

# Prediksi Gender Berdasarkan Citra Mata Menggunakan Metode Convolutional Neural Network, Inception dan MobileNet

**Nur Aini \***

Magister Ilmu Komputer, Universitas Nusa Mandiri,  
Jakarta, 13620

14002614@nusamandiri.ac.id

\*Corresponding author

**Dewi Yanti Liliana**

Magister Ilmu Komputer, Universitas Nusa Mandiri,  
Jakarta, 13620

dewiyanti.liliana@tik.pnj.ac.id

**Abstrak**—Gender manusia dianggap sebagai sifat demografis utama karena berbagai penggunaannya dalam domain praktis. Klasifikasi gender manusia dalam lingkungan yang tidak dibatasi adalah tugas yang rumit karena variasi besar dalam skenario gambar. Karena banyaknya gambar internet, akurasi klasifikasi menderita dari metode pembelajaran mesin tradisional. Penelitian ini bertujuan untuk mengefektifkan proses klasifikasi gender dengan menggunakan konsep *transfer learning*. Hasil eksperimen menunjukkan bahwa model *CNN*, *InceptionV3* dan *MobileNet* menggunakan transfer *learning* tiga hidden layer, setiap hidden layer terdiri dari convolutional layer, aktivasi ReLU dan max-pooling dapat mengklasifikasikan citra berjenis kelamin – laki-laki dan perempuan dengan tingkat yang baik. Akurasi ini juga karena pengoptimal kinerja yang digabungkan selama pelatihan dan pengujian data menggunakan pengoptimal Adam. Hasil pengujian dan evaluasi menggunakan menghasilkan nilai loss terendah untuk model *MobileNet* sebesar 0,149, dan juga nilai akurasi tertinggi 0,9390. Dengan hasil percobaan ini, maka kesimpulan yang dapat diambil adalah bahwa model *MobileNet* memiliki tingkat akurasi yang paling tinggi dalam proses pelatihan dan pengujian.

**Kata kunci**—*Transfer Learning*, *CNN*, *Inceptionv3*, *MobileNet*

## I. PENDAHULUAN

Klasifikasi gender merupakan topik yang sudah sering dibahas. Algoritme sebelumnya berfokus terutama pada penggunaan fitur tekstur dan tidak banyak penelitian yang dilakukan tentang penerapan *Convolutional Neural Networks (CNN)* untuk tugas ini. Eksperimen yang dilakukan melalui database gambar mata menunjukkan bahwa model *CNN* kami menunjukkan kinerja yang kompetitif dibandingkan dengan metode canggih lainnya.

Tugas-tugas ini mempunyai tantangan besar dalam suatu aplikasi dunia nyata. Salah satunya yakni variasi visual yang besar. Contohnya adalah obyek wajah, diantaranya perubahan pose, oklusi, hingga penchayaan

ekstrem. Pada makalah ini difokuskan mengenai penjelasan tentang model representasi pembelajaran transfer cepat (*Fast Transfer Learning*). Model yang dapat digunakan dalam *Fast Transfer Learning* diantaranya adalah penggunaan model jaringan saraf *Convolutional Neural Network (CNN)* untuk mengklasifikasi gender dari citra wajah. *Transfer learning* memiliki tujuan untuk menyediakan kerangka kerja. Hal ini bertujuan untuk memanfaatkan ilmu pengetahuan yang telah diperoleh sebelumnya. Hal tersebut juga untuk memecahkan beberapa masalah yang baru namun serupa dengan hasil yang jauh efektif dan lebih cepat.

Klasifikasi gender termasuk ke dalam masalah klasifikasi biner, yaitu memprediksi gambar yang terbagi menjadi dua kelas. Kelas tersebut adalah laki-laki dan perempuan. Hal tersebut merupakan sesuatu pekerjaan yang mudah bagi manusia, namun bagi komputer menjadi suatu hal yang menantang. Bagi sebagian besar model komputasi klasifikasi gender digunakan gambar area seluruh wajah yang memberikan bobot yang sama untuk semua area wajah. Hal ini terlepas dari pentingnya fitur internal (Buchala et al, 2004). Sebagian pemrosesan global berkaitan dengan informasi seperti halnya bentuk dan konfigurasi fitur internal, sedangkan untuk pemrosesan fitur melibatkan representasi yang lebih terperinci seperti bentuk mata.

