, buku, video, dan suara. Proses untuk merubah citra analog menjadi citra digital disebut sebagai proses digitasi. Proses digitasi tersebut adalah mengubah suatu gambar, video, atau suara yang berasal dari dalam data elektronik dan dapat disimpan untuk keperluan lainnya (Ramadhan et al., 2019).

## 2.5 Machine Learning

*Machine learning* adalah algoritma yang digunakan untuk mengoptimalkan kinerja komputer atau sistem berdasarkan data sampel yang ada. Kegunaan *machine learning* yang pertama adalah untuk memprediksi suatu nilai atau kelas sebuah individu dalam sebuah populasi. Selanjutnya untuk pencocokan kemiripan yaitu, untuk mengidentifikasi kemiripan antar individu berdasarkan data yang ada, dan yang terakhir yaitu pengklasteran yang berguna untuk mengelompokkan individu dalam grup yang sama berdasarkan kesamaan yang dimiliki (Handono et al., 2020). Algoritma *machine learning* yang sering kali digunakan yaitu *supervised learning* dan *unsupervised learning*.

## 2.6 Klasifikasi Citra

Klasifikasi citra adalah menganalisis berdasarkan input citra yang memiliki perbedaan kondisi cahaya, perbedaan skala, perbedaan sudut pandang dan lain-lain sehingga dapat dipisahkan sesuai dengan jenis-jenis kategori atau label yang telah ditentukan (Wulandari et al., 2020). Komputer merepresentasikan gambar sebagai satu *array* tiga dimensi besar angka. Setiap angka dalam array adalah bilangan bulat yang berkisar dari 0 (hitam) hingga 255 (putih). Dalam masalah klasifikasi, model harus mengubah matriks besar ini menjadi satu label. Untuk gambar berwarna tambahan itu akan memiliki tiga saluran warna: Merah, Hijau, Biru (RGB) untuk setiap piksel. Klasifikasi citra dapat menjadi tantangan bagi komputer karena ada berbagai tantangan terkait dengan representasi citra. Model klasifikasi yang sederhana mungkin tidak dapat mengatasi sebagian besar masalah ini tanpa banyak upaya rekayasa fitur.


## 2.7 Deep Learning

*Deep learning* adalah algoritma jaringan syaraf tiruan yang memiliki tingkat keakuratan yang lebih tinggi dibandingkan dengan metode mesin lainnya. Algoritma ini menggunakan data untuk input dan diproses menggunakan sejumlah *hidden layer* (Hasma & Silfianti, 2018).

### 2.7.1 Convolutional Neural Network (CNN)

Pada metode *Convolutional Neural Network* data yang digunakan hanya dapat berupa data yang memiliki dua dimensi seperti citra dan suara. Pra-pemrosesan pada *Convolutional Neural Network* jauh lebih rendah dibandingkan dengan algoritme klasifikasi lainnya. *Convolutional neural network* termasuk kedalam jenis *deep neural network* karena jaringan yang tinggi dan banyak digunakan pada data citra (Alwanda et al., 2020).

Struktur *Convolutional Neural Network* dapat dilihat pada Gambar 2.



Gambar 2. *Convolutional Neural Network* (Alwanda et al., 2020).

Gambar 2, merupakan struktur *Convolutional Neural Network* terdiri dari *input*, proses ekstraksi fitur, proses klasifikasi dan *output*.

a. *Convolution Layer*

*Convolutional Layer* bekerja dengan cara melakukan perkalian antara matriks dari citra input dengan *filter*, kemudian menjumlahkan hasil dari perkalian tersebut dan menyimpannya dalam matriks baru (Santoso & Ariyanto, 2018).


b. *Pooling Layer*

*Pooling layer* merupakan tahapan setelah *convolutional layer* yang terdiri dari sebuah *filter* dengan ukuran dan *stride* tertentu yang akan bergeser pada seluruh *activation map*. *Pooling* yang digunakan adalah *max* dan *average pooling*. *Max pooling* digunakan untuk mengembalikan nilai maksimum sedangkan *average pooling* untuk mengembalikan nilai rata-rata. *Pooling layer* berfungsi untuk mengurangi ukuran spasial dari fitur konvolusi sehingga dapat mengurangi sumber daya komputasi yang dibutuhkan untuk memproses data melalui pengurangan dimensi dari *feature map* sehingga dapat mempercepat komputasi (Santoso & Ariyanto, 2018).

c. *Fully Connected Layer*

*Fully Connected Layer* adalah lapisan yang digunakan untuk melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara *linear*. Setiap neuron pada *convolutional layer* perlu ditransformasi menjadi data satu dimensi terlebih dahulu. *Fully connected layer* hanya dapat diimplementasikan di akhir jaringan.

