

Klasifikasi Mata Katarak dan Mata Normal Menggunakan Algoritma Dasar Convolutional Neural Network (CNN)

Better Swengky¹, M.Hizbul Wathan², Indra Irawan³, Rosaura Aulia⁴

^{1,2,3,4}Politeknik Manufaktur Negeri Bangka Belitung

Penulis Korespondensi : mhizbul@polman-babel.ac.id

Article Information:

Received: May 17, 2025, Accepted: June 05, 2025, Published: July 05 2025

Abstract

Eye diseases encompass a wide range of conditions, from mild visual impairments to complete blindness, with cataracts being one of the leading causes. Despite advances in medical imaging, automated classification of cataract versus normal eye images remains a challenging task. This study proposes a classification method using a Convolutional Neural Network (CNN) to distinguish between cataract-affected eyes and normal eyes accurately. The approach involves collecting and preprocessing a labeled dataset, extracting features such as color and vein patterns (including average RGB values), and training the CNN model with optimized parameters. Experimental results demonstrate that the proposed model achieves a high classification accuracy of 95.1%. These findings indicate that CNN-based image classification is a promising tool for supporting automated cataract detection and early diagnosis.

Keywords: Classification, CNN, Deep Learning, Cataract and Normal Eyes.

1. Pendahuluan

Gangguan penglihatan merupakan masalah kesehatan global yang semakin meningkat dan berdampak langsung terhadap kualitas hidup penderitanya. Salah satu penyebab utama kebutaan adalah katarak, yaitu kekeruhan pada lensa mata yang menyebabkan penurunan fungsi penglihatan secara progresif [1]. Penyakit ini masih menjadi tantangan besar, terutama di wilayah dengan akses terbatas ke layanan kesehatan spesialis [2].

Proses diagnosis katarak saat ini masih sangat bergantung pada pemeriksaan manual oleh dokter spesialis mata. Keterbatasan jumlah tenaga ahli dan lamanya proses pemeriksaan menyebabkan keterlambatan deteksi dini dan penanganan [3]. Oleh karena itu, pengembangan sistem diagnosis otomatis yang cepat dan akurat berbasis kecerdasan buatan menjadi sangat penting.

Salah satu pendekatan paling menjanjikan dalam sistem pengenalan pola visual adalah Convolutional Neural Network (CNN), yang telah terbukti efektif dalam mengolah citra medis untuk mendeteksi berbagai penyakit mata seperti glaukoma, retinopati diabetik, dan degenerasi makula [5]. CNN memiliki kemampuan dalam mengekstraksi fitur visual kompleks seperti gradasi warna, bentuk pupil, dan distribusi kontras [6].

Namun demikian, efektivitas CNN sangat bergantung pada ketersediaan data pelatihan yang

memadai. Dalam kondisi data terbatas, teknik augmentasi data menjadi sangat penting. Salah satu teknik yang banyak digunakan adalah Generative Adversarial Network (GAN) yang memungkinkan penciptaan citra sintetis untuk meningkatkan keragaman dataset [3]. GAN telah dimanfaatkan untuk meningkatkan deteksi citra cacat pada industri yang aplikasinya kini mulai dikembangkan dalam bidang medis [4].

Penggunaan GAN dalam sistem klasifikasi citra medis juga telah diterapkan untuk deteksi anomali dalam dataset kecil [7], serta dalam segmentasi massa payudara dari citra X-ray menggunakan pelatihan adversarial [8]. Untuk mengatasi keterbatasan data pencitraan ultrasonografi, dikembangkan pula speckle-based augmentation yang terbukti efektif [9]. Dalam bidang oftalmologi, diagnosis retinopati diabetik dengan pendekatan semi-supervised berbasis multichannel GAN menunjukkan hasil klasifikasi yang menjanjikan [10]. Bahkan, simulasi berbasis geostatistik digunakan untuk menghasilkan citra medis sintetis yang menyerupai kondisi nyata [11].