Teknologi mesin pembelajaran pada masa ini telah banyak menarik perhatian yang besar dari peneliti. Fokusnya adalah pada berbagai bidang komputasi. Teknologi ini sebagian besar beroperasi di bawah asumsi umum, data yang digunakan terbagi dua, yaitu: data pelatihan dan data uji. Data uji dan data pelatihan tersebut mempunyai ruang fitur yang identik dengan distribusi dari data uji. Oleh karena itu, setelah distribusi fitur ataupun ruang fitur dari data uji mengalami perubahan, model prediksi tersebut tidak lagi dapat dipergunakan. Maka harus dibangun kembali dan dilatih ulang dari awal dengan mempergunakan data pelatihan yang baru dikumpulkan, kendalanya adalah harga yang relatif mahal dan juga terkadang tidak efektif dan praktis (Budiarto & Qudsi, 2018). Selain itu, penyebab lainnya adalah model tersebut berbasis pembelajaran sehingga membutuhkan

data berlabel yang memadai untuk pelatihan. Akan tetapi hal tersebut hampir tidak mungkin untuk membuat model berbasis pembelajaran untuk domain targer yang mempunyai sedikit data berlabel yang tersedia untuk pembelajaran yang diawasi. Oleh karena itu untuk mengantisipasi hal tersebut, jika dapat mentransfer dan mengeksplorasi pengetahuan tersebut dari sumber yang sama namun tidak identik dengan banyak data berlabel, maka dapat digunakan untuk pembangunan model berbasis pembelajaran untuk domain target (Budiarto & Qudsi, 2018).

Studi *transfer learning* tersebut terinspirasi oleh fakta. Fakta tersebut adalah bahwasanya manusia dapat memanfaatkan ilmu pengetahuan yang telah diperoleh sebelumnya. Hal ini berguna untuk memecahkan masalah yang baru namun serupa dengan jauh lebih cepat dan efektif (Budiarto & Qudsi, 2018). Dengan demikian, berdasarkan eksperimen makalah ini menunjukkan bahwa representasi pembelajaran transfer cepat melalui penggunaan model jaringan saraf *Convolutional Neural Network (CNN)* untuk klasifikasi gender berdasarkan citra wajah.

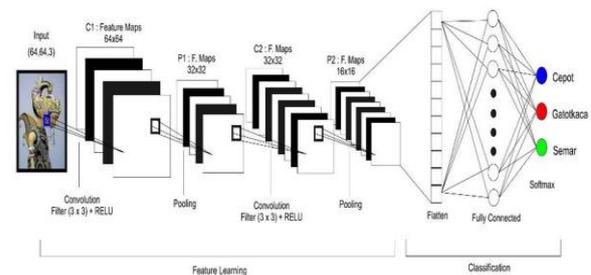
*Convolutional Neural Network (CNN)* merupakan salah satu metode yang termasuk di dalam kelas *Feed Forward Neural Network*. Hal ini terinspirasi oleh visual *cortex* dari otak. Fokusnya adalah dalam memproses data dengan struktur grid. CNN adalah suatu pengembangan dari *Multiplayer Perceptron (MLP)* yang dirancang untuk mengolah data dua dimensi. Akan tetapi, MLP kurang tepat digunakan dalam kasus klasifikasi citra. Hal ini dikarenakan MLP tidak menyimpan informasi spasial dari data citra. Selain itu, MLP juga menganggap setiap piksel adalah fitur yang independent sehingga menghasilkan hasil yang kurang baik.

CNN adalah tipe spesial untuk data spasial dari *Multilayer Neural Network*. Arsitektur dari CNN terinspirasi dari persepsi visual dari makhluk hidup. Arsitektur CNN menjadi populer setelah AlexNet memecahkan rekor kinerja pada 2012 tetapi sebenarnya CNN telah ada sejak tahun 1980an (Ghosh et al, 2020).. NeoCognitron merupakan nama awal dari CNN saat pertama kali dikembangkan. Kuniihiko Fukushima, sebagai seorang peneliti dari NHK Broadcasting Science Research Laboratories-lah yang mengembangkannya yang berlokasi di Kinuta, Setagaya, Tokyo, Jepang (Sun et al, 2006).

CNN memiliki beberapa jenis layer yang dapat dimanfaatkan. Later tersebut diantaranya adalah *subsampling layer*, *convolutional layer*, *fully connected layer* dan *loss layer*. Sebuah jaringan saraf convolutional tradisional terdiri dari satu atau beberapa blok convolutional dan lapisan penyatuan, diikuti oleh satu atau beberapa lapisan yang terhubung penuh dan lapisan keluaran. Lapisan convolutional adalah blok bangunan inti dari CNN. Lapisan ini bertujuan untuk mempelajari representasi fitur dari input. Lapisan konvolusi terdiri dari beberapa kernel atau filter konvolusi yang dapat dipelajari yang digunakan untuk menghitung peta fitur yang berbeda. Setiap unit peta fitur terhubung ke bidang reseptif di lapisan sebelumnya. Peta fitur baru dihasilkan

dengan menggabungkan input dengan kernel dan menerapkan fungsi aktivasi elemen non-linear pada hasil yang dikonvolusikan. Properti berbagi parameter lapisan convolutional mengurangi kompleksitas model. Pooling atau sub-sampling layer mengambil wilayah kecil dari output convolutional sebagai input dan menurunkannya untuk menghasilkan output tunggal. Ada beberapa teknik sub-sampling yang berbeda seperti contoh max pooling, min pooling, average pooling, dll (Ghosh et al, 2020).

