

# Analisis Pengaruh Fine-Tuning pada Model ResNet-50 untuk Deteksi Multikategori Penyakit Mata Berdasarkan Citra Fundus Retina

<sup>1</sup>Adil Setiawan, <sup>2</sup>Agus fs ndruru, <sup>3</sup>Rika Rosnelly, <sup>4</sup>Andreas Rezeki Zai  
<sup>1,2,3,4</sup>Universitas Potensi Utama  
Medan, Indonesia

<sup>1</sup>adio165@gmail.com, <sup>2</sup>agusndruru1999@gmail.com, <sup>3</sup>rikarosnelly@gmail.com,  
<sup>4</sup>andreasrezekizai@gmail.com

## \*Penulis Korespondensi

Diajukan : 16/07/2025  
Diterima : 17/03/2026  
Dipublikasi : 17/03/2026

## ABSTRAK

Penelitian ini bertujuan menganalisis pengaruh fine-tuning pada model *ResNet-50* terhadap kinerja deteksi multikategori penyakit mata berbasis citra fundus retina. Populasi penelitian menggunakan *Eye Disease Image Dataset* dari Kaggle dengan teknik total sampling, melibatkan 5.335 citra asli dan 16.242 citra hasil augmentasi. Data diproses melalui tahap preprocessing dengan *Contrast Limited Adaptive Histogram Equalization (CLAHE)*, augmentasi data, normalisasi, serta penanganan ketidakseimbangan kelas menggunakan *class weighting*. Model dikembangkan menggunakan pendekatan *transfer learning* dengan arsitektur *ResNet-50* sebagai *feature extractor*, dilanjutkan dengan pelatihan baseline dan fine-tuning pada lapisan akhir *conv5\_block*. Evaluasi dilakukan menggunakan *Confusion Matrix*, *Classification Report*, dan *Top-K Accuracy*. Hasil penelitian menunjukkan model baseline memperoleh *Top-1 Accuracy* sebesar 60,28%, sedangkan model setelah fine-tuning meningkat menjadi 72,82%. *Top-2 Accuracy* dan *Top-3 Accuracy* juga mengalami kenaikan dari 79,01% menjadi 90,69% dan dari 89,37% menjadi 96,86%. Peningkatan ini membuktikan bahwa fine-tuning mampu meningkatkan kemampuan generalisasi model, terutama dalam mengenali variasi antar kelas, termasuk kelas minoritas. Dengan demikian, fine-tuning menjadi tahap krusial dalam pengembangan model deep learning berbasis *transfer learning* untuk klasifikasi citra medis multikategori, sekaligus berpotensi mendukung sistem pengambilan keputusan klinis berbasis kecerdasan buatan di bidang oftalmologi.

**Kata Kunci:** *Fine-Tuning*, ResNet-50, *Transfer Learning*, Citra Fundus Retina, Klasifikasi Multikategori

## I. PENDAHULUAN

Kemampuan kecerdasan buatan (Artificial Intelligence/AI) untuk mempelajari pola kompleks dari data medis telah merevolusi pendekatan tradisional dalam diagnosis dan pengambilan keputusan klinis, terutama melalui penerapan metode deep learning dalam analisis citra medis. AI telah terbukti mampu meningkatkan efisiensi dan akurasi dalam diagnosis, klasifikasi penyakit, serta analisis data medis secara menyeluruh (S, 2023). Hal ini mendorong pemanfaatan AI, khususnya teknologi deep learning, dalam mendukung pengambilan keputusan klinis berbasis data.

Dalam dunia oftalmologi, *deep learning* telah membuka peluang besar dalam deteksi dan klasifikasi penyakit mata. (Jin & Ye, 2022) menunjukkan bahwa pendekatan ini memiliki kapabilitas tinggi dalam memproses citra fundus retina yang kompleks, serta meningkatkan ketepatan dan kecepatan diagnosis. Citra fundus retina menjadi media penting karena merepresentasikan kondisi bagian dalam mata, yang krusial dalam mengidentifikasi berbagai

penyakit mata.

(Sheng et al., 2022) mencatat bahwa penyakit seperti *diabetic retinopathy*, glaukoma, katarak, hingga *age-related macular degeneration* dapat dideteksi melalui analisis citra fundus retina. Model *convolutional neural network* (CNN) telah menjadi pendekatan dominan dalam menganalisis citra ini, karena kemampuannya mengenali pola visual secara otomatis tanpa memerlukan ekstraksi fitur manual.

Tidak hanya terbatas pada citra fundus, (Babenko et al., 2022) membuktikan bahwa CNN juga efektif dalam menganalisis citra eksternal mata. Hal ini memperkuat posisi CNN sebagai pendekatan andal dalam berbagai aplikasi citra medis, termasuk di oftalmologi.

Meski arsitektur baru seperti Vision Transformer (ViT) mulai banyak dieksplorasi, CNN seperti ResNet masih menunjukkan performa kompetitif dalam klasifikasi citra medis. (Hwang, Chen, Han, Jia, & Shan, 2023) menyatakan bahwa dalam berbagai eksperimen multi-dataset, ResNet, khususnya varian ResNet-50, tetap unggul dalam menganalisis citra fundus untuk diagnosis kelainan saraf optik.

(Fan et al., 2023) menegaskan bahwa ResNet-50 mampu bersaing dengan ViT dalam mendeteksi glaukoma. Dengan proses pelatihan dan pengolahan data yang optimal, model ini tetap menjadi pilihan utama dalam berbagai studi klasifikasi citra fundus retina.

Lebih lanjut, studi (Goutam, Hashmi, Geem, & Bokde, 2022) menyoroti pentingnya tahapan preprocessing, augmentasi data, dan transfer learning dalam mendukung kinerja model. Dalam hal ini, ResNet yang telah melalui proses *pretraining* di dataset besar seperti ImageNet menunjukkan performa yang menjanjikan saat digunakan di bidang medis.

Penelitian (Shoukat et al., 2023) memperlihatkan bahwa kombinasi transfer learning dan fine-tuning pada ResNet-50 mampu mendeteksi glaukoma secara dini dengan akurasi tinggi. Pendekatan fine-tuning memungkinkan model beradaptasi lebih baik terhadap karakteristik dataset target.

Studi dari domain lain pun mendukung efektivitas strategi ini. (Sahaai, Jothilakshmi, Ravikumar, Prasath, & Singh, 2022) berhasil mengimplementasikan ResNet-50 untuk klasifikasi tumor otak dengan akurasi tinggi berkat pendekatan transfer learning dan fine-tuning. Temuan serupa dilaporkan oleh (Kumar, Arora, Deb, & Yadav, 2024), yang menyatakan bahwa fine-tuning dapat meningkatkan performa model dalam klasifikasi, baik di bidang medis maupun non-medis.

Berdasarkan paparan tersebut, dapat disimpulkan bahwa penggunaan model CNN seperti ResNet-50 telah banyak diteliti dalam klasifikasi citra fundus retina. Namun, sebagian besar studi sebelumnya masih terbatas pada klasifikasi satu jenis penyakit, serta belum secara eksplisit menganalisis dampak penerapan fine-tuning terhadap performa model dalam deteksi multikategori penyakit mata.

