

Identifikasi Mata Katarak Menggunakan Arsitektur *EfficientNet-B7*

MUHAMMAD ICHWAN¹, MUHAMMAD DWIKI REZA^{1*}

¹Program Studi Informatika, Institut Teknologi Nasional Bandung
Email : muhammaddwiki01@mhs.itenas.ac.id

Received 13 01 2023 | *Revised* 20 01 2023 | *Accepted* 20 01 2023

ABSTRAK

Penyebab kebutaan terbesar yang ada di Indonesia adalah katarak. Katarak merupakan gangguan penglihatan yang merupakan tanda gangguan penglihatan pertama sebelum glaukoma dan retinopati diabetes, sebab itu perlu melakukan deteksi gangguan penglihatan sebelum terjadi kebutaan. Dengan perkembangan kecerdasan buatan terhadap computer vision saat ini sudah banyak diterapkan dalam identifikasi gambar dibidang kesehatan. Penelitian ini menggunakan deep learning dengan metode convolution neural network (CNN) dengan arsitektur efficientnet-b7 dan keterbaruan dari penelitian ini menggunakan hyperparameter optimizer SGD, learning rate 0,01 , batch size 10, epoch 10 dan dropout regularization untuk mengidentifikasi mata katarak dari beberapa percobaan yang dilakukan untuk mendapatkan nilai hyperparameter yang optimal. Hasil performa model yang diperoleh pada penelitian ini dengan akurasi 94%, dengan loss 5,7, serta nilai presisi sebesar 1.00, recall sebesar 1.00 dan fi-score sebesar 1.00. dapat disimpulkan bahwa metode convolution neural network (CNN) dengan arsitektur efficientnet-b7 dan hyperparameter dapat meningkatkan nilai akurasi.

Kata kunci: CNN, Efficientnet-B7, Mata, Katarak, Hyperparameter

ABSTRACT

The biggest cause of blindness in Indonesia is cataracts. Cataracts are visual impairment which is the first sign of visual impairment before glaucoma and diabetic retinopathy, therefore it is necessary to detect visual impairment before blindness occurs. With the development of artificial intelligence on computer vision, it has now been widely applied in image identification in the health sector. This study uses deep learning with the convolution neural network (CNN) method with efficientnet-b7 architecture and the update of this study using the SGD hyperparameter optimizer, learning rate 0.01 , batch size 10, epoch 10 and dropout regularization to identify cataract eyes from several experiments conducted to obtain optimal hyperparameter values. The model performance results obtained in this study with an accuracy of 94%, with a loss of 5,7, and a precision value of 1.00, a recall of 1.00 and a fi-score of 1.00. it can be concluded that the convolution neural network (CNN) method with efficientnet-b7 architecture and hyperparameters can increase the value of accuracy.

Keywords: CNN, Efficientnet-B7, Eye, Cataract, Hyperparameter

1. PENDAHULUAN

Penyebab kebutaan terbesar yang ada di Indonesia adalah katarak. Katarak merupakan gangguan penglihatan yang ditandai dengan hilangnya kejernihan atau terjadinya kekeruhan pada lensa mata (**Detty, Artini, & Yuliana, 2021**). Hilangnya kejernihan pada lensa mata disebabkan oleh adanya penambahan *volume* cairan pada lensa mata (hidrasi) atau karena terjadinya denaturasi protein yang terdapat pada lensa mata atau dapat terjadi karena kedua hal tersebut (**Hidayaturahmah, Andayani, & Kristina, 2021**). Sekitar 180 juta orang di seluruh dunia mengalami keterbatasan penglihatan, 40 sampai 45 juta di antaranya mengalami kebutaan akibat katarak dan sepertiga dari jumlah tersebut merupakan penduduk Asia Tenggara. Katarak di Nusa Tenggara Barat sekitar 1,6 % dengan *prevalensi* nasional sekitar 1,8%. Jumlah ini diperkirakan akan meningkat seiring dengan pertumbuhan penduduk yang pesat dan meningkatnya usia harapan hidup di Indonesia (**Salsabilla, Andari, & Nasrul, 2021**). Gangguan mata banyak sekali jenisnya, diantaranya katarak, glaucoma dan *retina disease*. Katarak merupakan keadaan dimana terjadi kekeruhan pada serabut atau bahan lensa didalam kapsul lensa. Katarak adalah suatu keadaan lensa dimana lensa menjadi keruh akibat hidrasi cairan lensa atau *denaturasi* protein lensa. Kekeruhan itu terjadi akibat gangguan *metabolism* tubuh normal lensa yang dapat timbul pada berbagai usia tertentu (**Cahya, Hardi, Riana, & Hadianti, 2021**). Melihat dari uraian sebelumnya, penting sekali untuk mendeteksi penyakit mata atau kelainan sebelum terjadinya kebutaan.

