


**KLASIFIKASI CITRA FUNDUS PENYAKIT KATARAK
MENGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*
BERBASIS WEBSITE**




**THESALONIKA APRILIA
D121201066**

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2024**



Optimized using
trial version
www.balesio.com

**KLASIFIKASI CITRA FUNDUS PENYAKIT KATARAK
MENGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*
BERBASIS WEBSITE**



**THESALONIKA APRILIA
D121201066**



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2024**

**KLASIFIKASI CITRA FUNDUS PENYAKIT KATARAK
MENGUNAKAN CONVOLUTIONAL NEURAL NETWORK
BERBASIS WEBSITE**

**THESALONIKA APRILIA
D121201066**



**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2024**



Optimized using
trial version
www.balesio.com

**KLASIFIKASI CITRA FUNDUS PENYAKIT KATARAK
MENGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*
BERBASIS WEBSITE**

Disusun dan diajukan oleh:

**THESALONIKA APRILIA
D121201066**

Skripsi
sebagai salah satu syarat untuk mencapai gelar sarjana

**PROGRAM STUDI TEKNIK INFORMATIKA
FAKULTAS TEKNIK
UNIVERSITAS HASANUDDIN
GOWA
2024**



Optimized using
trial version
www.balesio.com

SKRIPSI

KLASIFIKASI CITRA FUNDUS PENYAKIT KATARAK
MENGUNAKAN CONVOLUTIONAL NEURAL NETWORK
BERBASIS WEBSITE

THESALONIKA APRILIA
D121201066

Skripsi,

Telah dipertahankan di depan Panitia Ujian Sarjana Teknik Informatika pada
tanggal 2 Oktober 2024 dan dinyatakan telah memenuhi syarat kelulusan

Pada

Program Studi Sarjana Teknik Informatika
Departemen Teknik Informatika
Fakultas Teknik
Universitas Hasanuddin
Gowa

Mengesahkan:
Pembimbing tugas akhir,

Dr. Ir. Ingrid Nurtanio, M.T.
NIP. 19610813 198811 2 001

Mengetahui:
Ketua Program Studi



Prof. Dr. Ir. Indrabayu, ST, MT,
M.Bis.Sys., IPM, ASEAN Eng
NIP. 19750716 200212 1 004



PERNYATAAN KEASLIAN SKRIPSI DAN PELIMPAHAN HAK CIPTA

Dengan ini saya menyatakan bahwa skripsi berjudul "Klasifikasi Citra Fundus Penyakit Katarak Menggunakan *Convolutional Neural Network* Berbasis Website" adalah benar karya saya dengan arahan dari pembimbing Dr. Ir. Ingrid Nurtanio, M.T. Karya ilmiah ini belum diajukan dan tidak sedang diajukan dalam bentuk apa pun kepada perguruan tinggi manapun. Sumber informasi berasal atau dikutip dari karya yang diterbitkan maupun tidak diterbitkan dari penulis lain telah disebutkan dalam teks dan dicantumkan dalam daftar pustaka skripsi ini. Apabila dikemudian hari terbukti atau dapat dibuktikan bahwa sebagian atau keseluruhan skripsi ini karya orang lain, maka saya bersedia menerima sanksi atas perbuatan tersebut berdasarkan aturan yang berlaku. Dengan ini saya melimpahkan hak cipta (hak ekonomis) karya tulis saya berupa skripsi ini kepada Universitas Hasanuddin.

Gowa, 2 Oktober 2024



Thesalonika Aprilia
NIM D121201066



UCAPAN TERIMA KASIH

Puji syukur kehadiran Tuhan Yang Maha Esa yang telah memberikan rahmat dan penyertaan-Nya sehingga penulis dapat menyelesaikan tugas akhir yang berjudul “Klasifikasi Citra Fundus Penyakit Katarak Menggunakan Convolutional Neural Network Berbasis Website” yang disusun guna memenuhi salah satu persyaratan dalam menyelesaikan Studi Kesarjanaan (S1) di Departemen Teknik Informatika, Fakultas Teknik Universitas Hasanuddin. Penulis menyadari banyak hal hambatan dan tantangan yang dihadapi, namun dengan kesabaran dan keikhlasan serta bantuan dan bimbingan berbagai pihak sehingga skripsi ini dapat terselesaikan. Oleh karena itu, dengan ketulusan hati penulis ingin mengucapkan rasa terimakasih yang sebesar-besarnya kepada:

1. Tuhan Yesus Kristus atas rahmat, kasih, dan penyertaanNya yang tidak pernah putus kepada penulis.
2. Orang tua dan saudara penulis yang selalu mendoakan, memberikan dukungan, serta membantu baik secara materi maupun non-materi, sehingga penulis dapat menyelesaikan skripsi dengan baik.
3. Ibu Dr. Ir. Ingrid Nurtanio., M.T selaku Dosen Pembimbing yang senantiasa memberikan arahan dan meluangkan waktunya selama proses penyusunan skripsi sehingga penulis dapat menyelesaikan tugas akhir dengan baik dari awal hingga selesai.
4. Bapak dan ibu dosen serta staf Departemen Teknik Informatika, Fakultas Teknik, Universitas Hasanuddin.
5. Bapak dan ibu karyawan RS Mata Makassar yang telah mengizinkan dalam pengambilan data serta membantu dan membimbing dalam proses pengambilan data penulis.
6. Teman – teman angkatan Teknik Informatika 2020 dan KMK 2020 yang senantiasa kebersamai penulis selama masa perkuliahan.
7. Tasya yang senantiasa kebersamai dan menjadi tempat berkeluh kesah penulis selama masa perkuliahan.
8. Ngok, Mhs Tanpa Lab, Waddu dan Ber6 yang tidak pernah bosan untuk selalu bersama – sama serta selalu memberikan semangat dan bantuan dalam penyusunan skripsi ini.
9. Dan seluruh pihak-pihak yang telah membantu penulis menyelesaikan tugas akhir ini yang tidak dapat ditulis dan disebutkan namanya satu persatu.

Gowa, Agustus 2024
Penulis



ABSTRAK

THESALONIKA APRILIA. **Klasifikasi Citra Fundus Penyakit Katarak Menggunakan Convolutional Neural Network Berbasis Website** (dibimbing oleh Dr. Ir. Ingrid Nurtanio., M.T.)