Pooling mengurangi jumlah parameter yang akan dihitung serta membuat terjemahan jaringan menjadi invarian. Bagian terakhir dari CNN pada dasarnya terdiri dari satu atau lebih lapisan *Fully Connected (FC)* biasanya ditemukan di jaringan saraf feedforward. Lapisan FC mengambil input dari pooling akhir atau lapisan konvolusi dan menghasilkan output akhir CNN. Dalam hal klasifikasi citra, CNN dapat dilihat sebagai kombinasi dari dua bagian: bagian ekstraksi ciri dan bagian klasifikasi. Kedua convolution dan pooling layer melakukan ekstraksi fitur. Sebagai contoh gambar anjing, lapisan konvolusi yang berbeda dari tingkat yang lebih rendah ke tingkat yang lebih tinggi mendeteksi berbagai fitur seperti dua mata, telinga panjang, empat kaki, dll untuk pengenalan lebih lanjut. Di atas fitur ini, lapisan FC ditambahkan sebagai pengklasifikasi, dan probabilitas ditetapkan untuk gambar input menjadi seekor anjing. Selain desain lapisan, peningkatan CNN tergantung pada beberapa aspek yang berbeda seperti fungsi aktivasi, metode normalisasi, fungsi kerugian, regularisasi, optimasi dan kecepatan pemrosesan, dll (Ghosh et al, 2020). Gambar 1 Mengilustrasikan arsitektur jaringan CNN.



Gambar 1. Arsitektur CNN

Pembelajaran cerdas dari sejumlah besar data historis adalah fitur karakteristik utama dari metode diagnosis kesalahan berbasis data (Dai & Gao, 2013). Deep learning (DL), yang merupakan paradigma baru dalam bidang pembelajaran mesin (LeCun et al, 2015), telah banyak diterapkan dalam diagnosis kesalahan berbasis data. Liao dan Pavel (Liao et al, 2016) mempelajari mesin Boltzmann terbatas yang disempurnakan untuk penilaian prognostik dan kesehatan. Sebagai salah satu DL yang paling efektif, penerapan convolutional neural network (CNN) untuk diagnosis kesalahan juga telah diselidiki. Wang dkk. (Wang et al, 2017) menyelidiki model CNN adaptif dalam, dan parameter utama ditentukan oleh optimasi gerombolan partikel.

Namun, karena keterbatasan volume sampel berlabel di bidang diagnosis kesalahan serta kompleksitas model model DL yang sangat besar, kedalaman model DL untuk diagnosis kesalahan hampir mencapai 5 lapisan tersembunyi (Zhao et al, 2016). Sebaliknya, model CNN untuk ImageNet memiliki lebih dari ratusan lapisan. Model CNN untuk diagnosis kesalahan relatif dangkal, dan ini dapat membatasi akurasi prediksi akhir dan efektif pada diagnosis kesalahan. Tetapi sulit untuk melatih model CNN yang sangat mendalam tanpa kumpulan data yang terorganisir dengan baik dalam jumlah besar seperti ImageNet. Untuk menghadapi tantangan tersebut, transfer learning dipadukan dengan model CNN. Beberapa peneliti mentransfer model CNN dengan melatih model CNN yang mendalam pada dataset ImageNet dan kemudian menerapkan model CNN terlatih sebagai ekstraktor fitur ke dataset kecil (Donahue et al, 2014), dan mereka mencapai hasil yang luar biasa.

