

# Klasifikasi Gangguan Mata pada Anak Menggunakan Metode CNN Arsitektur Xception untuk Deteksi Dini [Classification of Eye Disorders in Children Using the CNN Xception Architecture Method for Early Detection]

Dewi Melisa Putri<sup>1)</sup>, Mochamad Alfian Rosid<sup>\*2)</sup>, Hamzah Setiawan<sup>3)</sup>, Ika Ratna Indra Astutik<sup>4)</sup>

<sup>1,2,3,4)</sup>Program Studi Informatika, Universitas Muhammadiyah Sidoarjo, Indonesia

\*Email: [alfanrosid@umsida.ac.id](mailto:alfanrosid@umsida.ac.id)

**Abstract.** *The increasing use of gadgets increases the risk of eye disorders in children, so early detection is crucial. This research focuses on the classification of three eye conditions namely crossed eyes, red eyes, and normal eyes using digital images. The method used involves the Xception architecture on a Convolutional Neural Network (CNN) to extract complex features from eye images. The data used consists of 4,500 images divided into three categories. This research compares two main training scenarios: using transfer learning without fine-tuning and with fine-tuning. The research results show that the best accuracy, precision, recall and f1-score values are found in scenarios with fine-tuning, each of which consistently reaches 96%. These results can contribute to the development of early detection models of eye disorders with high accuracy, especially in demonstrating the effectiveness of fine-tuning methods for specific medical image classification tasks.*

**Keywords** - *detection of eye disorders; convolutional neural networks; xception;*

**Abstrak.** *Meningkatnya penggunaan gadget memicu risiko gangguan mata pada anak, sehingga deteksi dini menjadi krusial. Penelitian ini berfokus pada klasifikasi tiga kondisi mata yaitu mata juling, mata merah, dan mata normal menggunakan citra digital. Metode yang digunakan melibatkan arsitektur Xception pada Convolutional Neural Network (CNN) untuk mengekstraksi fitur kompleks dari citra mata. Data yang digunakan terdiri dari 4.500 gambar yang dibagi ke dalam tiga kategori. Penelitian ini membandingkan dua skenario pelatihan utama: menggunakan transfer learning tanpa fine-tuning dan dengan fine-tuning. Hasil penelitian menunjukkan nilai accuracy, precision, recall, dan f1-score terbaik terdapat pada skenario dengan fine-tuning, yang masing-masing secara konsisten mencapai 96%. Hasil ini dapat memberikan kontribusi bagi pengembangan model deteksi dini gangguan mata dengan akurasi yang tinggi, terutama dalam menunjukkan efektivitas metode fine-tuning untuk tugas klasifikasi citra medis yang spesifik.*

**Kata Kunci** - *deteksi gangguan mata; convolutional neural network; xception;*

## I. PENDAHULUAN

### 1.1 Latar Belakang

Saat ini, inovasi pada perangkat elektronik, khususnya gadget, memainkan peran penting dalam keseharian masyarakat, yang juga mencakup anak-anak. Kamus Besar Bahasa Indonesia (KBBI) mendefinisikan gadget atau gawai sebagai perangkat elektronik yang didesain untuk memudahkan beragam kegiatan sehari-hari penggunaannya. Meningkatnya akses dan penggunaan smartphone di kalangan usia dini menandai transformasi digital yang terjadi secara masif. Menurut data GoodStats, jumlah pengguna aktif smartphone di Indonesia meningkat signifikan dari sekitar 54 juta pada tahun 2015 menjadi 209,3 juta pada tahun 2023 [1]. Sejalan dengan itu, data Badan Pusat Statistik (BPS) tahun 2023 menunjukkan bahwa sekitar 36,99% anak di bawah usia 15 tahun telah menggunakan perangkat digital secara aktif dalam kehidupan sehari-hari [2]. Anak-anak kini menggunakan gadget tidak hanya untuk hiburan seperti menonton animasi dan bermain game, tetapi juga sebagai sarana eksplorasi informasi di internet.

Namun, tingginya intensitas penggunaan gadget sejak usia dini menimbulkan kekhawatiran dan dapat berdampak negatif terhadap aspek kesehatan, salah satunya adalah masalah penglihatan yang menurun [3]. Salah satu kondisi yang umum terjadi adalah mata merah, yang diakibatkan oleh berkurangnya frekuensi berkedip saat menatap layar dalam waktu lama. Kondisi ini diperparah oleh paparan cahaya biru (blue light) dari layar, yang dapat menyebabkan iritasi dan peradangan pada mata [4]. Lebih jauh lagi, gangguan seperti mata juling (strabismus) juga dikaitkan dengan kebiasaan menggunakan gadget dari jarak dekat. Studi yang dipublikasikan dalam jurnal Strabismus menyatakan bahwa aktivitas visual jarak dekat dalam waktu lama dapat memicu hiperaktivitas otot siliaris, yang pada akhirnya meningkatkan risiko terjadinya strabismus pada anak [5].