Latar Belakang. Katarak adalah penyebab utama gangguan penglihatan global yang mempengaruhi sekitar 94 juta dari 2,2 miliar penderita pada tahun 2023 menurut WHO. Deteksi dini dan klasifikasi akurat sangat penting untuk pengobatan efektif. Convolutional Neural Networks (CNN) menunjukkan potensi besar dalam analisis citra medis, termasuk klasifikasi citra fundus. Citra fundus memberikan gambar yang lebih detail dan jelas dibandingkan dengan citra lainnya. Ketika seseorang menderita katarak maka akan mengalami kekeruhan lensa, menghalangi cahaya dan menghasilkan gambar fundus yang keruh. **Tujuan.** Penelitian ini bertujuan mengembangkan sistem klasifikasi citra fundus katarak menggunakan CNN berbasis website untuk mendukung diagnostik klinis dan meningkatkan aksesibilitas layanan kesehatan. Selain itu, penelitian ini juga bertujuan untuk mengukur performa dari sistem yang telah dibuat melalui lima skenario terkait dengan *tuning hyperparameter*. **Metode.** Metode meliputi pengumpulan dan pra-pemrosesan data, pelatihan model CNN, dan implementasi sistem menggunakan Flask. Data berasal dari Rumah Sakit Mata Makassar dan dataset publik, dengan augmentasi data untuk mengatasi ketidakseimbangan kelas. **Hasil.** Sistem berhasil dikembangkan dengan tingkat akurasi yang tinggi dalam klasifikasi penyakit katarak menjadi lima kelas: katarak imatur, katarak subkapsular, katarak lainnya, normal, dan bukan katarak. Implementasi pada website memungkinkan tenaga medis untuk mengunggah citra fundus dan mendapatkan hasil klasifikasinya. **Kesimpulan.** Model CNN terbaik berhasil diidentifikasi dengan menggunakan tiga lapisan konvolusi, *learning rate* sebesar 0.0001, *batch size* 8, *optimizer Adam*, dan *epoch* 100. Akurasi dari model ini mencapai 96% pada data validasi dan 98% pada data testing.

Kata kunci: katarak, citra fundus, convolutional neural network, klasifikasi, website



ABSTRACT

THESALONIKA APRILIA. **Classification of Cataract Disease Fundus Image Using Website-Based Convolutional Neural Network** (supervised by Dr. Ir. Ingrid Nurtanio., M.T.).

Background. Cataract is the leading cause of global visual impairment affecting an estimated 94 million of the 2.2 billion sufferers by 2023 according to WHO. Early detection and accurate classification are essential for effective treatment. Convolutional Neural Networks (CNN) show great potential in medical image analysis, including fundus image classification. Fundus images provide more detailed and clear images compared to other images. When a person suffers from cataract, they will experience clouding of the lens, blocking light and producing a cloudy fundus image. **Objective.** This research aims to develop a cataract fundus image classification system using web-based CNN to support clinical diagnostics and improve healthcare accessibility. In addition, this study also aims to measure the performance of the system that has been made through five scenarios related to hyperparameter tuning. **Methods.** Methods include data collection and pre-processing, CNN model training, and system implementation using Flask. The data comes from Makassar Eye Hospital and public datasets, with data augmentation to address class imbalance. **Results.** The system was successfully developed with high accuracy in classifying cataract disease into five classes: immature cataract, subcapsular cataract, other cataract, normal, and non-cataract. The implementation on the website allows medical personnel to upload fundus images and get the classification results. **Conclusion.** The best CNN model was identified using three convolution layers, learning rate of 0.0001, batch size 8, Adam optimizer, and epoch 100. The accuracy of this model reached 96% on validation data and 98% on testing data.

Keywords: cataract, fundus image, convolutional neural network, classification, website



Optimized using
trial version
www.balesio.com

DAFTAR ISI

Halaman

HALAMAN SAMPUL DEPAN	i
HALAMAN SAMPUL	ii
HALAMAN JUDUL	iii
HALAMAN PENGANTAR	iv
KLASIFIKASI CITRA FUNDUS PENYAKIT KATARAK	iii
MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK	iii
BERBASIS WEBSITE	iii
PERNYATAAN KEASLIAN SKRIPSI	v
UCAPAN TERIMA KASIH	vii
ABSTRAK	viii
ABSTRACT	ix
DAFTAR ISI	x
DAFTAR TABEL	xii
DAFTAR GAMBAR	xiii
DAFTAR LAMPIRAN	xv
DAFTAR SINGKATAN DAN ARTI SIMBOL	xvi
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	2
1.3 Tujuan	3
1.4 Manfaat	3
1.5 Ruang Lingkup	3
1.6 Teori	3
1.6.1 Citra Fundus	3
1.6.2 Katarak	4
1.6.3 <i>Clustering</i>	5
1.6.4 <i>K-means</i>	5
1.6.5 <i>Neural Network</i>	6
1.6.6 <i>Deep Learning</i>	6
1.6.7 <i>Convolutional Neural Network</i>	6
1.6.8 <i>Optimizer</i>	9
1.6.9 <i>Confusion matrix</i>	10
1.6.10 Akurasi, Presisi, Recall, dan F1-Score	11
1.6.11 Website	12
1.6.12 Flask	12
BAB II METODE PENELITIAN	13
2.1 Tahapan Penelitian	13
2.2 Waktu dan Lokasi Penelitian	14
2.3 Instrumen Penelitian	14
2.3.1 Data	14
2.3.2 Implementasi Sistem	16
2.3.3 Pengembangan Model Klasifikasi	16
2.3.4 Pengembangan Website	24
2.3.5 Uji Pelatihan	25
BAB III PEMBAHASAN	27
3.1 Kesimpulan	27