Sudah cukup banyak peneliti yang melakukan penelitian mengenai penyakit mata, diantaranya yaitu penelitian deteksi katarak ini dapat juga dilakukan menggunakan citra digital. Citra digital dapat diuraikan sebagai bentuk diskrit dari suatu citra analog baik berupa koordinat maupun berupa nilai intensitas cahayanya (**Cahya, Hardi, Riana, & Hadianti, 2021**).

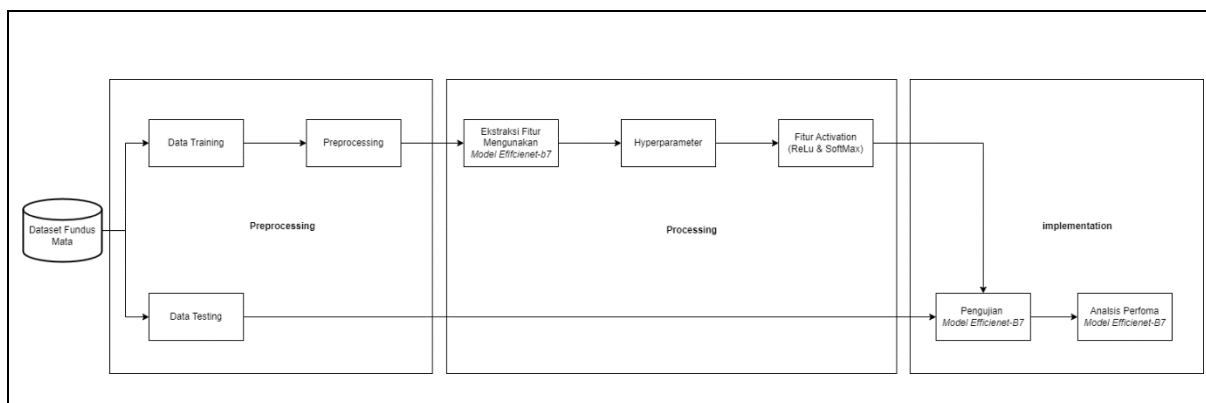
Penelitian tentang arsitektur *EfficientNet* telah dilakukan oleh (**Tan & Le, 2020**). Penelitian tersebut melakukan pegujian menggunakan *dataset* yang telah disediakan oleh *ImageNet* terhadap model arsitektur. Arsitektur *EfficientNet-B7* -secara signifikan mengungguli arsitektur lainnya. Khususnya, *Efficient-B7* mencapai top-1 *accruarcy* 84.3% yang berarti mengungguli berbagai arsitektur *convolutional neural network* lainnya. Arsitektur *EfficientNet* terdiri dari *EfficientNet-B0* sampai dengan *EfficientNet-B7* dan *EfficientNet-B7* dijadikan sebagai *The New State Of The Art* untuk kompetensi ILSVRC (*Imagenet Large Scale Visual Recognition Challenge*) ditahun 2019 (**Tan & Le, 2020**). Penelitian terkait yang pernah dilakukan untuk mendeteksi katarak menggunakan data gambar fundus mata menggunakan CNN pernah dilakukan oleh (**Nikhil, 2019**). Penelitian tersebut menggunakan CNN dengan menggabungkan menggabungkan arsitektur *VGG16*, *AlexNet*, dan *InceptionNet V3* . Hasil penelitian tersebut mendapatkan akurasi sebesar 80,1%. Selanjutnya penelitian lain yang pernah dilakukan oleh (**RIZAL, IBRAHIM,, PRATIWI, SAIDAH, & FU'ADAH, 2020**). Penelitian tersebut menggunakan arsitektur *EfficientNet-B0* sebagai model untuk melatih *dataset* yang sebelumnya dilakukan *pre-processing* menggunakan *Contrast Limited Adaptive Histogram Equalization* (CLAHE) sebagai metode untuk menaikkan kontras citra pada gambar *dataset*. Penelitian ini mendapatkan tingkat akurasi sebesar 79,8% dalam mengklasifikasikan 5 level penyakit mata.