Mengingat dampaknya yang serius terhadap perkembangan anak, deteksi dini terhadap gangguan mata menjadi sangat krusial. Teknologi kecerdasan buatan, khususnya machine learning, menawarkan solusi yang menjanjikan dalam mendeteksi gangguan mata melalui analisis citra. Machine learning mencakup studi tentang Jaringan Saraf Tiruan (JST), yang kemudian dikembangkan lebih lanjut menjadi apa yang dikenal sebagai deep learning. Salah satu

pendekatan yang terbukti efektif adalah penggunaan Convolutional Neural Network (CNN), sebuah metode deep learning yang sangat andal dalam klasifikasi gambar medis [6].

Beberapa peneliti telah melakukan penelitian terhadap system deteksi gangguan mata dengan menggunakan beberapa struktur CNN. Berdasarkan penelitian yang dilakukan oleh Giesta Rahguna Putri dkk. membahas identifikasi mata juling dan mata normal pada anak menggunakan *Convolutional Neural Network* (CNN) [7]. Dataset yang digunakan terdiri dari gambar mata juling dan mata normal dengan masing-masing kategori memiliki 20 gambar. Dalam penelitian ini model CNN menunjukkan keberhasilannya dalam membedakan mata juling dan mata normal dengan akurasi tinggi. Akurasi pelatihan mencapai 81.25%, namun akurasi pengujian pada data uji turun menjadi 65.5 %. Namun demikian, penelitian ini secara signifikan berkontribusi pada deteksi dini mata juling pada anak.

Kemudian pada penelitian yang dilakukan oleh Kazi Tanvir dkk. Dengan judul "*Clinical Insights through Xception: A Multiclass Classification of Ocular Pathologies*" yang berfokus pada klasifikasi multikelas gangguan mata menggunakan arsitektur Xception dalam *Convolutional Neural Network* (CNN) yang mengkategorikan empat kondisi mata yaitu mata normal, katarak, glukoma, dan *diabetic retinopathy* [8]. Model ini dinilai pada dataset yang terdiri dari 4.127 gambar yang diimplementasikan menggunakan *transfer learning* dan mencapai tingkat akurasi sebesar 92.87%. Hasil evaluasi disajikan dengan *confusion matrix*, nilai presisi, recall, dan F1-score.

Arsitektur CNN seperti Xception, yang menggabungkan kekuatan ekstraksi fitur mendalam dan efisiensi pemrosesan, telah menunjukkan performa unggul dalam berbagai studi pengenalan pola citra, termasuk dalam domain oftalmologi. Maka dari itu, penelitian ini bertujuan untuk mengembangkan model klasifikasi gangguan mata pada anak usia di bawah usia 15 tahun menggunakan pendekatan CNN dengan arsitektur Xception. Dataset yang digunakan berasal dari platform Kaggle, yang mencakup beberapa kategori kelainan mata pada anak seperti mata merah, mata juling, dan mata normal. Diharapkan, model ini dapat membantu proses deteksi dini secara lebih akurat dan efisien, serta berkontribusi sebagai alat bantu diagnosis bagi tenaga medis dan orang tua dalam memantau kesehatan visual anak sejak dini.

## 1.2 Tinjauan Pustaka

### a) Convolutional Neural Network (CNN)

Sebagai salah satu algoritma deep learning, Convolutional Neural Network (CNN) berfungsi untuk melakukan klasifikasi gambar dengan memanfaatkan operasi konvolusi dan melibatkan minimal satu lapisan pemrosesan. Jaringan saraf tiruan ini memproses masukan melalui serangkaian lapisan tersembunyi yang saling terhubung untuk menghasilkan prediksi. Lapisan CNN yang umum digunakan seperti convolutional layer (lapisan konvolusi), pooling layer (lapisan penggabungan), dan fully connected layer (lapisan terhubung penuh). Convolutional layer merupakan lapisan inti dari proses konvolusi yang berfungsi untuk mengekstrak fitur dari gambar, seperti pola, garis, sudut, atau bentuk yang lebih kompleks untuk menghasilkan *feature map* [9]. Kemudian Pooling layer bertujuan untuk mengurangi dimensi data yang dihasilkan pada layer konvolusi agar proses komputasi menjadi lebih cepat. Data yang telah melalui layer konvolusi dan pooling akan diproses lebih lanjut untuk dilakukannya klasifikasi, dimana semua fitur yang di ekstrak sebelumnya diintegrasikan untuk menentukan prediksi kelas akhir [10].

### b) Penyakit Mata

Penggunaan gadget yang berlebihan pada anak dapat menimbulkan berbagai gangguan kesehatan mata, di antaranya mata merah dan strabismus (mata juling).