3.1.1 Hasil Skenario Pertama	27
3.1.2 Hasil Skenario Kedua	30
3.1.3 Hasil Skenario Ketiga.....	32
3.1.4 Hasil Skenario Keempat	33
3.1.5 Hasil Skenario Kelima.....	35
3.1.6 Tahap <i>Testing</i>	39
3.2 Pembahasan.....	44
3.2.1 Skenario Pertama	44
3.2.2 Skenario Kedua	46
3.2.3 Skenario Ketiga.....	48
3.2.4 Skenario Keempat	49
3.2.5 Skenario Kelima.....	50
3.2.6 Pengujian Website	52
BAB IV PENUTUP	53
5.1 Kesimpulan.....	53
5.2 Saran	53
DAFTAR PUSTAKA.....	54
LAMPIRAN	57



DAFTAR TABEL

Nomor	Halaman
1. Tabel 1. Hasil perhitungan confusion matrix pada website.....	43
2. Tabel 2. Perbandingan hasil pengujian parameter learning rate	45
3. Tabel 3. Perbandingan hasil pengujian parameter batch size	46
4. Tabel 4. Perbandingan hasil pengujian parameter optimizer.....	48
5. Tabel 5. Perbandingan hasil pengujian parameter epoch	49
6. Tabel 6. Perbandingan hasil pengujian 3 macam lapisan konvolusi	50



DAFTAR GAMBAR

Nomor	Halaman
1. Contoh citra fundus mata katarak (a) dan citra fundus mata normal (b)	4
2. Struktur lapisan arsitektur CNN secara umum	7
3. Ilustrasi perhitungan pada lapisan konvolusi	7
4. Ilustrasi perhitungan jenis pooling layer	9
5. Ilustrasi lapisan fully connected	9
6. Contoh confusion matrix multiclass	11
7. Confusion matrix dua kelas	11
8. Tahapan penelitian	13
9. Flowchart perancangan sistem	16
10. Hasil pengurutan jarak euclidean citra katarak imatur	17
11. Contoh citra katarak imatur yang direduksi	17
12. Hasil pengurutan jarak euclidean citra katarak subcapsular	18
13. Contoh citra katarak subkapsular yang direduksi	18
14. Hasil pengurutan jarak euclidean citra katarak lainnya	18
15. Contoh citra katarak lainnya yang direduksi	19
16. Hasil pengurutan jarak euclidean citra mata normal	19
17. Contoh citra mata normal yang direduksi	19
18. Hasil pengurutan jarak euclidean citra bukan katarak	20
19. Contoh citra bukan katarak yang direduksi	20
20. Citra fundus dari RS (a) dan citra fundus dari Kaggle (b)	20
21. Hasil citra fundus dari RS (a) dan citra fundus dari Kaggle (b) setelah image processing	22
22. Arsitektur CNN yang digunakan	23
23. Use case diagram	24
24. Tampilan awal web	24
25. Proses kerja sistem di website	24
26. Model dengan tiga <i>Hidden Layer</i> (16, 32, 64)	27
27. Hasil training dengan learning rate 0.01	29
28. Hasil training dengan learning rate 0.001	29
29. Hasil training dengan learning rate 0.0001	29
30. Hasil training dengan learning rate 0.00001	29
31. Grafik perbandingan antara validation loss dan validation accuracy untuk empat nilai learning rate	30
32. Grafik perbandingan antara Testing loss dan Testing accuracy untuk empat nilai learning rate	30
33. Hasil training dengan batch size 8	31
34. Hasil training dengan batch size 10	31
35. Hasil training dengan batch size 12	31
36. Hasil training dengan batch size 16	31
37. Grafik perbandingan antara validation loss dan validation accuracy untuk empat nilai learning rate	31
38. Grafik perbandingan antara Testing loss dan Testing accuracy untuk empat nilai learning rate	32
39. Optimizer Adam	32
40. Optimizer SGD	32
41. Optimizer RMSprop	33



42. Grafik perbandingan antara validation loss dan validation accuracy untuk tiga optimizer	33
43. Grafik perbandingan antara Testing loss dan Testing accuracy untuk tiga optimizer	33
44. Hasil training epoch 50	34
45. Hasil training epoch 70	34
46. Hasil training epoch 100	34
47. Grafik perbandingan antara Testing loss dan Testing accuracy untuk tiga nilai epoch	34
48. Grafik perbandingan waktu training untuk tiga nilai epoch	35
49. Model dengan tiga <i>hidden</i> layer (16, 32, 64)	36
50. Hasil training dengan tiga <i>hidden</i> layer (16, 32, 64)	36
51. Model dengan empat <i>hidden</i> layer (16, 32, 64, 128)	37
52. Hasil training dengan empat <i>hidden</i> layer (16, 32, 64, 128)	37
53. Model dengan empat <i>hidden</i> layer (16, 32, 64, 128, 256)	38
54. Hasil training dengan lima <i>hidden</i> layer (16, 32, 64, 128, 256)	39
55. Grafik perbandingan antara validation loss dan validation accuracy untuk tiga macam lapisan konvolusi	39
56. Grafik perbandingan antara Testing loss dan Testing accuracy untuk tiga macam lapisan konvolusi	39
57. Confusion matrix data Testing	40
58. Hasil klasifikasi benar untuk label bukan katarak	42
59. Hasil klasifikasi benar untuk label bukan katarak imatur	42
60. Hasil klasifikasi benar untuk label katarak lainnya	42
61. Hasil klasifikasi benar untuk label normal	43
62. Hasil klasifikasi benar untuk label katarak subkapsular	43



DAFTAR LAMPIRAN

Nomor	Halaman
1. Dataset.....	58
2. Rincian <i>Source Code Program</i>	61
3. <i>Testing Website CataracDetect (60 Citra)</i>	75
4. Daftar hadir dan berita acara seminar hasil.....	81
5. Daftar hadir dan berita acara ujian skripsi	85
6. Lembar perbaikan skripsi.....	89



DAFTAR SINGKATAN DAN ARTI SIMBOL

Lambang/Singkatan	Arti dan Keterangan
AI	<i>Artificial Intelligence</i>
CNN	<i>Convolutional Neural Network</i>
DL	<i>Deep Learning</i>
3D	<i>Three-dimensional</i>
2D	<i>Two-dimensional</i>
RGB	<i>Red, Green, and Blue</i>
Adam	<i>Adaptive Moment Estimation</i>
SGD	<i>Stochastic Gradient Descent</i>
RMSprop	<i>Root Mean Square Propagation</i>
ReLU	<i>Rectified Linear Unit</i>



BAB I PENDAHULUAN

1.1 Latar Belakang

Perkembangan teknologi dalam bidang kecerdasan buatan (Artificial Intelligence, AI) telah membawa revolusi besar dalam berbagai sektor, termasuk bidang kesehatan. Salah satu aplikasi AI yang paling menonjol adalah penggunaan jaringan saraf tiruan (Neural Networks) untuk diagnosis medis. Teknologi ini memberikan harapan baru dalam mendeteksi dan mengklasifikasikan berbagai kondisi medis. Convolutional Neural Network (CNN) adalah jenis jaringan saraf tiruan yang dirancang khusus untuk analisis citra. CNN telah menunjukkan potensi besar dalam mengklasifikasikan dan mendeteksi berbagai kondisi medis berdasarkan gambar medis, termasuk citra fundus mata yang digunakan untuk mendeteksi katarak (LeCun et al., 2015).