CNN dalam tugas visi komputer, seperti mengklasifikasi gambar (Krizhevsky, 2012) serta pengenalan wajah (Wen et al, 2016) telah menginspirasi kinerja yang baik sehingga beberapa pendekatan klasifikasi gender berbasis CNN diusulkan. G. Levi dan T. Hassner telah mengusulkan CNN untuk klasifikasi gender yang kuat dalam lingkungan yang tidak dibatasi (Levi & Hessner, 2015). (Levi & Hessner, 2015) telah menguji metode tersebut pada basis data LFWA (Liu et al, 2015) dan telah mendapatkan kinerja terbaik yang tinggi, yaitu sebesar 98,8% untuk mengklasifikasi gender. Hal ini dibandingkan dengan klasifikasi objek menggunakan Imagenet, yaitu dataset berskala besar (Olga et al, 2015). Hanya terdapat sebagian dataset dengan skala kecil yang dikumpulkan dari dunia nyata untuk klasifikasi gender dan senyuman. Hal tersebut telah diusulkan oleh (Levi & Hessner, 2015) dengan pendekatan berbasis CNN yang telah bekerja dengan baik.

Dalam beberapa tahun terakhir model CNN yang spesifik telah dimanfaatkan untuk klasifikasi gender. Salah satunya yang diusulkan dalam (Levi & Hessner, 2015) yaitu model GilNet, dilatih dengan dataset Adience yang dari awal untuk mengestimasi gender. Dalam (Antipov et al, 2016) model ensemble CNN diusulkan agar dapat berjalan secara efisien pada perangkat yang disematkan. Hasil mutakhirnya diiperoleh sesuai dengan (Antipov et al, 2016). Studi di (Mansanet et al, 2016) menggunakan cara umpan maju untuk menggabungkan fitur lokal dan jaringan dalam berdasarkan belajar dari tumpang tindih lokal tambahan.

Penelitian ini bertujuan untuk membandingkan hasil dari ketiga metode yang diajukan untuk mendapatkan hasil prediksi dengan akurasi tertinggi.

## II. STUDI PUSTAKA

Berdasarkan penelitian terdahulu yang menggunakan metode CNN, Inception, dan MobileNet untuk memproses klasifikasi objek penelitiannya, hal tersebut dirangkum dalam Tabel 1.

Tabel 1. Tinjauan Penelitian Terkait

Tahun	Judul	Kontribusi
2020	Gender Classification from Periocular NIR Images using Fusion of CNNs Models	Menjadi acuan dalam penggunaan model CNN dalam klasifikasi gender menggunakan citra mata
2020	A Flower Classification Approach with MobileNetV2 and Transfer Learning	Menjadi acuan dalam penggunaan model MobileNet v2 dalam klasifikasi citra.
2017	Inception-v3 for Flower Classification	Menjadi acuan dalam penggunaan model Inception-V3 dalam klasifikasi citra
2020	Human Gender Classification Using Transfer Learning Via Pareto Frontier	Menjadi acuan dalam klasifikasi gender
2020	Recognition of Local Birds of Bangladesh using MobileNet and Inception-V3	Menjadi acuan dalam perbandingan penggunaan model MobileNet dan InceptionV3

### A. Convolutional Neural Network (CNN)

Metode CNN terdiri atas dua tahap. Tahap yang pertama adalah klasifikasi citra dengan menggunakan feedforward. Tahap yang kedua yaitu tahap pembelajaran dengan metode *backpropagation*. Sebelum dilakukannya klasifikasi, maka dilakukan praproses terlebih dahulu dengan menggunakan metode *wrapping* dan *cropping*. Hal ini bertujuan untuk memfokuskan objek yang akan diklasifikasi. Selanjutnya dilakukan training menggunakan metode *feedforward* dan *backpropagation*.

### B. Inception-V3

GoogleNet/Inception adalah model yang berfokus pada biaya komputasi. Model InceptionV3 adalah evolusi dari GoogleNet (Inception1) yang didasarkan pada konvolusi 7x7 terfaktor dan dibagi menjadi 2 atau 3, 3x3 lapisan operasi konvolusi dengan tujuan meningkatkan kecepatan komputasi untuk dapat menerima gambar yang lebih besar dari 299x299 piksel. Ini karena model ini hanya memiliki sekitar empat juta parameter. Apabila dibandingkan dengan VGG, jelas sangat kecil. Akan tetapi dengan arsitektur yang lebih kompleks. Ini karena model ini tidak menerapkan lapisan yang Terhubung Sepenuhnya dan menggantinya hanya dengan lapisan pooling. Parameter yang lebih sedikit ini menghasilkan ukuran model yang lebih kecil. Selain itu lebih cepat proses perhitungan model ketika dibandingkan dengan

model lainnya. Model ini memiliki kelemahan yaitu pada saat perform perhitungannya membutuhkan memori yang cukup banyak karena model ini berfokus pada lebar lapisan konvolusi (Antipov et al, 2016). Pembelajaran transfer tampil untuk klasifikasi gambar berdasarkan dataset lebih baik daripada model berdasarkan CNN dalam asli dengan penyetulan model Inception-v3 dapat secara efektif meningkatkan akurasi gambar pengklasifikasi.