*Fully connected layer* memiliki beberapa *hidden layer*, *action function*, *output layer*, dan *loss function* (Santoso & Ariyanto, 2018).




Gambar 3. *Fully Connected Layer* (Santoso & Ariyanto, 2018).

Pada Gambar 3, layer pertama memiliki 3 unit fitur dan 4 unit aktivasi di *hidden layer* berikutnya. Angka satu di setiap lapisan adalah unit bias, a01, a02, dan a03 adalah nilai input ke jaringan syaraf. Kemudian empat unit aktivasi *hidden layer* pertama terhubung kesemua tiga unit aktivasi *hidden layer* kedua parameter menghubungkan kedua *layer*.

### 2.7.2 Arsitektur *DenseNet-121*

*DenseNet* (*Densely Connected Convolutional Network*) adalah arsitektur jaringan konvolusional yang menghubungkan setiap lapisan dengan semua lapisan sebelumnya melalui koneksi yang padat (*dense connections*), sehingga setiap lapisan menerima masukan berupa fitur dari seluruh lapisan sebelumnya. Pendekatan ini memperkuat propagasi informasi dan *gradien*, mendorong penggunaan ulang fitur, serta secara signifikan mengurangi jumlah parameter yang dibutuhkan dibandingkan arsitektur CNN tradisional (Huang et al., 2017). Arsitektur *DenseNet* terdiri dari tiga blok utama, di mana setiap blok memuat sejumlah lapisan yang mencakup batch normalization, aktivasi ReLU, dan konvolusi berukuran  $3 \times 3$ . Antara dua blok tersebut terdapat lapisan transisi yang berperan dalam mengubah dimensi fitur dengan menerapkan operasi konvolusi dan *pooling*.



Gambar 4. Arsitektur *DenseNet*-121 (Huang et al., 2017).

Pada Gambar 4, setiap komposisi lapisan terdiri dari *batch normalization*, aktivasi ReLU, dan konvolusi dengan filter berukuran  $3 \times 3$ . Setiap blok menerima input berupa matriks yang merepresentasikan piksel citra. Data ini terlebih dahulu melewati proses *batch normalization* untuk membantu mengurangi risiko *overfitting* selama pelatihan. Selanjutnya, fungsi aktivasi ReLU diterapkan, di mana nilai negatif diubah menjadi nol, sementara nilai *non-negatif* dipertahankan. Setelah itu, hasil dari proses ReLU dikonvolusi dengan filter  $3 \times 3$ , menghasilkan matriks keluaran yang merupakan hasil dari serangkaian proses sebelumnya.

### 2.7.3 Arsitektur *MobileNetV1*

*MobileNetV1* adalah suatu arsitektur CNN yang dirancang agar ringan dan efisien untuk perangkat mobile, dengan memperkenalkan *depthwise separable convolutions* dua langkah konvolusi (*depthwise* dan *pointwise*) yang memecah operasi konvolusi standar untuk secara signifikan mengurangi biaya komputasi tanpa mengorbankan performa. (Howard et al., 2017). Arsitektur *MobileNet* menggunakan konvolusi *pointwise*, yang menerapkan filter  $1 \times 1$  ke *output* dari konvolusi *depthwise*, untuk menggabungkan fitur *channel-wise* dan menghasilkan *output* akhir. Dengan menggunakan konvolusi yang dapat dipisahkan secara mendalam, *MobileNet* mampu mencapai tingkat efisiensi parameter

yang tinggi, namun tetap menghasilkan hasil yang akurat (Darmatasia et al., 2023).

