

Perbandingan Model Convolutional Neural Network pada Klasifikasi Wajah Orang Papua dan Etnis Lainnya

Yuni Naomi Yenusi^{1*}, Suryasatriya Trihandaru², Adi Setiawan³ 

^{1,2,3} Magister Sains Data, Universitas Kristen Satya Wacana, Salatiga, Indonesia

ARTICLE INFO

Article history:

Received May 22, 2022

Revised May 29, 2022

Accepted November 12, 2022

Available online April 25, 2023

Kata Kunci:

Model Convolutional Neural Network, Klasifikasi Wajah, Komputer

Keywords:

Convolutional Neural Network Model, Face Classification, Computer



This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

Copyright © 2023 by Author. Published by Universitas Pendidikan Ganesha.

ABSTRAK

Klasifikasi objek pada citra menjadi salah satu problem dalam visi komputer. Komputer diharapkan dapat meniru kemampuan manusia dalam memahami informasi citra. Salah satu pendekatan yang berhasil yaitu dengan menggunakan Jaringan Syaraf Tiruan (JST) dimana pendekatan ini terinspirasi dari jaringan syaraf pada manusia yang dikembangkan lebih jauh menjadi Deep Learning. Convolutional Neural Network (CNN) merupakan salah satu jenis Deep Learning yang sangat terkenal dengan kemampuannya dalam melakukan klasifikasi citra. Dengan mengimplementasikan beberapa model CNN akan dilakukan perbandingan antara model arsitektur CNN dalam klasifikasi wajah etnis Papua dan wajah etnis lainnya untuk melihat model dengan akurasi terbaik pada kasus ini. Model CNN yang dipilih yaitu VGG16, VGG-19, ResNet-50 dan MobileNet v1 dan Mobilenet v2. Model terbaik adalah model arsitektur Mobile Net v1 untuk Pengenalan Wajah Papua dan Non Papua dengan akurasi 95%. Pada penelitian ini disimpulkan bahwa MobileNet V1 adalah model yang terbaik. Model ini menghasilkan akurasi, precision, recall, dan f1-score dengan nilai 95%, 99%, 91%, dan 94%. Adapun saran untuk penelitian selanjutnya adalah dilakukan modifikasi terhadap layer pada masing-masing molde untuk meningkatkan performa model arsitektur CNN.

ABSTRACT

Classification of objects in images is one of the problems in computer vision. Computers are expected to mimic the human ability to understand image information. One successful approach is to use an Artificial Neural Network (ANN) where this approach is inspired by neural networks in humans which are further developed into Deep Learning. Convolutional Neural Network (CNN) is a type of Deep Learning which is very famous for its ability to classify images. By implementing several CNN models, a comparison will be made between the CNN architectural models in the classification of Papuan ethnic faces and other ethnic faces to see which model has the best accuracy in this case. The selected CNN models are VGG16, VGG-19, ResNet-50 and MobileNet v1 and Mobilenet v2. The best model is the Mobile Net v1 architectural model for Papuan and Non-Papuan Face Recognition with an accuracy of 95%. In this study it was concluded that MobileNet V1 is the best model. This model produces accuracy, precision, recall, and f1-score with values of 95%, 99%, 91%, and 94%. The suggestion for further research is to modify the layers in each molde to improve the performance of the CNN architectural model.

1. PENDAHULUAN

Klasifikasi objek pada citra menjadi salah satu problem dalam visi komputer. Komputer diharapkan dapat meniru kemampuan manusia dalam memahami informasi citra. Salah satu pendekatan yang berhasil yaitu dengan menggunakan Jaringan Syaraf Tiruan (JST) dimana pendekatan ini terinspirasi dari jaringan syaraf pada manusia yang dikembangkan lebih jauh menjadi Deep Learning (Arrofiqoh & Harintaka., 2018; Michelsanti, Tan, Sigurdsson, & Jensen, 2019). Deep Learning merupakan cabang dari mechine learning, dimana machine learning dapat mengajarkan komputer untuk melakukan pekerjaan selayaknya manusia yang dilakukan dari proses training (Baryyah, Rasyidi, & Ngatini, 2021; Wayan Suartika Eka Putra, 2016). Convolutional Neural Network (CNN) adalah salah satu jenis Deep learning. CNN dianggap lebih unggul dibanding model klasik lainnya karena konsep pembagian bobot dimana parameter sharing dari CNN dapat membantu mengurangi jumlah parameter sehingga parameter yang membutuhkan training berkurang secara substansial, menghasilkan generalisasi yang lebih baik dan tidak mengalami overfitting (Indolia, Goswami, Mishra, & Asoopa, 2018; Kone, Yatsugi, Mizuno, & Nakamura, 2022). CNN pernah digunakan dalam Klasifikasi Citra pada Caltech 101 dimana hasil penelitaanya menggunakan CNN cukup handal dalam menentukan kebenaran dari kasifkcas citra objek yang dibuktikan dengan hasil akurasi 20% - 50% (Ma & Luo, 2021; Wayan Suartika Eka Putra, 2016). CNN juga diimplementasikan dalam klasifikasi tanaman pada

*Corresponding author.