### C. MobileNet-V2

MobileNet-V2 adalah model arsitektur yang sangat ringan dan ramping dibandingkan dengan model sebelumnya, dirancang untuk aplikasi seluler dan visi tertanam. Model ini didasarkan pada arsitektur streamline yang menggunakan depth-MobileNet- V2 dengan menggunakan deep separable convolutions untuk membangun jaringan neural dalam yang ringan dengan hanya 54 layer dan ukuran citra input 224x224 untuk melakukan komputasi secara cepat. MobileNets menggunakan konvolusi yang dapat dipisahkan secara mendalam, dan memiliki kesamaan dengan model Inception-v3. Model ini dapat mengurangi jumlah parameter dan latency. Selain itu, MobileNets juga memiliki model parameter penyusutan yang berguna yang dapat digunakan sebelum proses pelatihan dilakukan agar ukurannya pas dan pas (Krizhevsky et al, 2012). Hasil studi untuk MobileNet-V2 dengan membandingkan dua dataset dan analisis eksperimental menemukan bahwa MobileNet-V2 mencapai akurasi yang lebih tinggi daripada model MobileNet-V1 dengan menggunakan desain terbalik (Wen et al, 2016).

## III METODOLOGI

### A. DESKRIPSI MASALAH

Klasifikasi gender adalah topik yang menantang. Algoritme sebelumnya berfokus terutama pada penggunaan fitur tekstur dan tidak banyak penelitian yang dilakukan tentang penerapan Convolutional Neural Networks (CNN) untuk tugas ini. Dalam pekerjaan ini kami melatih jaringan saraf convolutional kecil untuk mata kiri dan kanan, dan yang lebih penting, mempelajari efek penggabungan model-model tersebut dan membandingkannya dengan model yang diperoleh dengan melatih CNN di atas mata kiri yang menyatu. gambar mata kanan. Kami menunjukkan bahwa jaringan mendapat manfaat dari pendekatan penggabungan model ini, dan menjadi lebih kuat terhadap oklusi dan degradasi resolusi rendah, mengungguli hasil penggunaan model CNN tunggal untuk kumpulan gambar kiri dan kanan. Eksperimen yang dilakukan melalui database gambar mata menunjukkan bahwa model CNN kami menunjukkan kinerja yang kompetitif dibandingkan dengan metode canggih lainnya.

### B. DATASET

Dataset yang digunakan dalam penelitian ini adalah dataset yang dikumpulkan dari Kaggle yang dapat diunduh di <https://www.kaggle.com/pavelbiz/eyes-rte>. Terdapat 11.525 foto, untuk data pelatihan ada 9220 foto dan 2305 foto. Foto tersebut digunakan untuk pengujian yang dikelompokkan menjadi dua kelas yaitu *femaleeyes* dan *maleeyes*. Berikut adalah penjelasan dari pembagian dua kelas sample pada Gambar 2.



Gambar 2. Sample Dataset

### C. RENCANA EKSPERIMEN

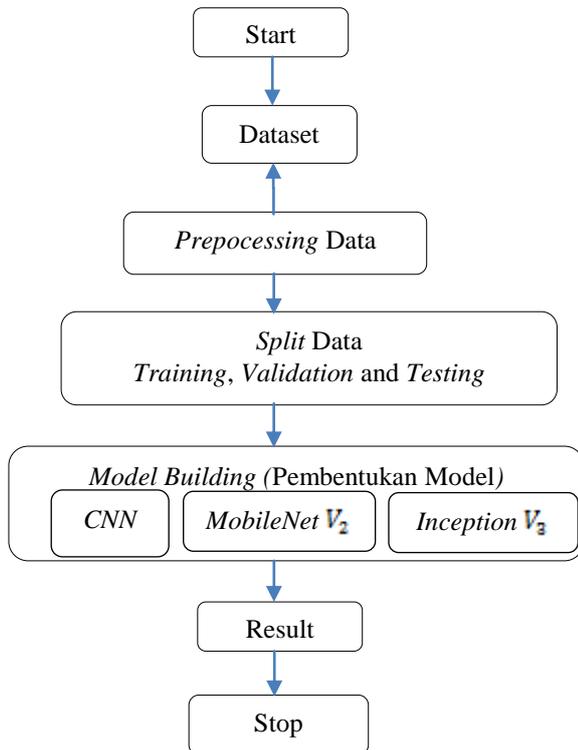
Rencana eksperimen yang digunakan dapat dilihat pada gambar 3. Metode yang digunakan untuk klasifikasi gender pada langkah pertama adalah tahapan preprocessing yang digunakan untuk menambah data. Menambah data menggunakan generator data gambar. Setelah melakukan tahapan preprocessing, selanjutnya adalah proses transfer learning dengan menggunakan model berbasis CNN, Inception dan MobileNet.