#### 1) Mata Merah


Penggunaan gadget dalam durasi yang panjang dapat menyebabkan mata jarang berkedip, sehingga kelembapan pada permukaan mata berkurang dan memicu iritasi yang ditandai dengan mata merah [11]. Kondisi ini semakin diperparah oleh paparan cahaya biru (*blue light*) yang mengganggu stabilitas lapisan air mata serta menimbulkan inflamasi ringan pada retina mata. Mata merah pada penggunaan gadget umumnya tidak berdiri sendiri, melainkan muncul bersamaan dengan keluhan lain seperti mata kering, perih, gatal, penglihatan kabur, hingga sakit kepala, yang keseluruhannya merupakan tanda astenopia atau mata lelah akibat aktivitas visual berlebihan [11].

#### 2) Mata Juling

Penggunaan gadget dalam durasi panjang dapat meningkatkan risiko strabismus atau mata juling pada anak dan remaja. Paparan cahaya biru (*blue light*) dari layar, terutama ketika dilihat dari jarak dekat dan intensitas tinggi, membuat mata cenderung menyipit serta memaksa otot okular bekerja lebih keras untuk mempertahankan fokus [12]. Ketegangan otot mata yang berlangsung terus-menerus ini dapat mengganggu koordinasi gerakan bola mata sehingga dalam jangka panjang berpotensi menimbulkan strabismus. Mata juling (strabismus) merupakan sebuah kondisi di mana posisi mata tidak lurus, yang menyebabkannya tidak bisa fokus ke arah yang sama secara bersamaan [7]. Kondisi tersebut tidak hanya berdampak pada aspek estetika, tetapi juga memengaruhi kualitas penglihatan, karena penderita dapat mengalami penglihatan ganda, cepat lelah saat membaca, dan kesulitan memfokuskan pandangan.

## II. METODE PENELITIAN

Pada bagian metode penelitian ini, peneliti akan menjelaskan secara detail setiap tahapan yang akan dilalui, mulai dari perencanaan awal, hingga tahapan akhir. Pada Gambar 2.1 berikut akan menunjukkan tahapan pada penelitian ini.




**Gambar 2.1** Tahapan Penelitian

### 2.1 Studi Literatur

Tahap ini dimulai dengan membaca dan menganalisis penelitian sebelumnya yang berkaitan dengan pengolahan citra mata dan arsitektur CNN (khususnya Xception) untuk memberikan pemahaman mengenai landasan teori, keunggulan metode, serta celah penelitian yang dapat dikembangkan.

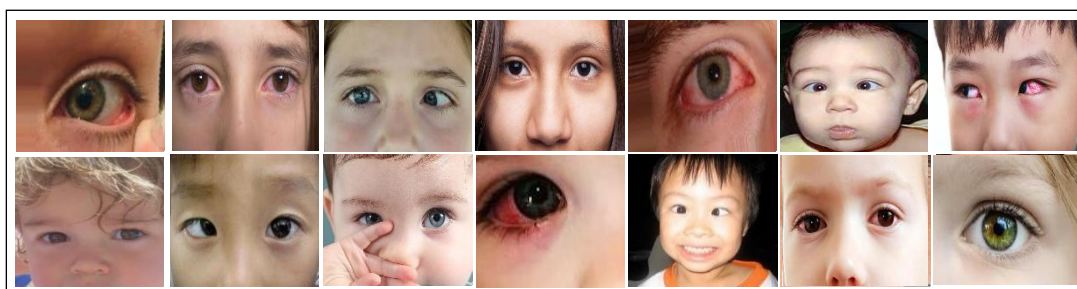
### 2.2 Pengumpulan Dataset

Pada tahapan ini, penulis mengumpulkan data yang diperlukan yang diambil melalui Kaggle yaitu platform *online* milik Google untuk data *scientist* dan praktisi machine learning yang memungkinkan pengguna untuk menemukan dan menerbitkan ribuan *dataset* publik, serta komunitas aktif untuk belajar, kolaborasi, dan pengembangan model *machine learning*. Total citra yang digunakan sebanyak 4.500 citra dengan bagian yang digunakan adalah foto pupil mata. Terdapat 3 kategori mata yaitu mata normal, mata merah, dan mata juling yang masing-masing kategori berjumlah 1.500 citra. Proses kategori dapat dilihat pada gambar 2.2.



**Gambar 2.2** Pengelompokan dataset berdasarkan kategori

Setiap data dalam *dataset* menggunakan citra dengan ekstensi .jpg. untuk melihat contoh data yang digunakan, dapat dilihat pada Gambar 2.3.



**Gambar 2.3** Sampel Dataset

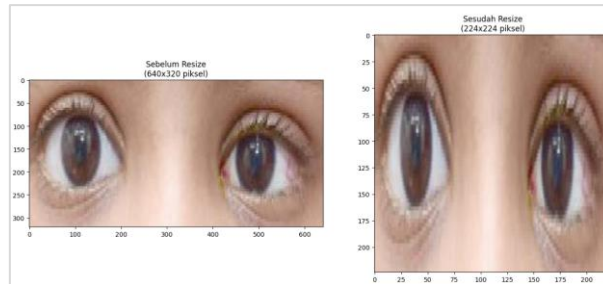
### 2.3 Pembagian Data

Keseluruhan dataset dalam penelitian ini disusun menjadi tiga komponen: 3.150 data (70%) untuk data latih, 900 data (20%) untuk data validasi, dan 450 data (10%) sisanya untuk data uji. Data train dan validasi digunakan dalam proses pelatihan, dimana data train untuk melatih model belajar pola gambar dan data validasi digunakan untuk memantau kinerja model selama pelatihan. Di sisi lain, data uji digunakan untuk mengevaluasi kinerja akhir model secara objektif.