Katarak merupakan kondisi dimana lensa mata mengalami kekeruhan, yang menghambat cahaya untuk sampai ke retina secara jelas, sehingga mengakibatkan penurunan kemampuan penglihatan. Gejala katarak mencakup penurunan ketajaman penglihatan, pandangan yang kabur, perubahan dalam persepsi warna, serta meningkatnya sensitivitas terhadap cahaya atau silau. Selain itu, katarak dapat menyebabkan gejala tambahan seperti diplopia monokular (pandangan ganda) dan perubahan myopik (bergeser menuju rabun jauh), yang kesemuanya berpengaruh pada aktivitas sehari-hari dan kualitas hidup individu yang terkena (Brown, 1993).

Pada tahun 2023, World Health Organization (WHO) menyatakan bahwa gangguan penglihatan diseluruh dunia diperkirakan mencapai 2,2 miliar orang. Dari jumlah tersebut, 94 juta orang menderita katarak. Fakta ini menunjukkan bahwa katarak merupakan penyebab utama gangguan penglihatan jarak jauh atau kebutaan di seluruh dunia. Data ini sejalan dengan temuan nasional terbaru dari Rapid Assessment of Avoidable Blindness tahun 2014 hingga 2016, yang diungkapkan oleh Pusat Data dan Informasi Kementerian Kesehatan Republik Indonesia. Menurut data tersebut, penyebab utama kebutaan dan gangguan penglihatan terbesar pada penduduk berusia di atas 50 tahun di Indonesia adalah katarak yang tidak dioperasi, dengan proporsi sebesar 77,7% (InfoDatin, Kemenkes RI, 2018). Sebagai langkah pencegahan, sangat penting untuk melakukan pemeriksaan mata secara dini jika terdapat keluhan atau gangguan terkait penglihatan (Simanjuntak, 2022).

Sistem perawatan medis saat ini dalam mendeteksi katarak membutuhkan keahlian dokter spesialis mata, yang mendiagnosis dan menilai tingkat keparahan pengalaman klinis mereka (Qiao et al., 2017). Dibandingkan pemeriksaan manual, sistem analisis katarak otomatis dapat menghemat waktu dan biaya (Ali et al., 2022).



Optimized using
trial version
www.balesio.com

dan klasifikasi katarak otomatis saat ini menggunakan tiga jenis gambar, yaitu *B-ultrasound*, dan gambar fundus. Wang et al. (2021) menyatakan bahwa pemeriksaan *B-ultrasound* memiliki beberapa kelemahan dalam

mendeteksi katarak, antara lain kualitas gambar yang sering kali rendah dan memiliki noise tinggi. Selain itu, B-ultrasound sulit membedakan tingkat keparahan katarak karena gambar pada berbagai tahap dapat terlihat sangat mirip.

Berbeda dengan pemeriksaan fundus mata yang dapat memberikan gambar lebih detail dan jelas. Citra fundus adalah gambaran sisi belakang mata, termasuk retina, saraf mata, makula, dan pembuluh darah retina, yang dihasilkan dari mikroskop skala rendah dengan kamera yang terintegrasi (Abramoff & Kay, 2013). Ketika seseorang menderita katarak lensa mata akan mengalami kekeruhan, yang berdampak langsung pada kualitas gambar fundus yang dihasilkan. Seiring berkembangnya katarak, kekeruhan ini dapat menghalangi cahaya yang masuk ke dalam mata, sehingga menghasilkan gambar fundus yang buram atau tidak jelas (Xie et al., 2023).

Dengan mengintegrasikan teknologi CNN, analisis citra fundus mata dapat dilakukan secara otomatis dan cepat, sehingga membuka peluang untuk meningkatkan aksesibilitas layanan kesehatan. Selain itu, penggunaan platform website untuk klasifikasi citra fundus penyakit katarak berbasis CNN akan memudahkan penyebaran dan pemanfaatan teknologi ini secara luas. Dokter dan tenaga medis dapat mengunggah citra fundus pasien ke sistem berbasis website dan mendapatkan hasil klasifikasi secara real-time. Beberapa penelitian telah menunjukkan keberhasilan penggunaan CNN dalam mendeteksi katarak dari citra fundus mata. Misalnya penelitian oleh Andreas & Widhiarso (2023) mengatakan bahwa metode CNN dengan arsitektur InceptionV3 dapat melakukan klasifikasi gambar fundus mata katarak dan mata normal dengan akurasi sebesar 97%. Selain itu, penelitian Ali et al. (2022) menunjukkan bahwa CNN mampu mengklasifikasikan citra fundus mata katarak ringan, sedang, parah atau normal dengan akurasi 96.9%. Penelitian-penelitian ini mendukung pengembangan sistem ini dan diharapkan dapat memberikan kontribusi yang signifikan dalam peningkatan kualitas layanan kesehatan dan penanganan penyakit katarak secara lebih efektif dan efisien.

Oleh karena itu, penelitian ini bertujuan untuk mengembangkan dan mengimplementasikan sistem klasifikasi citra fundus penyakit katarak (imatur, subkapsular, lainnya, normal, dan bukan katarak) menggunakan CNN berbasis website. Dengan adanya sistem ini, diharapkan dapat membantu tenaga medis dalam melakukan diagnosis dini katarak, serta meningkatkan aksesibilitas dan kualitas layanan kesehatan bagi masyarakat luas.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah diuraikan di atas dapat dirumuskan kut:



ncang model CNN untuk klasifikasi penyakit katarak berdasarkan
dengan waktu pemrosesan yang optimal?
rma model CNN dalam melakukan klasifikasi katarak berdasarkan
?

