

## Diagnosis Dini Penyakit Mata: Klasifikasi Citra Fundus Retina dengan Convolutional Neural Network VGG-16

Chana Amelinda Putri <sup>1,\*</sup>, Sindhu Rakasiwi <sup>1</sup>

<sup>1</sup> Program Studi Teknik Informatika, Universitas Dian Nuswantoro, Indonesia

\* Correspondence: 111202113296@mhs.dinus.ac.id

**Copyright:** © 2025 by the authors

Received: 13 Februari 2025 | Revised: 27 Februari 2025 | Accepted: 28 Maret 2025 | Published: 16 April 2025

### Abstrak

Klasifikasi penyakit mata berbasis citra fundus retina penting untuk mendukung diagnosis dini gangguan penglihatan seperti katarak, glaukoma, dan retinopati diabetik. Penelitian ini bertujuan untuk mendiagnosis dini penyakit mata dengan klasifikasi citra fundus retina menggunakan *Convolutional Neural Network* VGG-16. Model dikembangkan untuk mendeteksi katarak, glaukoma, dan retinopati diabetik guna mendukung diagnosis dini. Dataset yang digunakan berasal dari Kaggle, mencakup 4.217 citra fundus retina yang terdiri dari 1.038 citra katarak, 1.007 glaukoma, 1.098 retinopati diabetik, dan 1.074 normal. Citra diproses melalui normalisasi, augmentasi, dan *resizing* ke 224×224 piksel, dengan pembagian dataset dalam rasio 80:10:10 untuk pelatihan, validasi, dan pengujian. Hasil menunjukkan bahwa model VGG-16 dengan *transfer learning* mencapai akurasi 88%, meningkat 13% dari sebelumnya 75% pada model CNN tanpa *transfer learning*. Model ini berpotensi diintegrasikan dalam sistem pendukung keputusan klinis atau aplikasi *mobile* untuk meningkatkan kecepatan dan akurasi diagnosis. Keterbatasan penelitian mencakup ukuran dataset yang terbatas dan potensi bias data yang dapat mempengaruhi akurasi model dalam mendeteksi penyakit mata secara dini, sehingga penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih besar dan lebih beragam, serta mengeksplorasi arsitektur *deep learning* lainnya guna meningkatkan kinerja klasifikasi.

**Kata kunci:** citra fundus retina; cnn; klasifikasi penyakit mata; vgg-16

### Abstract

*Retinal fundus image-based eye disease classification is important to support early diagnosis of vision disorders such as cataracts, glaucoma, and diabetic retinopathy. This study aims to diagnose early eye diseases with retinal fundus image classification using Convolutional Neural Network VGG-16. The model was developed to detect cataract, glaucoma and diabetic retinopathy to support early diagnosis. The dataset used comes from Kaggle, including 4,217 retinal fundus images consisting of 1,038 cataract, 1,007 glaucoma, 1,098 diabetic retinopathy, and 1,074 normal images. The images were processed through normalization, augmentation, and resizing to 224×224 pixels, with the dataset divided in a ratio of 80:10:10 for training, validation, and testing. Results showed that the VGG-16 model with transfer learning achieved 88% accuracy, a 10% increase from the previous 75% in the CNN model without transfer learning. This model has the potential to be integrated in clinical decision support systems or mobile applications to improve the speed and accuracy of diagnosis. Limitations of the study include the limited dataset size and potential data bias that may affect the accuracy of the model in detecting eye diseases early, so future research is recommended to use larger and more diverse datasets, as well as explore other deep learning architectures to improve classification performance.*

