

BAB II

TINJAUAN PUSTAKA

2.1 Tinjauan Pustaka

2.1.1 Katarak

Gangguan penglihatan yang disebut katarak merupakan kondisi medis di mana lensa mata mengalami perubahan struktural sehingga kehilangan kejernihan. Proses ini mengakibatkan terhalangnya cahaya masuk ke retina, yang secara bertahap menurunkan kualitas visual seseorang (Asmara dkk., 2023). Kekeruhan ini terjadi akibat reaksi biokimia yang memicu koagulasi protein lensa. Katarak dapat bersifat kongenital (terjadi sejak lahir) atau umumnya berkembang akibat proses penuaan (Sari dkk., 2023). Jika tidak segera ditangani, penyakit mata ini berpotensi menyebabkan penurunan tajam penglihatan hingga keadaan buta permanen (Fildzah dkk., 2021). Katarak dapat disebabkan oleh berbagai faktor, termasuk penuaan, faktor genetik, cedera, atau paparan zat beracun. Di antara penyebab tersebut, faktor usia merupakan yang paling umum, di mana gangguan penglihatan berkembang secara bertahap dan progresif akibat pengaruh genetik, lingkungan, asupan gizi, serta kondisi iskemik (Izzuddin dkk., 2022).

Diabetes melitus juga dapat menyebabkan gangguan penglihatan, termasuk kemungkinan berkembangnya katarak. Kondisi ini terjadi akibat peningkatan kadar glukosa yang memicu kekeruhan pada lensa mata. Salah satu dampaknya adalah perubahan pada kapsul lensa yang menjadi keruh dan berkerut. Etiopatogenesis katarak hingga saat ini masih belum dapat dipastikan secara definitif dan diduga

melibatkan berbagai faktor. Penuaan dan diabetes merupakan dua faktor risiko utama yang berkontribusi terhadap perkembangan katarak. Berdasarkan usia, katarak dikategorikan menjadi tiga jenis, yaitu katarak kongenital (sejak lahir), katarak juvenil (terjadi pada usia muda), dan katarak senilis (berkaitan dengan proses penuaan) (Ali Faisal, 2023).

2.1.2 Klasifikasi Citra Digital

Klasifikasi citra digital adalah proses pengelompokan piksel atau elemen gambar dalam suatu citra ke dalam berbagai kelas, di mana setiap kelas merepresentasikan suatu entitas dengan karakteristik tertentu agar dapat dikenali (Herdiansah dkk., 2022). Klasifikasi citra digital memungkinkan komputer meniru kemampuan manusia dalam memahami informasi visual, seperti mengenali objek, pola, atau tulisan tangan dalam sebuah gambar. Dengan teknik ini, komputer dapat mengidentifikasi dan membedakan berbagai elemen dalam citra sebagaimana yang dilakukan oleh penglihatan manusia (A'yunnisa dkk., 2022). Proses klasifikasi citra melibatkan *preprocessing*, ekstraksi fitur, serta pemilihan model klasifikasi menggunakan *machine learning* atau *deep learning*. Setelah pelatihan, model dievaluasi dengan metrik seperti akurasi dan lainnya (Nugroho dkk., 2021). Teknik ini digunakan dalam berbagai bidang, termasuk diagnosis medis.

2.1.3 Convolutional Neural Network (CNN)


Convolutional Neural Network (CNN) adalah jenis jaringan saraf tiruan yang digunakan secara luas dalam pengenalan dan deteksi citra. CNN termasuk dalam *deep learning* yang memiliki keistimewaan dapat mengidentifikasi fitur-fitur gambar secara mandiri, tanpa memerlukan proses ekstraksi fitur manual. Arsitektur

CNN terdiri dari beberapa lapisan penting seperti konvolusi, *pooling*, aktivasi non-linear dan *fully connected* (Rahmadwati dkk., 2024).

Lapisan konvolusi memiliki tugas utama mengekstraksi karakteristik dari gambar input menggunakan filter atau kernel khusus. Setiap filter dalam lapisan ini mampu mengenali pola spesifik, misalnya garis tepi, sudut, atau variasi tekstur. Setelah proses konvolusi selesai, hasilnya akan diteruskan ke lapisan *pooling*, yang memiliki fungsi menurunkan dimensi fitur guna mengurangi beban komputasi dan mencegah terjadinya *overfitting* pada model. Keunggulan utama CNN terletak pada fleksibilitas dan akurasi tinggi dalam mengenali objek, bahkan ketika terdapat variasi posisi atau transformasi gambar. Teknologi ini telah sukses diimplementasikan dalam berbagai bidang, mulai dari pengenalan wajah hingga diagnosis medis (Taye, 2023).