Selain perluasan data, peningkatan performa CNN juga bergantung pada struktur jaringan dan teknik pelatihan seperti regularisasi dropout, forward-backward pass, dan penggunaan residual block. Pendekatan semi-otomatis dalam pelabelan dan pelatihan adversarial terbukti efektif untuk segmentasi citra medis [12]. Arsitektur residual dengan peningkatan konvolusional juga mampu memperbaiki akurasi klasifikasi objek dalam citra satelit [13].

Dalam studi klasifikasi penyakit mata, CNN dikombinasikan dengan teknik augmentasi dan pra-pemrosesan adaptif menghasilkan akurasi tinggi dalam membedakan citra mata normal dan patologis [14]. CNN juga terbukti fleksibel dan efisien dalam domain lain seperti klasifikasi buah jeruk, yang memiliki pola visual kompleks serupa [15].

Berdasarkan tinjauan tersebut, penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model klasifikasi berbasis CNN untuk membedakan citra mata katarak dan mata normal secara otomatis. Dataset diperoleh dari sumber terbuka dan diolah melalui teknik pra-pemrosesan serta augmentasi data untuk meningkatkan performa model. Hasil dari penelitian ini diharapkan dapat menjadi kontribusi nyata dalam pengembangan sistem diagnosis otomatis berbasis citra pada bidang oftalmologi, khususnya dalam deteksi dini penyakit katarak.

2. Tinjauan Literatur

Berbagai metodologi telah dikembangkan untuk mendukung proses klasifikasi dan diagnosis penyakit mata dengan memanfaatkan pendekatan pembelajaran mesin. Penelitian sebelumnya banyak menerapkan beragam teknik klasifikasi, metode ekstraksi fitur, serta dataset khusus yang dikembangkan dari citra fundus dan retinografi [12]. Salah satu pendekatan yang digunakan adalah algoritma klasifikasi berbasis Convolutional Neural Network (CNN), yang divalidasi melalui skema K-Fold Cross Validation untuk memastikan keandalan model. Dalam studi tersebut, klasifikasi difokuskan pada dua jenis penyakit mata, yaitu glaukoma dan retinopati diabetik, dengan tingkat akurasi mencapai 99,89%. Evaluasi model dilakukan menggunakan metrik numerik seperti akurasi, presisi, recall, spesifisitas, dan F1-score yang mendekati nilai sempurna, serta dilengkapi dengan kurva ROC sebagai pendukung analisis performa [13].

Penelitian lain yang juga mengadopsi pendekatan berbasis jaringan syaraf menerapkan strategi residual dan pra-pemrosesan lanjutan untuk meningkatkan kualitas data input. Beberapa teknik yang digunakan mencakup pengurangan wilayah target, histogram equalization adaptif dengan kontras iso-luminan terbatas, serta augmentasi data secara sistematis. Dengan menggunakan dataset publik, penelitian ini berhasil mengklasifikasikan tiga jenis penyakit mata, yaitu glaukoma (GLC), age-related macular degeneration (AMD), dan diabetic retinopathy (DR), dengan akurasi puncak sebesar 91,16% dan rata-rata 85,79%. Spesifisitas masing-masing kategori juga tinggi, yakni 90,06% untuk

mata sehat, 99,63% untuk GLC, 99,82% untuk AMD, dan 91,90% untuk DR [14].

Studi tersebut menjadi landasan utama dalam pengembangan penelitian ini. Untuk meningkatkan presisi klasifikasi, digunakan berbagai jenis dataset dengan pendekatan ensemble stacking sebagai metode penggabungan prediksi akhir. Validasi dilakukan menggunakan data volumetrik dari Optical Coherence Tomography (OCT) yang mencakup 156 mata normal dan 798 mata dengan glaukoma. Nilai rata-rata dari tiga pengujian acak menunjukkan skor Cohen's kappa sebesar 0,839 dan akurasi tertimbang sebesar 0,809, yang mengindikasikan performa yang stabil dan andal [15].