Penelitian ini bertujuan untuk mengisi celah tersebut dengan menganalisis pengaruh fine-tuning pada model ResNet-50 dalam mendeteksi berbagai kategori penyakit mata berdasarkan citra fundus retina. Melalui pendekatan ini, diharapkan diperoleh pemahaman yang lebih komprehensif mengenai peran fine-tuning dalam meningkatkan performa model deep learning dalam klasifikasi multikategori citra medis, khususnya di bidang oftalmologi.

## II. STUDI LITERATUR

### Penelitian Terdahulu

Studi literatur ini mengkaji berbagai penelitian terdahulu yang relevan dengan penerapan *Convolutional Neural Network* (CNN), khususnya arsitektur ResNet-50, dalam klasifikasi dan deteksi penyakit berbasis citra medis. Fokus utama diarahkan pada strategi *transfer learning*, *fine-tuning*, segmentasi, serta klasifikasi multikategori pada citra fundus retina. Berikut adalah uraian detail lima belas jurnal yang menjadi dasar teoritis dari penelitian ini:

1. (Khan et al., 2022) mengusulkan metode klasifikasi penyakit mata berbasis CNN yang dirancang untuk mengatasi ketidakseimbangan kelas (*class imbalance*) dalam dataset citra fundus retina. Model dikembangkan menggunakan teknik penyeimbangan internal kelas dan berhasil mencapai akurasi sebesar 97,56%, sensitivitas 96,34%, serta

- spesifisitas 98,12%. Hasil ini menunjukkan bahwa penanganan ketidakseimbangan kelas merupakan faktor krusial dalam meningkatkan performa model klasifikasi citra medis.
- (Bohlol, Hosseinpour, & Soltani Firouz, 2025) memodifikasi arsitektur ResNet-50 dengan melakukan penyesuaian pada lapisan *fully connected* untuk meningkatkan akurasi klasifikasi multikategori pada citra makanan. Penelitian ini menerapkan *fine-tuning* menyeluruh serta penyesuaian struktur lapisan akhir jaringan. Hasil eksperimen menunjukkan peningkatan akurasi hingga 98,90%, membuktikan bahwa modifikasi arsitektur CNN dapat berkontribusi signifikan terhadap peningkatan kinerja model.
  - (Alghamdi & Abdel-Mottaleb, 2021) melakukan studi komparatif antara beberapa arsitektur CNN populer seperti VGG-16, Inception V3, dan ResNet-50 untuk diagnosis glaukoma menggunakan citra fundus. Dengan menerapkan *transfer learning* dan *fine-tuning*, ResNet-50 terbukti memiliki performa terbaik dengan akurasi 96,40%, memperkuat posisinya sebagai model yang andal untuk klasifikasi penyakit mata berbasis citra.
  - (Victor Ikechukwu, Murali, Deepu, & Shivamurthy, 2021) membandingkan model ResNet-50, VGG-19, dan Iyke-Net (CNN yang dilatih dari awal) untuk mendeteksi pneumonia dari citra X-ray. Dengan pendekatan *transfer learning* dan *fine-tuning*, ResNet-50 menunjukkan keunggulan dengan akurasi 96,20% dan *recall* 98,40%. Hal ini menegaskan bahwa model pretrained lebih unggul dalam kondisi data pelatihan yang terbatas.
  - (Tayal et al., 2022) mengembangkan pendekatan berbasis CNN untuk diagnosis empat jenis penyakit retina melalui citra OCT. Penelitian ini menggunakan jaringan CNN dengan 5, 7, dan 9 lapis yang dioptimalkan melalui preprocessing dan segmentasi. Model CNN 7-lapis menunjukkan performa terbaik dengan akurasi 96,54%, sensitivitas 96,30%, dan spesifisitas 98,00%, menunjukkan efektivitas arsitektur berlapis dalam klasifikasi penyakit retina.
  - (Veena, Muruganandham, & Senthil Kumaran, 2022) merancang dua model CNN khusus untuk segmentasi optic disc (OD) dan optic cup (OC) dalam rangka diagnosis glaukoma berbasis citra fundus. Dengan menggunakan dataset DRISHTI-GS, model segmentasi OD dan OC masing-masing mencapai akurasi 98% dan 97%. Hasil ini menegaskan bahwa segmentasi otomatis berbasis CNN memainkan peran penting dalam sistem diagnosis glaukoma berbasis citra.
  - (Muchuchuti & Viriri, 2023) menyajikan tinjauan literatur sistematis mengenai penerapan deep learning dalam deteksi penyakit retina. Mereka menekankan pentingnya preprocessing, augmentasi data, serta penggunaan *transfer learning*, khususnya pada model ResNet. ResNet-50 disebut secara eksplisit karena konsistensinya dalam menghasilkan performa tinggi serta kemampuannya mengekstraksi fitur penting dari citra fundus retina.
  - (Abbood et al., 2022) mengembangkan pendekatan *hybrid preprocessing* yang menggabungkan CLAHE dan *adaptive histogram equalization* sebelum tahap klasifikasi menggunakan CNN. Pendekatan ini ditujukan untuk meningkatkan kualitas citra retina dalam deteksi diabetic retinopathy. Hasilnya, akurasi model meningkat hingga 97,28%, memperlihatkan bahwa kualitas citra input memiliki dampak besar terhadap performa sistem klasifikasi.
  - (Heikal, El-Ghamry, Elmougy, & Rashad, 2024) meneliti pengaruh *fine-tuning* pada model ResNet-50 yang diterapkan untuk klasifikasi tumor payudara. Penyesuaian model terhadap dataset khusus dilakukan dengan mengatur parameter pelatihan secara tepat. Hasil eksperimen menunjukkan peningkatan akurasi dari baseline hingga 98,73%, menggarisbawahi peran penting *fine-tuning* dalam mengadaptasi model terhadap karakteristik data baru.
  - (Nazir et al., 2021) mengembangkan sistem deteksi diabetic eye disease berbasis CNN yang didukung dengan preprocessing, augmentasi data, dan *transfer learning* menggunakan ResNet-50. Model ini menunjukkan akurasi 97,34%, sensitivitas 96,90%, dan spesifisitas 97,80%, menunjukkan bahwa integrasi teknik preprocessing dan transfer

