



Pendekatan *Transfer Learning* untuk Klasifikasi Penyakit Mata Menggunakan Citra dengan *CNN InceptionV3*

Rahmad Gunawan¹, Raihan Fathurrahman², Amelia Ismania Sita Widianingrum³, Febri Issandra⁴, Muhammad Andhika Abdurachman⁵, Yogi Ernanda Putra⁶, Naufal⁷

Email: ¹goengoen78@umri.ac.id, ²210401232@student.umri.ac.id, ³210401246@student.umri.ac.id, ⁴210401265@student.umri.ac.id, ⁵210401264@student.umri.ac.id, ⁶210401228@student.umri.ac.id, ⁷210401060@student.umri.ac.id

^{1,2,3,4,5,6,7}Teknik Informatika, Fakultas Ilmu Komputer, Universitas Muhammadiyah Riau

Diterima: 8 Januari 2025 | Direvisi: 29 April 2025 | Disetujui: 22 Mei 2025
©2020 Program Studi Teknik Informatika Fakultas Ilmu Komputer,
Universitas Muhammadiyah Riau, Indonesia

Abstrak

Penyakit mata merupakan salah satu penyebab utama gangguan penglihatan dan kebutaan di seluruh dunia. Untuk itu, deteksi penyakit mata sangat penting dalam upaya pencegahan kebutaan. Penelitian ini mengembangkan model klasifikasi penyakit mata berbasis *Convolutional Neural Network (CNN)* menggunakan *Transfer Learning* dengan *InceptionV3*. Dataset yang digunakan terdiri dari 1559 gambar, terbagi menjadi 1249 gambar pelatihan dan 310 gambar validasi, dengan 8 kelas penyakit mata. Model dilatih menggunakan 40 *epoch* dengan *Adam optimizer*. Hasil evaluasi menunjukkan akurasi validasi 81,29%. Meskipun performa model baik, beberapa kelas, seperti *hordeolum*, menunjukkan akurasi yang lebih rendah, yang memerlukan perbaikan lebih lanjut. Penelitian ini membuktikan bahwa *Transfer Learning* dengan *InceptionV3* efektif untuk klasifikasi penyakit mata.

Kata kunci: *Klasifikasi penyakit mata, InceptionV3, Transfer Learning*

Transfer Learning Approach for Eye Disease Classification Using Images with CNN InceptionV3

Abstract

Eye diseases are a leading cause of vision impairment and blindness worldwide. Therefore, detection of eye diseases is crucial in the prevention of blindness. This study develops an eye disease classification model based on Convolutional Neural Network (CNN) using Transfer Learning with InceptionV3. The dataset consists of 1559 images, divided into 1249 training images and 310 validation images, covering 8 eye disease classes. The model was trained using 40 epochs with the Adam optimizer. Evaluation results show a validation accuracy of 81.29%. While the model performed well, some classes, such as hordeolum, showed lower accuracy, indicating areas that need further improvement. This study confirms that Transfer Learning with InceptionV3 is an effective approach for eye disease classification.

Keywords: *Eye disease classification, InceptionV3, Transfer Learning*

1. PENDAHULUAN

Mata adalah organ sensorik yang kompleks dengan fungsi utama sebagai alat untuk melihat dan mengenali dunia di sekitar kita. Organ ini memiliki kemampuan luar biasa untuk menangkap dan mengorganisasikan informasi dari lingkungan melalui cahaya yang masuk ke dalamnya. Sebagai salah satu indera utama, mata memainkan peran penting dalam menyerap berbagai informasi visual, yang kemudian diproses oleh otak untuk membantu kita memahami, beradaptasi, dan berinteraksi dengan lingkungan [1]. Berdasarkan data Kementerian Komunikasi dan Informatika, pengguna internet di Indonesia mencapai 167 juta orang atau 89

persen dari total populasi penduduk di Indonesia, berdasarkan pernyataan tersebut diasumsikan bahwa sebagian besar masyarakat Indonesia memiliki beresiko memiliki gangguan penglihatan atau penyakit mata [2].

Deteksi dini penyakit mata adalah langkah krusial dalam mencegah terjadinya gangguan mata yang lebih serius. Melalui identifikasi dan penanganan masalah mata sejak tahap awal, risiko perkembangan penyakit yang lebih parah dapat diminimalkan. Selain itu, deteksi dini juga berperan penting dalam menjaga kesehatan mata secara keseluruhan dan mencegah potensi kehilangan penglihatan yang dapat berdampak signifikan pada kualitas hidup seseorang. Seiring dengan perkembangan deep learning, CNN telah terbukti efektif dalam klasifikasi citra medis, termasuk pada analisis penyakit mata. CNN mampu secara otomatis mempelajari fitur-fitur relevan dari data citra dan mengklasifikasikannya dengan akurasi yang tinggi [3]. Oleh karena itu, penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit mata menggunakan algoritma CNN dengan arsitektur InceptionV3. Penelitian ini diharapkan dapat menunjukkan efektivitas model dalam mendeteksi penyakit mata secara akurat dan efisien, sekaligus mengoptimalkan parameter untuk meningkatkan performa model dalam proses klasifikasi.