Metode lain yang juga digunakan dalam klasifikasi penyakit mata adalah algoritma Artificial Neural Network (ANN) dengan pendekatan kuantisasi non-uniform terhadap histogram warna yang berasal dari ruang warna Hue, Min, Max, Diff (HMMD). Proses ini mengikuti standar MPEG-7 yang membentuk struktur 32 bin. Selain itu, fitur tekstur Laws diambil dari saluran Sum dalam ruang warna HMMD untuk menjaga keakuratan klasifikasi. Model ini mencapai tingkat akurasi sebesar 75,71%, yang menunjukkan potensi ANN dalam skenario klasifikasi citra medis dengan pendekatan berbasis warna dan tekstur [12].

Pendekatan model GMD (Glaukoma, Miopia, dan Retinopati Diabetik) juga dikembangkan sebagai upaya untuk meningkatkan akurasi klasifikasi penyakit mata. Model ini menggunakan data citra medis baik sintesis maupun non-sintesis yang mencakup 300 kasus dari empat kondisi: glaukoma, miopia, retinopati diabetik, dan mata normal. Hasil eksperimen menunjukkan adanya peningkatan akurasi model secara signifikan, dari 76,58% menjadi 80,45% pada data pelatihan, dan dari 76,42% menjadi 83,74% pada data validasi, menegaskan efektivitas pendekatan tersebut [7].

3. Metode Penelitian

Penelitian ini menggunakan pendekatan klasifikasi citra berbasis Convolutional Neural Network (CNN) untuk membedakan antara citra mata katarak dan mata normal. CNN dipilih karena kemampuannya yang tinggi dalam mengenali pola visual kompleks pada citra, seperti perbedaan warna, tekstur, dan bentuk morfologis yang menjadi ciri khas dari masing-masing kondisi. CNN telah terbukti efektif dalam berbagai studi klasifikasi citra medis maupun non-medis, termasuk pada klasifikasi tanaman berdasarkan morfologi daun [14].

Model CNN yang digunakan dikembangkan dengan menyesuaikan konfigurasi arsitektur dasar, yang terdiri dari beberapa lapisan konvolusi, fungsi aktivasi ReLU, proses pooling, serta lapisan fully connected pada tahap akhir untuk menghasilkan prediksi klasifikasi. Proses pelatihan dilakukan dengan pendekatan supervised learning, di mana model menerima input berupa citra yang telah diberi label (mata katarak atau mata normal) dan menyesuaikan bobot secara bertahap melalui algoritma backpropagation.

Fokus utama dalam pendekatan ini adalah pada ekstraksi fitur visual seperti gradasi warna dan pola area pupil, yang menjadi pembeda utama antara mata katarak dan mata normal. Oleh karena itu, sebelum proses pelatihan dilakukan, data citra terlebih dahulu melalui tahap pra-pemrosesan untuk meningkatkan kualitas input, antara lain dengan melakukan normalisasi warna (rata-rata RGB) dan augmentasi citra untuk memperluas variasi data pelatihan.

Dataset yang digunakan berasal dari sumber terbuka (Kaggle), yang mencakup dua kelas utama: citra mata katarak dan citra mata normal. Dataset dibagi menjadi dua bagian, yakni data pelatihan dan data pengujian, dengan komposisi proporsional. Evaluasi performa model dilakukan menggunakan metrik akurasi, presisi, recall, dan F1-score untuk memastikan efektivitas CNN dalam membedakan kedua jenis citra secara akurat dan konsisten.

3.1 Arsitektur CNN

Arsitektur Convolutional Neural Network (CNN) yang digunakan dalam penelitian ini terdiri dari sejumlah lapisan utama, yaitu lapisan konvolusi, fungsi aktivasi, pooling, dan lapisan fully connected. Tahapan ini disusun untuk mengekstraksi fitur penting dari citra mata yang digunakan dalam proses klasifikasi antara mata katarak dan mata normal.

3.1.1 Convolution Layer

Tahap pertama dalam arsitektur CNN adalah lapisan konvolusi, di mana filter (kernel) diterapkan secara sistematis pada citra input untuk menghasilkan peta fitur (feature map). Jumlah kernel dan ukurannya ditentukan berdasarkan jumlah dan kompleksitas fitur yang ingin diekstrak dari gambar mata.