- learning mampu meningkatkan generalisasi dan kinerja klasifikasi.
11. (Kaibassova, Nurtay, Tau, & Kissina, 2022) memfokuskan penelitian pada *hyperparameter tuning* model CNN pretrained, termasuk ResNet-50, dalam konteks klasifikasi citra medis. Variabel yang diuji meliputi learning rate, batch size, dan jenis optimizer. Penyesuaian parameter tersebut meningkatkan akurasi model dari 90% menjadi 97%, membuktikan bahwa optimasi hiperparameter merupakan elemen penting dalam pengembangan model yang robust.
  12. (Mushtaq & Siddiqui, 2021) mengembangkan sistem klasifikasi diabetic retinopathy berbasis ResNet-50 dengan menerapkan teknik augmentasi data dan *fine-tuning*. Pendekatan ini berhasil meningkatkan akurasi hingga 96,78%, menegaskan bahwa kombinasi preprocessing dan adaptasi model dapat mengatasi variasi dan kompleksitas dalam dataset medis.
  13. (Indraswari, Herulambang, & Rokhana, 2022) melakukan penelitian deteksi penyakit mata multikategori dari citra fundus retina menggunakan CNN. Proses pelatihan model diawali dengan preprocessing dan augmentasi data untuk meningkatkan keberagaman sampel. Model yang dihasilkan mencapai akurasi 94,56%, memperlihatkan efektivitas CNN dalam klasifikasi citra medis meskipun tanpa menggunakan model pretrained.
  14. (Pan et al., 2023) membandingkan performa antara Inception V3 dan ResNet-50 dalam klasifikasi citra fundus retina. Dengan menerapkan *transfer learning* dan *fine-tuning*, ResNet-50 menghasilkan akurasi tertinggi sebesar 98,20%, dibandingkan Inception V3 yang hanya 96,50%. Temuan ini mendukung keunggulan ResNet-50 dalam mengidentifikasi fitur kompleks pada citra retina.
  15. (Saeed, Hussain, & Aboalsamh, 2021) mengembangkan metode diagnosis diabetic retinopathy otomatis dengan memanfaatkan arsitektur ResNet-50 yang di-*fine-tune* secara adaptif. Penelitian ini menggunakan kombinasi preprocessing, augmentasi, dan *adaptive fine-tuning*. Model yang dihasilkan mencapai akurasi 98,45% dengan nilai AUC sebesar 0,995, membuktikan bahwa strategi penyesuaian model secara dinamis mampu mengoptimalkan kinerja klasifikasi citra medis.

### III. METODE

Penelitian ini menggunakan metode eksperimen dengan pendekatan kuantitatif. Tahapan penelitian meliputi pengumpulan data, preprocessing data, pengolahan dan augmentasi data, pengembangan model deep learning menggunakan arsitektur ResNet-50, pelatihan model, evaluasi kinerja, serta fine-tuning model. Setiap tahap dilakukan secara sistematis untuk mengkaji pengaruh fine-tuning terhadap performa deteksi multikategori penyakit mata berdasarkan citra fundus retina.

#### Pengumpulan Data

Data penelitian ini diperoleh dari *Eye Disease Image Dataset* yang tersedia di platform Kaggle (<https://www.kaggle.com/datasets/abhinav099802/eye-disease-image-dataset>). Dataset ini berisi citra *fundus retina* yang telah dikategorikan ke dalam beberapa jenis penyakit mata, seperti *Retinitis Pigmentosa*, *Retinal Detachment*, *Pterygium*, *Myopia*, *Macular Scar*, *Glaucoma*, *Disc Edema*, *Diabetic Retinopathy*, *Central Serous Chorioretinopathy*, serta kategori mata normal. Data dikumpulkan oleh ahli medis dari Anwara Hamida Eye Hospital dan BNS Zahrul Haque Eye Hospital di Bangladesh, yang terdiri atas 5.335 citra asli dan 16.242 citra hasil *augmentasi*.

Proses pengumpulan data dilakukan secara daring menggunakan API *KaggleHub*, kemudian dilanjutkan dengan penggabungan antara dataset asli dan data hasil *augmentasi* ke dalam satu direktori utama. Struktur folder dataset disesuaikan agar kompatibel dengan alur pemrosesan *ImageDataGenerator* yang digunakan dalam tahap pelatihan model. Setelah proses penggabungan, dilakukan verifikasi jumlah citra pada masing-masing kelas serta visualisasi acak beberapa sampel gambar untuk memastikan integritas dan representativitas data sebelum memasuki tahap pelatihan model.

#### Preprocessing Data




Preprocessing data dalam penelitian ini bertujuan untuk meningkatkan kualitas citra dan menyiapkan data agar sesuai dengan kebutuhan pelatihan model deep learning. Beberapa tahapan preprocessing yang dilakukan meliputi:

### 1. Penggabungan Dataset

Penggabungan dataset dilakukan dengan mengintegrasikan *Original Dataset* dan *Augmented Dataset* ke dalam satu direktori utama bernama *All\_Dataset*. Kedua sumber data memiliki struktur folder berdasarkan kategori penyakit mata, sehingga file dari masing-masing kategori dipindahkan ke subfolder yang sesuai menggunakan skrip Python otomatis. Untuk mencegah duplikasi, setiap file diperiksa sebelum dipindahkan. Struktur direktori akhir disusun mengikuti format standar *ImageDataGenerator*, di mana setiap kelas tersimpan dalam subfolder terpisah sesuai labelnya.

Setelah proses penggabungan selesai, dilakukan verifikasi jumlah citra pada setiap kelas serta visualisasi lima sampel citra acak dari masing-masing kategori. Tahap ini bertujuan untuk memastikan bahwa seluruh kelas terwakili dengan benar dan bahwa struktur serta kualitas data telah sesuai untuk digunakan dalam proses pelatihan model *deep learning*, sebagaimana ditunjukkan pada Gambar 1.



Gambar 1. Sampel Citra Fundus Retina Sebelum Preprocessing  
Sumber: Dataset Eye Disease Image Dataset (Kaggle)

### 2. Penerapan CLAHE (*Contrast Limited Adaptive Histogram Equalization*)

Tahap *preprocessing* selanjutnya difokuskan pada peningkatan kualitas citra menggunakan metode *Contrast Limited Adaptive Histogram Equalization* (CLAHE). Teknik ini bertujuan untuk meningkatkan kontras lokal pada citra fundus retina, sehingga struktur penting seperti pembuluh darah, disk optik, dan pola kelainan retina dapat terlihat lebih jelas oleh model.

Proses CLAHE diawali dengan konversi ruang warna dari RGB ke LAB. Kanal L (*lightness*) dari ruang warna LAB diekstrak dan diproses menggunakan CLAHE dengan parameter *clip limit* sebesar 2.0 dan *tile grid size*  $8 \times 8$ . Setelah peningkatan kontras, kanal L

digabungkan kembali dengan kanal A dan B, kemudian dikonversi kembali ke ruang warna BGR dan disimpan menggantikan citra asli.

Secara matematis, proses *histogram equalization* yang menjadi dasar CLAHE dirumuskan sebagai:

$$s = (L - 1) \cdot \int_0^r p_r(w) dw$$

Dimana:

$s$  = nilai piksel setelah *equalization*


$r$  = nilai piksel sebelum *equalization*

$p_r(w)$  = fungsi distribusi probabilitas intensitas piksel  $w$

$L$  = jumlah total tingkat intensitas (biasanya 256)

Pada CLAHE, proses ini diterapkan secara lokal pada tiap *tile* (sub-blok) citra. Untuk menghindari *over-enhancement*, histogram pada tiap *tile* dibatasi oleh *clip limit*, lalu redistribusi dilakukan secara merata ke seluruh *bin*.