Berdasarkan penelitian tersebut, maka penelitian ini dibuat untuk meningkatkan akurasi dari sistem mode diatas. Sistem yang dibuat merupakan untuk deteksi mata katarak menggunakan CNN dengan menggunakan model *EfficientNet-B7* dan menambahkan parameter yang mampu meningkatkan akurasi cukup tinggi sebesar 94%.

2. METODE PENELITIAN

Tujuan dari penelitian ini adalah mendeteksi secara dini mata katarak pada pasien sebagai upaya pencegahan bertambah parahnya penyakit tersebut dengan menyediakan tiga kelas yaitu mata katarak, mata *normal* dan bukan fundus mata.

Pada penelitian kali ini, Blok diagram pembuatan *training model efficientnet-b7* dengan *hyperparameter* untuk identifikasi mata katarak pada Gambar 1.



Gambar 1. Blok Diagram Sistem

Pada Gambar 1 blok diagram proses pembuatan *training model* identifikasi ditampilkan secara keseluruhan/umum, diawali proses *pre-processing* yang dimana terdapat proses *resize image* menjadi 150 x 150, lalu dilakukan pemisahan *dataset* menjadi 2 bagian yaitu *training* sebesar 70% dan *testing* sebesar 30% dari total keseluruhan *dataset*, lalu ke ketahap *processing*, dimulai dengan ekstraksi fitur menggunakan arsitektur *efficientnet-b7*, lalu dilakukan proses *hyperparameter* berfungsi untuk membantu meningkatkan akurasi lalu dilakukan fitur *activation relu & softmax* hingga menghasilkan *model extracted feature* yang optimal. Tahap terakhir *implementation* berfungsi untuk menguji *model* dengan *dataset testing* dan dilakukan evaluasi model.

2.1 Pemilihan Citra *Input*

Citra *input (dataset)* yang unakan adalah *dataset* yang *open public* dan mempunyai *license* diambil melalui kaggle yang dibuat oleh Guna Venkat Doddi yang telah diperbarui datanya pada bulan agustus 2022, "*eye_diseases_classification, Eye Disease Retinal Images*".

Tabel 1. Jumlah dataset tiap kelas

No	Kelas	Jumlah data
1	Mata <i>normal</i>	1074
2	Mata katarak	1038
3	Bukan fundus mata	1057
	Total	3169




Gambar 2. Kelas Mata Normal, Mata Katark dan Bukan Fundus Mata

Gambar 2 merupakan jumlah kelas yang dapat dibaca disistem. Kelas mata *normal* adalah mata yang tidak terkena penyakit mata lalu kelas mata katarak yang telah terjadi hilangkan kejernihan atau kekeruhan pada lensa mata dan kelas bukan fundus mata adalah kelas sebagai *other* yang tidak dapat mendeteksi mata katarak atau mata *normal* karena sistem hanya mendeteksi mata katarak dengan citra fundus mata.

2.2 Pre-processing

Sebelum dimasukkan kedalam model *deep learning*, perlu dilakukan *pre-processing* pada *dataset* yang digunakan. *Pre-processing* yang digunakan adalah *resize image* karena ukuran *image* dari *dataset* yang didapatkan sangat beragam ukurannya lalu ubah menjadi 150x150 dan dilakukan *rename dataset* untuk mempermudah mengenali citra, terakhir dilakukan *split dataset* yang bertujuan untuk membagi jumlah data dalam proses pembagian gambar. Pada penelitian kali ini nilai dari *training* sebesar 70% dan *testing* sebesar 30%.