CNN adalah metode yang umum digunakan untuk mendeteksi dan mengklasifikasi objek atau jenis penyakit. Dengan menggunakan gambar sebagai input, algoritma ini mampu mengidentifikasi dan membedakan berbagai objek dalam sebuah gambar. Teknik ini dirancang untuk membantu mesin mengenali serta memahami perbedaan antar gambar. Penggunaan CNN untuk klasifikasi penyakit telah diaplikasikan dalam berbagai penelitian sebelumnya [4]. CNN bekerja dengan menggunakan proses konvolusi, di mana filter dengan ukuran tertentu diterapkan pada gambar untuk menghasilkan representasi baru melalui operasi perkalian antara filter dan bagian gambar tersebut. Arsitektur CNN dirancang dengan struktur berlapis yang dimulai dengan fungsi *Sequential*, di mana satu tensor input diproses untuk menghasilkan satu tensor output. Proses klasifikasi data dalam CNN terdiri dari dua tahap utama. Tahap pertama adalah pelatihan, di mana algoritma membangun model klasifikasi dengan mempelajari pola dari data pelatihan. Tahap kedua adalah pengujian, di mana model yang telah dilatih digunakan untuk mengklasifikasikan data uji [5].

Metode CNN memiliki beragam arsitektur, salah satunya adalah *InceptionV3* yang digunakan dalam penelitian ini. Arsitektur ini berawal dari *GoogLeNet* yang dikenal sebagai *InceptionV1*, kemudian disempurnakan melalui berbagai inovasi, termasuk pengenalan batch normalization pada *InceptionV2*. Pengembangan lebih lanjut menghasilkan *InceptionV3* dengan tambahan konsep faktorisasi pada iterasi ketiga. Model ini dirancang untuk mengurangi dimensi pada setiap tahapan proses, sehingga memungkinkan waktu komputasi yang lebih cepat, penggunaan memori yang efisien, dan performa tinggi dalam klasifikasi gambar meskipun dengan kapasitas memori yang terbatas [6].

Sejumlah penelitian sebelumnya telah membahas penggunaan CNN dengan berbagai arsitektur untuk mendeteksi penyakit mata, termasuk katarak. Salah satu studi menunjukkan bahwa penerapan CNN dengan tiga lapisan konvolusi, *optimizer* Adam, dan *dropout* masing-masing sebesar 0,25 serta 0,26 menghasilkan akurasi hingga 93,31% pada data pelatihan dan 95% pada data pengujian. Penelitian lainnya dengan konfigurasi dropout berbeda mencapai akurasi 82,55% pada data pelatihan dan 90% pada data pengujian. Hasil ini membuktikan bahwa kombinasi parameter dan optimasi model memiliki dampak signifikan pada performa klasifikasi [6].

Penelitian sebelumnya menunjukkan bahwa algoritma CNN efektif dalam mengklasifikasi penyakit kronis melalui citra mata, termasuk diabetes, glaukoma, hipertensi, katarak, dan degenerasi makula terkait usia. Dalam penelitian tersebut, dataset awal beresolusi 500x500 piksel diubah menjadi 224x224 piksel untuk efisiensi pemrosesan, kemudian diekstraksi menjadi nilai matriks untuk proses pelatihan dan pengujian. Dengan menggunakan pendekatan transfer learning, akurasi klasifikasi yang dicapai sebesar 81% dengan nilai loss 0,4913. Hasil ini menunjukkan kemampuan CNN dalam mengekstraksi fitur dari citra beresolusi besar secara efektif, meskipun peningkatan akurasi dapat diperoleh dengan memperluas jumlah dataset dan variasi penyakit yang dianalisis [7].