Sebagai tahap verifikasi, ditampilkan lima sampel gambar acak dari setiap kelas setelah penerapan CLAHE, guna memastikan konsistensi peningkatan kontras di seluruh dataset, sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Sampel Citra Fundus Retina Setelah Penerapan CLAHE

### 3. Visualisasi dan Validasi Data Awal

Setelah proses penggabungan dataset dan penerapan *preprocessing*, dilakukan tahap visualisasi dan validasi data awal guna memastikan kualitas serta konsistensi data. Visualisasi dilakukan dengan menampilkan lima sampel citra acak dari setiap kelas, baik sebelum maupun sesudah penerapan CLAHE. Langkah ini bertujuan untuk memastikan bahwa distribusi kelas telah sesuai dan proses peningkatan kontras citra telah diterapkan secara merata di seluruh dataset.

Validasi struktur dan distribusi data dilakukan menggunakan *ImageDataGenerator* dari TensorFlow. Dataset dibagi secara otomatis menjadi 80% data pelatihan dan 20% data validasi

dengan parameter *validation\_split*, serta diubah ukurannya menjadi 224×224 piksel sesuai dengan format input arsitektur ResNet-50. Hasil pengecekan menunjukkan bahwa terdapat 12.997 citra untuk pelatihan dan 3.245 citra untuk validasi, yang tersebar secara seimbang dalam 10 kelas. Visualisasi hasil pemetaan ini memastikan bahwa seluruh kelas dikenali dengan benar oleh sistem dan siap digunakan pada tahap pelatihan model.

#### 4. Normalisasi dan Augmentasi Data

Tahap normalisasi dan augmentasi merupakan bagian krusial dalam proses *preprocessing* citra sebelum pelatihan model. Normalisasi dilakukan menggunakan fungsi *preprocess\_input* dari *TensorFlow Keras* yang telah disesuaikan untuk model ResNet-50. Fungsi ini menyesuaikan skala nilai piksel dengan cara mengurangi rata-rata nilai per kanal, sesuai dengan standar dataset ImageNet. Tujuannya adalah untuk menyelaraskan distribusi input dengan karakteristik data yang telah dipelajari oleh model *pretrained*, sehingga meningkatkan efektivitas *transfer learning*.

Selain itu, augmentasi data diterapkan secara *real-time* menggunakan *ImageDataGenerator* guna meningkatkan keragaman citra dan mengurangi risiko *overfitting*. Teknik augmentasi yang digunakan meliputi rotasi acak hingga  $\pm 30^\circ$ , pergeseran horizontal dan vertikal sebesar 10%, *zooming* hingga 20%, serta *flip* horizontal dan vertikal secara acak. Augmentasi ini diterapkan baik pada data pelatihan maupun validasi dengan pemisahan otomatis 80:20 melalui parameter *validation\_split*.

#### 5. Penanganan *Imbalanced Data*

Dataset yang digunakan dalam penelitian ini memiliki distribusi jumlah citra yang tidak merata antar kelas, dengan beberapa kelas memiliki jumlah sampel yang jauh lebih sedikit dibandingkan kelas lainnya. Ketidakseimbangan ini berpotensi menyebabkan model condong memprediksi kelas mayoritas, sehingga mengurangi performa klasifikasi terhadap kelas minoritas.

Untuk mengatasi hal tersebut, diterapkan strategi *class weighting* yang memberikan bobot lebih besar terhadap kelas dengan jumlah data yang lebih sedikit. Bobot dihitung secara otomatis menggunakan metode *balanced weighting* dari Scikit-Learn, berdasarkan rumus:

$$w_j = \frac{n}{k \cdot n_j}$$

Dimana:


$w_j$  = bobot untuk kelas ke- $j$

$n$  = total jumlah sampel

$k$  = jumlah total kelas

$n_j$  = jumlah sampel pada kelas ke- $j$

visualisasi distribusi jumlah citra per kelas dalam bentuk diagram batang untuk menunjukkan tingkat ketimpangan antar kelas sebelum proses pelatihan, sebagaimana ditunjukkan pada Gambar 3.



Gambar 3. Distribusi Jumlah Gambar per Kelas pada Data Training

**Arsitektur Model**

Pengembangan model dalam penelitian ini menggunakan pendekatan *transfer learning* dengan arsitektur ResNet-50 yang telah dipretrain pada dataset ImageNet. Bagian konvolusional ResNet-50 dimanfaatkan sebagai *feature extractor*, kemudian ditambahkan lapisan klasifikasi di atasnya untuk menyesuaikan dengan 10 kelas citra fundus retina. Proses pelatihan dilakukan dalam dua tahap, yakni pelatihan awal menggunakan transfer learning dan dilanjutkan dengan *fine-tuning* untuk menyempurnakan kinerja model pada data spesifik penelitian.

1. Pengembangan Model Deep Learning (Transfer Learning)

Pengembangan model dalam penelitian ini menggunakan pendekatan *transfer learning* dengan arsitektur ResNet-50 yang telah dilatih pada dataset ImageNet. Lapisan konvolusional dibekukan sebagai *feature extractor*, kemudian ditambahkan lapisan klasifikasi berupa *Global Average Pooling 2D*, *Dropout* (0.5), dan *Dense layer* dengan aktivasi *softmax* untuk mengklasifikasikan citra ke dalam 10 kelas. Fungsi aktivasi *softmax* mengubah output logit menjadi probabilitas antar kelas, dirumuskan sebagai:

$$\sigma(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}}$$

Dimana:

$\sigma(z_i)$  = probabilitas prediksi untuk kelas ke-*i*

$z_i$  = output logit dari neuron ke-*i*

$K$  = jumlah total kelas

Model dikompilasi menggunakan *optimizer* Adam dengan *learning rate* sebesar 0.0001, *oss function categorical crossentropy*, dan metrik evaluasi akurasi. *Fungsi categorical crossentropy* dihitung dengan rumus:

$$L = - \sum_{i=1}^K y_i \cdot \log(\hat{y}_i)$$

Dimana:

$L$  = nilai loss

$y_i$  = label aktual kelas ke-*i* (bernilai 1 jika benar, 0 jika tidak)

$\hat{y}_i$  = probabilitas prediksi kelas ke-*i* dari softmax

$K$  = jumlah kelas

2. Pelatihan Model Baseline

Model baseline dilatih menggunakan data hasil *preprocessing* dan augmentasi dengan pendekatan *transfer learning*. Proses pelatihan dilakukan selama maksimum 30 *epoch* menggunakan fungsi *fit()* dari TensorFlow Keras, dengan konfigurasi: *optimizer* Adam (*learning rate* 0.0001), *loss function* *categorical\_crossentropy*, dan metrik akurasi. Untuk mencegah *overfitting*, diterapkan dua *callback*, yaitu *EarlyStopping* (berhenti jika tidak ada peningkatan *val\_loss* selama 5 *epoch*) dan *ModelCheckpoint* (menyimpan bobot model terbaik berdasarkan performa validasi).