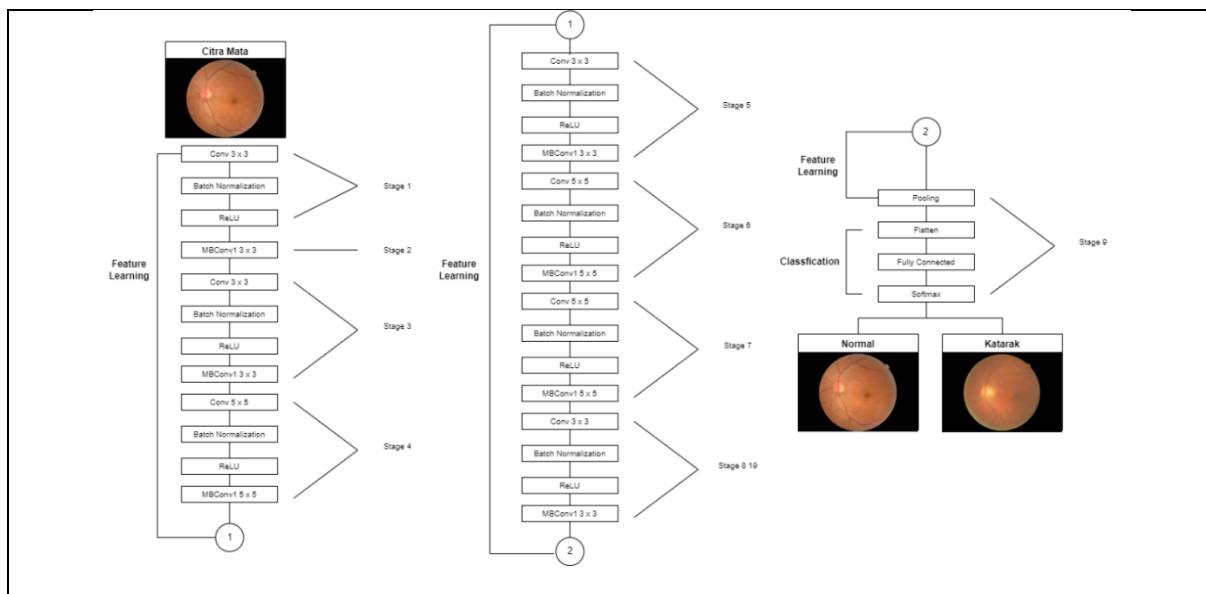
Gambar 3. Hasil Preprocessing Data

2.3 Perancangan dan Pelatihan Sistem

Sistem pada penelitian ini dirancang menggunakan model *EfficientNet-B7*. Model ini merupakan pengembangan dari model-model lainnya dengan meningkatkan dimensi baik dari kedalaman, lebar layer (Tan & Le, 2020). Citra hasil dari *pre-processing* akan dijadikan *dataset* untuk mendukung performa model *EfficientNet-B7* dan akan ditambahkan parameter lainnya.

Identifikasi Mata Katarak Menggunakan Arsitektur EfficientNet-B7

Penelitian ini menggunakan model *EfficientNet-B7* sebagai model dasar yang dapat dilihat pada gambar 4. Sebelum mencapai layer klasifikasi, penulis melakukan penambahan parameter lainnya untuk meningkatkan performa model dapat dilihat pada gambar 5.



Gambar 4. Model *EfficientNet-B7*

```

Model: "sequential"
Layer (type)                Output Shape                Param #
-----
efficientnetb7 (Functional) (None, 5, 5, 2560)         64097687
dropout (Dropout)           (None, 5, 5, 2560)         0
global_average_pooling2d (GlobalAveragePooling2D) (None, 2560)               0
flatten (Flatten)           (None, 2560)                0
batch_normalization (Batch Normalization) (None, 2560)               10240
dropout_1 (Dropout)         (None, 2560)                0
dense (Dense)                (None, 152)                 389272
batch_normalization_1 (Batch Normalization) (None, 152)                608
dropout_2 (Dropout)         (None, 152)                0
dense_1 (Dense)              (None, 48)                  7344
dropout_3 (Dropout)         (None, 48)                  0
dense_2 (Dense)              (None, 8)                   392
=====
Total params: 64,505,543
Trainable params: 64,189,392
Non-trainable params: 316,151
    
```

Gambar 5. Layer Model

Pada penelitian ini menggunakan arsitektur *EfficientNet-B7* yang didalamnya terdapat 9 *stage* konvolusi yang terdiri dari operasi konvolusi 3x3 dan 5x5. *EfficientNet-B7* dari *convolutional neural network* yang didasarkan pada metode penskalaan yang sederhana dan sangat efektif. *EfficientNet-B7* mampu menskalakan semua dimensi, seperti *depth* (kedalaman) yang 27 merupakan jumlah lapisan *convolutional neural network*, *width* (lebar) yang merupakan jumlah channel, dan *resolution* (resolusi) yang merupakan resolusi gambar, dengan menggunakan koefisien gabungan.