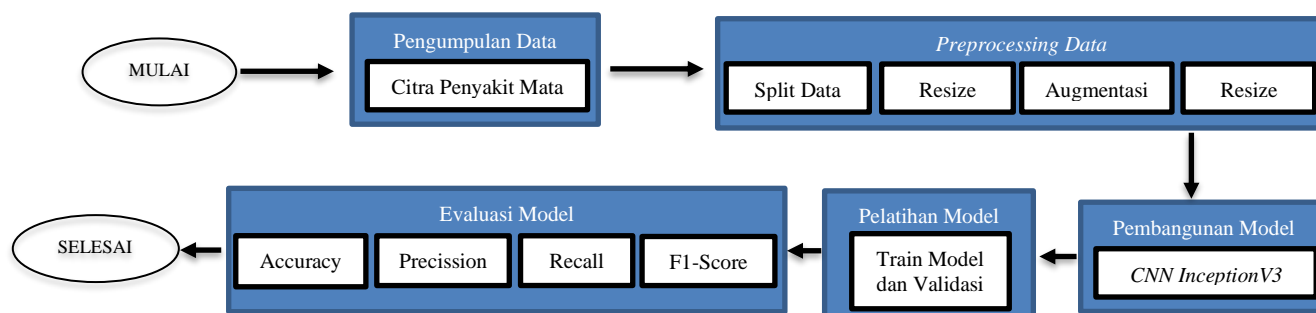
Penelitian yang membahas klasifikasi penyakit mata menggunakan CNN. Penyakit mata yang dianalisis mencakup berbagai jenis gangguan, seperti katarak, glaukoma, dan penyakit pada retina. Studi ini berfokus pada penerapan CNN untuk mengelompokkan penyakit mata, dengan proses pelatihan model yang dilakukan selama 150 epoch. Hasilnya menunjukkan bahwa metode CNN mampu mencapai tingkat akurasi klasifikasi hingga 98,37% [8].

Penelitian tambahan membandingkan performa arsitektur *ResNet-101* dan *InceptionV3* dalam mendeteksi penyakit kulit. Hasil menunjukkan bahwa *InceptionV3* mencapai akurasi 87,42%, yang lebih tinggi dibandingkan *ResNet-101* dengan akurasi 84,09%. Hal ini memperkuat temuan bahwa *InceptionV3* memberikan hasil yang lebih unggul untuk tugas klasifikasi gambar dibandingkan beberapa arsitektur lainnya. Penelitian tambahan membandingkan performa arsitektur *ResNet-101* dan *InceptionV3* dalam mendeteksi penyakit kulit. Hasil menunjukkan bahwa *InceptionV3* mencapai akurasi 87,42%, yang lebih tinggi dibandingkan *ResNet-101* dengan akurasi 84,09%. Hal ini memperkuat temuan bahwa *InceptionV3* memberikan hasil yang lebih unggul untuk tugas klasifikasi gambar dibandingkan beberapa arsitektur lainnya [9].

Berdasarkan berbagai penelitian sebelumnya, *InceptionV3* dipilih dalam penelitian ini karena kemampuannya yang unggul dalam mengekstraksi fitur visual kompleks melalui *Inception modules*, yang memungkinkan analisis detail seperti pembuluh darah retina dan kondisi papil optik pada citra fundus. Dengan efisiensi komputasi melalui lapisan 1×1 *convolution* untuk pengurangan dimensi, *InceptionV3* mampu memproses data secara cepat tanpa mengorbankan akurasi. Arsitektur ini juga telah terbukti memberikan hasil akurasi tinggi pada berbagai tugas klasifikasi gambar medis, menjadikannya pilihan ideal untuk prediksi berbagai penyakit mata. Selain itu, fleksibilitas *transfer learning* dari bobot yang dilatih sebelumnya pada *ImageNet* memungkinkan model untuk beradaptasi dengan dataset medis yang lebih kecil, mendukung diagnosis dini secara efisien dan akurat.

2. METODE PENELITIAN

Metode penelitian ini bertujuan untuk mengembangkan model klasifikasi penyakit mata berbasis citra menggunakan algoritma CNN arsitektur *InceptionV3* dengan pendekatan *Transfer Learning*.



Gambar 1. Diagram Tahapan Penelitian

Pada Gambar 1, dapat dilihat langkah-langkah penelitian meliputi pengumpulan data, preprocessing data, pembangunan model, pelatihan model, serta evaluasi performa model yang diuraikan dibawah ini:

2.1. Pengumpulan Data

Data yang digunakan dalam penelitian ini adalah dataset citra penyakit mata yang diperoleh dari dua sumber, yaitu *Kaggle* dan *Roboflow* [10]. Dari proses pengumpulan data melalui dua sumber tersebut, didapatkan sebanyak 1.559 data citra penyakit mata. Kemudian, data tersebut diorganisasikan ke dalam 8 class yang berisi citra berbagai kondisi penyakit mata, yaitu *Cataract*, *Conjunctivitis*, *Bulging*, *Crossed Eyes*, *Glaucoma*, *Hordeolum*, *Uveitis* dan *Normal*.