Selain itu, digunakan *class weighting* berdasarkan distribusi data yang tidak seimbang. Bobot kelas dihitung untuk memberikan penalti lebih besar pada kesalahan prediksi kelas minoritas, sehingga *loss* dikalkulasi secara berbobot sesuai rumus:

$$L_{\text{weighted}} = w_j \cdot L_j$$

Dimana:

$L_{\text{weighted}}$  = loss berbobot

$w_j$  = class weight untuk kelas ke- $j$

$L_j$  = categorical crossentropy loss untuk kelas ke- $j$

Model kemudian melakukan pembaruan bobot berdasarkan algoritma *gradient descent*, dengan persamaan:

$$w = w - \eta \cdot \frac{\partial L}{\partial w}$$

Dimana:

$w$  = bobot yang diperbarui

$\eta$  = learning rate

$\frac{\partial L}{\partial w}$  = gradien dari fungsi loss terhadap bobot

Setelah pelatihan, hasil perkembangan akurasi dan loss divisualisasikan menggunakan grafik learning curve, baik untuk data training maupun validasi.

### 3. Fine-Tuning Model ResNet-50

Setelah pelatihan *baseline*, dilakukan proses *fine-tuning* untuk meningkatkan kemampuan generalisasi model terhadap karakteristik spesifik citra fundus retina. Teknik ini dilakukan dengan membuka (unfreeze) beberapa lapisan akhir ResNet-50, khususnya pada blok *conv5\_block*, agar bobotnya dapat diperbarui selama pelatihan, sementara lapisan awal tetap dibekukan untuk menjaga fitur umum hasil pelatihan dari ImageNet.

Model kemudian dikompilasi ulang menggunakan *Adam optimizer* dengan *learning rate* lebih kecil ( $1e-5$ ) untuk menghindari pembaruan bobot yang agresif. Proses pelatihan disertai *callback* *ReduceLROnPlateau*, yang menurunkan *learning rate* secara bertahap jika tidak terjadi penurunan *loss*, mengikuti rumus:

$$\eta_{\text{new}} = \eta_{\text{current}} \times \text{factor}$$

Dimana:

$\eta_{\text{new}}$  = learning rate setelah penyesuaian

$\eta_{\text{current}}$  = learning rate saat ini

Factor = nilai pengali penurunan learning rate

Untuk mengatasi ketidakseimbangan data, *class weighting* tetap diterapkan, dan fungsi *loss* yang digunakan adalah *categorical\_crossentropy* berbobot, dirumuskan sebagai:

$$L_{\text{weighted}} = w_j \cdot \left( - \sum_{i=1}^K y_i \cdot \log(\hat{y}_i) \right)$$

Dimana:

$w_j$  = bobot kelas ke- $j$

$y_i$  =abel aktual untuk kelas ke- $i$

$\hat{y}_i$  = probabilitas prediksi kelas ke- $i$  hasil softmax

$K$  = jumlah total kelas

Pelatihan juga menggunakan *EarlyStopping* dan *ModelCheckpoint* untuk menghentikan pelatihan secara otomatis saat tidak ada perbaikan dan memastikan bobot terbaik disimpan berdasarkan performa validasi.

#### 4. Pelatihan Model Fine-Tuned

Setelah proses *fine-tuning* pada beberapa lapisan akhir arsitektur ResNet-50, model dilatih ulang menggunakan dataset yang sama seperti pada pelatihan *baseline*. Tujuan dari pelatihan ini adalah untuk menyesuaikan bobot pada lapisan yang telah dibuka (*conv5\_block*) agar model dapat lebih optimal dalam mengenali pola-pola spesifik pada citra fundus retina.

Pelatihan dilakukan selama maksimal 30 *epoch*, dengan tetap menerapkan *EarlyStopping* untuk menghentikan pelatihan ketika tidak ada peningkatan performa validasi, serta *ModelCheckpoint* untuk menyimpan bobot terbaik model. Selain itu, digunakan *ReduceLROnPlateau* sebagai mekanisme penyesuaian *learning rate* secara otomatis apabila nilai *loss* pada data validasi tidak mengalami penurunan dalam beberapa *epoch* berturut-turut.

Model dikompilasi kembali menggunakan *Adam optimizer* dengan *learning rate* yang lebih rendah ( $1e-5$ ) guna menjaga stabilitas pelatihan ulang dan mencegah perubahan bobot yang terlalu agresif. Strategi *class weighting* tetap diterapkan agar model memberikan perhatian yang seimbang terhadap seluruh kelas, khususnya kelas dengan jumlah sampel yang lebih sedikit.

Selama pelatihan, bobot model diperbarui secara bertahap melalui algoritma *gradient descent* berdasarkan nilai *loss* berbobot. *Loss function* ini mempertimbangkan proporsi kelas, sehingga kesalahan pada kelas minoritas akan memberikan kontribusi yang lebih besar terhadap proses pembelajaran. Hasil pelatihan dievaluasi melalui visualisasi kurva akurasi dan *loss* terhadap jumlah *epoch*, baik pada data pelatihan maupun validasi.

Melalui pendekatan *fine-tuning* ini, diharapkan model mampu mencapai performa klasifikasi yang lebih baik dibandingkan model *baseline* yang hanya mengandalkan *transfer learning* tanpa pembaruan bobot di lapisan akhir.

#### Evaluasi Kinerja Model

Evaluasi dilakukan untuk mengukur performa model dalam klasifikasi multikategori penyakit mata. Pengujian mencakup model *baseline* dan model *fine-tuned*, dengan menggunakan metrik confusion matrix, classification report, dan Top-K Accuracy. Evaluasi dilakukan melalui beberapa metrik dan metode analisis sebagai berikut:

##### A. Confusion Matrix:

Confusion matrix digunakan untuk melihat distribusi prediksi model terhadap label sebenarnya.

Matriks ini menggambarkan jumlah prediksi benar dan salah untuk setiap kelas.

##### B. Classification Report:

Classification report menampilkan metrik evaluasi utama:

##### Precision:

$$\text{Precision} = \frac{TP}{TP + FP}$$

##### Recall:

$$\text{Recall} = \frac{TP}{TP + FN}$$

**F1-Score:**

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

Dimana:

 $TP$  = True Positive $FP$  = False Positive $FN$  = False Negative**C. Top-K Accuracy:**

Top-K Accuracy digunakan untuk mengukur keberhasilan model saat prediksi benar berada di antara K kemungkinan teratas.

**Top-1:**

$$\text{Top-1 Accuracy} = \frac{\text{Jumlah Prediksi Benar}}{\text{Total Prediksi}}$$

**Top-K (K > 1):**


$$\text{Top-K Accuracy} = \frac{\text{Jumlah prediksi dengan label benar di Top-K}}{\text{Total Prediksi}}$$

**IV. HASIL DAN PEMBAHASAN**

Bagian ini menyajikan hasil eksperimen yang diperoleh dari proses pelatihan dan evaluasi model, baik pada tahap baseline (tanpa fine-tuning) maupun setelah penerapan fine-tuning. Analisis difokuskan pada performa model dalam mendeteksi multikategori penyakit mata berdasarkan citra fundus retina.