| Type / Stride | Filter Shape                                     | Input Size                 |
|---------------|--------------------------------------------------|----------------------------|
| Conv / s2     | $3 \times 3 \times 3 \times 32$                  | $224 \times 224 \times 3$  |
| Conv dw / s1  | $3 \times 3 \times 32 \text{ dw}$                | $112 \times 112 \times 32$ |
| Conv / s1     | $1 \times 1 \times 32 \times 64$                 | $112 \times 112 \times 32$ |
| Conv dw / s2  | $3 \times 3 \times 64 \text{ dw}$                | $112 \times 112 \times 64$ |
| Conv / s1     | $1 \times 1 \times 64 \times 128$                | $56 \times 56 \times 64$   |
| Conv dw / s1  | $3 \times 3 \times 128 \text{ dw}$               | $56 \times 56 \times 128$  |
| Conv / s1     | $1 \times 1 \times 128 \times 128$               | $56 \times 56 \times 128$  |
| Conv dw / s2  | $3 \times 3 \times 128 \text{ dw}$               | $56 \times 56 \times 128$  |
| Conv / s1     | $1 \times 1 \times 128 \times 256$               | $28 \times 28 \times 128$  |
| Conv dw / s1  | $3 \times 3 \times 256 \text{ dw}$               | $28 \times 28 \times 256$  |
| Conv / s1     | $1 \times 1 \times 256 \times 256$               | $28 \times 28 \times 256$  |
| Conv dw / s2  | $3 \times 3 \times 256 \text{ dw}$               | $28 \times 28 \times 256$  |
| Conv / s1     | $1 \times 1 \times 256 \times 512$               | $14 \times 14 \times 256$  |
| 5×            | Conv dw / s1 $3 \times 3 \times 512 \text{ dw}$  | $14 \times 14 \times 512$  |
|               | Conv / s1 $1 \times 1 \times 512 \times 512$     | $14 \times 14 \times 512$  |
|               | Conv dw / s2 $3 \times 3 \times 512 \text{ dw}$  | $14 \times 14 \times 512$  |
|               | Conv / s1 $1 \times 1 \times 512 \times 1024$    | $7 \times 7 \times 512$    |
|               | Conv dw / s2 $3 \times 3 \times 1024 \text{ dw}$ | $7 \times 7 \times 1024$   |
|               | Conv / s1 $1 \times 1 \times 1024 \times 1024$   | $7 \times 7 \times 1024$   |
|               | Avg Pool / s1 Pool $7 \times 7$                  | $7 \times 7 \times 1024$   |
|               | FC / s1 $1024 \times 1000$                       | $1 \times 1 \times 1024$   |
|               | Softmax / s1 Classifier                          | $1 \times 1 \times 1000$   |

Gambar 5. Arsitektur *MobileNet* (Howard et al., 2017).

## 2.8 Evaluasi Kinerja Klasifikasi

Evaluasi kinerja klasifikasi dilakukan dengan cara menganalisis kemampuan metode klasifikasi dari kelas yang berbeda-beda, sehingga dibutuhkan suatu *confusion matriks*. Berikut ini beberapa parameter yang digunakan untuk mengevaluasi kinerja klasifikasi.

### 1. *Confusion Matrix*

*Confusion Matrix* adalah metode yang digunakan untuk melakukan perhitungan akurasi pada konsep data *maining*. *Confusion Matrix* menunjukkan cara-cara ketika klasifikasi menentukan *class*-nya dalam membuat prediksi. Klasifikasi ini menghasilkan empat hasil yaitu *true*

*positive* (TP), *false positive* (FP), *true negative* (TN), dan *false negative* (FN) (Rahman et al., 2017).

Tabel 2. *Confusion Matrix* (Rahman et al., 2017).

| <i>Predicted</i> | <i>Actual</i>    |              |
|------------------|------------------|--------------|
|                  | <i>Non-event</i> | <i>Event</i> |
| <b>Perempuan</b> | <b>TN</b>        | <b>FN</b>    |
| <b>Laki-Laki</b> | <b>FP</b>        | <b>TP</b>    |

- True Positive* (TP): jumlah data *positif* yang diklasifikasikan dengan benar oleh sistem.
- True Negative* (TN): jumlah data *negatif* yang diklasifikasikan dengan benar oleh sistem.
- False Positive* (FP): jumlah data *positif* yang diklasifikasikan dengan salah oleh sistem.
- False Negative* (FN): jumlah data *negatif* yang diklasifikasikan dengan salah oleh sistem.

Tabel *Confusion Matrix* pada Tabel 2 bertujuan untuk menghitung kinerja metode klasifikasi dengan perhitungan *recall*, *precision*, *f1 score* dan *accuracy*.

- Accuracy*

*Accuracy* merupakan parameter penilaian untuk menguji akurasi model dan tingkat *confident* dalam melakukan klasifikasi. *Accuracy* dapat ditulis dengan Persamaan 2.

$$Accuracy = \frac{(TP + TN)}{(TP + FP + FN + TN)} \dots \dots \dots (2)$$

- Precision*

*Precision* parameter penilaian yang menghitung nilai rata-rata *precision* dari data hasil klasifikasi yaitu jumlah data yang benar antara nilai sebenarnya dengan hasil prediksi model (Resa et al., 2020). *Precision* dapat ditulis dengan Persamaan 3.

$$\text{Precision} = \frac{TP}{TP + FP} \dots \dots \dots (3)$$

c. *Recall*

*Recall* merupakan parameter yang didapat dari jumlah data benarseberapa banyak data yang keluar dalam hasil klasifikasi. *Recall* dapat dituliskan dengan Persamaan 4.