Berdasarkan dataset terdapat 6.323 foto mata pria dan 5.202 foto mata wanita. Jumlah data tersebut masih belum memadai untuk mendapatkan hasil kinerja yang baik dan optimal. Oleh karena itu, untuk mengantisipasi diperlukan penambahan data. Teknik yang digunakan dalam penambahan data adalah augmentasi data yaitu untuk memanipulasi data tanpa kehilangan inti atau esensi data (Krizhevsky et al, 2012). Dalam penelitian ini, dilakukan proses penggeseran, memperbesar, hingga membalik. Sedangkan untuk parameter skala ulang yang digunakan dibagi menjadi nilai RGB (Merah, Hijau, dan Biru) dari 0-255 dengan 255. Sehingga diperoleh nilai RGB tersebut berada dalam rentang 0-1. Selanjutnya, untuk pengujian data, hanya dilakukan skala ulang. Kemudian, *Image Data Generator* digunakan untuk mengubah data dalam bentuk gambar mentah menjadi dataset hasil augmentasi yang dipergunakan untuk pelatihan dan pengujian.

Selanjutnya adalah tahap pelatihan. Telah diketahui sebelumnya bahwa model klasifikasi termasuk dalam klasifikasi biner, yang berarti terbagi atas dua kelas, yaitu: 0 untuk kelas pria, sedangkan 1 untuk kelas wanita. Selanjutnya, digunakan *Sigmoid* sebagai fungsi aktivasi di lapisan output, sedangkan untuk semua lapisan

yang tersembunyi digunakan *rectified linear unit (ReLU)* dan *cross-entropy biner*.

Pada tahap yang terakhir, dilakukan pengujian untuk mengukur serta memperoleh keakuratan hasil dari metode tersebut.



Gambar 3. Tahapan Metoda Penelitian

#### IV. HASIL PENELITIAN

Berikut adalah hasil dari perbandingan ketiga model, yaitu *CNN*, *InceptionV3*, dan *MobileNet* pada Tabel 2.

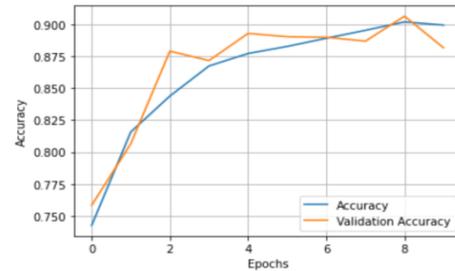
Tabel 2. Hasil Perbandingan Ketiga Model

Arsitektur dan Model	Akurasi (%)	Loss (%)
<i>CNN</i>	90,18	23,1
<i>InceptionV3</i>	90,63	22,6
<i>MobileNet</i>	93,90	14,9

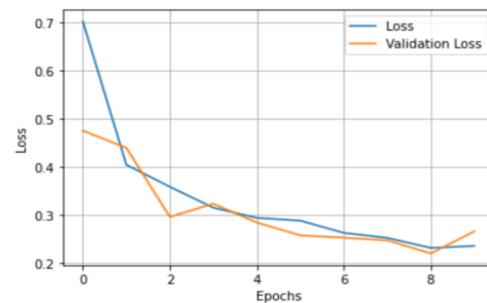
Model berbasis *CNN* mendapatkan hasil akurasi 90,18% dengan loss 23,1%, *InceptionV3* mendapatkan hasil akurasi 90,63% dengan loss 22,6% dan *MobileNet-V2* menghasilkan akurasi tertinggi yaitu 93,90% dengan loss 14,9%. Selanjutnya akan disajikan grafik dari ketiga model yang disajikan pada Gambar 4-9.

#### *Convolutional Neural Network*

Dapat dilihat pada gambar 4 dan gambar 5 adalah hasil *accuracy* dan *loss* menggunakan *Convolutional Neural Network*.