2.1.4 CataractNet

CataractNet adalah sebuah model *deep learning* berbasis *Convolutional Neural Network* (CNN) yang memiliki 16-layer baru dan dirancang khusus untuk mendeteksi katarak secara otomatis. Model ini dikembangkan untuk meningkatkan akurasi deteksi katarak dengan parameter yang lebih sedikit serta biaya komputasi yang lebih rendah dibandingkan model CNN yang lainnya. Ukuran memori model *CataractNet* ini setara dengan ukuran memori sekitar 5.05 MB. Dibandingkan dengan model CNN lainnya seperti *VGG-16*, *AlexNet*, *ResNet*, *DenseNet*, *U-Net*, *GoogleNet*, *MobileNet* dan *EfficientNet*, parameter model *CataractNet* ini adalah yang paling ringan (Junayed dkk., 2021).



Gambar 2. 1 Arsitektur *CataractNet*

Gambar 2.1 menunjukkan arsitektur dalam *CataractNet* yang terdiri dari 16 *layer* dan didalamnya terdapat 4 *Conv2D*, 4 *MaxPooling2D*, 1 *Flatten*, 4 *Dense*, dan 4 *Dropout*. Gambar pertama kali diinputkan dalam bentuk RGB dengan *piksel* gambar 224 x 224 pada *Conv2D*, lalu pada *MaxPooling2D* gambar di *resize* agar mengurangi ukuran yang dibutuhkan. Terakhir ReLU digunakan untuk mengubah nilai matriks negatif menjadi 0. Penggunaan *flatten*, *dense*, *dropout* didesain untuk deteksi pada katarak. *Dense layer* menggunakan struktur 64, 128, 256. *Dropout layer* di *setting* menjadi 0,4, 0,4 dan 0,5 untuk mencegah terjadinya *overfitting* pada model yang digunakan (Junayed dkk., 2021).

2.1.5 *Confusion Matrix*

Salah satu cara untuk menilai kinerja suatu model adalah dengan menghitung nilai akurasi. Dalam penghitungan akurasi, terdapat beberapa istilah dasar yang digunakan, yaitu *true positive*, *true negative*, *false positive* dan *false negative*. Istilah-istilah ini dikelompokkan dalam suatu tabel yang dikenal sebagai *confusion matrix* (I. Wulandari dkk., 2020).

	Negatif (0)	Positif (1)
Negatif (0)	TN	FP
Positif (1)	FN	TP

Gambar 2. 2 *Confusion Matrix*

Pada Gambar 2.2 terdapat istilah sebagai representasi hasil. *True Positive* (TP) terjadi ketika model berhasil mengidentifikasi data positif dengan benar. *False Positive* (FP) muncul ketika model memprediksi data sebagai positif padahal sebenarnya termasuk kelas negatif. Sebaliknya, *True Negative* (TN) adalah kondisi ketika model secara akurat mengenali data sebagai negatif, sementara *False Negative* (FN) terjadi ketika model salah mendeteksi data positif sebagai negatif. (Erbani dkk., 2024). Dari *confusion matrix* ini, berbagai metrik evaluasi dapat dihitung untuk mengukur kinerja model. *Precision* digunakan untuk mengetahui seberapa akurat model dalam memberikan prediksi positif, sedangkan *recall* mengukur sejauh mana model mampu mengenali seluruh data positif yang ada. Selain itu, *accuracy* menunjukkan tingkat kesesuaian keseluruhan antara hasil prediksi dan nilai aktual, sementara *F1-score* menggabungkan *precision* dan *recall* dalam satu ukuran untuk memberikan gambaran menyeluruh mengenai performa model (Borman dkk., 2022). Berikut rumus untuk menghitung *confusion matrix*:

$$Accuracy = \frac{TP+TN}{TP+FN+FP+TN} \quad (1)$$

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

$$Precision = \frac{TP}{TP+FP} \quad (3)$$

$$F1-score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (4)$$

$$Specificity = \frac{TN}{TN+FP} \quad (5)$$

Keterangan :