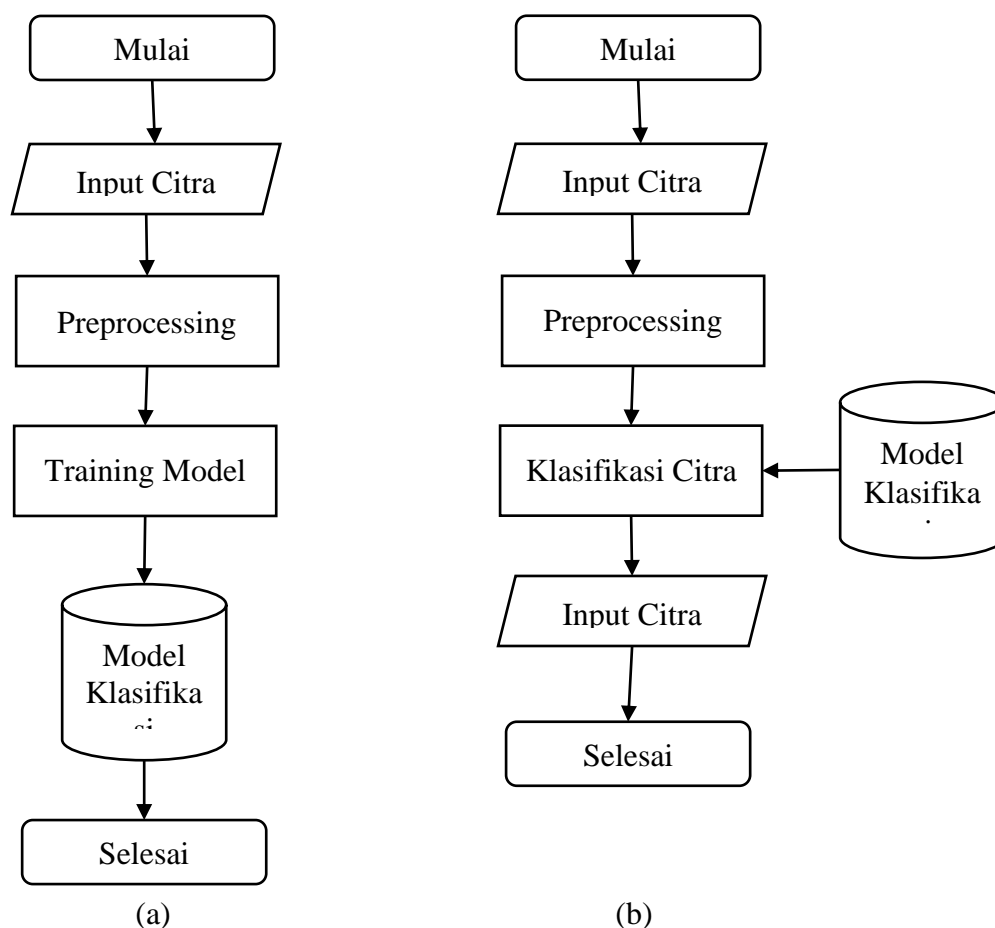
E-mail addresses: yenusiyuni@gmail.com (Yuni Naomi Yenusi)

Citra Resolusi Tinggi dimana diterapkan algoritma CNN membedakan 5 kelas jenis tanaman yaitu padi, bawang merah, kelapa, pisang dan cabai (Arrofiqoh & Harintaka., 2018). Dengan menggunakan CNN didapatkan akurasi 100% pada data training, 93% untuk data validasi dan 82% pada data tes. Selain klasifikasi jenis daun, CNN juga digunakan dalam melakukan klasifikasi ras seperti pada penelitian yang berjudul Klasifikasi Ras pada Kucing menggunakan Algoritma Convolutional Neural Network (CNN), dimana klasifikasi ini dilakukan untuk membantu pecinta kucing dalam memilih jenis makanan kucing berdasarkan Ras Kucing tersebut (Fawwaz, Ramadhani, & Stehvanie, 2021; Feng, Zheng, Qin, Bai, & Zhang, 2021). Dengan CNN dilakukan training dan testing terhadap dataset kucing dan menggunakan beberapa model CNN dan didapatkan akurasi 60.85% untuk model VGG16, 84.94% untuk model InceptionV3, 71.39% untuk model Resnet50 dan 93.75% dengan model Xception. Di tahun 2018 terdapat penelitian yang berjudul Race recognition using deep convolutional neural networks dalam penelitian tersebut dilakukan perbandingan antara dua model CNN yaitu RR-CNN dan RR-VGG dalam klasifikasi ras Jepang, Cina dan Brasil (Vo, Nguyen, & Le, 2018). Didapatkan model RR-CNN dengan akurasi 88.64% dan RR-VGG dengan akurasi 90%, sehingga didapatkan model RR-VGG sebagai model terbaik untuk skenario tersebut.