$$\text{Recall} = \frac{TP}{TP + FN} \dots \dots \dots (4)$$

d. *F1 Score*

*F1 Score* merupakan suatu ukuran dalam membandingkan rata-rata *precision* dan *recall*. *F1 Score* dapat ditulis dengan Persamaan 5.

$$F1 \text{ Score} = 2 \times \frac{(\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})} \dots \dots \dots (5)$$

## 2.9. Transformasi *Affine*

Transformasi *affine* merupakan transformasi geometris yang sering digunakan dalam pengolahan citra digital. Transformasi ini menerapkan kombinasi *linear* yang mencakup operasi seperti translasi, rotasi, skala, refleksi, dan *shearing* yang mempertahankan kolinearitas titik dan rasio jarak di sepanjang garis lurus (Gani, 2018). Transformasi *affine* juga banyak diterapkan dalam augmentasi citra, terutama dalam pembelajaran mesin berbasis CNN. Metode ini memungkinkan pembangkitan variasi citra tanpa mengubah informasi utama, sehingga membantu meningkatkan ketahanan model terhadap perubahan orientasi dan posisi objek (Purnomo et al., 2022). Transformasi *affine* digunakan untuk memanipulasi bentuk citra guna menguji kestabilan model klasifikasi berbasis CNN (Gani, 2018). Hasil penelitian menunjukkan bahwa kombinasi rotasi dan skala pada citra masukan mampu meningkatkan akurasi model sebesar 5-10% dibandingkan tanpa augmentasi. Kelebihan dari transformasi ini adalah menghitung faktor ketidaktegaklurusan sumbu, dipahami ada kalanya suatu sistem koordinat tidak memiliki sumbu koordinat yang tidak *orthogonal*. Persamaan matematis transformasi *affine* adalah sebagai berikut (Purworahardjo, 1994):

$$X = i.x + j.y + C_1 \dots \dots \dots (6)$$

$$X = k.x + l.y + C_2 \dots \dots \dots (7)$$

Di mana:

$i, j, k, l$  = elemen perbesaran dan *rotasi*.

$C_1, C_2$  = elemen *translasi*.

Karena ada 6 unsur parameter transformasi maka diperlukan minimal 3 buah titik sekutu untuk penyelesaiannya, agar hasil lebih teliti, jumlah titik sekutu lebih dari 3 dan dilakukan pemecahannya dengan perataan kuadrat terkecil. Dalam metode ini perbesaran ke arah sumbu X berbeda dengan perbesaran ke arah sumbu Y berbeda dengan perbesaran ke arah sumbu Y.

Dari persamaan final besarnya rotasi dan skala ( $S_x$  dan  $S_y$ ) adalah sebagai berikut:

$$\omega = \tan^{-1}(k / i) \dots \dots \dots (8)$$

$$\varphi = \tan^{-1} \left( \frac{l \sin \omega - j \cos \omega}{l \cos \omega - j \sin \omega} \right) \dots \dots \dots (9)$$

$$\lambda_x = \frac{i \cos \varphi}{\cos \theta} \dots \dots \dots (10)$$

$$\lambda_y = \frac{1}{\cos \omega - \sin \omega \tan \varphi} \dots \dots \dots (11)$$

Di mana:

$\omega$  = elemen *rotasi*

$i, j, k, l$  = elemen perbesaran dan *rotasi*.

$\lambda_x$  = elemen perbesaran pada sumbu X.

$\lambda_y$  = elemen perbesaran pada sumbu Y.

### **III. METODE PENELITIAN**

#### **3.1. Tempat dan Waktu Penelitian**

##### **3.1.1 Tempat Penelitian**

Penelitian dilaksanakan di Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung, bertempat di Jalan Prof. Dr. Soemantri Brojonegoro No. 1. Gedung Meneng, Bandar Lampung.

##### **3.1.2 Waktu Penelitian**

Penelitian dilakukan pada semester ganjil tepatnya bulan Desember 2024 hingga penyelesaian pada bulan Juni 2025. Pengerjaan dibagi menjadi tiga tahap, yaitu:

###### **a. Tahap Penelitian Awal**

Tahap ini merupakan tahap pengumpulan data pemahaman studi literatur dan penyusunan *draft* untuk bab 1-3.