## 2.4 Preprocessing Data

Tahap *Preprocessing* data ini dilakukan untuk mempersiapkan dan meningkatkan kualitas *dataset* sebelum digunakan dalam pelatihan model, meliputi *resize*, normalisasi dan augmentasi untuk mengubah, menyiapkan, dan memperkaya data mentah agar sesuai dan efektif saat proses pelatihan [13]. Gambar 2.4 sampai 2.6 adalah tahapan yang dilakukan pada *preprocessing data*.

*Resize* adalah proses mengubah ukuran citra agar sesuai dengan input yang diharapkan oleh model [14]. Pada penelitian ini ukuran citra diubah menjadi 224×224 piksel. Contoh proses *resize* dapat dilihat pada Gambar 2.4.



**Gambar 2.4** Resize Citra Sebelum (kiri) dan Sesudah (kanan)

Normalisasi merupakan proses menyamakan skala nilai piksel, dimana nilai piksel akan diubah dari rentang [0, 255] menjadi rentang [0.0, 1.0]. Hal ini dilakukan untuk meningkatkan pelatihan model. Untuk penggambarannya bisa dilihat pada Gambar 2.5.



**Gambar 2.5** Normalisasi Citra Sebelum (kiri) dan Sesudah (kanan)

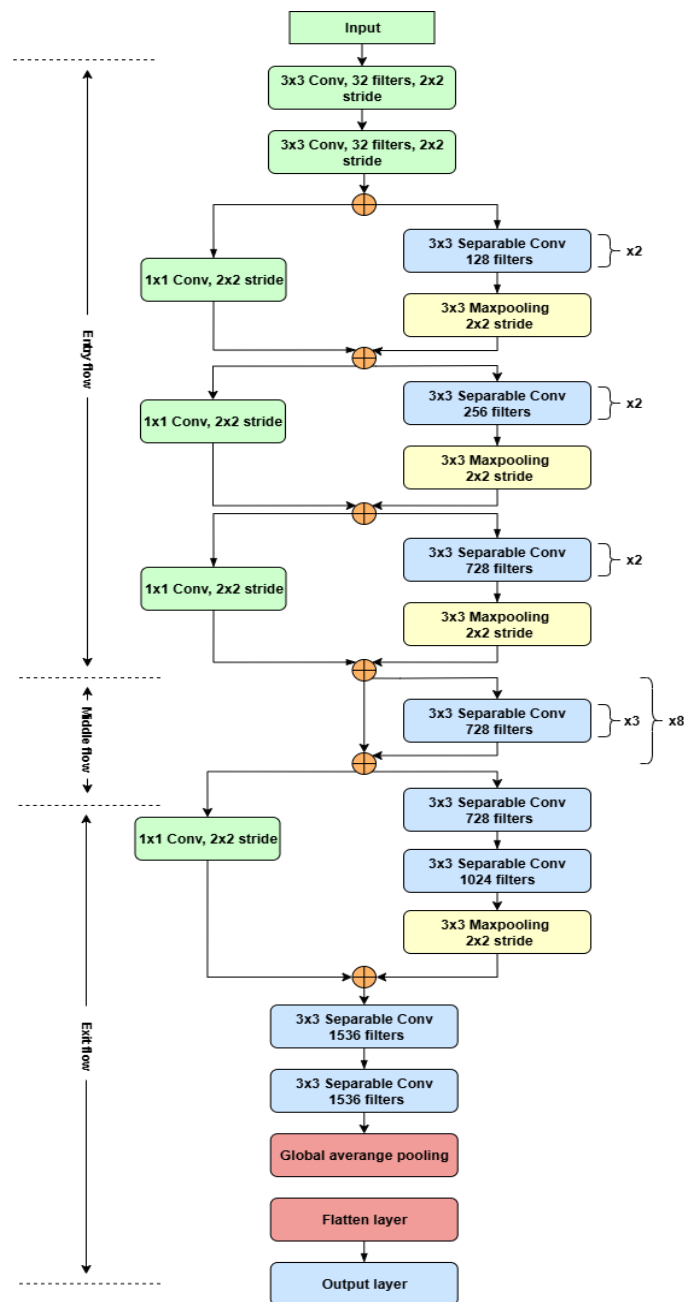
Augmentasi data merupakan proses yang dilakukan untuk memperbanyak jumlah dan variasi dataset pelatihan [15]. Proses ini menerapkan beberapa transformasi pada gambar. Dalam penelitian ini, augmentasi akan dilakukan dengan menggunakan teknik seperti rotasi, flip dan zoom. Contoh dari proses augmentasi dapat dilihat pada Gambar 2.6.