Klasifikasi ras dilakukan dalam penelitian ini untuk menentukan model CNN terbaik diantara model CNN yaitu VGG16, VGG-19, ResNet-50 dan MobileNet v1 dan MobileNet v2 dalam klasifikasi wajah etnis papua dan etnis lainnya.

2. METODE

Terdapat dua tahap dalam klasifikasi yang dilakukan pada masing-masing model CNN yaitu training dan testing model seperti pada Gambar 1.



Gambar 1. Diagram Alir Training (a) dan Testing(b).

Pre-Processing

Pada tahap ini dilakukan data preprocessing mulai dari menginput data, membagi data dalam data train, data validasi dan data test, melihat karakteristik data terutama ukuran dari setiap data image, yaitu dilakuka rezise, augmentasi dan normalisasi terhadap data.

Deep Learning


Deep Learning adalah jenis metode pembelajaran mesin berdasarkan representasi data pembelajaran. Deep learning adalah konsep machine learning berdasarkan artificial neural networks (Hussein, Malik, Ong, & Slik, 2021; Janiesch, Zschech, & Heinrich, 2021). Ada beberapa tipe neural networks yang ada pada deep learning yaitu Artificial Neural Networks(ANN), Convolutional Neural Networks(CNN), dan Recurrent Neural Networks(RNN).

Convolutional Neural Networks(CNN)

Convolutional Neural Networks(CNN) adalah salah satu jenis neural networks yang ada pada deep learning yang digunakan untuk mengolah data dalam bentuk citra (Fawwaz et al., 2021). Satu langkah dalam pemrosesan CNN disebut layer, yang biasanya berupa input layer,convolution layer, pooling layer, normalisasi layer, fully connected layer, loss layer dan lain-lain.

Input layer adalah layer pertama dalam Jaringan Syaraf Tiruan. Dimana dilakukan input terhadap gambar. Citra. Semakin besar ukuran gambar, semakin dalam layer-nya, dan kinerja prediktor juga tinggi. Performa yang lebih tinggi didapat dengan melakukan peningkatan CPU, GPU, dan RAM dari sistem komputer. Jika gambar berukuran kecil, jaringannya tidak terlalu dalam. Hal ini berpengaruh pada kinerja jaringan yang buruk. Jadi untuk menggunakan jaringan secara optimal, entri data yang optimal harus disediakan.

Convolutional layer didalamnya dilakukan operasi matematika yang disebut konvolusi dengan menggeser matriks Kernel di atas matriks input. Di setiap lokasi, dilakukan perkalian elemen matriks dan menjumlahkan hasilnya ke peta fitur. Konvolusi adalah jenis khusus dari operasi linier yang banyak digunakan dalam berbagai domain termasuk pemrosesan gambar, statistik, fisika. Pada operasi konvolusi, terdapat padding, stride, dan filter sebagai parameternya. Padding adalah penambahan satu baris atau kolom ditambahkan di luar empat tepi input (Wu, 2017). Terdapat 2 macam padding yaitu padding same seperti pada Gambar 2(a) dan padding valid seperti pada Gambar 2(b) (Tammina, 2019). Padding same lebih dikenal dengan istilah zero padding yaitu menambahkan pixel tambahan di sekeliling matriks dengan nilai 0. Hal tersebut dilakukan untuk mengatasi kehilangan pixel citra saat proses konvolusi. Sedangkan pada padding valid tidak ada penambahan pixel di sekeliling matriks dan langsung dilakukan proses konvolusi.



Gambar 2. Padding Same (a) dan Padding Valid (b)

Pooling Layer, Selama proses ekstraksi fitur di layer konvolusi, banyak data dan parameter yang tidak diperlukan dihasilkan. Ini didasarkan pada ukuran gambar yang dimasukkan sebagai input. Di layer pooling, parameter yang akan diproses di jaringan dikurangi. Hal tersebut membantu peningkatan kecepatan jaringan. Max pooling, Average pooling, Global Max pooling, dan metode Global Average Pooling digunakan untuk proses pooling. Ketika citra dari layer konvolusi ke layer ini, fitur penting dalam peta fitur dipertahankan, dan fitur lainnya dibuang. Hal ini dilakukan untuk meminimalisir kehilangan data pada feature map (L., Hareendran S, & Chandra, 2021; Shambhu, Koundal, Das, & Sharma, 2022).