###### **b. Tahap Penelitian Lanjutan**

Pada tahap ini mulai mengerjakan penelitian dengan menjalankan program untuk proses *pre-processing*, Metode klasifikasi dengan menggunakan CNN, pengujian pelatihan dataset dan evaluasi hasil

###### **c. Tahap Evaluasi**

Pada tahap ini yaitu penulisan *draft* hasil bab 4-5 dan penyampaian hasil penelitian melalui seminar hasil.

## 3.2. Data dan Alat

### 3.2.1 Data

Data yang digunakan dalam penelitian ini adalah data yang didapatkan dari *kaggle* yaitu *Female and Male Eyes* (Sumber: *Kaggle*). Data yang digunakan dalam penelitian ini sebanyak 11.525 gambar yang terbagi menjadi 6.323 citra mata pria dan 5.202 citra mata wanita. Data yang digunakan dalam penelitian ini terdiri 2 jenis data, yaitu data *training*, dan data *testing*. *Sample* dataset dapat dilihat pada gambar 6.



Gambar 6. Sampel *Dataset*. (Sumber: *Pavelbiz/Eyes-rttl/Kaggle*).

### 3.2.2. Alat

#### 3.2.2.1 Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan pada penelitian ini yaitu:

- a. *Processor*: Intel (R) Celeron (R) N5100
- b. *Installed RAM*: 4.00 GB.

#### 3.2.2.2. Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan pada penelitian ini yaitu:

- a. Sistem Operasi: Windows 11 64-bit.
- b. *Python* versi 3.9.1.

*Python* merupakan bahasa pemrograman yang tidak ada batasan dalam mendistribusikannya. *Python* bahasa pemrograman berorientasi objek yang efisien, karena mempunyai kekuatan dalam struktur dan penggunaan kembali kode yang telah ada sehingga tidak sulit untuk digunakan (Clinton & Sengkey, 2019).

c. *Tensorflow* versi 2.6.0


*Tensorflow* merupakan salah satu *library* untuk data science yang bersifat *free open source*, dan dapat digunakan dalam berbagai bidang. *Tensorflow* memiliki fitur untuk menjalankan pelatihan model menggunakan *Central Processing Unit* (CPU) dan pelatihan model *Graphic Processing Unit* (GPU) (Manajang et al., 2020).

d. Keras versi 2.4.3

Keras merupakan perangkat lunak jaringan yang berbasis *open source* yang juga dapat dijalankan menggunakan MXNet, *library* keras khusus dirancang guna mempercepat eksperimen yang berhubungan dengan *deep learning* (Alwanda et al., 2020).

### 3.3. Alur Pengerjaan Penelitian

Penelitian ini melalui beberapa tahapan yang dapat dilihat pada Gambar 7.



Gambar 7. Alur Pengerjaan Penelitian.

Berikut ini penjelasan dari setiap tahapan pada Gambar 7.

#### 3.3.1 Pengumpulan Dataset

Tahap pertama adalah mengumpulkan dataset berupa citra mata yang akan digunakan sebagai data penelitian. Pengumpulan data gambar mata manusia didapat dari *kaggle* yaitu *Female and Male Eyes* (Sumber: *Kaggle*). Data yang digunakan dalam penelitian ini sebanyak 11.525 gambar yang terbagi menjadi 6.323 citra mata pria dan 5.202 citra mata wanita.

### 3.3.2 Pre-Processing

Setelah data dikumpulkan selanjutnya dilakukan tahap *pre-processing* berupa pengambilan label. Label pada dataset ditentukan berdasarkan nama folder tempat gambar berada. Gambar yang berada dalam folder *femaleeyes* secara otomatis diberi label "*femaleeyes*", sedangkan gambar dalam folder *maleeyes* diberi label "*maleeyes*". Proses ini dilakukan dengan menggunakan struktur direktori dataset dan menghasilkan sebuah *dataframe* yang berisi *path file* dan label masing-masing gambar. Langkah ini penting untuk membangun model klasifikasi *biner* berdasarkan jenis kelamin mata.

### 3.3.3 Pembagian Data

Tahap selanjutnya yaitu pembagian data, dataset dibagi menjadi dua bagian yaitu:

1. *Data Training*

*Data training* merupakan data yang digunakan untuk melakukan proses *learning* dari citra. Data yang digunakan dalam proses *training* ini yaitu dengan persentase 60% dari total dataset.

2. *Data Validation*

*Data validation* adalah bagian dari dataset yang digunakan untuk mengevaluasi kinerja model selama proses pelatihan. Data ini tidak digunakan untuk melatih model, tetapi untuk memantau performa agar dapat mendeteksi *overfitting*. Dalam penelitian ini, *data validation* diambil sebanyak 20% dari total dataset.