**1. Hasil Pelatihan Model Baseline (Tanpa Fine-Tuning)**


Model baseline dilatih menggunakan arsitektur ResNet-50 dengan bobot *pretrained* dari ImageNet, tanpa melakukan *fine-tuning* pada lapisan konvolusional. Proses pelatihan berlangsung selama 30 *epoch* dengan menerapkan teknik *class weighting* untuk mengatasi ketidakseimbangan distribusi kelas. Hasil visualisasi performa pelatihan dapat dilihat pada Gambar 4.



Gambar 4. Kurva Akurasi dan Loss Model Baseline

Gambar 4 menunjukkan bahwa akurasi pada data pelatihan mengalami peningkatan secara konsisten, dari sekitar 0,14 pada *epoch* pertama hingga mencapai sekitar 0,59 pada *epoch* ke-30. Akurasi validasi juga menunjukkan tren peningkatan yang signifikan di awal pelatihan, kemudian relatif stabil pada kisaran 0,58–0,61 setelah melewati *epoch* ke-15. Kurva *loss* mengalami penurunan bertahap baik pada data pelatihan maupun validasi, yang mengindikasikan bahwa model tidak mengalami *overfitting* selama proses pelatihan.

Evaluasi performa model terhadap data validasi ditunjukkan melalui *confusion matrix* dan *classification report* sebagaimana ditampilkan pada Gambar 5.



Gambar 5. Confusion Matrix Model Baseline pada Data Validasi

Berdasarkan hasil Gambar 5, model menunjukkan kinerja yang cukup baik dalam mengklasifikasikan sebagian besar kategori. Beberapa kelas seperti Pterygium, Retinal Detachment, dan Retinitis Pigmentosa memiliki nilai *precision* dan *recall* yang tinggi. Namun, terdapat pula kelas seperti Glaucoma dan Macular Scar yang menunjukkan tingkat kesalahan prediksi lebih tinggi, kemungkinan disebabkan oleh kemiripan karakteristik visual antar kelas.

Selanjutnya, hasil evaluasi menggunakan metrik Top-K Accuracy pada model baseline ditampilkan pada Tabel 1.


Tabel 1. Hasil Evaluasi Top-K Accuracy Model Baseline

Model	Top-1 Accuracy	Top-2 Accuracy	Top-3 Accuracy
Baseline	0.6028	0.7901	0.8937

Hasil Tabel 1. menunjukkan bahwa model memiliki performa yang menjanjikan dalam konteks klasifikasi multi-kelas. Meskipun demikian, masih terdapat ruang untuk peningkatan performa lebih lanjut, misalnya dengan menerapkan strategi pelatihan lanjutan seperti *fine-tuning* pada seluruh lapisan model.

## 2. Hasil Pelatihan Model Setelah Fine-Tuning

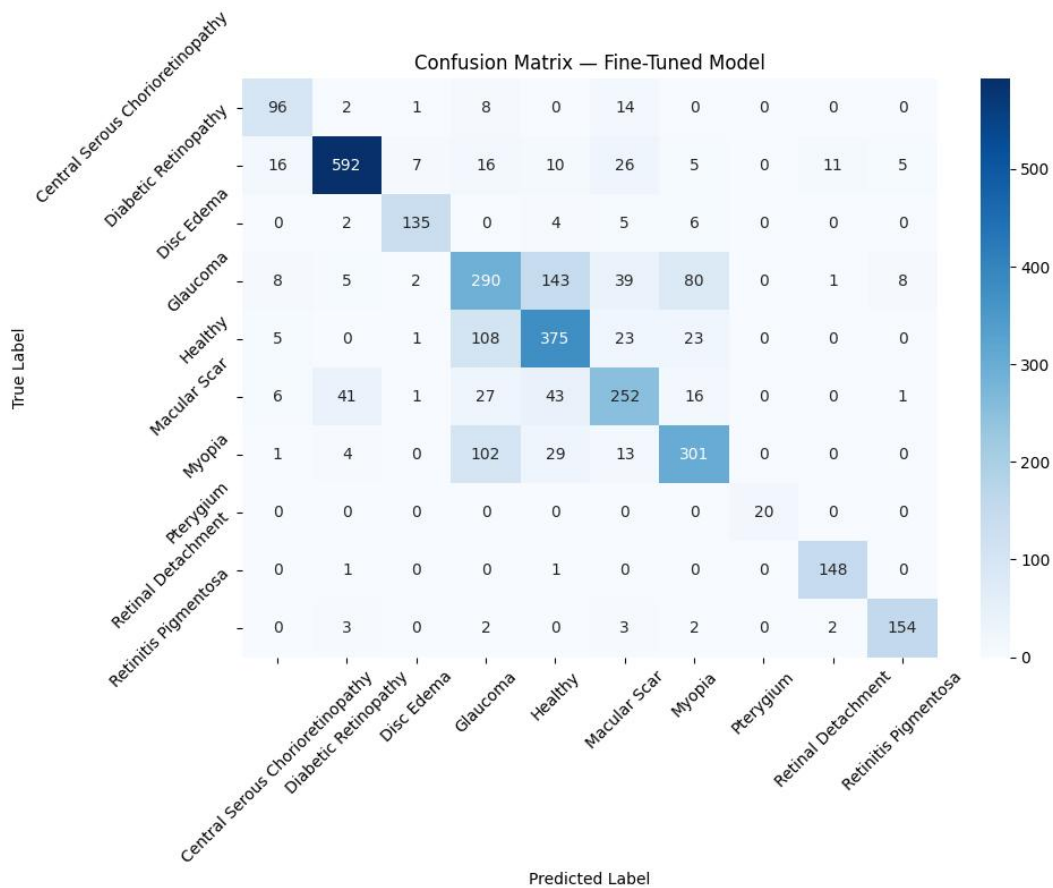
Setelah tahap baseline, model dilanjutkan ke proses *fine-tuning*, di mana sebagian lapisan akhir dari arsitektur ResNet-50 (blok *conv5\_block*) diaktifkan kembali untuk dilatih bersamaan dengan lapisan klasifikasi. Proses *fine-tuning* dilakukan dengan menyesuaikan *learning rate* menjadi lebih kecil untuk mencegah perubahan bobot yang terlalu drastis. Visualisasi hasil pelatihan dapat dilihat pada Gambar 6.



Gambar 6. Kurva Akurasi dan Loss Model Setelah Fine-Tuning

Gambar 6 menunjukkan bahwa akurasi pelatihan mengalami peningkatan yang konsisten hingga mencapai sekitar 85%, sementara akurasi validasi juga meningkat hingga mendekati 73% sebelum akhirnya stabil. Kurva *loss* pada data validasi menunjukkan penurunan selama beberapa *epoch* awal dan kemudian relatif stabil, mengindikasikan bahwa model tidak mengalami *overfitting* setelah *fine-tuning* diterapkan.

Evaluasi performa model pada data validasi yang ditunjukkan melalui *confusion matrix* dalam Gambar 7.