Fully Connected Layer yaitu layer yang terdiri atas lebih dari satu layer neuron, dan setiap neuron terhubung dengan semua neuron lainnya dalam jaringan (Fuadah et al., 2022; Yao, Chen, Tian, & Jiang, 2020). Ini berbeda dengan CNN karena neuron di CNN terhubung secara lokal, tetapi setiap neuron terhubung ke neuron lain di jaringan di layer ini (Li, Jing, & Shi, 2022). Setiap layer neuron menyediakan

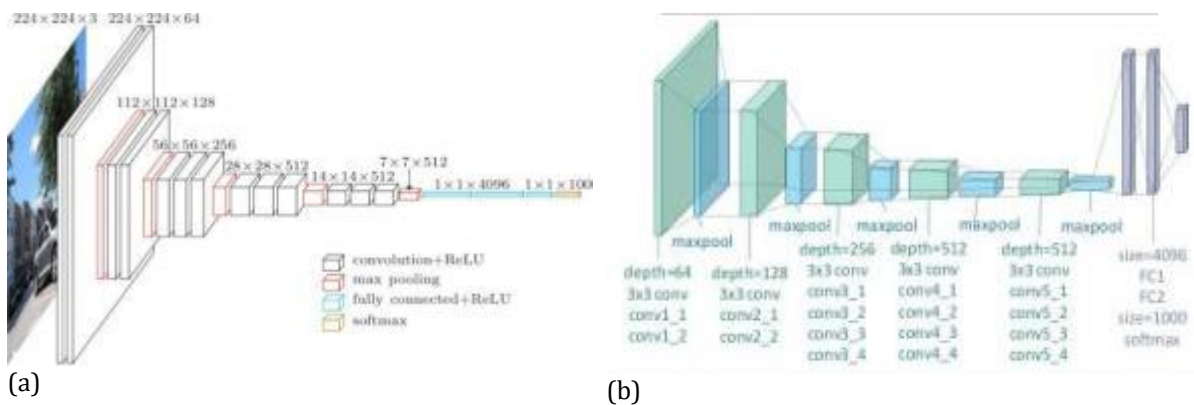
koneksi penuh ke layer yang berbeda, yang memisahkannya ke dalam kelas-kelas. Layer neuron yang terhubung sepenuhnya diarahkan ke kelas yang diperlukan sebagai hasil akhir.

Dropout layer merupakan layer berikut yang dibutuhkan karena jaringan neuron ini juga menghadapi masalah overfitting. Karena ukuran gambar yang besar, neuron yang diproses juga memungkinkan layer untuk mengingat data. Ini adalah aktivitas yang tidak diinginkan yang perlu dihilangkan agar prediksi kelas yang benar dapat dilakukan. Data yang tidak diinginkan yang dibuat di layer CNN dihilangkan secara acak di layer ini, sehingga mengatasi overfitting

Classification Layer adalah layer terakhir dalam jaringan yang mengidentifikasi kelas data. Pelatihan dilakukan pada layer ini, dan keluarannya adalah matriks dimensi 1xN. Di sini N adalah jumlah kelas keluaran yang diinginkan. Nilai dalam matriks 1xN berada dalam kisaran antara 0 dan 1. Ini dilakukan dengan menggunakan fungsi aktivasi.

Visual Geometry Group (VGG)


Dalam keluarga VGG, model VGG-16 menjadi model yang paling sering digunakan, selain itu juga model VGG-19. Kedua model ini merupakan model dengan performa terbaik dalam keluarga VGG-Net. Model VGG-16 misalnya berhasil meraih juara 1 dan 2 pada kategori di atas pada tantangan ILSVRC 2014 dimana ImageNet Large Scale Visual Recognition Challenge (ILSVRC) adalah kompetisi visi komputer tahunan. Model CNN VGG-Verydeep-16 adalah model CNN pra-pelatihan yang dirilis oleh grup Oxford VGG. Arsitektur model VGG-16 ditunjukkan pada Gambar 3.



Gambar 3. Contoh Model Arsitektur VGG-16 (a) dan VGG-19 (b)

Resnet-50

ResNet-50, dan ini adalah versi yang lebih kecil dari ResNet 152. ResNet 50 sering digunakan sebagai titik awal untuk transfer learning. Salah satu alasan menggunakan Resnet 50 yaitu meraih juara 1 dalam kompetisi klasifikasi ILSVRC 2015 dengan tingkat kesalahan top-5 sebesar 3,57%. Memenangkan Juara 1 dalam kompetisi ILSVRC dan COCO 2015 di ImageNet Detection, ImageNet localization, Coco detection dan Coco segmentation (Mahmud, Saira Wahid, & Arif, 2019). Berikut ini adalah gambar arsitektur untuk ResNet-50. Arsitektur ResNet-50 pada Gambar 4 memiliki 50 layer yang terdiri 49 konvolusi dan 1 layer dense untuk proses klasifikasi.