**Keywords:** retinal fundus image; cnn; eye disease classification; vgg-16



## PENDAHULUAN

Mata merupakan organ tubuh yang sangat penting sebagai indra utama dalam menerima informasi visual. Seperti organ lainnya, mata berisiko terkena berbagai penyakit akibat faktor internal maupun eksternal. WHO melaporkan bahwa 2,2 miliar orang mengalami gangguan penglihatan, dengan 1 miliar kasus yang sebenarnya dapat dicegah (Qulub et al., 2024). Di Indonesia, terdapat 2.338 dokter spesialis mata dengan rasio pelayanan 1:155.618 yang belum merata (William et al., 2022). Secara fisik, penyakit mata dapat dikenali dari mata merah, perubahan warna kornea, sakit kepala, penglihatan berpelangi, dan mata berair (Marcella et al., 2022). Beberapa penyakit mata, seperti *cataract*, *glaucoma*, dan *diabetic retinopathy*, dapat menyebabkan kebutaan permanen jika tidak dideteksi dini (Verdy et al., 2024). Identifikasi penyakit mata dilakukan dengan meninjau riwayat keluarga, pemeriksaan fisik, dan analisis citra fundus melalui *oftalmoskop* (Andreas et al., 2023). Citra fundus adalah representasi 2D dari jaringan retina 3D yang diperoleh dengan mikroskop berdaya rendah, bersifat non-invasif, dan berbiaya relatif terjangkau (Muhlashin et al., 2023; Indraswari et al., 2022).

Kemajuan teknologi medis semakin mendorong penggunaan citra medis dalam diagnosis dini dan pengambilan keputusan klinis (Shidik et al., 2024). Salah satu teknologi yang berkembang pesat adalah *deep learning*, khususnya *Convolutional Neural Network* (CNN), yang meniru sistem pengenalan visual manusia untuk mengolah citra secara efisien. CNN dikembangkan untuk klasifikasi citra fundus retina guna membantu dokter menganalisis penyakit mata lebih akurat dan cepat. CNN memproses data bertopologi *grid*, terdiri dari neuron 3D dengan dimensi lebar, tinggi, dan kedalaman (Nurhamzah et al., 2024; Firdaus et al., 2022).

Keunggulan utama CNN adalah ekstraksi fitur otomatis tanpa metode tambahan, sehingga efektif membedakan citra dengan karakteristik serupa (Pamungkas et al., 2024; Septipalan et al., 2024). Dalam penelitian (Rozaqi et al., 2021), CNN terbukti mampu mendeteksi lebih dari 26 jenis penyakit pada tanaman dengan akurasi >90%. Model CNN juga diterapkan untuk deteksi cacar monyet dengan akurasi 81% (Triginandri et al., 2024) dan kanker payudara menggunakan *DenseNet* dengan akurasi 92% (Mas'ud et al., 2024). Potensi ini juga dapat diterapkan dalam bidang kesehatan, seperti dalam klasifikasi citra fundus retina untuk mengidentifikasi penyakit mata (Iswantoro et al., 2022). Namun, salah satu tantangan dalam pelatihan model CNN adalah kebutuhan akan kumpulan data yang besar, sedangkan data medis sering kali terbatas (Fadlun et al., 2024). Meskipun CNN membutuhkan dataset yang besar untuk mencapai performa optimal, teknologi ini tetap menjadi pilihan utama dalam klasifikasi citra medis karena kemampuannya dalam mengekstraksi fitur secara otomatis tanpa memerlukan teknik ekstraksi manual. Selain itu, keterbatasan jumlah data medis dapat diatasi dengan metode seperti *transfer learning*, yang memungkinkan model memanfaatkan fitur dari dataset besar yang telah dilatih sebelumnya, serta augmentasi data untuk meningkatkan variasi sampel pelatihan. Dengan strategi ini, CNN tetap menjadi pendekatan yang efektif dalam analisis citra fundus retina.

Penelitian sebelumnya menggunakan CNN dengan akurasi 75,27%, namun memiliki keterbatasan dalam mengenali pola kompleks, tidak menerapkan *transfer learning*, dan kurang mendalam dalam evaluasi model (Jatmoko et al., 2024). Pada penelitian kami ini, ingin mengatasi hal tersebut dengan menggunakan VGG-16, *transfer learning*, augmentasi data, serta evaluasi yang lebih komprehensif, sehingga meningkatkan akurasi hingga 88% dan memperkuat potensi implementasi dalam sistem diagnosis berbasis kecerdasan buatan. Keunggulan utama VGG-16 terletak pada penggunaan lapisan konvolusi berukuran kecil (3x3), yang memungkinkan model untuk menangkap pola yang lebih kompleks dalam citra fundus retina tanpa meningkatkan jumlah parameter secara signifikan (Agustina et al., 2022).