1.3 Tujuan

Adapun tujuan dari penelitian ini adalah:

- Untuk mengimplementasikan deep learning dalam melakukan klasifikasi penyakit katarak menggunakan metode CNN.
- Untuk mengetahui performa model CNN dalam melakukan klasifikasi katarak berdasarkan citra fundus mata.

1.4 Manfaat

Adapun manfaat yang diharapkan dari penelitian ini, sebagai berikut:

- Penelitian ini diharapkan dapat menghasilkan sebuah alat bantu yang dapat digunakan untuk mendukung hasil diagnosa para dokter.
- Bagi pihak lain penelitian ini diharapkan sebagai referensi untuk penelitian selanjutnya.

1.5 Ruang Lingkup

Ruang lingkup dalam penelitian ini adalah:

- Klasifikasi dibatasi pada lima kelas, yaitu katarak imatur, katarak subkapsular, katarak lainnya, normal, dan bukan katarak.
- Metode yang digunakan adalah *Convolutional Neural Network* (CNN).


1.6 Teori

1.6.1 Citra Fundus

Citra fundus dihasilkan melalui pemanfaatan kamera fundus, yang merupakan gabungan dari mikroskop skala rendah dan terdapat kamera yang tergabung di dalamnya. Selama proses pengambilan citra fundus mata, kamera tersebut memungkinkan penangkapan gambar dari sisi belakang mata yang meliputi retina, saraf mata (saraf optikus), makula, dan pembuluh darah retina. Citra fundus ini tercipta melalui proses pemantulan cahaya yang digunakan untuk mendapatkan representasi dua dimensi (2D) dari 3D, semitransparan, dan jaringan retina yang diproyeksikan ke bidang pencitraan. Teknik yang digunakan kamera fundus dalam menghasilkan citra fundus yaitu teknik *color fundus image*. Dalam teknik ini, intensitas citra terdiri dari kombinasi gelombang *Red* (R), *Green* (G), dan *Blue* (B) yang dipantulkan sesuai dengan sensitivitas spectral sensor (Abramoff & Kay, 2013). Berikut merupakan contoh citra

dan mata normal.





Gambar 1. Contoh citra fundus mata katarak (a) dan citra fundus mata normal (b)
(Sumber: <https://www.kaggle.com/datasets/jr2ngb/cataractdataset>)

1.6.2 Katarak

Katarak adalah kondisi di mana lensa mata yang umumnya terlihat jernih dan transparan, mengalami opasifikasi atau kekeruhan (Simargolang & Rahmawati, 2018). Gejala katarak mencakup penurunan ketajaman penglihatan, pandangan yang kabur, perubahan dalam persepsi warna, serta meningkatnya sensitivitas terhadap cahaya atau silau. Selain itu, katarak dapat menyebabkan gejala tambahan seperti diplopia monokular (pandangan ganda) dan perubahan myopik (bergeser menuju rabun jauh), yang kesemuanya berpengaruh pada aktivitas sehari-hari dan kualitas hidup individu yang terkena (Brown, 1993).

Katarak terbagi menjadi dua jenis utama, yaitu katarak kongenital dan katarak senilis. Katarak kongenital adalah kondisi yang terjadi akibat faktor genetik, sedangkan katarak senilis berkembang seiring dengan bertambahnya usia. Katarak senilis merupakan 90% dari semua jenis katarak. Katarak senilis sendiri dibagi menjadi tiga jenis berdasarkan lokasi kekeruhannya, yaitu katarak nuklear, katarak kortikal, dan katarak subkapsular. Selanjutnya, berdasarkan tingkat keparahan atau maturitasnya, katarak dapat diklasifikasikan menjadi empat tahapan, yaitu insipiens, imatur, matur, dan hiper matur (Astari, 2018).

a. Katarak Nuklear

Katarak nuklearis adalah kondisi di mana bagian tengah lensa mata menjadi keruh dan warnanya berubah secara perlahan menjadi kuning atau cokelat. Hal ini dapat menyebabkan penglihatan menjadi sangat kabur. Perubahan warna ini membuat penderita sulit membedakan warna-warna. Katarak nuklearis lebih banyak mempengaruhi penglihatan jauh daripada penglihatan dekat. Seiring waktu, bagian dalam lensa menjadi lebih keras, yang meningkatkan kemampuan lensa untuk suatu kondisi yang disebut miopisasi. Miopisasi ini memungkinkan usia lanjut dan mengalami kesulitan melihat dekat (presbiopia) ia perlu kacamata, dan kondisi ini sering disebut "second sight"



ilar

Katarak ini dapat terjadi di subkapsuler anterior dan posterior. Katarak subkapsular anterior berada tepat di bawah kapsul lensa. Katarak subkapsular posterior terletak tepat di depan kapsul belakang lensa dan terlihat seperti bintik-bintik kecil, butiran, atau plak. Kekeruhan ini tampak hitam ketika diterangi dari belakang. Karena posisinya yang berada di titik pusat mata, katarak subkapsular posterior memiliki dampak yang lebih besar pada penglihatan dibandingkan dengan katarak lainnya (Kanski, 2007).

c. Katarak Kortikal

Katarak kortikal adalah jenis katarak yang terjadi karena proses oksidasi dan penumpukan protein di dalam sel-sel lensa mata. Katarak ini biasanya muncul di kedua mata, tetapi tidak selalu sama antara satu mata dengan yang lain, dan dapat menyebabkan silau saat melihat ke arah cahaya. Penurunan penglihatan bisa terjadi secara perlahan atau cepat. Kerusakan ini bisa membuat lensa menjadi lebih panjang ke depan dan terlihat seperti embun (Astari, 2018).

d. Katarak Imatur

Katarak imatur adalah suatu kondisi mata di mana kekeruhan terjadi pada sebagian lensa mata sehingga masih ditemukan bagian-bagian yang jernih. Keadaan ini dapat mengakibatkan miopia atau rabun jauh (Fuadah et al., 2019). Pada tahap ini, kekeruhan lensa semakin meningkat dan penglihatan mulai menurun. Peningkatan cairan dalam lensa menyebabkan iris terdorong, sehingga ruang anterior mata menjadi dangkal dan sudut ruang anterior mata menjadi sempit (Astari, 2018).

e. Katarak Matur

Katarak matur adalah tahap lanjut dari katarak imatur, di mana seluruh lensa mata menjadi keruh. Jika dibiarkan, penglihatan bisa menurun drastis hingga hanya bisa melihat gerakan tangan dari jarak satu meter, yang setara dengan visus 1/300 (Astari, 2018).