Operasi konvolusi secara matematis dinyatakan sebagai berikut:

$$s(t) = (x * w)(t) = \sum_{\alpha=-\infty}^{\infty} x(\alpha) \cdot w(t - \alpha)$$

Dengan x sebagai input dan w sebagai kernel (bobot filter). Untuk citra dua dimensi, operasi konvolusi diperluas menjadi:

$$s(i, j) = \sum_m \sum_n I(m, n) \cdot K(i - m, j - n)$$

Dimana I adalah input image, K adalah kernel dan $s(i, j)$ adalah output citra hasil konvolusi pada posisi piksel (i, j) .

3.1.2 Fungsi Aktivasi

Setelah proses konvolusi, diterapkan fungsi aktivasi ReLU (*Rectified Linear Unit*) untuk menambahkan sifat non-linearitas ke dalam model. Fungsi ini membantu model mengenali pola yang lebih kompleks dengan lebih efisien.

3.1.3 Pooling Layer

Pooling dilakukan untuk mereduksi dimensi spasial dari peta fitur sekaligus menjaga fitur utama. Proses ini mengurangi jumlah parameter dan waktu komputasi serta membantu menghindari overfitting. Umumnya digunakan metode max pooling pada penelitian ini.

3.1.4 Perhitungan Volume Output

Dimensi output dari setiap lapisan ditentukan dengan mempertimbangkan beberapa parameter penting, yaitu:

W = ukuran volume citra input

F = ukuran filter (kernel)

P = nilai padding yang digunakan

S = ukuran pergeseran (stride)

Rumus dimensi output:

$$\frac{W - F + 2P}{S} + 1$$

Rumus ini membantu dalam mengatur struktur jaringan agar sesuai dengan ukuran input dan output yang diinginkan.

3.1.5 Lapisan Fully Connected

Setelah beberapa iterasi konvolusi dan pooling, output dari jaringan akan diratakan (*flattened*) dan dimasukkan ke dalam satu atau lebih lapisan *fully connected*. Di sinilah proses klasifikasi akhir dilakukan untuk menentukan apakah citra mata yang diinputkan tergolong ke dalam kelas mata katarak atau mata normal.

3.2 Metode yang Diusulkan

Dalam penelitian ini diklasifikasikan mata yang mengalami katarak dan mata normal menggunakan algoritma Convolutional Neural Network (CNN). Algoritma CNN memiliki konfigurasi yang meniru struktur dan fungsi otak manusia. Penelitian ini dilakukan dengan pendekatan pembelajaran mendalam (*deep learning*), yang telah banyak diterapkan secara luas dalam tugas klasifikasi citra. Evaluasi terhadap akurasi dan nilai loss sangat penting dalam proses pelatihan model, karena keduanya menentukan seberapa optimal hasil yang dapat dicapai. Semua perhitungan dan pengujian model dilakukan secara menyeluruh untuk memastikan hasil yang optimal.

Notasi	Deskripsi
$x^{(i)} \in \mathbb{R}$	Fitur Input
$x^{(i)} \in Y(\text{e.g. } \mathbb{R}, \{0,1\}, \{1, \dots, p\})$	Output
$\theta \in \mathbb{R}^k$	Parameter model
$h_{\theta}: \mathbb{R}^n \rightarrow \mathbb{R}$	Fungsi Hipotesis
$\ell: \mathbb{R} \times Y \rightarrow \mathbb{R}_+$	Fungsi loss