Penelitian kami ini bertujuan untuk mendiagnosis dini penyakit mata dengan klasifikasi citra fundus retina menggunakan CNN VGG-16. Arsitektur ini dipilih karena kemampuannya

dalam mengekstraksi fitur yang lebih dalam, memungkinkan model untuk mengenali pola pada citra fundus retina dengan lebih akurat. Dengan pendekatan ini, penelitian diharapkan dapat memberikan kontribusi dalam pengembangan sistem berbasis kecerdasan buatan untuk mendukung diagnosis dini penyakit mata secara lebih efektif.

## METODE

Penelitian ini mengembangkan model klasifikasi penyakit mata berbasis CNN dengan arsitektur VGG-16 untuk deteksi dini pada citra fundus retina. Tahapan penelitian mencakup pengumpulan data, *preprocessing* data, pembagian dataset, perancangan arsitektur CNN, pelatihan model, hingga evaluasi model. Dataset yang digunakan bersumber dari Kaggle (<https://www.kaggle.com/datasets/gunavenkatdoddi/eye-diseases-classification>) yaitu *Eye Diseases Classification*, mencakup 4.217 citra fundus retina yang dikategorikan ke dalam empat kelas: *Cataract*, *Diabetic Retinopathy*, *Glaucoma*, dan *Normal*. *Preprocessing* dilakukan dengan konversi format citra, pemfilteran ekstensi, *resizing* ke 224×224 piksel, serta augmentasi menggunakan *ImageDataGenerator* seperti *rescaling*, *rotation*, *zooming*, dan *flipping* horizontal untuk meningkatkan kualitas dan variasi data. Setelah *preprocessing*, dataset dibagi menjadi 80% untuk pelatihan dan 20% untuk pengujian, tanpa validasi tambahan seperti *cross-validation*.

Model CNN dirancang menggunakan VGG-16 dengan *layer* awal dibekukan (*freeze*) untuk mempertahankan fitur dari *ImageNet*, sementara 10 *layer* terakhir dilatih ulang (*fine-tuning*). Modifikasi dilakukan dengan *Global Average Pooling*, *Dense layer* 128 unit ReLU, dan *Dropout* 0.3 sebelum *output softmax* untuk mencegah *overfitting*. Model dilatih dengan *batch size* 32, *epoch* 50, *optimizer* Adam (*learning rate* 0.0001), serta *loss function* *sparse\_categorical\_crossentropy*. Evaluasi model menggunakan *accuracy*, *precision*, *recall*, *F1-score*, serta *confusion matrix* untuk mengukur performa klasifikasi. Seluruh eksperimen dilakukan dengan Python, TensorFlow/Keras, dan T4 GPU dari Google Colab untuk efisiensi komputasi.



**Gambar 1.** Arsitektur CNN

Arsitektur dasar CNN terdiri dari berbagai lapisan yang berfungsi untuk memproses dan mengekstraksi fitur dari data input. Tiga lapisan utama dalam CNN meliputi *convolutional layer*, *pooling layer*, dan *fully connected layer*. *Convolutional layer* berfungsi mengekstraksi fitur yang diberikan pada persamaan (1), *pooling layer* mereduksi ukuran, dan *fully connected layer* melakukan klasifikasi yang diberikan pada persamaan (2).

$$(Z * P)(o, q) = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} Z(o + i, q + j) * P(i, j) \quad (1)$$

### Keterangan:


$(o + i, q + j)$  : Matriks input atau fitur map dari lapisan sebelumnya

$(i, j)$  : Kernel atau filter yang digunakan untuk ekstraksi fitur  
 $o, q$  : Koordinat posisi piksel dalam *output* fitur map  
 $N, M$  : Ukuran kernel filter dalam arah vertikal dan horizontal

$$X_q = \sum_{o=1}^N (W_{o,q} * Actv_o) + B_q \quad (2)$$

**Keterangan:**

$X_q$  : Output dari *fully connected layer* pada unit ke- $q$   
 $W_{o,q}$  : Bobot yang menghubungkan neuron ke- $o$  dengan neuron ke- $q$   
 $Actv_o$  : Aktivasi dari neuron ke- $o$  pada lapisan sebelumnya  
 $B_q$  : Bias yang ditambahkan ke *output* neuron ke- $q$   
 $\Sigma$  : Operasi penjumlahan untuk mengakumulasi kontribusi dari semua neuron sebelumnya