**Gambar 2.6** Augmentasi Citra Mata

## 2.5 Perancangan Model

Model yang digunakan dalam penelitian ini adalah *Xception*, sebuah arsitektur CNN yang dikenal sebagai pengembangan ekstrim dari model Inception yang disebut sebagai “*Xtreme of Inception*” [16]. *Xception* mengimplementasikan *depthwise separable convolution* yang lebih efisien dibandingkan konvolusi tradisional. Arsitektur ini memiliki 36 lapisan konvolusi yang membentuk dasar ekstraksi fitur citra pada jaringan.



Gambar 2.7 Arsitektur Xception

Pada Gambar 2.7, struktur Xception dibagi menjadi tiga bagian yaitu *Entry Flow* untuk mengekstrak fitur dasar, *Middle Flow* untuk mempelajari fitur-fitur yang lebih kompleks, dan *Exit Flow* untuk menyaring dan menyusun fitur akhir untuk menghasilkan output klasifikasi. Lapisan akhir dari model disesuaikan dengan jumlah kelas pada dataset dan diakhiri dengan fungsi aktivasi softmax. Untuk kelas kategori akan di inialisasi dengan nilai awal 0, 1, dan 2. Nilai 0 merepresentasikan mata juling, nilai 1 untuk mata normal, dan nilai 3 untuk mata merah.

## 2.6 Pelatihan Model

Pada tahap ini, dilakukan proses pelatihan model menggunakan dataset yang sebelumnya telah disiapkan dan melalui proses *preprocessing*. Optimizer yang digunakan adalah Adam, karena mampu menghemat sumber daya komputasi dan mempercepat proses pembelajaran, dengan *learning rate* sebesar 0.001. Proses pelatihan berlangsung selama 50 epoch, dimana pada setiap epoch model mempelajari pola dari data pelatihan dan melakukan pengoptimalan bobot berdasarkan lost function *categorical crossentropy*. Selama pelatihan, model di evaluasi menggunakan data validasi untuk memantau kinerjanya dan memastikan model tidak mengalami overfitting. Setiap epoch, performa

model dicatat dalam bentuk akurasi dan loss. Menggunakan beberapa *callback functions* yaitu *EarlyStopping* untuk menghentikan pelatihan lebih awal jika tidak ada peningkatan dan *ReduceOnPlateau* untuk menurunkan *learning rate* secara otomatis jika validasi tidak membaik.

## 2.7 Pengujian Model

Skenario pengujian model dilakukan agar mendapatkan hasil yang sesuai dengan target yang akan dicapai. Penelitian ini melibatkan 2 skenario pengujian untuk menilai kinerja model Xception yaitu dengan *fine-tuning* dan tanpa *fine-tuning*. Data yang telah diproses dan di augmentasi dibagi menjadi data latih, validasi, dan uji dengan proporsi yang telah ditentukan. Menerapkan model Transfer Learning dengan parameter uji yang mencakup 50 epoch, batch size 32, dan learning rate 0.001.

## 2.8 Evaluasi Model

Untuk menilai kinerja model, pengujian dilakukan pada data uji yang belum pernah dilihat sebelumnya. Evaluasi ini memanfaatkan Confusion Matrix untuk memvisualisasikan jumlah prediksi yang benar dan salah pada setiap kategori. Selanjutnya, gambaran performa model yang lebih detail diperoleh dengan menghitung metrik evaluasi seperti akurasi, presisi, recall, dan F1-score, sesuai dengan Persamaan 1 sampai 4.

- a) Akurasi (accuracy) : menghitung seberapa banyak prediksi yang benar

$$\text{Akurasi} = \frac{\text{jumlah prediksi benar}}{\text{total jumlah prediksi}} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

- b) Presisi (precision) : menghitung seberapa banyak positif yang benar-benar positif

$$\text{Presisi} = \frac{TP}{TP+FP} \quad (2)$$

- c) Sensitivitas (recall) : Menghitung seberapa banyak positif sesungguhnya yang berhasil ditemukan oleh model

$$\text{Sensitivitas} = \frac{TP}{TP+FN} \quad (3)$$

- d) F1-Score : nilai rata-rata dari nilai precision dan recall

$$\text{F1 Score} = 2 \times \frac{\text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \quad (4)$$

## III. HASIL DAN PEMBAHASAN

Analisis CNN arsitektur Xception untuk klasifikasi gangguan mata pada anak dengan pengaturan hyperparameter, serta pengujian menggunakan fine-tuning dan tanpa fine-tuning dibahas pada bagian hasil dan pembahasan. Pada penelitian ini, pengaturan hyperparameter dilakukan dengan cermat untuk mengoptimalkan performa model dalam mengklasifikasi gangguan mata pada anak. Hyperparameter yang akan digunakan dalam penelitian ini tercantum pada Tabel 3.1.