2.4 Training Model

Pada proses pelatihan, dataset dibagi menjadi 3 untuk dijadikan data latih 70%, data *validasi* dan data *testing* 30%. Uji model diperlukan untuk memvalidasi akurasi dari model yang telah dibuat. Beberapa skenario akan dilakukan untuk dijadikan pembandingan dan mencari nilai akurasi terbaik dari menambahkan parameter lainnya.

Parameter yang dipasang pada model menggunakan beberapa *optimizer* ini learning rate 0,01 dan pelatihan dilakukan proses iterasi sebanyak 10 *epoch* dengan ukuran *batch size* 10. Pelatihan model ini ditambahkan *dropout regularization* berfungsi untuk mengurangi dari *overfitting* dan *underfitting*. *Overfitting* akan menyebabkan sebuah sistem hanya mengenali data yang dilatih saja jika ada masukan data baru, maka sistem akan kesulitan mengklasifikasi data tersebut sehingga performa sistem dapat dikatakan rendah.

3. ANALISI SISTEM DAN HASIL


Penelitian ini memiliki 4 skenario yang memiliki perbedaan dari *hyperparameter optimizer* agar untuk mencapai tingkat akurasi maksimal dari model yang diusulkan menggunakan *EfficientNet-B7*. Adapun perbedaan masing-masing skenario dapat dilihat pada table 2 berikut.

Tabel 2. Parameter Hyperparameter Optimizer Penelitian

Skenario	Optimizer
1	SGD
2	Adam
3	RMSprop
4	AdaGrad

3.1 Skenario 1 : Pelatihan Model Dengan Optimizer SGD

Pada skenario pertama ini dilakukan percobaan model *EfficientNet-B7* menggunakan *hyperparameter optimizer* SGD.



Gambar 6. Hasil dari Pelatihan dan Pengujian Menggunakan *Optimizer* SGD

Terlihat pada gambar 6, nilai validasi akurasi sebesar 94% dan nilai validasi loss sebesar 5,7. Dilihat dari hasil grafik akurasi dapat disimpulkan *goodfitt* walaupun sempat mengalami penurunan akurasi di *epoch* kesatu dan hasil grafik loss dapat disimpulkan *goodfitt* pada model yang telah dibuat.

3.2 Skenario 2 : Pelatihan Model Dengan *Optimizer* ADAM

Pada skenario kedua ini dilakukan percobaan model *EfficientNet-B7* menggunakan *hyperparameter optimizer* ADAM.




Gambar 7. Hasil dari Pelatihan dan Pengujian Menggunakan *Optimizer* ADAM

Terlihat pada gambar 7, nilai validasi akurasi sebesar 61% dan nilai validasi loss sebesar 15,24. Dilihat dari hasil grafik dapat disimpulkan performa model sering terjadi penurunan pada model yang telah dibuat.

3.3 Skenario 3 : Pelatihan Model Dengan *Optimizer* RMSprop

Pada skenario ketiga ini dilakukan percobaan model *EfficientNet-B7* menggunakan *hyperparameter optimizer* RMSprop.




Gambar 8. Hasil dari Pelatihan dan Pengujian Menggunakan *Optimizer* RMSprop

Terlihat pada gambar 8, nilai validasi akurasi sebesar 62% dan nilai validasi loss sebesar 29,07. Dilihat dari hasil grafik dapat disimpulkan performa model sering terjadi penurunan pada model yang telah dibuat.

3.4 Skenario 4 : Pelatihan Model Dengan *Optimizer* AdaGrad

Pada skenario keempat ini dilakukan percobaan model *EfficientNet-B7* menggunakan *hyperparameter optimizer* AdaGrad.