**Gambar 2.** Arsitektur VGG-16

Arsitektur VGG-16 pada gambar 2 memiliki 16 lapisan, termasuk *convolutional*, *max-pooling*, dan *fully connected layers*. VGG-16 dipilih karena struktur yang sederhana namun mendalam, serta kinerjanya yang baik dalam klasifikasi citra. Model ini mengekstrak fitur citra fundus retina, diklasifikasikan dengan *softmax*, serta mendukung *transfer learning* untuk meningkatkan akurasi, mempercepat pelatihan, dan efisiensi diagnosis dini penyakit mata.


## HASIL DAN PEMBAHASAN

### Hasil

Hasil analisis model CNN menggunakan arsitektur VGG-16, dirancang untuk menerima *input* gambar dengan resolusi  $224 \times 224$  piksel yang terdiri dari tiga kanal warna RGB. Dataset yang digunakan dalam proses pelatihan diperoleh dari situs Kaggle dalam format JPG, dengan total 4.217 citra fundus retina yang dikategorikan ke dalam empat jenis penyakit mata, yaitu *Glaucoma*, *Diabetic Retinopathy*, *Cataract*, dan *Normal*. Untuk memastikan model dapat belajar dengan optimal, dataset citra fundus retina dibagi dengan perbandingan 80:20, di mana 80% gambar digunakan untuk pelatihan (*training*) dan 20% sisanya untuk pengujian (*testing*). Pembagian ini bertujuan agar model dapat mengenali pola pada data pelatihan dengan baik dan dapat diuji kemampuannya dalam mengklasifikasikan gambar yang belum pernah dilihat sebelumnya. Pada gambar 3 ditampilkan contoh citra fundus retina yang terdapat dalam folder *training*, sedangkan gambar 4 menampilkan contoh citra fundus retina yang digunakan dalam folder *testing*. Kedua gambar ini memberikan ilustrasi visual mengenai bagaimana dataset dibagi dan digunakan dalam proses pelatihan serta pengujian model.




**Gambar 3.** Gambar di folder *training*



**Gambar 4.** Gambar di folder *testing*


Data dibagi menjadi data pelatihan untuk melatih model dan data validasi untuk menguji kinerjanya. Pelatihan berlangsung selama 50 *epoch* dengan *batch size* 32 dan *learning rate* 0,0001, yang dipilih berdasarkan eksperimen *tuning* guna menjaga kestabilan dan memastikan konvergensi optimal. *Optimizer* Adam (*Adaptive Moment Estimation*) diterapkan untuk mempercepat proses pembaruan bobot, sementara *ImageDataGenerator* digunakan agar pemrosesan lebih efisien selama pelatihan dan validasi. Pada tahap pelatihan, lapisan awal VGG-16 dibekukan untuk mempertahankan bobot *pretrained*, sedangkan lapisan akhir dilatih agar lebih sesuai dengan dataset. *Fine-tuning* diterapkan dengan mengaktifkan kembali beberapa lapisan akhir guna meningkatkan generalisasi model. Untuk mencegah *overfitting*, digunakan *Dropout* 30%, yang terbukti efektif dalam mengurangi ketergantungan model terhadap pola tertentu dalam data pelatihan. Selain itu, *callback ReduceLROnPlateau* diterapkan untuk menyesuaikan *learning rate* secara dinamis berdasarkan perubahan *loss* pada data validasi. Hal ini membantu stabilisasi pelatihan setelah *epoch* ke-30, yang terlihat dari grafik akurasi dan *loss* yang menunjukkan tren konvergen serta minimnya fluktuasi yang tajam setelah tahap tersebut.