2.2. Preprocessing Data

Preprocessing Data merupakan langkah awal yang sangat penting dalam menyiapkan data agar sesuai dengan kebutuhan model yang akan dilatih [11]. *Preprocessing* ini melibatkan beberapa tahapan untuk memastikan data yang masuk ke model dalam kondisi yang baik dan siap diproses, mulai dari *Split Data*, *Resize*, dan *Augmentasi* yang akan diuraikan dibawah ini:

2.2.1. Split Data

Dari total citra penyakit mata yang dikumpulkan sebanyak 1.559 citra, lalu dilakukan pembagian data sebanyak 1.249 citra digunakan untuk pelatihan, dan 310 citra digunakan untuk validasi. Pembagian ini diatur dengan rasio 80% untuk pelatihan dan 20% untuk validasi. Setiap kelas memiliki distribusi citra yang bervariasi. Kelas *normal* dan *glaucoma* memiliki jumlah citra pelatihan terbesar, yaitu masing-masing 250 citra untuk pelatihan dan 60 citra untuk validasi. Kelas *cataract*, *uveitis*, dan *conjunctivitis* memiliki sekitar 150 citra untuk pelatihan, sementara kelas *bulging* dan *crossed* memiliki 100 citra masing-masing.

2.2.2. Resize

Setelah pembagian data, langkah selanjutnya adalah melakukan *resize* pada gambar. *Resize* merupakan suatu proses untuk mengubah ukuran citra menjadi lebih kecil maupun lebih besar dari ukuran sebelumnya [12]. Semua gambar yang berasal dari dataset yang berbeda-beda memiliki ukuran dan resolusi yang bervariasi. Agar model dapat memproses gambar dengan ukuran yang konsisten, semua citra diubah ukurannya menjadi 160×160 piksel, ukuran yang sesuai dengan input yang dibutuhkan oleh model *InceptionV3*. Ukuran ini dipilih karena lebih efisien dalam hal komputasi, sambil tetap mempertahankan informasi yang relevan dalam gambar yang diperlukan untuk klasifikasi.

2.2.3. Augmentasi

Augmentasi adalah proses di mana masing-masing gambar akan diperbanyak dengan cara mengubah sudut pandang gambar (*horizontal flip*), kemiringan gambar (*rotation*), memperbesar fokus gambar (*zoom*), dan melakukan *shift*. Proses ini bertujuan agar model dapat mengenali gambar dalam berbagai posisi [13]. Pada penelitian ini, augmentasi data dilakukan untuk

meningkatkan keberagaman data pelatihan dan mencegah *overfitting*. Teknik augmentasi ini menghasilkan variasi baru dari gambar-gambar yang ada tanpa menambah data secara fisik, yang memungkinkan model untuk belajar dari berbagai variasi gambar yang lebih banyak. Dengan menggunakan teknik augmentasi ini, dataset pelatihan menjadi lebih beragam, sehingga model tidak hanya belajar dari citra yang ada, tetapi juga dari berbagai bentuk dan kondisi gambar yang berbeda. Teknik ini membantu model dalam menggeneralisasi lebih baik pada data yang tidak terlihat sebelumnya, sehingga meningkatkan kemampuannya dalam melakukan prediksi pada data nyata.

2.2.4 Normalisasi

Setelah proses *resize* dan augmentasi selesai, gambar-gambar tersebut dinormalisasi dengan membagi setiap nilai piksel dengan 255, sehingga nilai piksel berada dalam rentang [0,1]. Normalisasi ini dilakukan untuk mengubah skala piksel dari rentang awalnya [0,255] menjadi nilai yang lebih kecil dan seragam. Rentang [0,1] dipilih karena skala ini lebih optimal untuk digunakan dalam pelatihan model neural network, yang sensitif terhadap skala data masukan. Dengan normalisasi ini, model dapat belajar lebih stabil dan cepat, karena nilai masukan yang kecil mencegah gradient dalam jaringan menjadi terlalu besar, yang dapat menghambat proses pelatihan. Normalisasi ini tidak hanya membuat pelatihan lebih stabil, tetapi juga membantu mengurangi dominasi nilai piksel yang lebih besar, sehingga model dapat fokus pada pola dan fitur penting dalam gambar. Pada akhirnya, seluruh proses *preprocessing* ini menghasilkan citra seperti Gambar 2.



Gambar 2. Citra yang telah diproses dengan *resize*, augmentasi, dan normalisasi

2.3. Pembangunan Model

Setelah *preprocessing*, langkah selanjutnya adalah membangun model klasifikasi penyakit mata berbasis citra dengan menggunakan arsitektur *InceptionV3* yang merupakan salah satu arsitektur CNN yang dikembangkan oleh tim peneliti di Google pada tahun 2015. *InceptionV3* adalah pengembangan dari model sebelumnya yang disebut *InceptionV1* dan *InceptionV2*. Tujuan utama dari *InceptionV3* adalah untuk meningkatkan kecepatan komputasi dan kinerja model dalam pengenalan gambar [14]. Model *InceptionV3* dipilih pada penelitian ini karena kemampuannya dalam menangkap berbagai fitur penting dari gambar dengan menggunakan banyak ukuran filter konvolusi dalam satu lapisan, yang memungkinkan model belajar representasi lebih beragam dari citra input.