Perhitungan untuk memperoleh hasil optimal dilakukan dengan menggunakan rumus berikut:

$$\text{Minimize } \theta \sum_{i=1}^m \ell(h_{\theta}(x^{(i)}), y^{(i)})$$

Disini diterapkan fungsi hipotesis $h_{\theta}: \mathbb{R}^n \rightarrow \mathbb{R}$ dalam pemrosesan neural network dan menggunakan proses forward pass dan backward pass untuk menghasilkan gradien dari fungsi loss. Untuk menghasilkan output konvolusi, forward pass dihitung dengan melakukan konvolusi antara matriks input dengan sebuah filter, yang dirumuskan sebagai berikut:

$$f: \mathbb{R}^n \rightarrow \mathbb{R}^m$$

$$z_i(x_i) = w_i x_i + b$$

Konfigurasi jaringan saraf konvolusional (CNN) yang digunakan selama fase pelatihan direpresentasikan oleh filter-filter dan istilah bias b CNN terdiri dari sejumlah besar neuron yang serupa satu sama lain dan tersebar di seluruh lapisannya. Hal ini memungkinkan model melakukan komputasi yang lebih luas dengan melibatkan sejumlah besar parameter. Ketika jaringan memproses satu input, khususnya peta fitur (*feature map*), ia menggunakan filter konvolusi untuk menghasilkan peta fitur tambahan. Selama fase pelatihan, filter dan parameter model yang terkait dengan lapisan konvolusi diperbarui melalui proses back-propagation untuk tujuan pembelajaran. Pada saat melakukan backward pass, digunakan dimensi matriks Jacobian yang berukuran $m \times n$ untuk menghitung fungsi $f: \mathbb{R}^n \rightarrow \mathbb{R}^m$ dalam proses backward pass tersebut.

$$\left(\frac{\partial f(x)}{\partial x}\right) \in \mathbb{R}^{m \times n} = \begin{bmatrix} \frac{\partial f_1(x)}{\partial x_1} & \frac{\partial f_1(x)}{\partial x_2} & \dots & \frac{\partial f_1(x)}{\partial x_n} \\ \frac{\partial f_2(x)}{\partial x_1} & \frac{\partial f_2(x)}{\partial x_2} & \dots & \frac{\partial f_2(x)}{\partial x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_m(x)}{\partial x_1} & \frac{\partial f_m(x)}{\partial x_2} & \dots & \frac{\partial f_m(x)}{\partial x_n} \end{bmatrix}$$

Dalam pelatihan CNN, salah satu masalah yang paling umum muncul adalah overfitting selama proses pelatihan. Untuk mengatasi masalah ini, maka digunakan teknik regularisasi. Dengan menggunakan regularizer, berbagai konfigurasi jaringan dapat digabungkan secara efektif sehingga menghasilkan model yang lebih general. Salah satu metode yang digunakan selama fase pelatihan adalah dropout, yang bertujuan untuk menghasilkan jaringan yang lebih kompak. Namun, regulasi dropout ini tidak diterapkan pada saat prediksi selama pelatihan.

Perhatikan fungsi yang direpresentasikan oleh jaringan dengan L lapisan tersembunyi. Fungsi dropout menentukan output pelatihan y -train. Parameter pelatihan meliputi input x dan probabilitas Bernoulli p . Dalam arsitektur feedforward standar, untuk setiap lapisan $l \in \{0, \dots, L-1\}$, terdapat vektor z^l input pada lapisan ke-1, serta vektor y^l output dari lapisan tersebut. Vektor independen r^l dari variabel acak Bernoulli dengan probabilitas p bernilai 1 dan $\hat{y}^l$ digunakan untuk $\hat{y}^l = r^l * y^l$ menentukan output yang "ditempel" (thinned output) dengan perhitungan:

$$z_i^{(l+1)} = z_i^{(l+1)} y^l \theta + z_i^{(l+1)}$$

$$y_i^{(l+1)} = f(z_i^{(l+1)})$$

Untuk menghitung regularizer menggunakan operasi feed-forward dengan rumus sebagai berikut:

$$r_j^l \sim \text{Bernoulli probability } p$$

$$y^l = r^l * y^l$$

$$z_i^{(l+1)} = z_i^{(l+1)} y^l \theta + z_i^{(l+1)}$$

$$y_i^{(l+1)} = f(z_i^{(l+1)})$$

Setiap lapisan dalam lapisan tersembunyi menjalankan proses yang berbeda-beda. Hasil dari proses tersebut bertujuan untuk membedakan sub-jaringan dari jaringan utama yang lebih besar. Turunan dari fungsi *loss fallback* disalurkan melalui sub-jaringan selama proses pelatihan.