**Gambar 5.** Model *accuracy* & model *loss*

Gambar 5 menunjukkan hasil akurasi dan *loss* model selama proses pelatihan. Pada grafik akurasi, terlihat bahwa model mengalami peningkatan akurasi yang signifikan pada

tahap awal pelatihan dan mencapai stabilitas setelah beberapa *epoch*. Akurasi pelatihan mencapai 95,71%, sementara akurasi validasi stabil pada 88,37%, dengan tanda-tanda konvergensi mulai terlihat setelah *epoch* ke-40. Grafik *loss* menunjukkan tren penurunan yang signifikan pada awal pelatihan, yang kemudian melambat dan mencapai kestabilan setelah *epoch* ke-35, mengindikasikan bahwa model mampu melakukan generalisasi dengan baik terhadap data validasi. Tidak terdapat kesenjangan yang signifikan antara kurva akurasi dan *loss* pada data pelatihan serta validasi, meskipun sedikit indikasi *overfitting* mulai muncul setelah *epoch* ke-45. Hasil ini menjadi bukti bahwa model telah terlatih dengan baik, mampu menangkap pola dari data pelatihan, dan dapat memprediksi data validasi secara akurat.



**Gambar 6.** Confusion matrix

Gambar 6 menunjukkan *confusion matrix* yang menggambarkan distribusi prediksi model terhadap kelas sebenarnya dalam tugas klasifikasi citra fundus retina. Matriks ini menampilkan jumlah sampel yang diklasifikasikan dengan benar maupun yang salah klasifikasi untuk setiap kelas. Pada tahap evaluasi model, sebanyak 808 citra fundus retina yang terbagi ke dalam empat kelas penyakit berhasil dievaluasi dan divisualisasikan dalam *confusion matrix*. Model menunjukkan performa tinggi dalam mengenali kelas *diabetic retinopathy*, dengan 191 sampel diklasifikasikan dengan benar dan hanya sedikit kesalahan klasifikasi. Namun, beberapa kesalahan terjadi, terutama pada kelas *glaucoma*, di mana 39 sampel salah diklasifikasikan sebagai *normal*, yang mengindikasikan kesulitan model dalam membedakan karakteristik visual antara kedua kelas tersebut. Dalam praktik klinis, kesalahan ini dapat menjadi permasalahan serius karena pasien *glaucoma* yang salah diklasifikasikan sebagai *normal* berisiko tidak mendapatkan diagnosis dini yang tepat.

Selain itu, terdapat kesalahan pada kelas *cataract*, di mana 14 sampel diklasifikasikan sebagai *normal*, yang juga berpotensi menyebabkan keterlambatan dalam intervensi medis jika diterapkan dalam lingkungan klinis. Keterbatasan dari evaluasi model ini mencakup potensi bias dari dataset yang digunakan. Dataset mungkin tidak mencerminkan variasi klinis secara menyeluruh, seperti variasi pencahayaan, kualitas gambar, dan tingkat keparahan penyakit yang berbeda-beda. Selain itu, jumlah data pengujian yang digunakan (808 citra) dapat menjadi faktor yang mempengaruhi keakuratan generalisasi model. Dengan dataset yang lebih besar dan lebih bervariasi, performa model mungkin dapat lebih ditingkatkan agar lebih *robust* terhadap berbagai kondisi klinis.

Tabel 1 menunjukkan hasil laporan klasifikasi yang mencakup metrik *precision*, *recall*, dan *f1-score*. Berdasarkan hasil evaluasi, kelas *cataract* mencapai *precision* sebesar 0,95, *recall* sebesar 0,89, dan *f1-score* sebesar 0,92 yang menunjukkan performa yang cukup baik. Kelas *diabetic retinopathy* memiliki performa terbaik dengan *precision* 0,97 dan *f1-score* tertinggi sebesar 0,96 yang mengindikasikan bahwa model mampu mengenali karakteristik



visual penyakit ini dengan baik. Sementara itu, kelas *glaucoma* memiliki *precision* sebesar 0,90, tetapi dengan *recall* yang lebih rendah, yaitu 0,76. Rendahnya *recall* ini menunjukkan bahwa model masih mengalami kesulitan dalam mendeteksi beberapa kasus *glaucoma*, yang kemungkinan disebabkan oleh kemiripan karakteristik visual antara *glaucoma* dan *normal*, terutama pada tahap awal penyakit. Kelas *normal* memiliki *precision* terendah dibandingkan kelas lainnya, yakni sebesar 0,75, dengan *f1-score* sebesar 0,84 yang menunjukkan bahwa beberapa sampel *normal* diklasifikasikan sebagai kelas penyakit. Secara keseluruhan, model berhasil mencapai akurasi sebesar 88% (0,88), yang mencerminkan stabilitas dan kemampuannya dalam mengklasifikasikan citra fundus retina. Selain itu, hasil ini juga menunjukkan keberhasilan model dalam klasifikasi, tetapi juga mengindikasikan perlunya peningkatan dalam membedakan *glaucoma* dari kelas *normal* guna mengurangi kesalahan deteksi pada kondisi klinis yang krusial.