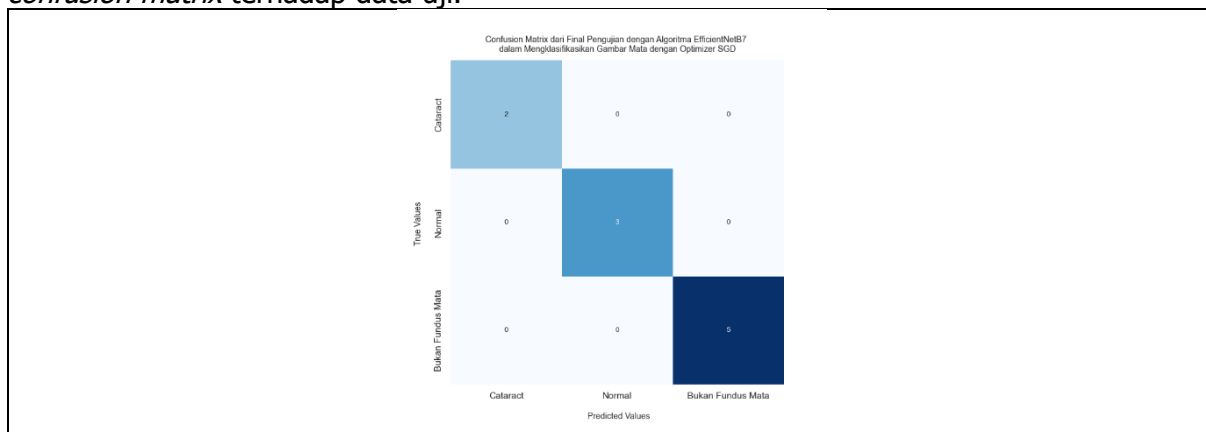
Gambar 9. Hasil dari Pelatihan dan Pengujian Menggunakan Optimizer AdaGrad
 Terlihat pada gambar 9, nilai validasi akurasi sebesar 95% dan nilai validasi loss sebesar 3,17. Dilihat dari hasil grafik dapat disimpulkan terjadinya *goodfitt* pada model yang telah dibuat, tetapi jarak garis *validation* dan *training* sering berjauhan yang berarti model hanya baik mendeteksi menggunakan data *training*.



Gambar 10. Perbandingan Nilai Akurasi dan Loss dari Ke-Empat Skenario
 Terlihat pada gambar 10 bahwa nilai akurasi dan loss yang paling baik terdapat pada skenario kesatuyaitu dengan menggunakan *optimizer* SGD tahap pemilihan *hyperparameter optimizer* serta dengan menggunakan *learning rate* 0,01 *batch size* 10 dan dilakukan perulangan dengan 10 *epoch*.

3.5 Confusion Matrix

Pada skenario kesatu ini dilakukan pengujian model *EfficientNet-B7* dengan menggunakan *confusion matrix* terhadap data uji.



Gambar 11. Confusion Matrix dari Data Uji

Terlihat pada gambar 11, pada skenario kesatu mendapatkan nilai akurasi sebesar 94% dan nilai loss sebesar 5,7 terhadap data uji. Dilakukan proses evaluasi dengan salah satu kelas dengan persamaan *presisi*, *recall* dan *f1-score* kemudian didapatkan nilai *presisi* sebesar 1.00, nilai *recall* sebesar 1.00 dan nilai *f1-score* sebesar 1.00.

4. KESIMPULAN

Berdasarkan pengujian yang telah dilakukan, metode *convolution neural network* (CNN) dengan arsitektur *efficientnet-b7* dan menambahkan *hyperparameter optimizer SGD*, *batch size 10*, *learning rate 0.01* dan *epoch 10* dari beberapa percobaan yang dilakukan untuk mendapatkan nilai *hyperparameter optimizer* yang optimal untuk mampu melakukan identifikasi mata katarak dengan gambar fundus mata. Hasil performa model yang diperoleh pada penelitian ini dengan akurasi 94% dan *loss* 5,7, lalu dengan pengujian model mendapatkan nilai *presisi* sebesar 1.00, *recall* sebesar 1.00 dan *f1-score* sebesar 0.922. Dengan hasil tersebut metode *convolution neural network* (CNN) dengan arsitektur *efficientnet-b7* memiliki kinerja baik dalam identifikasi mata katarak dengan didukung banyaknya *dataset*. Untuk penelitian lebih lanjut, disarankan untuk menggunakan resolution yang sudah ditentukan arsitektur *efficientnet-b7* yaitu 150x150 karena akan berpengaruh di nilai akurasi dan nilai loss yang akan didapatkan.