1.6.3 Clustering

Clustering atau klasterisasi adalah teknik atau metode yang digunakan untuk mengelompokkan data. Menurut Tan (2006), *clustering* merupakan proses mengelompokkan data ke dalam beberapa *cluster* atau kelompok sehingga data dalam satu *cluster* memiliki kemiripan yang tinggi, sementara kemiripan antar *cluster* diminimalkan. *Clustering* adalah proses mempartisi sekumpulan objek data ke dalam bagian-bagian yang disebut *cluster*. Objek-objek dalam satu *cluster* memiliki karakteristik yang mirip satu sama lain dan berbeda dengan objek-objek di *cluster* lain. Proses partisi ini tidak dilakukan secara manual, melainkan menggunakan algoritma *clustering* (Irwansyah & Faisal, 2015).



Optimized using
trial version
www.balesio.com

ns adalah metode *clustering* yang paling sederhana dan umum. mengelompokkan data dalam jumlah besar dengan cepat dan efisien. adalah satu metode klasterisasi yang menggunakan metode partisi dengan titik pusat (*centroid*) sebagai dasarnya.

Dalam penerapannya, algoritma *k-means* memerlukan tiga parameter yang sepenuhnya ditentukan oleh pengguna, yaitu jumlah *cluster* k , inisialisasi *cluster*, dan jarak sistem. Biasanya, *k-means* dijalankan secara independen dengan inisialisasi yang berbeda, menghasilkan *cluster* akhir yang bervariasi karena algoritma ini secara prinsip hanya mengelompokkan data menuju *local minimal*. Algoritma *k-means* bekerja secara iterative dengan meningkatkan variasi nilai dalam setiap *cluster*, di mana objek berikutnya ditempatkan dalam kelompok terdekat, dihitung dari titik tengah *cluster*. Titik tengah baru ditentukan setelah semua data ditempatkan dalam *cluster* terdekat (Irwansyah & Faisal, 2015).

1.6.5 Neural Network

Neural network atau jaringan syaraf tiruan adalah metode pertama yang dirancang untuk meniru jaringan syaraf biologis. Model ini dibuat secara berlapis-lapis, sehingga proses pembelajarannya menjadi lebih panjang dan diharapkan dapat meningkatkan ketepatan dan akurasi. Metode ini terinspirasi oleh dua aspek utama otak manusia, yaitu kemampuannya untuk membuat keputusan baru berdasarkan contoh-contoh sebelumnya (Goodfellow et al., 2016).

1.6.6 Deep Learning

Menurut Goodfellow et. al. (2016), pendekatan *machine learning* yang meniru cara kerja otak manusia dikenal sebagai *deep learning* (DL). DL memungkinkan model komputasi yang memiliki beberapa lapisan pemrosesan untuk mempelajari representasi data dengan berbagai tingkat abstraksi.

Algoritma DL biasanya diterapkan pada data yang tidak terstruktur seperti gambar, susunan suara, dan teks. Penggunaan DL meliputi *image and speech recognition*, *potential drug molecule analysis*, *natural language understanding* seperti *topic classification*, *sentiment analysis*, *question answering and language translation* (LeChun, 2015). Menurut Aggarwal (2018), terdapat beberapa model arsitektur dari perkembangan deep learning seperti *Simulating Basic Machine Learning with Shallow Models*, *Radial Basis Function Networks*, *Restricted Boltzmann Machines*, *Recurrent Neural Networks*, *Convolutional Neural Networks*, *Hierarchical Feature Engineering* dan *Pretrained Models*. Khusus untuk manajemen data gambar dalam deep learning, *Convolutional Neural Networks* (CNN) banyak digunakan. CNN secara efektif mengamati data gambar pada setiap tahap dengan bantuan kernel convolutional di dalam CNN (LeCun et al., 2015).




Optimized using
trial version
www.balesio.com

al Neural Network

an *neural network* spesial yang dikembangkan oleh LeCun et.al., telah menunjukkan potensi besar dalam bidang *computer vision* salah satu algoritma dalam *deep learning* yang menerima input mudian belajar melalui penyesuaian bobot dan bias untuk ek dalam gambar tersebut. Metode CNN sangat efektif dalam

pembelajaran gambar dan memberikan hasil yang signifikan dalam pengolahan informasi dari gambar (Nugroho et al., 2020). Tujuan utama CNN adalah mempelajari fitur-fitur tingkat tinggi dari data menggunakan operasi konvolusi (Patterson & Gibson, 2017). Oleh karena itu, CNN sangat cocok digunakan untuk pengenalan dan klasifikasi gambar. CNN terdiri dari beberapa lapisan secara umum, yaitu lapisan *convolutional*, fungsi aktivasi, lapisan *pooling*, dan lapisan *fully connected*.