3.3 Pengaturan Eksperimental

3.3.1 Ide Utama

Tujuan utama dari penelitian ini adalah menggunakan model algoritma Convolutional Neural Network (CNN) untuk klasifikasi data berlabel melalui metodologi *supervised learning*, dengan menggunakan variabel pelatihan dan target untuk mengkategorikan data ke dalam kelas-kelas yang berbeda. Model klasifikasi ini memanfaatkan algoritma CNN yang memungkinkan klasifikasi cepat dan akurat [14][15].

3.3.2 Dataset

Dataset yang dikumpulkan terdiri dari gambar berukuran 300 x 268 piksel yang diunduh dari

kaggle.com. Selanjutnya membagi dataset yang terdiri dari total 1268 gambar tersebut menjadi dua kategori, yaitu gambar mata normal dan gambar mata katarak. Kedua kategori ini selanjutnya dibagi lagi menjadi dataset pelatihan dan dataset pengujian. Informasi mengenai distribusi dataset dapat dilihat pada tabel berikut.

Table 1 Rincian Distribusi Dataset

Dataset Label	features	
	Training 80,31%	Testing 19,69%
Cataract	208	51
Normal	208	51

3.3.3 Pre Processing

Sebelum tahap pemrosesan, pertama mengumpulkan dan mempersiapkan dataset yang akan digunakan. Dataset berupa data mentah yang belum mampu menghasilkan akurasi yang diinginkan ketika diproses secara langsung. Untuk teknik pra-pemrosesan, menggunakan metode normalisasi rata-rata RGB. Proses augmentasi data diimplementasikan menggunakan bahasa pemrograman Python dengan bantuan pustaka TensorFlow dan augment library[15].


3.3.4 Classification Method

Penelitian ini dimulai dengan pengumpulan dataset yang sudah diberi label yang sesuai, yang berasal dari dua kategori studi kasus mata: mata yang mengalami katarak dan mata normal. Proses vektorisasi dilakukan untuk mengubah data mentah menjadi bentuk vektor melalui metode pengkodean label dan penskalaan fitur, setelah semua data dikumpulkan. Dataset kemudian dibagi menjadi dua bagian: dataset pelatihan yang digunakan untuk mengembangkan atau melatih model dan mengklasifikasikan berbagai variasi, serta dataset pengujian yang digunakan untuk mengevaluasi kinerja atau akurasi model.

4. Hasil dan Pembahasan

4.1 Classification Test

Pada tahap ini ditemukan adanya trade-off antara akurasi dan waktu operasional jaringan yang optimal. Dalam percobaan menggunakan jumlah epoch sebanyak 15 dan batch size sebesar 64. Dari pengujian model diperoleh akurasi lebih dari 95%. Dengan tingkat akurasi tersebut, model yang diusulkan mampu menunjukkan kemampuan komputer dalam mengklasifikasikan citra, baik dalam pengenalan maupun dalam membedakan antara mata katarak dan mata normal. Hasil pengujian tersebut disajikan dalam bentuk diagram berikut:



Gambar 1. Akurasi pelatihan

4.2 Evaluation Matrix

4.2.1 Classification Report


Tabel dibawah ini menyajikan laporan klasifikasi untuk model Basic CNN yang digunakan dalam klasifikasi citra mata katarak dan mata normal. Metrik utama presisi, recall, dan skor F1 diberikan untuk kedua kelas, dengan akurasi keseluruhan sebesar 95% berdasarkan 102 sampel pengujian. Untuk kelas katarak, model mencapai presisi 0,85, recall 0,86, dan skor F1 sebesar 0,85, sedangkan untuk kelas mata normal, model memperoleh presisi 0,86, recall 0,84, dan skor F1 sebesar 0,85. Nilai-nilai ini menunjukkan performa yang seimbang di antara kedua kategori. Rata-rata makro, mikro, dan berbobot semuanya melaporkan skor F1 sebesar 0,85, yang menguatkan stabilitas performa model pada distribusi kelas yang berbeda. Tingginya akurasi sebesar 95% mengindikasikan bahwa model secara efektif dapat membedakan antara mata katarak dan mata normal dengan kesalahan klasifikasi yang minimal. Namun, variasi kecil antara presisi dan recall pada masing-masing kelas menunjukkan adanya beberapa kasus salah klasifikasi yang dapat diperbaiki melalui augmentasi data, penyetelan hiperparameter, atau penggunaan arsitektur yang lebih kompleks untuk meningkatkan ekstraksi fitur.