TP: Jumlah data aktual yang sebenarnya benar dan diprediksi benar

TN: Jumlah data aktual yang sebenarnya salah dan diprediksi salah

FP: Jumlah data aktual yang sebenarnya benar dan diprediksi salah

FN: Jumlah data aktual yang sebenarnya salah dan diprediksi benar

2.1.6 Adam Optimizer

Adam (*Adaptive Moment Estimation*) merupakan salah satu algoritma optimasi yang umum digunakan dalam pelatihan model *deep learning*. Algoritma ini bekerja dengan menyesuaikan *learning rate* secara otomatis untuk setiap parameter berdasarkan estimasi momen pertama dan kedua dari gradien. Dengan demikian, Adam dapat mempercepat proses konvergensi dan menghindari osilasi gradien yang sering terjadi pada metode *Stochastic Gradient Descent* (SGD) konvensional (Sudewo dkk., 2025).

Secara umum, Adam menggabungkan keunggulan dari dua algoritma optimasi sebelumnya, yaitu Momentum dan RMSProp. Momentum mempercepat proses pembaruan bobot dengan mempertahankan arah gradien yang stabil, sedangkan RMSProp menyesuaikan *learning rate* berdasarkan rata-rata kuadrat

gradien terkini. Kombinasi keduanya memungkinkan Adam memperbarui bobot jaringan dengan adaptif, sehingga proses pelatihan menjadi lebih efisien dan stabil (Kartowisastro & Latupapua, 2023).

Keunggulan utama Adam adalah kemampuannya menyesuaikan *learning rate* per parameter, kestabilan dalam pelatihan data besar atau bervariasi, serta kebutuhan penyetelan *hyperparameter* yang relatif sedikit. Oleh karena itu, Adam sering menjadi pilihan *default* dalam berbagai penelitian berbasis CNN, termasuk deteksi citra medis (Sun dkk., 2024).

2.1.7 Grid Search

Grid search adalah metode pencarian sistematis untuk menentukan kombinasi nilai terbaik dari *hyperparameter* model pembelajaran mesin. Metode ini bekerja dengan menyiapkan sekumpulan nilai untuk setiap *hyperparameter*, lalu mencoba setiap kombinasi nilai tersebut secara menyeluruh dan memilih kombinasi yang menghasilkan performa terbaik pada data validasi (A Ilemobayo dkk., 2024). Penggunaan *grid search* memungkinkan penyesuaian *hyperparameter* penting seperti *learning rate*, *batch size*, dan parameter *callback* sehingga meningkatkan kemampuan konvergensi dan generalisasi model. (Belete & Huchaiah, 2022).

2.2 *State of the Art*

Penelitian-penelitian sebelumnya terkait deteksi citra katarak telah berkembang pada beberapa tahun terakhir. Berbagai model diterapkan untuk meningkatkan akurasi pada deteksi citra katarak. *State of the Art* pada Tabel 2.1 menunjukkan beragam penelitian dengan berbagai pendekatan yang telah dikaji untuk menghasilkan akurasi deteksi citra yang lebih akurat.

Tabel 2. 1 *State of the Art*

No	Nama Peneliti/Model	Hasil Penelitian				
		Akurasi	Hasil	Dataset	Kelebihan	Kekurangan
1	(Widyawati dkk., 2025) VGG-16	96.43%	Sistem klasifikasi citra digital katarak	Citra digital kamera	Menggunakan filter kecil (3x3) pada setiap lapisan konvolusi dan menerapkan ReLU untuk memperkenalkan non-linearitas.	Tidak dijelaskan lebih lanjut terkait penerapan model VGG-16.
2	(Mulyasari dkk., 2024) <i>Alex-Net</i>	88%	Sistem klasifikasi citra fundus katarak	Fundus	Pengujian dengan berbagai parameter <i>resize</i> citra, optimisasi Adam, Nadam, dan RMSprop, nilai <i>learning rate</i> , nilai <i>epoch</i> , dan nilai <i>batch size</i> .	Dataset dibagi 4 kelas, sehingga data tidak seimbang.