Gambar 7. Confusion Matrix Model Fine-Tuned pada Data Validasi

Berdasarkan hasil Gambar 7 menunjukkan adanya peningkatan yang signifikan dibandingkan dengan model baseline. Peningkatan tersebut terutama terjadi pada beberapa kelas

yang sebelumnya memiliki performa rendah, seperti Healthy, Glaucoma, dan Macular Scar. Selain itu, hampir seluruh kelas minoritas seperti Retinal Detachment dan Retinitis Pigmentosa juga berhasil dikenali dengan lebih baik oleh model.

Hasil pengujian metrik Top-K Accuracy pada model yang telah di-*fine-tune* disajikan pada Tabel 2.

Tabel 2. Hasil Pengujian Top-K Accuracy pada Model Setelah Fine-Tuning

Model	Top-1 Accuracy	Top-2 Accuracy	Top-3 Accuracy
Setelah Fine-Tuning	72,82%	90,69%	96,86%

Dibandingkan dengan model baseline, penerapan fine-tuning mampu meningkatkan performa model secara keseluruhan, terutama dalam meningkatkan kemampuan generalisasi terhadap data validasi.


### 3. Analisis Perbandingan Kinerja Model Baseline vs Fine-Tuned

Perbandingan performa model dilakukan untuk menilai dampak penerapan fine-tuning terhadap hasil klasifikasi multikategori citra fundus retina. Pengukuran kinerja dilakukan menggunakan metrik Top-1 Accuracy, Top-2 Accuracy, dan Top-3 Accuracy, dengan hasil ringkasan ditampilkan pada Tabel 3.

Tabel 3. Perbandingan Hasil Evaluasi Top-K Accuracy Model Baseline dan Fine-Tuned

Model	Top-1 Accuracy	Top-2 Accuracy	Top-3 Accuracy
Baseline	60,28%	79,01%	89,37%
Fine-Tuned	72,82%	90,69%	96,86%

Berdasarkan hasil tersebut, penerapan fine-tuning memberikan dampak positif terhadap performa model. Top-1 Accuracy mengalami peningkatan sebesar 12,54%, menunjukkan bahwa model fine-tuned lebih mampu menghasilkan prediksi yang benar pada percobaan pertama. Peningkatan juga terlihat pada Top-2 dan Top-3 Accuracy, yang masing-masing naik sebesar 11,68% dan 7,49%. Visualisasi perbandingan kinerja ditampilkan pada Gambar 8.



Gambar 8. Visualisasi Perbandingan Top-K Accuracy Model Baseline dan Fine-Tuned

Hasil Gambar 8. menunjukkan bahwa proses fine-tuning pada lapisan akhir ResNet-50 memungkinkan model untuk menyesuaikan bobotnya terhadap karakteristik dataset fundus retina

dengan lebih optimal. Model menjadi lebih peka terhadap fitur-fitur penting pada citra medis yang sebelumnya kurang ditangkap saat baseline training.

Secara keseluruhan, hasil analisis membuktikan bahwa penerapan fine-tuning efektif dalam meningkatkan akurasi dan generalisasi model, serta meningkatkan keandalan sistem klasifikasi multikategori penyakit mata berbasis citra fundus retina.

## V. KESIMPULAN

Berdasarkan hasil penelitian yang bertujuan untuk menganalisis pengaruh proses *fine-tuning* terhadap kinerja model ResNet-50 dalam mendeteksi penyakit mata multikategori berdasarkan citra fundus retina, diperoleh beberapa kesimpulan sebagai berikut:

1. Penerapan Transfer Learning dengan menggunakan ResNet-50 sebagai *feature extractor* / ekstraktor fitur berhasil membentuk *model baseline* yang mampu melakukan klasifikasi multikategori penyakit mata dengan tingkat akurasi yang cukup baik. Pada tahap ini, model mencapai *Top-1 Accuracy* sebesar 60,28%, *Top-2 Accuracy* sebesar 79,01%, dan *Top-3 Accuracy* sebesar 89,37%. Hasil ini menunjukkan bahwa arsitektur ResNet-50 yang telah dilatih sebelumnya pada *ImageNet dataset* dapat dimanfaatkan sebagai dasar dalam membangun model klasifikasi citra medis, meskipun belum dilakukan penyesuaian secara spesifik terhadap data retina.
2. Proses *fine-tuning* pada lapisan akhir ResNet-50, khususnya pada blok *conv5\_block*, memberikan dampak signifikan terhadap peningkatan kinerja model. Dengan membuka dan melatih ulang beberapa lapisan akhir menggunakan data fundus retina, model menunjukkan peningkatan kemampuan dalam mengenali fitur-fitur spesifik pada citra medis. Evaluasi menunjukkan peningkatan *Top-1 Accuracy* menjadi 72,82%, *Top-2 Accuracy* menjadi 90,69%, dan *Top-3 Accuracy* menjadi 96,86%. Peningkatan ini mengindikasikan bahwa proses *fine-tuning* efektif dalam meningkatkan kemampuan generalisasi / *generalization ability* model terhadap data validasi.
3. Hasil analisis perbandingan antara model *baseline* dan model setelah *fine-tuning* mempertegas bahwa *fine-tuning* tidak hanya meningkatkan akurasi secara keseluruhan, tetapi juga mampu memperbaiki kinerja pada kelas-kelas minoritas / *minority classes* yang sebelumnya sulit dikenali. Pendekatan ini menjadikan model lebih adaptif terhadap variasi visual dalam dataset multikategori, sehingga meningkatkan keandalan sistem klasifikasi.
4. Dari sisi metodologi, kombinasi antara *preprocessing* (menggunakan teknik CLAHE / *Contrast Limited Adaptive Histogram Equalization*), *data augmentation* / augmentasi data, penanganan ketidakseimbangan kelas dengan *class weighting*, serta penggunaan strategi pelatihan berbasis *callback* seperti *EarlyStopping*, *ModelCheckpoint*, dan *ReduceLROnPlateau*, terbukti berkontribusi terhadap keberhasilan model, baik pada tahap *baseline* maupun setelah *fine-tuning*.
5. Secara keseluruhan, penelitian ini menunjukkan bahwa *fine-tuning* merupakan tahap krusial dalam pengembangan model *deep learning* berbasis *transfer learning*, khususnya untuk tugas klasifikasi citra medis multikategori. Proses ini tidak hanya meningkatkan akurasi, tetapi juga memperkuat kemampuan model dalam mengenali variasi antar kelas, yang sangat penting untuk mendukung pengambilan keputusan klinis berbasis kecerdasan buatan / *artificial intelligence* di bidang oftalmologi.

## VI. REFERENSI

- Abbood, S. H., Hamed, H. N. A., Rahim, M. S. M., Rehman, A., Saba, T., & Bahaj, S. A. (2022). Hybrid Retinal Image Enhancement Algorithm for Diabetic Retinopathy Diagnostic Using Deep Learning Model. *IEEE Access*, 10(June), 73079–73086. <https://doi.org/10.1109/ACCESS.2022.3189374>
- Alghamdi, M., & Abdel-Mottaleb, M. (2021). A Comparative Study of Deep Learning Models for Diagnosing Glaucoma from Fundus Images. *IEEE Access*, 9, 23894–23906. <https://doi.org/10.1109/ACCESS.2021.3056641>
- Babenko, B., Mitani, A., Traynis, I., Kitade, N., Singh, P., Maa, A. Y., ... Liu, Y. (2022).