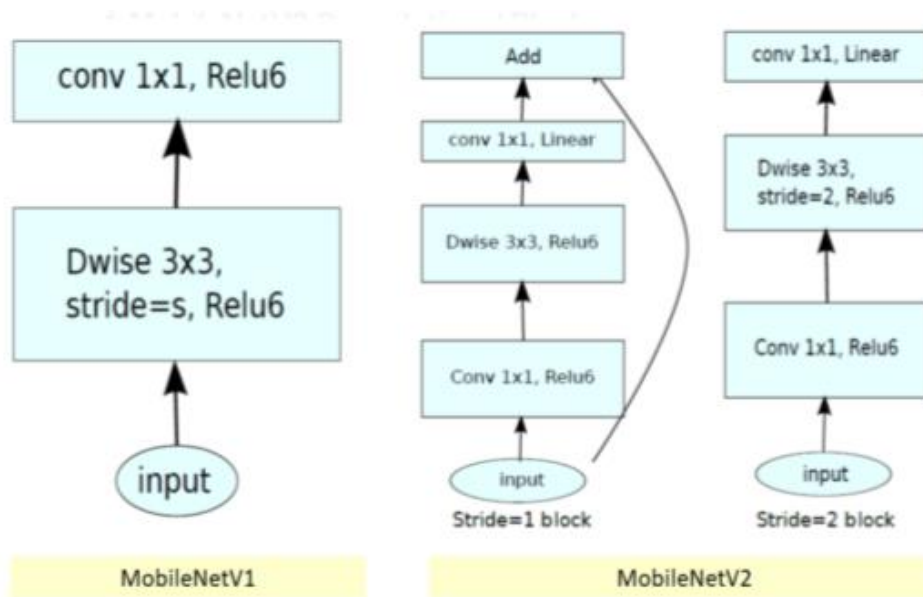


Gambar 4. Contoh Arsitektur ResNet-50

(Jahromi et al., 2019)

MobileNet

Model MobileNet dirancang untuk digunakan dalam aplikasi seluler, dan merupakan model visi komputer seluler pertama TensorFlow. MobileNet menggunakan konvolusi yang dapat dipisahkan secara mendalam. Ini secara signifikan mengurangi jumlah parameter jika dibandingkan dengan jaringan dengan lilitan biasa dengan kedalaman jaring yang sama. Ini menghasilkan jaringan saraf dalam yang ringan. Konvolusi yang dapat dipisahkan secara mendalam dibuat dari dua operasi yaitu Depthwise convolution dan Pointwise convolution. Model MobileNet didasarkan pada konvolusi yang dapat dipisahkan secara mendalam yang merupakan bentuk konvolusi terfaktor yang memfaktorkan konvolusi standar menjadi konvolusi mendalam dan konvolusi 1x1 yang disebut konvolusi pointwise. Untuk MobileNets, Depthwise convolution menerapkan filter tunggal ke setiap saluran input. Depthwise convolution kemudian menerapkan konvolusi 1 x 1 untuk menggabungkan output dari Depthwise convolution (Howard et al., 2017). Tampilan arsitektur mobilenet dapat dilihat pada Gambar 5.




Gambar 5. Contoh Arsitektur Mobile Net

(Sandler et al., 2018)

3. HASIL DAN PEMBAHASAN

Hasil

Data wajah orang Papua yang dikumpulkan yaitu sebanyak 565 image wajah etnis papua dapat dilihat pada Gambar 6(a) dan diambil 565 sample image wajah lainnya yang berasal dari The All-Age-Faces (AAF) Dataset (Cheng et al., 2019) dapat dilihat pada Gambar 6(b). Data didistribusi menjadi data Train dan data Test seperti pada Tabel 1 berikut



Gambar 6. Wajah Etnis Papua (a), The All-Age-Faces (AAF) Dataset (b).