Gambar 2. Struktur lapisan arsitektur CNN secara umum

a. Convolutional Layer

Berdasarkan penelitian Nayak et al., pada tahun 2020, lapisan ini adalah komponen utama dari CNN. Lapisan ini terdiri dari sekumpulan neuron kernel konvolusi. Setiap neuron dalam lapisan ini bertindak sebagai sebuah kernel konvolusi. Kernel konvolusi bekerja dengan cara membagi data input menjadi beberapa potongan kecil, yang kemudian dikenal sebagai *feature map* (LeCun et al., 2015). Proses lapisan konvolusi dapat dirumuskan sebagai berikut (Khan et al., 2020):

$$G[m,n] = (I * K)[m,n] = \sum_i \sum_k I[i,k]K[m-j,n-k] \quad (1)$$

Output $G[m,n]$ dari proses konvolusi berupa *feature map*, dengan operasi * sebagai operator konvolusi, input *image* direpresentasikan dengan I , kemudian dikalikan dengan K yang menunjukkan kernel atau *filter* dari lapisan konvolusi. Dimana $[i,k]$ adalah elemen input *layer* yang sebelumnya *image* telah dirubah menjadi tensor. Ilustrasi dari proses perhitungannya dapat dilihat pada gambar di bawah ini:



Gambar 3. Ilustrasi perhitungan pada lapisan konvolusi

b. Fungsi Aktivasi

Hasil dari *feature map* dari lapisan sebelumnya diaktifkan terlebih dahulu menggunakan fungsi aktivasi sebelum masuk ke lapisan berikutnya. Fungsi aktivasi ini berperan untuk mempelajari pola dalam gambar dan mempercepat proses *training* (Khan et al., 2020). Secara umum, terdapat dua jenis fungsi aktivasi, yaitu linear dan *nonlinear*. Fungsi aktivasi linear digunakan untuk menangani masalah sederhana, sehingga penerapannya terbatas (Ketkar, 2017). Sementara itu, fungsi aktivasi nonlinear yang sering digunakan adalah sebagai berikut:

1. ReLU

Fungsi aktivasi *Rectified Linear Unit* (ReLU) adalah salah satu fungsi aktivasi yang paling umum digunakan dalam metode CNN. Fungsi aktivasi ReLU adalah fungsi *piecewise non-linear* yang mengubah nilai x negatif menjadi nol dan tetap bernilai x jika nilai x adalah bilangan bulat positif. Fungsi aktivasi ReLU dapat didefinisikan pada persamaan (2) berikut:

$$g(x) = \max(0, x) \quad (2)$$

Persamaan (2) menghasilkan nilai output pada kisaran nilai 0 hingga tak terhingga (Gu et al., 2018). Pada proses *pooling layer*, fungsi aktivasi ReLU ini berfungsi untuk mengurangi ukuran fitur dan sebagai fungsi *non-linear layer-wise down-sampling*.

2. Softmax

Wani (2020) menyatakan bahwa fungsi aktivasi *softmax* adalah fungsi matematika yang menerima input atau masukan vektor dan menghasilkan vektor dalam rentang nilai (0-1). Fungsi *softmax* berguna sebagai *layer* akhir pada *deep neural network*, terutama dalam hal masalah klasifikasi dan klasifikasi multi-kelas. Persamaan (3) berikut menunjukkan fungsi *softmax*:

$$S(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}} \quad (3)$$

Keterangan:

$S(y_i)$: hasil probabilitas

e^{y_i} : eksponensial dari skor logit y_i untuk kelas i .

$\sum_j e^{y_j}$: eksponensial dari skor logit untuk semua kelas j .


Dimana untuk nilai *softmax* $S(y_i)$, e^{y_i} adalah kemungkinan dari output y_j dibagi dengan jumlah dari keseluruhan kemungkinan $\sum_j e^{y_j}$.

c. Pooling Layer


Lapisan *pooling* mengambil *feature map* dari lapisan sebelumnya dan membuat *feature map* baru dengan resolusi yang dipadatkan. Lapisan *pooling* ini berfungsi utama. Pertama adalah untuk mengurangi jumlah parameter atau ukuran untuk mengurangi biaya komputasi. Tujuan kedua adalah *overfitting* (Gholamalizadeh & Khosravi, 2020).



dan *average pooling* adalah jenis *pooling layer* yang paling umum. *pooling* mengambil nilai maksimum dari setiap grid, sedangkan *average pooling* mengambil nilai rata-rata dari setiap grid. Perhitungan untuk kedua ini digambarkan pada gambar di bawah ini.

Gambar 4. Ilustrasi perhitungan jenis *pooling layer*d. *Fully connected layer*

Fully connected layer adalah lapisan terakhir dari CNN, yang berarti setiap dimensi yang dihasilkan dari lapisan sebelumnya dikumpulkan di *fully connected layer*. Pada umumnya, *feature map* yang dihasilkan masih berbentuk multidimensional array, sehingga perlu diflattenkan untuk membuat dimensi matriks menjadi vector berdimensi satu, yang kemudian dapat menjadi input *fully connected layer* (Yamashita et al., 2018).

Gambar 5. Ilustrasi lapisan *fully connected*1.6.8 *Optimizer*

Optimizer digunakan untuk mengoptimalkan langkah kerja model *neural network* untuk mendapatkan hasil yang cepat dan akurat. Untuk mencapai tujuan ini, dilakukan proses optimasi yang bertujuan untuk menentukan parameter bobot dan bias, juga dikenal sebagai *hyperparameter*, di dalam arsitektur CNN. *Hyperparameter* pada model CNN yang tepat memiliki kemampuan untuk mengurangi fungsi *loss* (*gradient descent*) (Dogo et al., 2018). Terdapat beberapa jenis optimasi, antara lain:



Optimized using
trial version
www.balesio.com

Gradient Descent (SGD)

Gradient Descent (SGD) adalah algoritma optimasi fundamental digunakan dalam aplikasi pembelajaran mesin. Algoritma ini dikenal umumnya untuk menangani masalah optimasi skala besar secara efisien dalam skenario di mana fungsi objektifnya adalah jumlah dari kuadrat selisih yang dapat dibedakan dengan banyak variabel (Shen et al., 2020).

SGD bekerja dengan memperbarui parameter model secara iteratif menggunakan gradien fungsi *loss* yang diestimasi dari subset data pelatihan, sehingga membuatnya efisien secara komputasi dan cocok untuk menangani data yang besar (Berrada et al., 2018).