**Tabel 3.1** Hyperparameter yang digunakan

Parameter	Xception
Image Size	224×224
Batch Size	32
Epoch	50
Learning Rate	0.001
Dropout	0.3
Optimizer	Adam
Function Activation	Softmax
Lost Function	Categorical Crossentropy

Input gambar diatur menjadi 224×224 piksel untuk memastikan kesesuaian dengan arsitektur Xception. Model dilatih menggunakan optimasi Adam, dengan *learning rate* yang ditetapkan pada 0.001, bertujuan untuk mencapai konvergensi yang stabil dan efisien. Penggunaan *batch size* sebesar 32 mempercepat proses pelatihan dalam jumlah dataset yang besar secara bersamaan. Pelatihan model berlangsung selama 50 *epoch*, dimana *dropout* sebesar 0.3 diterapkan pada lapisan sebelum output untuk mencegah *overfitting*.

### 3.1 Hasil Pelatihan Model

Berdasarkan parameter yang digunakan dalam Tabel 3.1 dengan arsitektur Xception yang diterapkan, didapat hasil seperti yang terlihat pada Gambar 3.1 sampai 3.2.



**Gambar 3.1** Grafik hasil pelatihan model Xception tanpa fine tuning: (a) Grafik Akurasi dan (b) Grafik Loss.

Proses pelatihan tanpa fine tuning dilakukan selama 50 epoch dengan menggunakan early stopping dan menghentikan pelatihan pada epoch ke-35, seperti yang ditunjukkan pada Gambar 3.1. Pada grafik akurasi (a), nilai akurasi pelatihan meningkat dari 71,05% pada epoch pertama menjadi 97,34% pada epoch ke 35, sementara akurasi validasi juga menunjukkan kenaikan signifikan hingga 95,33% di epoch 22. Pada grafik loss (b), nilai loss pelatihan terus menurun seiring berjalannya pelatihan dan nilai loss validasi mencapai titik terendahnya sebesar 0,1661 pada epoch ke-25. Setelah epoch ini, performa pada data validasi tidak menunjukkan peningkatan yang signifikan, yang memicu *callback early stopping* untuk menghentikan pelatihan pada epoch ke-35. Dengan demikian, meskipun pelatihan berhenti di epoch ke-35, model akhir yang digunakan berasal dari epoch ke-25 karena nilai loss validasinya menunjukkan nilai yang paling minimum, sebagai indikator performa generalisasi model yang optimal.



**Gambar 3.2** Grafik hasil pelatihan model Xception dengan fine tuning: (a) Grafik Akurasi dan (b) Grafik Loss.

Setelah melakukan fine tuning pada model, pelatihan berlanjut dengan peningkatan akurasi yang lebih pesat, seperti yang terlihat pada Gambar 3.2. Pada grafik akurasi (a), akurasi pelatihan meningkat tajam mencapai 99,76% pada epoch-20, dan akurasi validasi mencapai 98,22%, yang menunjukkan keberhasilan fine tuning dalam meningkatkan kinerja model. Pada grafik loss (b), nilai loss pada data pelatihan turun drastis, sementara loss validasi mencapai titik terendahnya sebesar 0,0656 pada epoch ke-16. Early stopping diterapkan pada epoch ke-21 karena tidak ada peningkatan yang signifikan setelah epoch ke-16, dan model terbaik dipilih berdasarkan epoch ke-16. Untuk lebih jelasnya dapat dilihat pada Tabel 3.2.




**Tabel 3.2** Perbandingan Hasil Pelatihan Model dengan dan Tanpa Fine Tuning.


Skenario Pelatihan	Training Accuracy	Validation Accuracy	Training Loss	Validation Loss
Xception tanpa fine tuning	97,66% (epoch 25)	95,11% (epoch 25)	0,0676 (epoch 25)	0,1661 (epoch 25)
Xception dengan fine tuning	99,12% (epoch 16)	98,22% (epoch 16)	0,0323 (epoch 16)	0,0656 (epoch 16)

### 3.2 Hasil Evaluasi Model

Perbandingan antara skenario pelatihan dengan dan tanpa fine-tuning menjadi dasar evaluasi untuk menentukan tingkat keberhasilan model CNN arsitektur Xception dalam mengklasifikasikan penyakit mata pada anak usai proses pelatihan.

**Gambar 3.3** Hasil Pengujian Model tanpa Fine Tuning: (a) Confusion Matrix dan (b) Classification Report.

Evaluasi pertama untuk model yang dilatih tanpa fine-tuning, seperti yang dirinci pada Gambar 3.3, menunjukkan pencapaian akurasi keseluruhan 92% pada 450 data uji. Namun, di balik angka akurasi yang baik ini, confusion matrix mengungkap adanya kesulitan model dalam membedakan kelas tertentu. Kelemahan yang paling menonjol adalah pada kelas "mata merah", di mana 16 citra keliru diklasifikasikan sebagai "mata normal". Kesalahan ini secara langsung tercermin pada nilai recall yang rendah sebesar 0.88 untuk kelas tersebut, yang berarti model gagal mengenali sebagian kasusnya. Sebagai pembanding, kelas "mata juling" menunjukkan performa jauh lebih andal dengan recall 0.94 dan precision 0.97. Meskipun ada ketidakseimbangan antarkelas, hasil ini mengonfirmasi bahwa arsitektur dasar Xception sudah cukup andal dalam menghindari sebagian besar kesalahan prediksi.