Tabel 1. *Elemental Compositions of Sampling Sites*

| Kategori | Train | Test |
|-----------|-------|------|
| Papua | 415 | 150 |
| Non Papua | 415 | 150 |

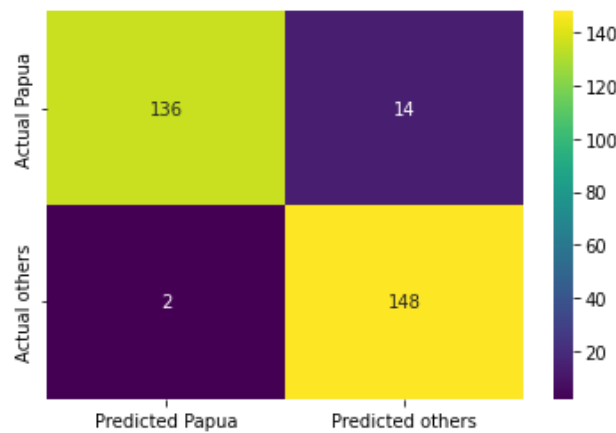
Setelah dilakukan testing maka didapat hasil akurasi yang terbaik di tiap modelnya. Dari model-model tersebut didapat hasil terbaik jatuh kepada model MobileNetV1 dengan akurasi training sebesar 99,88% dan akurasi testing sebesar 95,33%. Sedangkan akurasi terburuk yaitu pada model ResNet50 dengan akurasi training sebesar 77,23% dan akurasi testing sebesar 67,67%. Perbandingan Hasil Akurasi Model Arsitektur CNN dapat dilihat pada [Tabel 2](#).

Tabel 2. *Perbandingan Hasil Akurasi Model Arsitektur CNN*

| Model | Training | Testing |
|-------------|----------|---------|
| VGG-16 | 0,9904 | 0,8967 |
| VGG-19 | 0,9819 | 0,8767 |
| ResNet-50 | 0,7723 | 0,6767 |
| MobileNetV1 | 0,9988 | 0,9533 |
| MobileNetV2 | 0,9988 | 0,8733 |

Pembahasan

Berdasarkan hasil training data dan testing data didapatkan model arsitektur CNN terbaik yaitu Model Arsitektur Mobilenet-V1. Dari ke lima model arsitektur yang digunakan, model ResNet-50 merupakan model dengan akurasi terburuk pada pengenalan wajah orang Papua dengan Non Papua. Sementara itu model VGG-16 dan VGG-19 memiliki performa yang baik namun tidak lebih baik dari performa Mobilenet. Setelah didapatkan model terbaik yaitu mobilenet V1 selanjutnya dilakukan evaluasi pengukuran performansi dengan menggunakan metrik accuracy, precision, recall, dan f-1 score. Setiap nilai tersebut didapatkan dari confusion matrix pada [Gambar 7](#).



Gambar 7. *Confusion Matrix Setiap Model Mobile Net V1.*

Setelah mendapatkan nilai True Positive, True Negative, False Positive, dan False Negative seperti pada [Gambar 7](#) maka dapat diketahui nilai pada metrik maka didapatkan nilai accuracy, precision, recall, dan f-1 score untuk model MobileNet V1 seperti pada [Tabel 3](#).

Tabel 3. *Perbandingan Hasil Akurasi Model Arsitektur CNN*

| Model | precision | recall | f1-score | accuracy |
|-------------|-----------|--------|----------|----------|
| MobileNetV1 | 0,99 | 0,91 | 0,94 | 0,95 |

Model VGG awalnya diharapkan sebagai model terbaik dalam penelitian ini, untuk Model VGG baik VGG 16 maupun VGG 19 sudah terbukti performanya dalam berbagai penelitian. Beberapa penelitian yang melakukan klasifikasi pada Fundus, didapatkan model dengan performa terbaik untuk kasus tersebut adalah model VGG 16 dan VGG 19 ([Setiawan, 2019](#); [Supratman & Rafiqi, 2016](#)). Penelitian lainnya yang juga menunjukkan bahwa performa VGG sebagai model terbaik, bahkan menyarankan penggunaan VGG dalam