Dalam proses pelatihan SGD, nilai estimasi turunan dari setiap mini-batch dalam kumpulan data yang telah bersesuaian dengan target, yang dihitung pada fungsi *loss* (J) dan dikali dengan learning rate (η) saat mengubah nilai parameter (θ). Persamaan berikut dapat digunakan untuk menulis perhitungan SGD (Goodfellow et al., 2016):

$$\theta = \theta - \eta \nabla J(\theta_t) \quad (4)$$

Keterangan:

θ = parameter bobot, bias, atau fungsi aktivasi dimensi dari output pooling,

η = learning rate

J = *loss function* yang akan dioptimasi

b. *Adaptive Moment Estimation (Adam)*

Optimizer Adam adalah teknik optimasi yang digunakan dalam memperbarui bobot dalam model. Adam merupakan pengembangan dari algoritma SGD klasik, dimana metode ini memperbarui bobot jaringan dengan mempertimbangkan estimasi momen adaptif orde satu dan dua (Kamaludin et al., 2023). Adam dikenal dengan efisiensi dalam komputasi, penghematan penyimpanan, dan fleksibilitasnya dalam menangani masalah optimasi non-konveks pada pembelajaran mesin (Putra et al., 2021). Adam juga merupakan metode optimasi stokastik yang diterapkan pada model CNN untuk memperbarui parameter jaringan untuk mengoptimalkan fungsi objektif (Shafirra & Irhamah, 2020).

c. *Root Mean Squared Propagation (RMSProp)*

RMSprop adalah metode optimisasi yang menggunakan gradien terbaru untuk menormalkan nilai gradien. Ini memungkinkan RMSprop untuk mempertahankan rata-rata bergerak dari nilai akar kuadrat rata-rata (root mean square) dari gradien. RMSprop dikenal sebagai salah satu metode optimisasi yang menjaga rata-rata kuadrat gradien untuk setiap bobot (Witanto et al., 2022).

1.6.9 Confusion matrix

Confusion matrix adalah tabel silang yang mencatat frekuensi kemunculan antara dua nilai, yaitu klasifikasi yang sebenarnya dan klasifikasi yang diprediksi, seperti yang ditunjukkan pada Tabel 2.2. Dalam tabel ini, kolom menunjukkan nilai prediksi model (*predicted classification*), sementara baris menunjukkan nilai dari klasifikasi yang sebenarnya (*actual classification*). Kelas-kelas dicantumkan dalam urutan yang sama di baris dan kolom, sehingga elemen yang diklasifikasikan dengan benar berada pada diagonal utama dari kiri atas ke kanan bawah (Grandini et al., 2020).



		Prediksi			Total
		Kelas	A	B	C
Aktual	A	6	1	0	7
	B	2	8	1	11
	C	0	1	10	11
Total		8	10	11	29

Gambar 6. Contoh *confusion matrix* multiclass

Untuk setiap kelas, *confusion matrix multiclass* akan dibentuk menjadi *confusion matrix 2x2* seperti yang ditunjukkan pada gambar 9. Kemudian dilakukan perhitungan pada parameter TP, FP, FN, dan TN untuk menghitung nilai akurasi, presisi, recall, dan nilai f1.

		Prediksi	
		Positive (1)	Negative (0)
Aktual	Positive (1)	TP	FN
	Negative (0)	FP	TN

Gambar 7. *confusion matrix* dua kelas

Pada *confusion matrix* yang ditampilkan pada gambar 9, terdapat TP, TN, FP, dan FN. True Positives (TP) adalah jumlah kasus dengan label positif yang diprediksi benar sebagai positif. True Negatives (TN) adalah jumlah kasus dengan label negatif yang diprediksi benar sebagai negatif. False Positives (FP) adalah jumlah kasus dengan label negatif yang salah diprediksi sebagai positif. False Negatives (FN) adalah jumlah kasus dengan label positif yang salah diprediksi sebagai negatif.

1.6.10 Akurasi, Presisi, Recall, dan F1-Score

Akurasi, Presisi, *Recall*, dan *F1-Score* adalah metrik penting dalam pemodelan dan evaluasi kinerja model, terutama dalam masalah klasifikasi.

1. Akurasi: mengukur seberapa sering model membuat prediksi yang benar (baik positif maupun negatif) terhadap keseluruhan prediksi yang dilakukan oleh model. Adapun rumus untuk menghitung akurasi dapat dilihat pada persamaan 4 di bawah ini:

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (5)$$

2. Presisi: mengukur seberapa banyak prediksi positif yang benar dari seluruh prediksi positif yang dibuat. Adapun rumus untuk menghitung presisi dapat dilihat an 5 di bawah ini:

$$= \frac{TP}{TP+FP} \quad (6)$$



ity atau True Positive Rate): mengukur seberapa baik model dalam mua kasus positif yang sebenarnya terjadi. Adapun rumus untuk call dapat dilihat pada persamaan 6 di bawah ini:

$$Recall = \frac{TP}{TP+FN} \quad (7)$$

4. *F1-Score*: perpaduan antara presisi dan recall menjadi satu nilai tunggal yang memberikan gambaran seimbang tentang kinerja model. *F1-Score* tinggi menunjukkan keseimbangan yang baik antara presisi dan recall. Adapun rumus untuk menghitung recall dapat dilihat pada persamaan 7 di bawah ini:

$$F1 - score = 2 \times \frac{presisi \times recall}{presisi + recall} \quad (8)$$

1.6.11 Website

Website merupakan kumpulan halaman web yang dapat dijangkau melalui internet, memberikan informasi dan layanan kepada para pengguna (Kurniawan et al., 2022). Informasi yang disajikan dalam website meliputi teks, gambar, video, dan lain-lain. Halaman-halaman tersebut saling terhubung menggunakan hyperlink dan dapat diakses melalui browser. Setiap website memiliki alamat unik yang dikenal sebagai URL (*Uniform Resource Locator*), yang memudahkan pengguna untuk menemukan dan mengakses situs.

1.6.12 Flask

Flask adalah sebuah kerangka kerja web yang ditulis menggunakan bahasa pemrograman Python. Dikategorikan sebagai kerangka kerja mikro, Flask berfungsi sebagai struktur aplikasi dan antarmuka web yang memungkinkan pengembangan aplikasi web dengan cepat (Rusminto et al., 2024). Kelebihan Flask terletak pada kemampuannya untuk membuat pembangunan aplikasi menjadi lebih ringan karena termasuk dalam kategori microframework yang tidak memerlukan library tambahan dan mudah dipahami serta digunakan karena fiturnya yang sederhana namun mampu menangani pembangunan aplikasi web yang kompleks (Budianto & Saian, 2023).