Table 2 Hasil *classification report*

Classification Report	Precision	Recall	F1-Score	Support
Cataract	0.85	0.86	0.85	51
Normal	0.86	0.84	0.85	51
Accuracy	-	-	0.95	102
micro avg	0.85	0.85	0.85	102
macro avg	0.85	0.85	0.85	102
Weight avg	0.85	0.85	0.85	102
weighted avg	0.85	0.85	0.85	102

4.2.2 Confusion Matrix

Matriks confusion pada Gambar 2 memberikan rincian performa klasifikasi model Basic CNN dalam membedakan antara citra mata katarak dan mata normal. Nilai diagonal (true positives) menunjukkan bahwa 86% (0.86) kasus katarak dan 84% (0.84) kasus normal berhasil diklasifikasikan dengan benar. Nilai off-diagonal (false positives dan false negatives) mengindikasikan bahwa 14% (0.14) gambar katarak salah diklasifikasikan sebagai normal, dan 16% (0.16) gambar normal salah diklasifikasikan sebagai katarak. Hasil ini menunjukkan bahwa model secara keseluruhan memiliki performa yang baik, dengan akurasi tinggi dan klasifikasi yang seimbang antar kedua kelas. Namun, tingkat *missclassification* yang sedikit lebih tinggi pada gambar normal (16%) menunjukkan bahwa model masih memerlukan fine-tuning lebih lanjut untuk meningkatkan sensitivitasnya. Beberapa langkah perbaikan yang mungkin dilakukan termasuk meningkatkan diversitas dataset, memperdalam arsitektur untuk ekstraksi fitur yang lebih baik, atau menerapkan teknik regularisasi guna mengurangi overfitting dan memperbaiki generalisasi model.



Gambar 2. *Confusion Matrix*

5. Kesimpulan

Teknik klasifikasi telah digunakan sejak lama, mulai dari metode konvensional, pembelajaran mesin (machine learning), hingga pembelajaran mendalam (deep learning). Metode klasifikasi konvensional mulai ditinggalkan karena memiliki banyak keterbatasan dalam mengolah dataset besar dan kompleks. Klasifikasi tanaman juga telah banyak dilakukan oleh berbagai peneliti. Namun, sangat sedikit studi yang mengkaji klasifikasi antara mata katarak dan mata normal menggunakan metode konvensional, dan bahkan belum ada yang menggunakan pembelajaran mesin atau pembelajaran mendalam. Dalam penelitian ini, algoritma CNN digunakan untuk membuat model yang mampu membedakan antara mata katarak dan mata normal dengan harapan memperoleh hasil terbaik. Pada eksperimen menggunakan data dalam jumlah besar, melakukan pra-pemrosesan, melatih parameter model dengan tujuan mendapatkan hasil akurasi yang tinggi, kemudian menguji model menggunakan data serupa lainnya.

Dengan penyesuaian beberapa hiperparameter, model yang diusulkan mampu mencapai keseimbangan antara akurasi dan waktu performa. Pada pelatihan model, ditetapkan epoch sebanyak 15, batch size 64, dan rasio validasi sebesar 0,2. Diperoleh hasil uji klasifikasi yang tinggi, yaitu sebesar 95,1%, yang diperoleh dari tabel pengujian klasifikasi. Oleh karena itu diusulkan model ini sebagai solusi yang menjanjikan untuk klasifikasi antara mata katarak dan mata normal.