melakukan Race Recognition (Tammina, 2019; Vo et al., 2018). Sehingga keunggulan VGG dalam penelitian ini tidak perlu diragukan lagi namun disisi lain jika melihat Mobile net sebagai model dengan akurasi tertinggi, cukup mengejutkan karena model ini bisa memiliki akurasi yang tidak jauh dari model populer seperti VGG bahkan lebih tinggi. Penelitian selanjutnya menunjukkan bahwa model arsitektur mobile net memiliki akurasi yang dekat dengan model populer seperti VGG-16 dan GoogleNet bahkan hasil akurasi MobileNet lebih besar dibanding model Googlenet (Howard et al., 2017). Dalam penelitian yang lebih terkini juga menunjukkan tingginya akurasi Mobilnet dibanding model populer seperti VGG dan Resnet, dimana Mobilnet yang dibandingkan dengan model Resnet-50, VGG-16 dan VGG-19 menunjukkan hasil dimana model mobilnet merupakan model dengan akurasi terbaik, bahkan dalam penelitiannya dibuat modifikasi terhadap model arsitektur mobilnet dan model tersebut juga merupakan model terbaik jika dibandingkan dengan model lainnya yang digunakan dalam penelitian tersebut (Han, Liu, & Fan, 2018; Pan, Pang, Wang, Wang, & Lin chen, 2020). Bahkan pada penelitian selanjutnya, dilakukan perbandingan mobilnet terhadap hasil modifikasi mobilnet itu sendiri dan didapatkan hasil mobilnet yang telah dimodifikasi sebagai model dengan akurasi tertinggi (Wang et al., 2020). Performa MobileNet semakin dipertimbangkan dan digunakan dalam banyak penelitian terbaru seperti pada klasifikasi aorta (Yang, Ojha, Aranof, Green, & Tavassolian, 2020). Dalam *Survey on deep learning object detection* juga menjadikan Mobile Net V1 sebagai salah satu model arsitekturnya (Zaidi et al., 2022; Zhao, Rao, Dong, & Zhang, 2020). Bahkan dalam deteksi hewan juga sudah memanfaatkan Mobilnet sebagai model arsitektur pilihan (A., Alsaadi, & Abbadi, 2020). Dengan demikian dalam penelitian ini didapatkan model terbaik yaitu Model arsitektur MobileNetv1.

4. SIMPULAN

Pada penelitian ini disimpulkan bahwa MobileNet V1 adalah model yang terbaik. Model ini menghasilkan akurasi, precision, recall, dan f1-score dengan nilai 95%, 99%, 91%, dan 94%. Adapun saran untuk penelitian selanjutnya adalah dilakukan modifikasi terhadap layer pada masing-masing model untuk meningkatkan performa model arsitektur CNN.

5. DAFTAR PUSTAKA

- A., E. M. T., Alsaadi, & Abbadi, N. K. El. (2020). An Automated Mammals Detection Based on SSD-Mobile Net. *Journal of Physics: Conference Series*, 1879. <https://doi.org/10.1088/1742-6596/1879/2/022086>.
- Arrofiqoh, E. N., & Harintaka. (2018). Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi. *GEOMATIKA*, 61–68. <https://doi.org/10.24895/JIG.2018.24-2.810>.
- Bariyah, T., Rasyidi, M. A., & Ngatini, N. (2021). Convolutional Neural Network untuk Metode Klasifikasi Multi-Label pada Motif Batik. *Jurnal Techno.Com*, 20(1). <https://doi.org/10.33633/tc.v20i1.4224>.
- Fawwaz, M. A., Ramadhani, K. N., & Sthevanie, F. (2021). Klasifikasi Ras pada Kucing menggunakan Algoritma Convolutional Neural Network(CNN). *Proceedings of Engineering*, 8(1), 75-730. <https://doi.org/10.34818/eoe.v8i1.14320>.
- Feng, Y., Zheng, J., Qin, M., Bai, C., & Zhang, J. (2021). 3D Octave and 2D Vanilla Mixed Convolutional Neural Network for Hyperspectral Image Classification with Limited Samples. *Remote Sensing*, 13(4407), 4407. <https://doi.org/10.3390/rs13214407>.
- Fuadah, Y. N., Ubaidullah, I. D., Ibrahim, N., Taliningsing, F. F., Sy, N. K., & Pramuditho, M. A. (2022). Optimasi Convolutional Neural Network dan K-Fold Cross Validation pada Sistem Klasifikasi Glaukoma. *Jurnal Elkomika*, 10(3). <https://doi.org/10.26760/elkomika.v10i3.728>.
- Han, D., Liu, Q., & Fan, W. (2018). A new image classification method using CNN transfer learning and web data augmentation. *Expert Systems with Applications*, 95, 43–56. <https://doi.org/10.1016/j.eswa.2017.11.028>.
- Howard, A., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., & Adam, H. (2017). MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. *Computer Science Computer Vision and Pattern Recognition*. Retrieved from <https://arxiv.org/abs/1704.04861>.
- Hussein, B. R., Malik, O. A., Ong, W.-H., & Slik, J. W. F. (2021). Reconstruction of damaged herbarium leaves using deep learning techniques for improving classification accuracy. *Ecological Informatics*, 61. <https://doi.org/10.1016/j.ecoinf.2021.101243>.
- Indolia, S., Goswami, A. K., Mishra, S. P., & Asoopa, P. (2018). Conceptual Understanding of Convolutional Neural Network- A Deep Learning Approach. *Procedia Computer Science*, 132, 679–688. <https://doi.org/10.1016/j.procs.2018.05.069>.
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31,