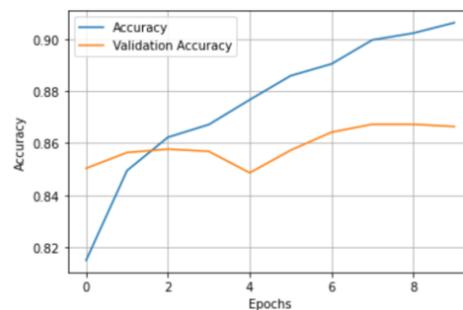
Gambar 4. Accuracy CNN



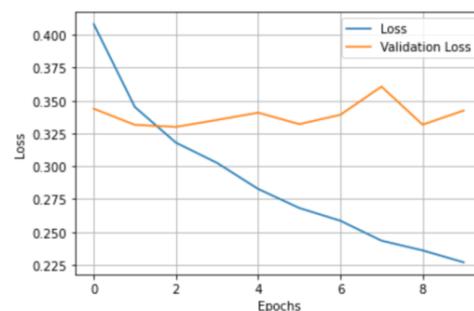
Gambar 5. Loss CNN

#### *InceptionV3*

Dapat dilihat pada gambar 6 dan gambar 7 adalah hasil *accuracy* dan *loss* menggunakan *InceptionV3*.



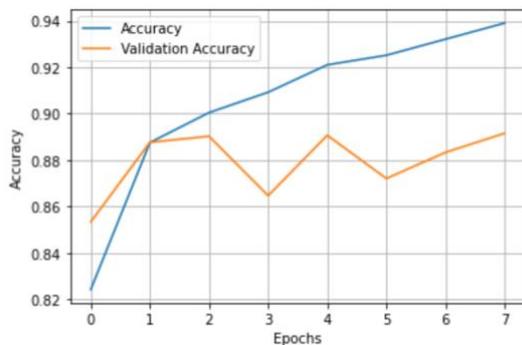
Gambar 6. Accuracy InceptionV3



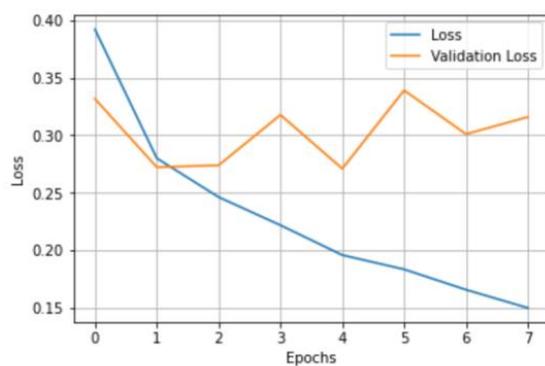
Gambar 7. Hasil Loss InceptionV3

### MobileNet

Dapat dilihat pada gambar 8 dan gambar 9 adalah hasil *accuracy* dan *loss* menggunakan *MobileNet*.



Gambar 8. Accuracy MobileNet



Gambar 9. Loss MobileNet

## V. KESIMPULAN

Hasil eksperimen menunjukkan bahwa model *CNN*, *InceptionV3* dan *MobileNet* menggunakan *transfer learning* tiga hidden layer, setiap hidden layer terdiri dari convolutional layer, aktivasi ReLU dan max-pooling dapat mengklasifikasikan citra berjenis kelamin – laki-laki dan perempuan dengan tingkat yang baik. Akurasi ini juga karena pengoptimal kinerja yang digabungkan selama pelatihan dan pengujian data menggunakan pengoptimal Adam. Hasil pengujian dan evaluasi menggunakan menghasilkan nilai *loss* terendah untuk model *MobileNet* sebesar 0.149, dan juga nilai akurasi tertinggi 0.9390. Dengan hasil percobaan ini, diperoleh hasil akhir yaitu model *MobileNet* memiliki tingkat akurasi yang paling tinggi dalam pengklasifikasian gender menggunakan citra mata.

## DAFTAR PUSTAKA

Antipov, G., Berrani, S. A., & Dugelay, J. L. (2016). Minimalistic CNN-based ensemble model for gender prediction from face images. *Pattern recognition letters*, 70, 59-65. <https://doi.org/10.1016/j.patrec.2015.11.011>.