**Tabel 1.** *Confusion matrix* hasil prediksi

| <i>Class</i>                | <i>Precision</i> | <i>Recall</i> | <i>F1-Score</i> | <i>Support</i> |
|-----------------------------|------------------|---------------|-----------------|----------------|
| <i>Cataract</i>             | 0,95             | 0,89          | 0,92            | 202            |
| <i>Diabetic Retinopathy</i> | 0,97             | 0,95          | 0,96            | 202            |
| <i>Glaucoma</i>             | 0,90             | 0,76          | 0,83            | 202            |
| <i>Normal</i>               | 0,75             | 0,94          | 0,84            | 202            |
| <i>Accuracy</i>             |                  |               | 0,88            | 808            |

## Pembahasan

Pendekatan CNN dasar memiliki keterbatasan dalam mengekstraksi fitur kompleks pada citra fundus retina yang dapat menyebabkan penurunan akurasi dalam klasifikasi penyakit mata. Jatmoko et al. (2024) menunjukkan bahwa model CNN tanpa *transfer learning* memiliki akurasi sebesar 75% yang kemungkinan disebabkan oleh keterbatasan arsitektur dalam menangkap fitur penting, terutama pada kelas dengan perbedaan visual yang halus. Selain itu, jumlah data pelatihan yang relatif sedikit serta kurang optimalnya teknik augmentasi turut berkontribusi terhadap performa yang kurang maksimal. Untuk meningkatkan akurasi, penelitian ini menerapkan VGG-16 dengan *transfer learning* yang memungkinkan model memanfaatkan fitur yang telah dipelajari dari dataset besar.

Hasil eksperimen menunjukkan bahwa VGG-16 dengan *transfer learning* mencapai akurasi 88%, meningkat 13% dibandingkan model CNN dasar. Pendekatan ini memungkinkan model memanfaatkan fitur yang telah dipelajari dari dataset besar, sehingga meningkatkan akurasi klasifikasi dibandingkan model CNN dasar. Dengan arsitektur yang lebih dalam, VGG-16 mampu mengekstraksi fitur lebih kompleks dan meningkatkan generalisasi model. Meskipun demikian, masih terdapat tantangan dalam membedakan kelas dengan perbedaan visual yang halus, seperti antara *glaucoma* dan *normal* yang menyebabkan rendahnya *recall* pada kelas *glaucoma*.

Qulub et al. (2024) mengembangkan model klasifikasi penyakit mata menggunakan VGG-16 tanpa *transfer learning* dan memperoleh akurasi 45%. Rendahnya akurasi ini kemungkinan besar disebabkan oleh ketidakseimbangan dataset dan kurang optimalnya strategi augmentasi. Sementara William et al. (2022) menerapkan augmentasi dataset secara ekstensif menggunakan VGG-16 tanpa *transfer learning* dan mencapai akurasi 91%. Model yang mereka kembangkan tidak menggunakan *transfer learning*, sehingga membutuhkan lebih banyak data untuk mencapai hasil yang optimal. Penelitian ini menggunakan *transfer learning* dan *fine-tuning* untuk mengatasi permasalahan tersebut, dengan evaluasi model yang lebih komprehensif. Kombinasi metode dari penelitian sebelumnya, seperti augmentasi dataset yang lebih optimal, dapat diterapkan dalam penelitian mendatang guna meningkatkan kinerja model dengan mempertimbangkan lebih banyak kategori penyakit dan dataset yang lebih besar.