3. *Data testing* adalah data yang digunakan dalam proses pengujian terhadap hasil *learning* citra yang telah disimpan dalam pemodelan. Data yang digunakan pada proses *testing* dengan persentase 20% dari total dataset.

### 3.3.4 Augmentasi Data

Augmentasi data diterapkan pada data *training* untuk meningkatkan

variasi data secara virtual tanpa perlu menambah data baru. Dalam penelitian ini, dilakukan augmentasi citra menggunakan transformasi *Affine* melalui fungsi '*ImageDataGenerator*' dari *Keras*. Transformasi *Affine* menerapkan kombinasi linear yang mencakup beberapa operasi dasar seperti translasi dan rotasi. Transformasi *affine* ini juga menjaga kolinearitas garis, sehingga model dapat belajar dari pola yang lebih realistis dan tetap akurat saat menghadapi variasi posisi, orientasi, dan skala pada data baru. Dengan menerapkan transformasi ini, model diharapkan dapat menggeneralisasi lebih baik, sehingga mampu mengenali pola pada citra mata dengan lebih akurat, meskipun terdapat sedikit perbedaan dalam posisi mata.

### 3.3.5 Perancangan Model *Convolutional Neural Network* (CNN)

Pada tahap ini, model dikembangkan menggunakan metode *transfer learning* dengan memanfaatkan dua *arsitektur Convolutional Neural Network* (CNN), yaitu *MobileNetV1* dan *DenseNet-121*. Kedua arsitektur ini dipilih karena memiliki performa yang baik dalam tugas klasifikasi citra serta telah terbukti efisien dalam mengekstraksi fitur visual dari gambar.

### 3.3.6 Pelatihan Model *Convolutional Neural Network* (CNN)

Tahapan selanjutnya adalah pelatihan model. Model yang telah dirancang, yaitu dengan menggunakan arsitektur *MobileNetV1* dan *DenseNet-121* melalui pendekatan *transfer learning*, dilatih menggunakan data *training*. Pada tahap ini, model akan belajar melalui proses iteratif, biasanya disebut *epoch*, di mana data *training* diproses secara berulang kali. *Optimizer*, seperti *Adam*, digunakan untuk mempercepat konvergensi model, sementara fungsi *loss* seperti *binary cross-entropy* digunakan untuk menghitung *error*.

### 3.3.7 Evaluasi Model *Convolutional Neural Network* (CNN)

Setelah model CNN yang menggunakan arsitektur *MobileNetV1* dan *DenseNet-121* dilatih menggunakan data *training*, langkah selanjutnya adalah mengevaluasi kinerjanya menggunakan data *testing*. Tujuannya

adalah untuk mengukur sejauh mana model dapat melakukan prediksi yang akurat terhadap data baru yang tidak digunakan selama proses pelatihan. Tahapan evaluasi model CNN meliputi penggunaan data *testing*, pengukuran nilai *loss*, serta analisis performa melalui *confusion matrix*.

### 3.3.8 Evaluasi Hasil

Setelah proses evaluasi model selesai, hasilnya perlu dianalisis secara mendalam menggunakan arsitektur *MobileNetV1* dan *DenseNet-121*, untuk mengetahui tingkat kebenaran dalam mengklasifikasikan berbagai metrik evaluasi. Hal ini bertujuan untuk memberikan gambaran menyeluruh mengenai kinerja model dalam menangani data *testing*. Evaluasi dilakukan terhadap model CNN yang dibangun menggunakan jenis kelamin manusia berdasarkan citra mata. Penelitian ini berfokus pada pengujian terhadap nilai *loss* dan *accuracy*, serta menggunakan metrik tambahan seperti *recall*, *precision*, dan *F1-score* sebagai bahan perbandingan. Nilai *loss* digunakan untuk mengukur seberapa baik model dalam tahap pelatihan dan validasi, serta menjadi indikator terhadap performa model setelah melalui proses iterasi dan pengoptimalan. Sementara itu, akurasi digunakan untuk mengukur rasio prediksi benar terhadap keseluruhan data. *Recall* atau sensitivitas adalah proporsi prediksi benar positif dibandingkan dengan seluruh data yang benar positif. *Precision* adalah proporsi prediksi benar positif terhadap seluruh data yang diprediksi positif. Sedangkan *F1-score* merupakan rata-rata harmonis dari *precision* dan *recall*, yang digunakan untuk memberikan penilaian seimbang terhadap kinerja model dalam situasi data tidak seimbang.