Sebagai tindak lanjut penelitian ini, peneliti berikutnya dapat melakukan penelitian serupa dengan menggunakan algoritma lain seperti GAN, RNN, SVM, pembelajaran mesin, maupun pembelajaran mendalam, serta mengaplikasikannya pada jenis penyakit mata lain seperti rabun jauh, rabun dekat, dan buta malam. Peneliti berharap eksperimen selanjutnya dapat menghasilkan akurasi yang lebih tinggi dan kualitas yang lebih baik.

Referensi

- [1] O. Bernabe, E. Acevedo, A. Acevedo, R. Carreno, and S. Gomez, "Classification of eye diseases in fundus images," *IEEE Access*, vol. 9, pp. 123456–123470, 2021.
- [2] A. K. Akan, M. A. Genc, and F. T. Yarman Vural, "Just noticeable difference for machines to generate adversarial images," in *Proc. International Conference on Image Processing*

(ICIP), 2020.

- [3] S. K. Venu and S. Ravula, "Evaluation of deep convolutional generative adversarial networks for data augmentation of chest X-ray images," [Online].
- [4] S. Niu, B. Li, X. Wang, and H. Lin, "Defect image sample generation with GAN for improving defect recognition," [Online].
- [5] S. Menon et al., "Generating realistic COVID-19 x-rays with a mean teacher + transfer learning GAN," in Proc. 2020 IEEE International Conference on Big Data (Big Data), 2020.
- [6] X. Zeng, L. W. Xu, and C. Ji, "Generating diagnostic report for medical image by high-middle-level visual information incorporation on double deep learning models," Computer Methods and Programs in Biomedicine, 2020.
- [7] G. J. Horng, M. X. Liu, and C. C. Hsu, "The anomaly detection mechanism using deep learning in a limited amount of data for fog networking," Computer Communications, 2021.
- [8] T. Shen, C. Gou, F. Y. Wang, Z. He, and W. Chen, "Learning from adversarial medical images for X-ray breast mass segmentation," Computer Methods and Programs in Biomedicine, 2019.
- [9] L. Bargsten and A. Schlaefer, "SpeckleGAN: a generative adversarial network with an adaptive speckle layer to augment limited training data for ultrasound image processing," International Journal of Computer Assisted Radiology and Surgery, 2020.
- [10] S. Wang et al., "Diabetic retinopathy diagnosis using multichannel generative adversarial network with semisupervision," IEEE Transactions on Automation Science and Engineering, 2021.
- [11] T. D. Pham, "Geostatistical simulation of medical images for data augmentation in deep learning," IEEE Access, 2019.
- [12] L. Wang, D. Guo, G. Wang, and S. Zhang, "Annotation-efficient learning for medical image segmentation based on noisy pseudo labels and adversarial learning," IEEE Transactions on Medical Imaging, vol. 40, no. 8, pp. 2104–2115, 2021.
- [13] L. Li, C. Wang, H. Zhang, and B. Zhang, "SAR image ship object generation and classification with improved residual conditional generative adversarial network," IEEE Geoscience and Remote Sensing Letters, vol. 19, pp. 1–5, 2022.
- [14] M. M. Islam, A. K. M. S. A. Rabby, H. R. M. Arfin, and S. A. Hossain, "Majedul Md Islam A. K. M. Shahahriar Azad Rabby Hafizur Rahman Md Arfin Syed Akhter Hossain," in Proc. 10th Int. Conf. Computing, Communication and Networking Technologies (ICCCNT), 2019.
- [15] Satria, R. L., & Wathan, M. H. (2023). ConFruit: Effective Fruit Classification Using CNN Algorithm. International Journal of Informatics and Computation, 5(1), 10–18.
<https://doi.org/10.35842/ijicom.v5i1.44>

Copyrights

Copyright for this article is retained by the author(s), with first publication rights granted to the

Published by:

journal.

This is an open-access article distributed under the terms and conditions of the Creative Commons Attribution license (<http://creativecommons.org/licenses/by/4.0/>)