Hasil penelitian kami menunjukkan bahwa klasifikasi penyakit mata berbasis citra fundus retina dapat terus dikembangkan dengan arsitektur *deep learning* yang lebih mutakhir, seperti *ResNet* dan *EfficientNet* yang berpotensi memberikan akurasi lebih tinggi. Selain itu, model yang dikembangkan memiliki potensi untuk diintegrasikan ke dalam sistem diagnostik berbasis aplikasi atau perangkat *mobile*, sehingga dapat membantu tenaga medis dalam mendeteksi penyakit mata dengan lebih cepat dan akurat. Implementasi ini berpotensi mengurangi kesalahan interpretasi serta mempercepat pengambilan keputusan medis, yang pada akhirnya dapat meningkatkan kualitas layanan kesehatan. Sebagai langkah penelitian selanjutnya, disarankan untuk mengeksplorasi *fine-tuning* lebih lanjut, menerapkan optimisasi *hyperparameter* otomatis, serta menggunakan dataset yang lebih besar dan beragam untuk meningkatkan *robustness* model. Selain itu, pengembangan model berbasis multimodal, yang menggabungkan informasi klinis dengan citra fundus retina, dapat menjadi arah penelitian yang menjanjikan dalam meningkatkan akurasi diagnosis penyakit mata.

## SIMPULAN

Penelitian ini menunjukkan bahwa penggunaan CNN dengan arsitektur VGG-16 dan *transfer learning* dapat meningkatkan akurasi klasifikasi penyakit mata berbasis citra fundus retina hingga 88%, lebih tinggi dibandingkan model CNN tanpa *transfer learning* yang hanya mencapai 75%. Hasil ini membuktikan bahwa *transfer learning* efektif dalam meningkatkan akurasi dan efisiensi komputasi, terutama dalam menangkap fitur kompleks pada citra fundus retina. Model ini berpotensi diterapkan dalam sistem diagnosis berbasis kecerdasan buatan untuk membantu tenaga medis mendeteksi penyakit mata dengan lebih cepat dan akurat, serta dapat diintegrasikan ke dalam aplikasi *mobile* guna memperluas akses layanan kesehatan. Penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih besar dan beragam, mengeksplorasi arsitektur *deep learning* lainnya, serta menerapkan optimisasi *hyperparameter* untuk meningkatkan performa klasifikasi penyakit mata.

## REFERENSI

- Agustina, R., Magdalena, R., & Pratiwi, N. K. C. (2022). Klasifikasi Kanker Kulit menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 10(2), 446-457. <https://doi.org/10.26760/elkomika.v10i2.446>
- Andreas, E., & Widhiarso, W. (2023). Klasifikasi Penyakit Mata Katarak menggunakan Convolutional Neural Network dengan Arsitektur Inception V3. *MDP Student Conference*, 2(1), 107–113. <https://doi.org/10.35957/mdp-sc.v2i1.3660>
- Cahya, F. N., Hardi, N., Riana, D., & Hadiani, S. (2021). Klasifikasi Penyakit Mata menggunakan Convolutional Neural Network (CNN). *SISTEMASI: Jurnal Sistem Informasi*, 10(3), 618-626. <https://doi.org/10.32520/stmsi.v10i3.1248>
- Fadlun, M. H., Martanto, M., & Hayati, U. (2024). Klasifikasi Tumor Otak menggunakan Convolutional Neural Network dan Transfer Learning. *Jurnal Informatika dan Rekayasa Perangkat Lunak*, 6(1), 289-295.
- Firdaus, R., Satria, J., & Baidarus, B. (2022). Klasifikasi Jenis Kelamin berdasarkan Gambar Mata menggunakan Algoritma Convolutional Neural Network (CNN). *Jurnal CoSciTech (Computer Science and Information Technology)*, 3(3), 267-273. <https://doi.org/10.37859/coscitech.v3i3.4360>
- Indraswari, R., Herulambang, W., & Rokhana, R. (2022). Deteksi Penyakit Mata pada Citra Fundus menggunakan Convolutional Neural Network (CNN). *Techno.Com*, 21(2), 378-389. <https://doi.org/10.33633/tc.v21i2.6162>
- Iswantoro, D., & Handayani, D. U. (2022). Klasifikasi Penyakit Tanaman Jagung menggunakan Metode Convolutional Neural Network (CNN). *Jurnal Ilmiah Universitas*