Dalam penelitian ini, model *InceptionV3* digunakan dengan pendekatan *Transfer Learning*. *Transfer Learning* merupakan metode yang menggunakan *network* yang sudah dilatih sebelumnya dan menggunakannya sebagai titik awal untuk mempelajari tugas baru. Pendekatan ini sangat berguna karena memungkinkan model memanfaatkan pengetahuan yang telah dipelajari dari dataset besar, seperti *ImageNet*, sehingga proses pelatihan pada dataset spesifik menjadi lebih cepat dan efisien. Dengan *Transfer Learning*, *fine-tuning* hanya dilakukan pada lapisan-lapisan terakhir untuk menyesuaikan jaringan dengan dataset penyakit mata. Sementara itu, lapisan awal yang telah dilatih pada dataset besar tetap dipertahankan untuk mengenali fitur dasar seperti tepi, pola, dan tekstur. Langkah ini memungkinkan model untuk langsung memanfaatkan pengetahuan awal, sehingga proses pelatihan tidak hanya lebih cepat tetapi juga menghasilkan akurasi yang lebih baik meskipun dataset yang digunakan relatif kecil [15].

Pada penelitian ini, lapisan-lapisan akhir dari *InceptionV3* diubah dan dilatih ulang untuk mengklasifikasikan gambar ke dalam 8 kelas penyakit mata: *bulging*, *cataract*, *conjunctivitis*, *crossed*, *glaucoma*, *hordeolum*, *normal*, dan *uveitis*. Beberapa lapisan tambahan juga diterapkan setelah lapisan konvolusi dari *InceptionV3*. Pertama, lapisan *Global Average Pooling* (GAP) digunakan untuk mereduksi dimensi fitur menjadi vektor fitur yang lebih sederhana. GAP mengurangi kompleksitas model dengan mengambil rata-rata fitur dalam setiap channel, yang memungkinkan model untuk lebih fokus pada fitur utama yang relevan untuk tugas klasifikasi. Setelah GAP, dense layer dengan 1.024 unit dan fungsi aktivasi *Rectified Linear Unit* (ReLU) ditambahkan. Fungsi *ReLU* merupakan transformasi non-linear yang mempercepat proses pelatihan dengan menghindari masalah *vanishing gradient* [11]. Untuk mencegah *overfitting*, *dropout layer* dengan tingkat 50% diterapkan, di mana sebagian neuron dihilangkan secara acak selama pelatihan. *Dropout* memaksa model belajar pola-pola yang lebih umum dan meningkatkan kemampuan generalisasi model pada data baru.

Lapisan terakhir adalah dense layer dengan 8 unit dan fungsi aktivasi *softmax*. Fungsi *softmax* menghasilkan output berupa probabilitas untuk setiap kelas, di mana kelas dengan probabilitas tertinggi diambil sebagai prediksi. Fungsi ini memastikan bahwa model dapat menangani klasifikasi multi-kelas dengan akurasi yang baik [16]. Kombinasi lapisan-lapisan ini memastikan bahwa model yang dibangun mampu memanfaatkan pengetahuan yang diperoleh dari dataset besar, meningkatkan efisiensi pelatihan, dan menghasilkan prediksi yang akurat. Dengan demikian, *Transfer Learning* berperan penting dalam meningkatkan performa model dengan memanfaatkan dataset yang terbatas secara efektif.

2.4. Pelatihan Model

Pelatihan dilakukan dengan menggunakan *Adam optimizer* dan *learning rate* 0.0001 selama 40 epoch pada data pelatihan. *Fine-tuning* dilakukan pada 100 lapisan terakhir dari model *InceptionV3* dengan *learning rate* 0.00001 untuk menyempurnakan model pada dataset penyakit mata.

2.5. Evaluasi Model


Langkah terakhir merupakan tahap perhitungan untuk mengetahui bagaimana hasil dan seberapa tinggi tingkat akurasi dalam mengklasifikasi citra *Cataract*, *Conjunctivitis*, *Bulging*, *Crossed Eyes*, *Glaucoma*, *Hordeolum*, *Uveitis* dan *Normal*. Adapun parameter yang dihitung untuk mengetahui performa model tersebut antara lain adalah nilai *Accuracy*, *Precision*, *Recall* dan *F1-Score*.

3. HASIL DAN PEMBAHASAN

3.1. Hasil Pelatihan

Pada tahap awal pelatihan, pendekatan *Transfer Learning* diterapkan dengan cara membekukan (freeze) lapisan-lapisan konvolusi dari *InceptionV3*. Ini berarti bobot pada lapisan-lapisan tersebut tidak diperbarui selama pelatihan awal, sehingga model hanya belajar dari lapisan-lapisan baru yang ditambahkan. Hal ini bertujuan untuk memanfaatkan pengetahuan dari dataset *ImageNet* tanpa mengubah fitur dasar yang telah dipelajari.