- Detection of signs of disease in external photographs of the eyes via deep learning. *Nature Biomedical Engineering*, 6(12), 1370–1383. <https://doi.org/10.1038/s41551-022-00867-5>
- Bohlol, P., Hosseinpour, S., & Soltani Firouz, M. (2025). Improved food recognition using a refined ResNet50 architecture with improved fully connected layers. *Current Research in Food Science*, 10(February), 101005. <https://doi.org/10.1016/j.crfs.2025.101005>
- Fan, R., Alipour, K., Bowd, C., Christopher, M., Brye, N., Proudfoot, J. A., ... Zangwill, L. M. (2023). Detecting Glaucoma from Fundus Photographs Using Deep Learning without Convolutions: Transformer for Improved Generalization. *Ophthalmology Science*, 3(1), 100233. <https://doi.org/10.1016/j.xops.2022.100233>
- Goutam, B., Hashmi, M. F., Geem, Z. W., & Bokde, N. D. (2022). A Comprehensive Review of Deep Learning Strategies in Retinal Disease Diagnosis Using Fundus Images. *IEEE Access*, 10, 57796–57823. <https://doi.org/10.1109/ACCESS.2022.3178372>
- Heikal, A., El-Ghamry, A., Elmougy, S., & Rashad, M. Z. (2024). Fine tuning deep learning models for breast tumor classification. *Scientific Reports*, 14(1), 1–26. <https://doi.org/10.1038/s41598-024-60245-w>
- Hwang, E. E., Chen, D., Han, Y., Jia, L., & Shan, J. (2023). Multi-Dataset Comparison of Vision Transformers and Convolutional Neural Networks for Detecting Glaucomatous Optic Neuropathy from Fundus Photographs. *Bioengineering*, 10(11). <https://doi.org/10.3390/bioengineering10111266>
- 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>
- Jin, K., & Ye, J. (2022). Artificial intelligence and deep learning in ophthalmology: Current status and future perspectives. *Advances in Ophthalmology Practice and Research*, 2(3), 100078. <https://doi.org/10.1016/j.aopr.2022.100078>
- Kaibassova, D., Nurtay, Tau, & Kissina. (2022). Fine-tuning the hyperparameters of pre-trained models for solving multiclass classification problems. *Computer Optics*, 46(6), 971–979. <https://doi.org/10.18287/2412-6179-CO-1078>
- Khan, M. S., Tafshir, N., Alam, K. N., Dhruva, A. R., Khan, M. M., Albraikan, A. A., & Almalki, F. A. (2022). Deep Learning for Ocular Disease Recognition: An Inner-Class Balance. *Computational Intelligence and Neuroscience*, 2022. <https://doi.org/10.1155/2022/5007111>
- Kumar, M., Arora, A., Deb, A., & Yadav, A. L. (2024). Deep Learning for Accurate Plant Disease Classification Using ResNet50: A Comprehensive Approach. *Proceedings - 2024 International Conference on Computational Intelligence and Computing Applications, ICCICA 2024*, 1(July), 125–130. <https://doi.org/10.1109/ICCICA60014.2024.10584860>
- Muchuchuti, S., & Viriri, S. (2023). Retinal Disease Detection Using Deep Learning Techniques: A Comprehensive Review. *Journal of Imaging*, 9(4). <https://doi.org/10.3390/jimaging9040084>
- Mushtaq, G., & Siddiqui, F. (2021). Detection of diabetic retinopathy using deep learning methodology. *IOP Conference Series: Materials Science and Engineering*, 1070(1), 012049. <https://doi.org/10.1088/1757-899x/1070/1/012049>
- Nazir, T., Nawaz, M., Rashid, J., Mahum, R., Masood, M., Mehmood, A., ... Hussain, A. (2021). Detection of diabetic eye disease from retinal images using a deep learning based centernet model. *Sensors*, 21(16). <https://doi.org/10.3390/s21165283>
- Pan, Y., Liu, J., Cai, Y., Yang, X., Zhang, Z., Long, H., ... Tan, Z. (2023). Fundus image classification using Inception V3 and ResNet-50 for the early diagnostics of fundus diseases. *Frontiers in Physiology*, 14(February), 1–9. <https://doi.org/10.3389/fphys.2023.1126780>
- S, K. R. (2023). *Artificial Intelligence on Medical Fields. Data Analytics and Artificial Intelligence* (Vol. 3). <https://doi.org/10.46632/daai/3/2/21>
- Saeed, F., Hussain, M., & Aboalsamh, H. A. (2021). Automatic Diabetic Retinopathy Diagnosis Using Adaptive Fine-Tuned Convolutional Neural Network. *IEEE Access*, 9, 41344–41359. <https://doi.org/10.1109/ACCESS.2021.3065273>
- Sahaai, M. B., Jothilakshmi, G. R., Ravikumar, D., Prasath, R., & Singh, S. (2022). ResNet-50

- based deep neural network using transfer learning for brain tumor classification. *AIP Conference Proceedings*, 2463(May). <https://doi.org/10.1063/5.0082328>
- Sheng, B., Chen, X., Li, T., Ma, T., Yang, Y., Bi, L., & Zhang, X. (2022). An overview of artificial intelligence in diabetic retinopathy and other ocular diseases. *Frontiers in Public Health*, 10. <https://doi.org/10.3389/fpubh.2022.971943>
- Shoukat, A., Akbar, S., Hassan, S. A., Iqbal, S., Mehmood, A., & Ilyas, Q. M. (2023). Automatic Diagnosis of Glaucoma from Retinal Images Using Deep Learning Approach. *Diagnostics*, 13(10), 1–17. <https://doi.org/10.3390/diagnostics13101738>
- Tayal, A., Gupta, J., Solanki, A., Bisht, K., Nayyar, A., & Masud, M. (2022). DL-CNN-based approach with image processing techniques for diagnosis of retinal diseases. *Multimedia Systems*, 28(4), 1417–1438. <https://doi.org/10.1007/s00530-021-00769-7>
- Veena, H. N., Muruganandham, A., & Senthil Kumaran, T. (2022). A novel optic disc and optic cup segmentation technique to diagnose glaucoma using deep learning convolutional neural network over retinal fundus images. *Journal of King Saud University - Computer and Information Sciences*, 34(8), 6187–6198. <https://doi.org/10.1016/j.jksuci.2021.02.003>
- Victor Ikechukwu, A., Murali, S., Deepu, R., & Shivamurthy, R. C. (2021). ResNet-50 vs VGG-19 vs training from scratch: A comparative analysis of the segmentation and classification of Pneumonia from chest X-ray images. *Global Transitions Proceedings*, 2(2), 375–381. <https://doi.org/10.1016/j.gltip.2021.08.027>