- Batanghari Jambi, 22(2), 900-905. <https://doi.org/10.33087/jiubj.v22i2.2065>
- Jatmoko, C., & Lestiawan, H. (2024). Prediksi Penyakit Mata menggunakan Convolutional Neural Network. *Semnas Ristek (Seminar Nasional Riset dan Inovasi Teknologi)*, 8(1), 34-38. <https://doi.org/10.30998/semnasristek.v8i01.7129>
- Marcella, D., Yohannes, Y., & Devella, S. (2022). Klasifikasi Penyakit Mata menggunakan Convolutional Neural Network dengan Arsitektur VGG-19. *Jurnal Algoritme*, 3(1), 60–70. <https://doi.org/10.35957/algoritme.v3i1.3331>
- Mas'ud, R. A., & Zeniarja, J. (2024). Optimasi Convolutional Neural Networks untuk Deteksi Kanker Payudara menggunakan Arsitektur DenseNet. *Edumatic: Jurnal Pendidikan Informatika*, 8(1), 310-318. <https://doi.org/10.29408/edumatic.v8i1.25883>
- Muhlashin, M. N. I., & Stefanie, A. (2023). Klasifikasi Penyakit Mata berdasarkan Citra Fundus menggunakan YOLO V8. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(2), 1363–1368. <https://doi.org/10.36040/jati.v7i2.6927>
- NurHamzah, D., Sariyanto, I. W., Suwirmayanti, N. L. G. P., & Indrianto. (2024). Identifikasi Pneumonia pada Citra Rontgen Paru-paru menggunakan Convolutional Neural Network. *Seminar Nasional Sistem Informasi dan Teknologi (SPINTER)*, 1(3), 72–77. Denpasar, Indonesia: STIKOM Bali.
- Pamungkas, N. B., & Suhendar, A. (2024). Penerapan Metode Convolutional Neural Network pada Sistem Klasifikasi Penyakit Tanaman Apel berdasarkan Citra Daun. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 675–684. <https://doi.org/10.29408/edumatic.v8i2.27958>
- Qulub, M. S., & Agustin, S. (2024). Identifikasi Penyakit Mata dengan Klasifikasi Citra Foto Fundus menggunakan Convolutional Neural Network (CNN). *JATI (Jurnal Aplikasi Teknik dan Inovasi)*, 8(5), 11034–11039. <https://doi.org/10.36040/jati.v8i5.10974>
- Rozaqi, A. J., Sunyoto, A., & Arief, R. (2021). Deteksi Penyakit pada Daun Kentang menggunakan Pengolahan Citra dengan Metode Convolutional Neural Network. *Creative Information Technology Journal*, 8(1), 22-31. <https://doi.org/10.24076/citec.2021v8i1.263>
- Septipalan, M. L., Hibrizi, M. S., Latifah, N., Rosalina, & Bimantoro, F. (2024). Klasifikasi Tumor Otak menggunakan CNN dengan Arsitektur ResNet50. *Seminar Nasional Teknologi & Sains*, 3(1), 103–108. <https://doi.org/10.29407/stains.v3i1.4357>
- Shidik, F. A., Musthofa, K., Kartiningtyas, A. P., & Agustin, T. (2024). Analisis Citra Medis untuk Identifikasi Penyakit Mata dengan Teknologi Convolutional Neural Networks. *Seminar Nasional AMIKOM Surakarta (SEMNAS)*, 68–80. Surakarta, Indonesia: Semnasa.
- Triginandri, R., & Subhiyakto, E. R. (2024). Deteksi Dini Cacar Monyet menggunakan Convolutional Neural Network (CNN) dalam Aplikasi Mobile. *Edumatic: Jurnal Pendidikan Informatika*, 8(2), 516-525. <https://doi.org/10.29408/edumatic.v8i2.27625>
- Verdy, & Hartati, E. (2024). Klasifikasi Penyakit Mata menggunakan Convolutional Neural Network Model ResNet-50. *Jurnal Rekayasa Sistem Informasi dan Teknologi*, 1(3), 199–206. <https://doi.org/10.59407/jrsit.v1i3.529>
- William, W., & Lubis, C. (2022). Klasifikasi Penyakit Mata menggunakan CNN. *Jurnal Ilmu Komputer dan Sistem Informasi*, 10(1), 1–4. <https://doi.org/10.24912/jiksi.v10i1.17834>