Selama proses pelatihan, akurasi dan loss pada data pelatihan dan validasi dihitung untuk memantau kinerja model. Pada tahap awal pelatihan, grafik *Training-Validation Accuracy and Loss* memberikan gambaran mengenai bagaimana model berkembang. Gambar 3 menunjukkan *Training and Validation Accuracy* selama pelatihan awal, yang menggambarkan bagaimana akurasi model meningkat pada data pelatihan dan validasi. Meskipun akurasi pada pelatihan meningkat secara signifikan, ada fluktuasi pada akurasi validasi, yang mengindikasikan bahwa model perlu lebih disesuaikan dengan data validasi.



Gambar 3. Training dan Validation Accuracy-Loss pada awal pelatihan

Setelah beberapa *epoch* pelatihan, dilakukan *fine-tuning* pada lapisan-lapisan terakhir dari *InceptionV3*. *Fine-tuning* memungkinkan model untuk menyesuaikan lapisan-lapisan konvolusi yang lebih dalam dengan dataset penyakit mata. Proses ini dilakukan dengan *learning rate* yang kecil (0.00001) untuk memastikan bahwa perubahan bobot yang dilakukan tidak terlalu besar sehingga merusak pengetahuan yang sudah ada. *Fine-tuning* sangat penting untuk meningkatkan kemampuan model dalam menangkap pola-pola spesifik dari dataset penyakit mata yang lebih kecil dan lebih kompleks.


Setelah dilakukan *fine-tuning*, performa model meningkat secara signifikan. Pada Gambar 4 menunjukkan peningkatan akurasi pelatihan dan validasi setelah *fine-tuning*, yang menandakan bahwa model dapat lebih baik menyesuaikan diri dengan dataset penyakit mata. Penurunan lebih lanjut pada nilai loss juga terlihat, yang menunjukkan bahwa model semakin efektif dalam memproses data dan mengurangi kesalahan klasifikasi.



Gambar 4. Training dan Validation Accuracy-Loss setelah fine-tuning

3.2. Hasil Evaluasi

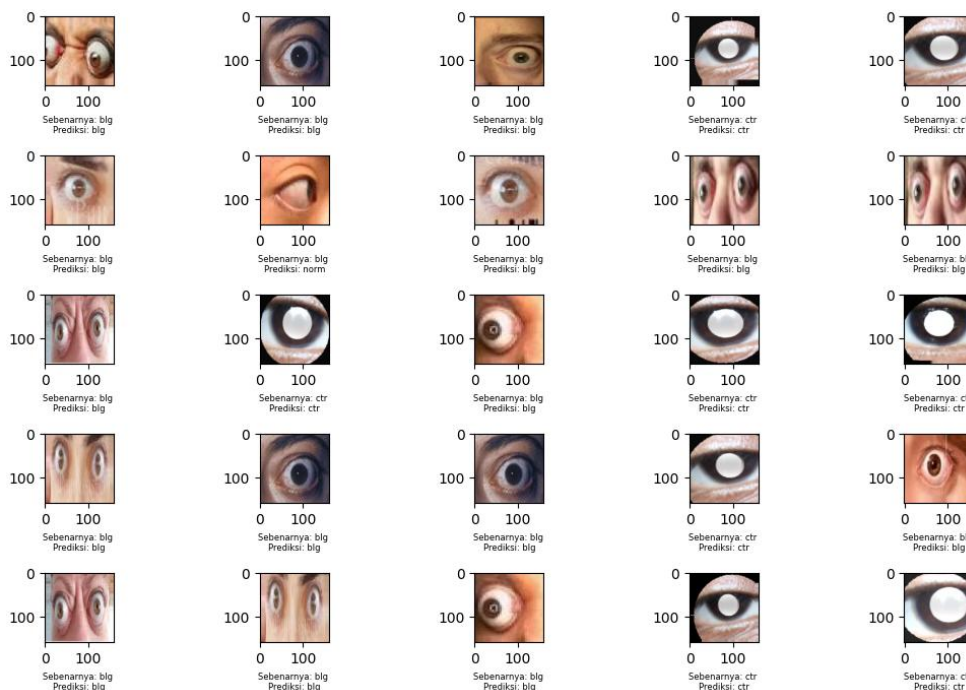
Pada tahap ini, model diuji menggunakan data validasi yang terdiri dari 310 gambar, yang sebelumnya tidak digunakan dalam proses pelatihan. Proses evaluasi dilakukan dengan menghitung beberapa metrik evaluasi seperti *accuracy*, *precision*, *recall*, dan *F1-score*. Selain itu, hasil prediksi divisualisasikan melalui *confusion matrix*. Akurasi model dihitung dengan membandingkan jumlah prediksi yang benar terhadap total prediksi yang dibuat. Berdasarkan hasil evaluasi, model mencapai akurasi validasi sebesar 81,29%, yang menunjukkan bahwa model memiliki kemampuan generalisasi yang cukup baik terhadap data yang tidak terlihat selama pelatihan. Selain itu, *precision* dan *recall* dihitung untuk setiap kelas, memberikan gambaran seberapa baik model dalam mengenali setiap kategori penyakit mata. Untuk memberikan gambaran lebih jelas tentang distribusi prediksi yang benar dan salah, ditampilkan visualisasi *confusion matrix* pada Gambar 5 yang menunjukkan *confusion matrix* hasil prediksi model, di mana elemen diagonal menunjukkan prediksi yang benar untuk setiap kelas, sedangkan elemen di luar diagonal menunjukkan kesalahan klasifikasi.