- Buchala, S., Davey, N., Frank, R. J., Gale, T. M., Loomes, M. J., & Kanargard, W. (2004, November). Gender classification of face images: The role of global and feature-based information. In *International Conference on Neural Information Processing* (pp. 763-768). Springer, Berlin, Heidelberg. [https://doi.org/10.1007/978-3-540-30499-9\\_117](https://doi.org/10.1007/978-3-540-30499-9_117).
- Budiarto, J., & Qudsi, J. (2018). Deteksi Citra Kendaraan Berbasis Web Menggunakan Javascript Framework Library. *MATRIK: Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 18(1), 125-133. <https://doi.org/10.30812/matrik.v18i1.325>.
- Dai, X., & Gao, Z. (2013). From model, signal to knowledge: A data-driven perspective of fault detection and diagnosis. *IEEE Transactions on Industrial Informatics*, 9(4), 2226-2238.
- Donahue, J., Jia, Y., Vinyals, O., Hoffman, J., Zhang, N., Tzeng, E., & Darrell, T. (2014, January). Decaf: A deep convolutional activation feature for generic visual recognition. In *International conference on machine learning* (pp. 647-655). PMLR.
- Fuan, W., Hongkai, J., Haidong, S., Wenjing, D., & ShuaiPeng, W. (2017). An adaptive deep convolutional neural network for rolling bearing fault diagnosis. *Measurement Science and Technology*, 28(9), 095005.
- Fukushima, K., & Miyake, S. (1982). Neocognitron: A self-organizing neural network model for a mechanism of visual pattern recognition. In *Competition and cooperation in neural nets* (pp. 267-285). Springer, Berlin, Heidelberg. [https://doi.org/10.1007/978-3-642-46466-9\\_18](https://doi.org/10.1007/978-3-642-46466-9_18).
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). Fundamental concepts of convolutional neural network. In *Recent Trends and Advances in Artificial Intelligence and Internet of Things* (pp. 519-567). Springer, Cham.
- Huang, G. B., Mattar, M., Berg, T., & Learned-Miller, E. (2008, October). Labeled faces in the wild: A database for studying face recognition in unconstrained environments. In *Workshop on faces in Real-Life Images: detection, alignment, and recognition*. <https://hal.inria.fr/inria-00321923/>.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25. <http://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-network>.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Levi, G., & Hassner, T. (2015). Age and gender classification using convolutional neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition workshops* (pp. 34-42). [https://www.cvfoundation.org/openaccess/content\\_cvpr\\_workshops\\_2015/W08/html/Levi\\_Age\\_and\\_Gender\\_2015\\_CVPR\\_paper.html](https://www.cvfoundation.org/openaccess/content_cvpr_workshops_2015/W08/html/Levi_Age_and_Gender_2015_CVPR_paper.html).

- Lian, H. C., & Lu, B. L. (2006, May). Multi-view gender classification using local binary patterns and support vector machines. In *International Symposium on Neural Networks* (pp. 202-209). Springer, Berlin, Heidelberg. [https://doi.org/10.1007/11760023\\_30](https://doi.org/10.1007/11760023_30).
- Liao, L., Jin, W., & Pavel, R. (2016). Enhanced restricted Boltzmann machine with prognosability regularization for prognostics and health assessment. *IEEE Transactions on Industrial Electronics*, 63(11), 7076-7083.
- Liu, Z., Luo, P., Wang, X., & Tang, X. (2015). Deep learning face attributes in the wild. In *Proceedings of the IEEE international conference on computer vision* (pp. 3730-3738). [http://openaccess.thecvf.com/content\\_iccv\\_2015/html/Liu\\_Deep\\_Learning\\_Face\\_ICCV\\_2015\\_paper.html](http://openaccess.thecvf.com/content_iccv_2015/html/Liu_Deep_Learning_Face_ICCV_2015_paper.html).
- Mansanet, J., Albiol, A., & Paredes, R. (2016). Local deep neural networks for gender recognition. *Pattern Recognition Letters*, 70, 80-86. <https://doi.org/10.1016/j.patrec.2015.11.015>.
- Russakovsky, O., Deng, J., Su, H., Krause, J., Satheesh, S., Ma, S., ... & Fei-Fei, L. (2015). Imagenet large scale visual recognition challenge. *International journal of computer vision*, 115(3), 211-252. <https://doi.org/10.1007/s11263-015-0816-y>.
- Sun, N., Zheng, W., Sun, C., Zou, C., & Zhao, L. (2006, May). Gender classification based on boosting local binary pattern. In *International symposium on neural networks* (pp. 194-201). Springer, Berlin, Heidelberg. [https://doi.org/10.1007/11760023\\_29](https://doi.org/10.1007/11760023_29).
- Wen, Y., Li, Z., & Qiao, Y. (2016). Latent factor guided convolutional neural networks for age-invariant face recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4893-4901). [http://openaccess.thecvf.com/content\\_cvpr\\_2016/html/Wen\\_Latent\\_Factor\\_Guided\\_LF\\_GCNets\\_for\\_Age-Invariant\\_Face\\_Recognition\\_CVPR\\_2016\\_paper.html](http://openaccess.thecvf.com/content_cvpr_2016/html/Wen_Latent_Factor_Guided_LF_GCNets_for_Age-Invariant_Face_Recognition_CVPR_2016_paper.html).
- Zhao, R., Yan, R., Chen, Z., Mao, K., Wang, P., & Gao, R. X. (2019). Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 115, 213-237.