DAFTAR RUJUKAN

- ANANDADIKA, F. D. (2022). PENINGKATAN PERFORMA ARSITEKTUR MOBILENETV3 PADA KLASIFIKASI JENIS IKAN KOI DENGAN FINE-TUNING.
- Budianita, E., & Novriyanto. (t.thn.). Klasifikasi Status Gizi Balita Berdasarkan Indikator Antropometri Berat Badan Menurut Umur Menggunakan Learning Vector Quantization.
- Cahya, F. N., Hardi, N., Riana, D., & Hadianti, S. (2021). Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN). *SISTEMASI: Jurnal Sistem Informasi*, 621-623.
- Detty, A. U., Artini, I., & Yuliana, V. R. (2021). Karakteristik Faktor Risiko Penderita Katarak. *Departemen Ilmu Mata Fakultas Kedokteran Universitas Malahayati*, 12-17.
- DEWI, S. R. (2018). DEEP LEARNING OBJECT DETECTION PADA VIDEO MENGGUNAKAN TENSORFLOW DAN CONVOLUTIONAL NEURAL NETWORK. *UNIVERSITAS ISLAM INDONESIA*, 1-55.
- Hidayaturahmah, R., Andayani, T. M., & Kristina, S. A. (2021). Analisis Faktor-Faktor Klinik yang Mempengaruhi Kualitas Hidup Pasien Katarak di Rumah Sakit Dr. YAP, Yogyakarta. *Jurnal Farmasi Dan Ilmu Kefarmasian Indonesia*, 207-214.
- Irfan, D., Rosnelly, R., Wahyuni, M., Samudra, J. T., & Rangga, A. (2022). PERBANDINGAN OPTIMASI SGD, ADADELTA, DAN ADAM DALAM KLASIFIKASI HYDRANGAEA MENGGUNAKAN CNN. *Journal of Science and Social Research I*, 244-253.
- Karno, A. S., Arif, D., & Sari, I. (2021). DETEKSI COVID-19 IMAGE CHEST X-RAY DENGAN CONVOLUTION NEURAL NETWORK EFFICIENT NET-B7. *SeNTIK*, 23-28.
- Mustamin, N. F., Sari, Y., & Khatimi, H. (2021). Klasifikasi Kualitas Kayu Kelapa Menggunakan Arsitektur CNN. *KLIK*, 49-51.
- Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). Implementasi Deep Learning Menggunakan Convolution Neural Network (CNN) Pada Ekspresi Manusia. *Jurnal Algor*, 12-15.
- Pangestu, R. A., Rahmat, B., & Anggraeny, F. T. (2020). IMPLEMENTASI ALGORITMA CNN UNTUK KLASIFIKASI CITRA. *JISoSI*, 166-174.

- Prasetyo, R. R. (2021). PERBANDINGAN METODE DEEP RESIDUAL NETWORK 50 DAN DEEP RESIDUAL NETWORK 152 UNTUK DETEKSI PENYAKIT PNEUMONIA PADA MANUSIA. *ITENAS LIBRARY*, 1-57.
- Salsabilla, R., Andari, M. Y., & Nasrul, M. (2021). KARAKTERISTIK KATARAK KONGENITAL DI RSUD PROVINSI NTB PERIODE 2018-2019. *Jurnal Syntax Fusion*, 947-949.
- Syurfi, I. (2021). PENERAPAN DEEP LEARNING DENGAN CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI CITRA DIABETIC DENGAN ARSITEKTUR EFFICIENTNET-B7. *UIN Suska Riau*, 6-45.
- Tan, M., & Le, Q. V. (2020). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *ICML*, 10691–10700.
- Vujović, Z. (2021). Classification Model Evaluation Metrics. *International Journal of Advanced Computer Science and Applications*, 599-606.
- Wahyu, S. A. (2015). hubungan tingkat pengetahuan tentang perioperatif katarak dengan tingkat kecemasan pada klien pre operasi katarak di RSD dr. Soebandi Jember. *Digital Respository Univ Jember*, 1-91.
- Yu, T., & Zhu, H. (2022). Hyper-Parameter Optimization: A Review of Algorithms. 1-43.