Gambar 5. Confusion Matrix

Hasil analisis menunjukkan akurasi yang tinggi pada beberapa kelas. Sebagai contoh, untuk kelas *blg*, model berhasil mengklasifikasikan 95% data dengan benar, hanya melakukan satu kesalahan klasifikasi dengan memprediksi gambar sebagai *uvt*. Demikian pula, kelas *glc* memiliki performa yang sangat baik, dengan tingkat akurasi mencapai 96%, menunjukkan bahwa model dapat mengenali pola visual dari kelas ini secara akurat. Namun, model mengalami kesulitan pada beberapa kelas tertentu, seperti *hrd* dan *crs*. Pada kelas *hrd*, hanya 54% data yang diklasifikasikan dengan benar, sementara sisanya salah diprediksi sebagai *norm* atau *cjc*. Hal yang sama terjadi pada kelas *crs*, di mana model hanya mencapai akurasi sebesar 48%, dengan sebagian besar kesalahan prediksi mengarah pada kelas *norm*. Kesalahan ini mengindikasikan adanya kemiripan fitur visual antara kelas-kelas ini, yang menyebabkan model kesulitan untuk membedakan pola spesifik dari setiap kategori. Selain itu, kelas *uvt* menunjukkan tingkat akurasi sebesar 71%, tetapi kesalahan klasifikasi masih terjadi, di mana beberapa data salah diprediksi sebagai *norm* atau kelas lainnya. Visualisasi *confusion matrix* juga mengungkapkan bahwa kelas seperti *ctr* (Cataract) memiliki akurasi sebesar 91%, tetapi ada kesalahan prediksi ke kelas seperti *crs* dan *uvt*.

Selain *confusion matrix*, evaluasi juga dilakukan dengan menampilkan prediksi model pada gambar individual dari data validasi. Gambar 6 memperlihatkan hasil prediksi model pada 25 gambar validasi secara acak, dengan label sebenarnya dan label prediksi yang dihasilkan oleh model. Pada beberapa gambar, terlihat bahwa prediksi model sesuai dengan label sebenarnya, sedangkan pada beberapa gambar lainnya, prediksi model salah. Visualisasi ini memberikan pemahaman lebih mendalam tentang bagaimana model memproses gambar individual dan membantu mengidentifikasi jenis gambar yang sering salah diklasifikasikan.



Gambar 6. Prediksi individual pada 25 gambar validasi dengan label sebenarnya dan prediksi

Secara keseluruhan, analisis ini menunjukkan bahwa model memiliki kemampuan yang cukup baik dalam mengenali pola-pola visual pada beberapa kategori penyakit mata. Namun, terdapat beberapa kelemahan dalam membedakan kelas yang memiliki fitur visual serupa, seperti *hrd* dan *norm*. Hasil ini memberikan wawasan penting untuk meningkatkan performa model seperti dengan menambahkan data pelatihan yang lebih beragam atau menggunakan teknik augmentasi yang lebih kompleks untuk kelas-kelas dengan performa rendah.

4. KESIMPULAN

Penelitian ini mengembangkan model klasifikasi penyakit mata berbasis citra menggunakan pendekatan *Transfer Learning* dengan *InceptionV3*. Model diuji menggunakan data validasi sebanyak 310 gambar, dan menghasilkan *accuracy* sebesar 81,29%, dengan *precision*, *recall*, dan *F1-score* yang bervariasi pada setiap kelas. Secara keseluruhan, hasil ini menunjukkan bahwa pendekatan *Transfer Learning* efektif untuk klasifikasi penyakit mata dan memiliki potensi untuk diimplementasikan dalam sistem deteksi penyakit mata.