- 685–695. Retrieved from <https://link.springer.com/article/10.1007/s12525-021-00475-2>.
- Kone, S. E. M. P., Yatsugi, K., Mizuno, Y., & Nakamura, H. (2022). Application of Convolutional Neural Network for Fault Diagnosis of Bearing Scratch of an Induction Motor. *Applied Sciences*, 12(5513), 5513. <https://doi.org/10.3390/app12115513>.
- L., A. A., Hareendran S, A., & Chandra, V. (2021). COVID-19 diagnosis and severity detection from CT-images using transfer learning and back propagation neural network. *Journal of Infection and Public Health*, 14(10), 1435–1445. <https://doi.org/10.1016/j.jiph.2021.07.015>.
- Li, P., Jing, R., & Shi, X. (2022). Apple Disease Recognition Based on Convolutional Neural Networks With Modified Softmax. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.820146>.
- Ma, Y., & Luo, Y. (2021). Bone fracture detection through the two-stage system of Crack-Sensitive Convolutional Neural Network. *Informatics in Medicine Unlocked*, 22, 100452.
- Mahmud, K. T., Saira Wahid, I., & Arif, I. (2019). Impact of training needs assessment on the performance of employees: Evidence from Bangladesh. *Cogent Social Sciences*, 5(1). <https://doi.org/10.1080/23311886.2019.1705627>.
- Michelsanti, D., Tan, Z.-H., Sigurdsson, S., & Jensen, J. (2019). Deep-learning-based audio-visual speech enhancement in presence of Lombard effect. *Speech Communication*, 115. <https://doi.org/10.1016/j.specom.2019.10.006>.
- Pan, H., Pang, Z., Wang, Y., Wang, Y., & Lin chen. (2020). A New Image Recognition and Classification Method Combining Transfer Learning Algorithm and MobileNet Model for Welding Defects. *IEEE Access*, 8, 119951–119960. <https://doi.org/10.1109/ACCESS.2020.3005450>.
- Setiawan, W. (2019). Perbandingan Arsitektur Convolutional Neural Network Untuk Klasifikasi Fundus. *SIMANTEC*, 7(2), 49–54. <https://doi.org/10.21107/simantec.v7i2.6551>.
- Shambhu, S., Koundal, D., Das, P., & Sharma, C. (2022). Binary Classification of COVID-19 CT Images Using CNN: COVID Diagnosis Using CT. *International Journal of E-Health and Medical Communications (IJEHMC)*, 13(2), 13. <https://doi.org/10.4018/IJEHMC.20220701.0a4>.
- Supratman, L. P., & Rafiqi, A. (2016). Kajian Etnografi Komunikasi Pada Gaya Berkomunikasi Komunitas Hansamo Modern Dance Boys Di Kota Bandung. *Jurnal Kajian Komunikasi*, 4(1). <https://doi.org/10.24198/jkk.v4i1.7852>.
- Tamma, S. (2019). Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images. *International Journal of Scientific and Research Publications*, 9(10), 143–150. <https://doi.org/10.29322/IJSRP.9.10.2019.p9420>.
- Vo, T., Nguyen, T., & Le, C. T. (2018). Race Recognition Using Deep Convolutional Neural Networks. *Symmetry*, 564. <https://doi.org/10.3390/sym10110564>.
- Wang, W., Hu, Y., Zou, T., Liu, H., Wang, J., & Wang, X. (2020). A New Image Classification Approach via Improved MobileNet Models with Local Receptive Field Expansion in Shallow Layers. *Computational Intelligence and Neuroscience*, 10. <https://doi.org/10.1155/2020/8817849>.
- Wayan Suartika Eka Putra. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101. *Jurnal Teknik ITS*, 5(1). <https://doi.org/10.12962/j23373539.v5i1.15696>.
- Wu, J. (2017). *Introduction to Convolutional Neural Networks*. Nanjing University.
- Yang, C., Ojha, B., Aranof, N., Green, P., & Tavassolian, N. (2020). Classification of aortic stenosis using conventional machine learning and deep learning methods based on multi-dimensional cardio-mechanical signals. *Scientific Reports*, 17521. <https://doi.org/10.1038/s41598-020-74519-6>.
- Yao, S., Chen, Y., Tian, X., & Jiang, R. (2020). GeminiNet: Combine Fully Convolution Network With Structure of Receptive Fields for Object Detection. *IEEE Access*, 8, 60305–60313. <https://doi.org/10.1109/ACCESS.2020.2982939>.
- Zaidi, S. S. A., Ansari, M. S., Aslam, A., Kanwal, N., Asghar, M., & Lee, B. (2022). A survey of modern deep learning based object detection models. *Digital Signal Processing*, 126, 103514. <https://doi.org/10.1016/j.dsp.2022.103514>.
- Zhao, Y., Rao, Y., Dong, S., & Zhang, J. (2020). Survey on deep learning object detection. *Journal of Image and Graphics*, 1. <https://doi.org/10.11834/jig.190307>.