**Gambar 3.4** Hasil Pengujian Model dengan Fine Tuning: (a) Confusion Matrix dan (b) Classification



Evaluasi kedua untuk model yang dilatih dengan fine tuning seperti yang di gambarkan pada Gambar 3.4, menunjukkan pencapaian akurasi keseluruhan yang lebih tinggi sebesar 96% pada 450 data uji. Berbeda dengan skenario sebelumnya, confusion matrix ini menunjukkan kinerja yang sangat seimbang dan andal. Jumlah kesalahan dalam klasifikasi sangat minim dan tersebar merata. Sebagai contoh, model berhasil mengklasifikasikan 145 kelas “mata normal”, dan 143 citra "mata merah" dengan benar. Keseimbangan ini juga terkonfirmasi secara kuantitatif pada laporan klasifikasi, di mana semua kelas menunjukkan nilai precision, recall, dan f1-score yang konsisten tinggi di sekitar 0.96. Hal ini mengonfirmasi bahwa model yang telah di fine tuning tidak hanya mencapai akurasi tinggi, tetapi juga memiliki kemampuan generalisasi yang baik dan merata untuk semua kelas kategori sehingga mampu menghindari kesalahan prediksi secara efektif.

**Tabel 3.3** Perbandingan Kinerja Metrik per Kelas pada Skenario dengan dan Tanpa Fine-Tuning.

Skenario	Akurasi	Mata Juling			Mata Merah			Mata Normal		
		Precision	Recall	F1-score	Precision	Recall	F1-score	Precision	Recall	F1-score
Tanpa Fine-Tuning	92%	0.97	0.94	0.96	0.93	0.88	0.90	0.87	0.95	0.91
Dengan Fine-Tuning	96%	0.96	0.96	0.96	0.97	0.95	0.96	0.95	0.97	0.96

Berdasarkan data pada Tabel 3.3, menunjukkan hasil akurasi terbesar ada pada skenario dengan fine-tuning sebesar 96% yang pengujiannya dilakukan pada 450 citra data uji yang terpisah dengan data latih dan data validasi. Dapat disimpulkan bahwa penerapan metode fine-tuning dalam penelitian ini memberikan peningkatan nilai akurasi yang signifikan dibandingkan skenario tanpa fine-tuning. Hasil akhir ini juga dipengaruhi oleh strategi pelatihan yang digunakan, jumlah data, serta metode preprocessing yang diterapkan

## VII. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, disimpulkan bahwa skenario dengan penerapan fine-tuning adalah model dengan performa terbaik untuk melakukan klasifikasi gangguan mata pada anak, dengan akurasi sebesar 96%, presisi rata-rata 96%, recall rata-rata 96%, dan f1-score rata-rata 96%. Performa ini menunjukkan peningkatan yang signifikan dibandingkan skenario tanpa fine-tuning yang hanya mencapai akurasi 92% dengan kinerja yang kurang seimbang. Penelitian ini memberikan kontribusi penting untuk pengembangan sistem deteksi dini gangguan mata pada anak, khususnya dengan menunjukkan bahwa kombinasi metode transfer learning dan fine tuning sangat efektif untuk membangun model yang akurat dan dapat diandalkan.

## VIII. SARAN

Meskipun model dengan fine-tuning menunjukkan performa yang sangat baik, penelitian ini memiliki keterbatasan karena dataset yang digunakan belum mencakup citra dengan kontras gelap atau pencahayaan rendah. Untuk penelitian selanjutnya, disarankan untuk memperkaya dataset dengan gambar berkontras rendah. Selain itu, dapat diterapkan teknik augmentasi untuk memanipulasi kecerahan. Dengan cara ini, model yang dikembangkan akan menjadi lebih andal dan efektif saat digunakan dalam kondisi dunia nyata yang tidak dapat diprediksi.

## UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih sebesar-besarnya kepada **Laboratorium Informatika Universitas Muhammadiyah Sidoarjo** yang telah menyediakan seluruh fasilitas yang diperlukan, serta pihak-pihak yang telah membantu dalam penelitian ini.