DAFTAR PUSTAKA

- [1] C. W. Djajanti, P. A. Sukmanto, and I. K. Wardhani, "Penyuluhan Meningkatkan Pengetahuan Remaja Tentang Kesehatan Mata," *Jurnal Keperawatan Muhammadiyah*, vol. 5, no. 1, pp. 248–252, 2020, doi: 10.30651/jkm.v5i1.4208.
- [2] N. Adisty, "Mengulik Perkembangan Penggunaan Smartphone di Indonesia," GoodStats. Accessed: Dec. 10, 2024. [Online]. Available: <https://goodstats.id/article/mengulik-perkembangan-penggunaan-smartphone-di-indonesia-sT2LA>
- [3] Verdy and Ery Hartati, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network Model Resnet-50," *Jurnal Rekayasa Sistem Informasi dan Teknologi*, vol. 1, no. 3, pp. 199–206, 2024, doi: 10.59407/jrsit.v1i3.529.
- [4] D. Marcella, Y. Yohannes, and S. Devella, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network Dengan Arsitektur VGG-19," *Jurnal. Algoritme*, vol. 3, no. 1, pp. 60–70, 2022, doi: 10.35957/algoritme.v3i1.3331.
- [5] Mukhlis Santoso, Sarjon Defit, and Yuhandri, "Penerapan Convolutional Neural Network pada Klasifikasi Citra Pola Kain Tenun Melayu," *Jurnal CoSciTech (Computer Science Information Technology)*, vol. 5, no. 1, pp. 177–184, 2024, doi: 10.37859/coscitech.v5i1.6713.
- [6] E. Andreas and W. Widhiarso, "Klasifikasi Penyakit Mata Katarak Menggunakan Convolutional Neural Network Dengan Arsitektur Inception V3," *MDP Student Conference*, vol. 2, no. 1, pp. 107–113, 2023, doi: 10.35957/mdp-sc.v2i1.3660.
- [7] Mohammad Haydir Awaludin Waskito, Andreas Nugroho Sihananto, and Achmad Junaidi, "Klasifikasi Penyakit Kronis Melalui Mata Menggunakan Algoritma Convolutional Neural Network Dengan Model MobileNet-V3," *Uranus Jurnal Ilmiah Teknik Elektro, Sains dan Informatika*, vol. 2, no. 2, pp. 48–60, 2024, doi: 10.61132/uranus.v2i2.120.
- [8] S. Satria, Sumijan, and Billy Hendrik, "Implementasi Convolutional Neural Network Untuk Klasifikasi Citra KTP-EI," *Jurnal CoSciTech (Computer Science Information Technology)*, vol. 5, no. 1, pp. 169–176, 2024, doi: 10.37859/coscitech.v5i1.6708.
- [9] M. K. Hasan *et al.*, "Cataract Disease Detection by Using Transfer Learning-Based Intelligent Methods," *Computational and Mathematical Methods in Medicine*, vol. 2021, 2021, doi: 10.1155/2021/7666365.
- [10] "Dataset 8 Class Penyakit Mata." [Online]. Available: <https://bit.ly/EyeDiseaseDataset>
- [11] M. Iksan Maulana, M. Martanto, and U. Hayati, "Perbandingan Algoritma Naïve Bayes Dan K-Nearest Neighbors Untuk Klasifikasi Topik Berita Pada Situs Detik.Com," *JATI (Jurnal Mahasiswa. Teknik Informatika.)*, vol. 8, no. 3, pp. 3733–3742, 2024, doi: 10.36040/jati.v8i3.9779.
- [12] F. M. Qotrunnada and P. H. Utomo, "Metode Convolutional Neural Network untuk Klasifikasi Wajah Bermasker," *Prisma (Prosiding Seminar Nasional Matematika)*, vol. 5, pp. 799–807, 2022, [Online]. Available: <https://journal.unnes.ac.id/sju/prisma/article/view/54602/21133>
- [13] A. Herbert, P. Sitohang, T. I. Hermanto, and C. D. Lestari, "KLASIFIKASI JENIS PENYAKIT PADA DAUN TUMBUHAN STROBERI MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK ARSITEKTUR INCEPTIONV3," *JITET (Jurnal Informatika dan Teknik Elektro Terapan)*, vol. 12, no. 3, 2024, [Online]. Available: <https://journal.eng.unila.ac.id/index.php/jitet/article/view/5274/2160>
- [14] A. W. Kosman, Y. Wahyuningsih, and F. Mahendrasusila, "Pengujian Metode Inception V3 dalam Mengidentifikasi Penyakit Kanker Kulit," *Jurnal Teknologi Informasi dan Komputer*, vol. 10, no. 1, pp. 136–146, 2024.
- [15] D. Martomanggolo, "Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih," *Ultimatics: Jurnal Teknik Informatika*, vol. 13, no. 1, p. 51, 2021, [Online]. Available: <https://ejournals.umn.ac.id/index.php/TI/article/view/2040/1107>
- [16] F. Mustakim, F. Fauziah, and N. Hayati, "Algoritma Artificial Neural Network pada Text-based Chatbot Frequently Asked Question (FAQ) Web Kuliah Universitas Nasional," *JTIK (Jurnal Teknologi Informasi dan Komunikasi)*, vol. 5, no. 4, p. 438, 2021, doi: 10.35870/jtik.v5i4.261.