## V. PENUTUP

### 5.1. Simpulan

Berdasarkan hasil penelitian dan analisis yang telah dilakukan mengenai penerapan metode *Convolutional Neural Network* (CNN) untuk klasifikasi jenis kelamin berdasarkan citra mata, maka dapat disimpulkan bahwa:

1. Metode *Convolutional Neural Network* (CNN) berhasil diterapkan untuk melakukan klasifikasi jenis kelamin melalui citra mata manusia. Dua arsitektur CNN yang digunakan adalah *MobileNetV1* dan *DenseNet-121*, keduanya diimplementasikan menggunakan pendekatan *transfer learning* yang disesuaikan dengan kebutuhan klasifikasi biner.
2. Model CNN mampu menghasilkan klasifikasi dengan tingkat akurasi yang tinggi. Arsitektur *MobileNetV1* dengan augmentasi rotasi dan translasi memberikan performa terbaik, yaitu akurasi sebesar 92.49% menggunakan augmentasi *rotasi*, mengungguli hasil dari arsitektur *DenseNet-121* yang mencapai akurasi maksimum 86.84% dengan kombinasi augmentasi *rotasi* dan *translasi*.

### 5.2. Saran

Berdasarkan kesimpulan tersebut, beberapa saran yang dapat disampaikan untuk penelitian selanjutnya adalah:

1. Perluasan jenis arsitektur model, Penelitian ini hanya menggunakan dua arsitektur CNN, yaitu *MobileNetV1* dan *DenseNet-121*. Untuk penelitian selanjutnya, disarankan untuk mengeksplorasi arsitektur

lain yang dapat memberikan performa lebih optimal dalam klasifikasi citra.

2. Penggunaan dataset dengan resolusi lebih tinggi, variasi citra yang lebih beragam, serta penambahan jumlah data akan sangat membantu dalam meningkatkan akurasi dan generalisasi model.

## DAFTAR PUSTAKA

- Alwanda, M. R., Ramadhan, R. P. K., & Alamsyah, D. (2020). Implementasi Metode *Convolutional Neural Network* Menggunakan Arsitektur LeNet-5 untuk Pengenalan *Doodle*. *Jurnal Algoritme*, 1(1), 45–56.
- Arrofiqoh, E. N., & Harintaka, H. (2018). Implementasi Metode *Convolutional Neural Network* Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi. *Geomatika*, 24(2), 61. <https://doi.org/10.24895/jig.2018.24-2.810>
- Asmara, R. A., Andjani, B. S., Rosiani, U. D., & Choirina, P. (2018). Klasifikasi Jenis Kelamin Pada Citra Wajah Menggunakan Metode Naive Bayes. *Jurnal Informatika Polinema*, 4(3), 212-217.
- Clinton, R. M. R., & Sengkey, S. (2019). Purwarupa Sistem Daftar Pelanggaran Lalulintas. *Jurnal Teknik Elektro Dan Komputer Vol.8*, 8(3), 181–192.
- DARMATASIA, D., & SYAFAR, A. M. (2023). Implementasi Convolutional Neural Network Untuk Klasifikasi Tanaman Rimpang Secara Virtual. *Jurnal INSTEK (Informatika Sains dan Teknologi)*, 8(1), 122-131.
- Pavelbiz. (2024). *Eyes-rtte [Dataset]*. Kaggle. Retrieved December 2024, from <https://www.kaggle.com/pavelbiz/eyes-rtte>.
- Gani, A. (2018). "Transformasi Affin pada Bidang." *Jurnal Matematika Unisba*.
- Handono, S. F., Anggraeny, F. T., & Rahmat, B. (2020). Implementasi *Convolutional Neural Networks* (CNN) untuk Deteksi Retinopati Diabetik. *Jurnal Informatika Dan Sistem Informasi (JIFoSI)*, 1(1), 669–678.
- Hasma, Y. A., & Silfianti, W. (2018). Implementasi *Deep Learning* Menggunakan *Framework Tensorflow* Dengan Metode *Faster Regional Convolutional Neural Network* Untuk Pendeteksian Jerawat. *Jurnal Ilmiah Teknologi Dan Rekayasa*, 23(2), 89–102. <https://doi.org/10.35760/tr.2018.v23i2.2459>

- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)* (pp. 684–692). <https://arxiv.org/abs/1704.04861>
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- Kurniawan, C., & Irsyad, H. (2022). Perbandingan Metode K-Nearest Neighbor Dan Naïve Bayes Untuk Klasifikasi Gender Berdasarkan Mata. *Jurnal Algoritme*, 2(2), 82-91.
- Listio, S. W. P. (2022). Performance of deep learning Inception model and MobileNet model on gender prediction through eye image. : *jurnal dan penelitian teknik informatika*, 6(4), 2593-2601.
- Manajang, D., Dompie, S., & Jacobus, A. (2020). Implementasi *Framework Tensorflow Object Detection* Dalam Mengklasifikasi Jenis Kendaraan Bermotor. *Jurnal Teknik Informatika*, 15(3), 171–178.
- Nelli, F. (2018). *Python Data Analytics: With Pandas, NumPy, and Matplotlib*. Apress.
- Online, T. (2020). Jurnal Politeknik Caltex Riau CNN *Modelling* Untuk Deteksi Wajah Berbasis Gender Menggunakan Python. *Jurnal Komputer Terapan*, 6(2), 190–199.
- Patil, B., & Hangarge, M. (2023). *Pre-trained Convolutional Neural Networks for Gender Classification*. In *First International Conference on Advances in Computer Vision and Artificial Intelligence Technologies (ACVAIT 2022)* (pp. 319-326). Atlantis Press.
- Purnomo, M. E., Suryoto, A., & Sari, D. P. (2022). "Pembangkitan Pohon Fraktal Bercabang Menggunakan Metode Iterated Function Systems." *Jurnal EurekaMatika*, 10(2), 99-110.
- Purworahardjo, Umaryono (1994). *Sistem Dan Transformasi Koordinat*. Bandung: ITB.
- Pradana, A. I., & Wijiyanto, W. (2024). Identifikasi Jenis Kelamin Otomatis Berdasarkan Mata Manusia Menggunakan Convolutional Neural Network (CNN) dan Haar Cascade Classifier. *G-Tech: Jurnal Teknologi Terapan*, 8(1), 502-511.
- Rahman, M. F., Alamsah, D., Darmawidjadja, M. I., & Nurma, I. (2017). Klasifikasi Untuk Diagnosa Diabetes Menggunakan Metode *Bayesian Regularization Neural Network* (BRNN). *Jurnal Informatika*, 11(1), 36.

- Ramadhan, M. S., Novamizanti, L., & Susatio, E. (2019). Sistem Pengenalan Individu Berbasis Citra Wajah 3D dengan Jaringan Syaraf Tiruan. *Techné : Jurnal Ilmiah Elektroteknika*, 18(01), 1–14.
- Resa, M., Yudianto, A., & Fatta, H. Al. (2020). Analisis Pengaruh Tingkat Akurasi Klasifikasi Citra Wayang dengan Algoritma Convolutional NeuralNetwork. *Jurnal Teknologi Informasi*, 4(2), 182–190.
- Rizal, A. A., & Hartati, S. (2017). *PREDIKSI KUNJUNGAN WISATAWAN DENGAN RECURRENT NEURAL NETWORK EXTENDED KALMAN FILTER* Program Studi Informatika , STMIK Bumigora Mataram Jurusan Ilmu Komputer dan Elektronika , FMIPA UGM , Yogyakarta. X(1), 7–18.
- Salamah, I., Said, M. R. A., & Soim, S. (2022). Perancangan Alat Identifikasi Wajah Dengan Algoritma You Only Look Once (YOLO) Untuk Presensi Mahasiswa. *Jurnal Media Informatika Budidarma*, 6(3), 1492.
- Santoso, A., & Ariyanto, G. (2018). Implementasi Deep Learning Berbasis Keras Untuk Pengenalan Wajah. *Emitor: Jurnal Teknik Elektro*, 18(01), 15–21. <https://doi.org/10.23917/emitor.v18i01.6235>
- Sutariawan, I. P. E., Dantes, G. R., & Aryanto, K. Y. E. (2018). Segmentasi Mata Katarak pada Citra Medis Menggunakan Metode Operasi Morfologi. *Jurnal Ilmu Komputer Indonesia*, 3(1), 23-31.
- Triwijoyo, B. K. (2019). Model *Fast Tansfer Learning* pada Jaringan Syaraf Tiruan Konvolusional untuk Klasifikasi Gender Berdasarkan Citra Wajah. *MATRIK : Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 18(2), 211–221. <https://doi.org/10.30812/matrik.v18i2.376>
- Wicaksono, R. D., & Shidiq, G. F. (2024). *Comparison of KNN and CNN Algorithms for Gender Classification Based on Eye Images*. *Scientific Journal of Informatics*, 11(4), 915-924.
- Wulandari, I., Yasin, H., & Widiharih, T. (2020). Klasifikasi Citra Digital Bumbu dan Rempah Dengan Algoritma *Convolutional Neural Network* (CNN). *Jurnal Gaussian*, 9(3), 273–282. <https://doi.org/10.14710/j.gauss.v9i3.27416>