## REFERENSI

- [1] GoodStats, "209,3 Juta Orang di Indonesia Menggunakan Smartphone pada Tahun 2023," GoodStats. Accessed: Jul. 01, 2025. [Online]. Available: <https://data.goodstats.id/statistic/2093-juta-orang-di-indonesia-menggunakan-smartphone-pada-tahun-2023-cbha0>
- [2] B. P. Statistik, "Proporsi Individu yang Menguasai/Memiliki Telepon Genggam Menurut Kelompok Umur (Persen)," Badan Pusat Statistik. [Online]. Available: <https://www.bps.go.id/id/statistics-table/2/MTIyMiMy/proporsi-individu-yang-menguasai-memiliki-telepon-genggam-menurut-kelompok-umur.html>
- [3] E. A. Mashudi and S. Monasari, "DAMPAK PENGGUNAAN GADGET TERHADAP KESEHATAN MATA DAN POSTUR TUBUH PADA ANAK USIA DINI," *J. Pendidik. Islam*, vol. 6, no. 1, pp. 21–28, 2024.
- [4] G. Heiting and S. Kelley, "Blue Light Facts: Is Blue Light Bad For Your Eyes?," All About Vision. Accessed: Jun. 18, 2025. [Online]. Available: <https://www.allaboutvision.com/conditions/computer-vision-syndrome/blue-light/overview-of-blue-light/>
- [5] E. Van Hoolst *et al.*, "Association between near viewing and acute acquired esotropia in children during tablet and smartphone use," *Strabismus*, vol. 30, no. 2, pp. 59–64, Apr. 2022, doi: 10.1080/09273972.2022.2046113.
- [6] D. C. Agustin, M. A. Rosid, and N. Ariyanti, "Implementasi Convolutional Neural Network Untuk Deteksi Kesegaran Pada Apel," *J. Fasilkom*, vol. 13, no. 02, pp. 145–150, 2023, doi: 10.37859/jf.v13i02.5175.
- [7] G. Rahguna Putri, M. Akbar Maulana, and T. Lestari, "Identifikasi Mata Juling dan Mata Normal Pada Anak Dengan Metode Convolutional Neural Network (CNN)," *Just IT J. Sist. Informasi, Teknol. Inf. dan Komput.*, vol. 13, no. 2, pp. 80–86, 2023, [Online]. Available: <https://jurnal.umj.ac.id/index.php/just-it/index>
- [8] K. Tanvir, A. I. Jony, D. M. K. Haq, D. F. Nazera, A. P. D. M. Dass, and P. D. V. Raju, "Clinical Insights through Xception: A Multiclass Classification of Ocular Pathologies," *Artic. Tuijin Jishu/Journal Propuls. Technol.*, no. November, 2023, doi: 10.52783/tjjpt.v44.i4.2018.
- [9] M. I. Rasyid and L. M. Wisudawati, "Klasifikasi Hama Ulat Pada Citra Daun Sawi Berbasis Convolutional Neural Network Dengan Model Xception," 2024.
- [10] Y. K. Bintang and H. Imaduddin, "Pengembangan Model Deep Learning Untuk Deteksi Retinopati Diabetik Menggunakan Metode Transfer Learning," *JIPi (Jurnal Ilm. Penelit. dan Pembelajaran Inform.*, vol. 9, no. 3, pp. 1442–1455, 2024, doi: 10.29100/jipi.v9i3.5588.
- [11] Buyung Reza Muhammad, Andri Nugraha, Eti Suliyawati, and Risma Yulyyawati, "Hubungan Durasi Penggunaan Gadget dengan Kejadian Mata Lelah (Asthenopia) pada Remaja SMAN 1 Garut," *J. Ris. Rumpun Ilmu Kesehat.*, vol. 4, no. 1, pp. 173–184, 2025, doi: 10.55606/jurrikes.v4i1.4463.
- [12] M. Nursyam, R. Laela, S. I. Dewi, and P. Indonesia, "DAMPAK RADIASI GADGET TERHADAP KESEHATAN MATA REMAJA," *J. Kesehat. Masy. Indones.*, vol. 1, no. 2, pp. 74–78, 2024.
- [13] M. A. A. Fawwaz, K. N. Ramadhani, and F. Sthevani, "Klasifikasi Ras pada hewan peliharaan menggunakan Algoritma Convolutional Neural Network (CNN)," vol. 8, no. 1, pp. 715–730, 2020.
- [14] W. R. PERDANI, R. MAGDALENA, and N. K. CAECAR PRATIWI, "Deep Learning untuk Klasifikasi Glaukoma dengan menggunakan Arsitektur EfficientNet," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 10, no. 2, p. 322, 2022, doi: 10.26760/elkomika.v10i2.322.
- [15] I. Aryadi and A. Suhendar, "Implementasi Arsitektur Xception Dalam Menentukan Kematangan Tandan Buah Segar Kelapa Sawit," *Jutisi J. Ilm. Tek. Inform. dan Sist. Inf.*, vol. 13, no. 3, 2024, doi: 10.35889/jutisi.v13i3.2337.
- [16] R. Kurniawan, P. B. Wintoro, Y. Mulyani, and M. Komarudin, "Implementasi Arsitektur Xception Pada Model Machine Learning Klasifikasi Sampah Anorganik," *J. Inform. dan Tek. Elektro Terap.*, vol. 11, no. 2, pp. 233–236, 2023, doi: 10.23960/jitet.v11i2.3034.