No	Nama Peneliti/Model	Hasil Penelitian				
		Akurasi	Hasil	Dataset	Kelebihan	Kekurangan
3	(Wardhani dkk., 2024) <i>Convolutional Neural Network</i> dan <i>K-Nearest Neighbor</i>	94,03%	Sistem klasifikasi citra fundus pada penyakit mata	Fundus penyakit mata	Hibrida CNN-KNN memiliki akurasi dengan optimasi, <i>learning rate</i> dan nilai tetangga terdekat lebih baik dibanding CNN murni.	Perlu pertimbangan penggunaan <i>hyperparameter</i> pada model CNN-KNN guna meningkatkan akurasi.
4	(Rachmawanto dkk., 2024) <i>Convolutional Neural Network</i>	95%	Sistem deteksi fundus penyakit mata	Fundus penyakit mata	Mendapatkan hasil akurasi 95%, lebih baik dibandingkan dengan penelitian pembanding yaitu 75% dan 81,33%.	Tidak melakukan augmentasi data pada dataset sehingga memungkinkan <i>overfitting</i> pada model.
5	(V. Wulandari & Putra, 2024) <i>Convolutional Neural Network</i>	94.13%	Sistem deteksi fundus penyakit mata	Fundus penyakit mata	Penggunaan <i>fine tuning</i> mendapatkan hasil yang lebih baik dibandingkan dengan hasil sebelumnya.	Tidak adanya penjelasan lebih lanjut mengenai apa yang diubah saat <i>fine tuning</i> .
6	(Jatmoko dkk., 2024) <i>DenseNet</i> dan <i>EfficientNetB3</i>	78.59%, 95.66%	Sistem deteksi fundus penyakit mata	Fundus pada penyakit mata	Penggunaan <i>split</i> data yang beragam dapat menjadi kelebihan untuk menentukan hasil yang baik dalam pencarian akurasi.	Perbedaan <i>fully connected layer</i> pada 2 algoritma dapat menjadi alasan mengapa salah satu algoritma mendapatkan akurasi lebih rendah.
7	(Ramadhani dkk., 2023) <i>Convolutional Neural Network</i>	92,5%	Sistem klasifikasi citra digital katarak	Citra digital kamera	Perubahan akurasi dan <i>loss</i> pada setiap <i>epoch</i> pada proses pelatihan berjalan dengan sangat baik.	Dataset hanya 612 citra digital dan tidak di augmentasi.

No	Nama Peneliti/Model	Hasil Penelitian				
		Akurasi	Hasil	Dataset	Kelebihan	Kekurangan
8	(Firdaus dkk., 2022) <i>Convolutional Neural Network</i>	93,33%	Sistem aplikasi berbasis <i>web</i>	Citra digital kamera	<i>Loss</i> rendah, tingkat keakuratan tepat.	Dataset tidak dijelaskan lebih lanjut.
9	(Simanjuntak dkk., 2022) CNN, <i>ResNet</i> , <i>GoogleNet</i> dan <i>MobileNet</i>	92%, 93%, 86%, 92%	Sistem klasifikasi citra fundus	Fundus	Layer arsitektur CNN dapat dikatakan sederhana untuk dipergunakan dengan mendapatkan hasil akursi 92%.	Akurasi model yang digunakan tidak lebih baik dari model <i>AlexNet</i> dan <i>CataractNet</i> .
10	(Jayachitra dkk., 2021) <i>DenseNet</i> dan <i>U-Net</i>	89.5%, 93.5%	Sistem klasifikasi citra digital katarak	Citra digital kamera	Menghasilkan sistem secara <i>realtime</i>	Akurasi <i>DenseNet</i> hanya 89,5%, hanya berdasarkan klasifikasi tingkat keparahan katarak dengan 200 dataset.
11	(Junayed dkk., 2021) <i>CataractNet</i>	99.13%.	Sistem klasifikasi citra fundus katarak	Fundus	Tingkat akurasi yang sangat tinggi dan menandingin model CNN yang lainnya.	Dataset yang digunakan hanya dataset fundus.

Penelitian-penelitian pada Tabel 2.1 dan yang dicantumkan pada latar belakang telah menjelaskan terkait efektivitas penggunaan CNN untuk deteksi citra medis seperti yang diterapkan pada penyakit mata yaitu katarak. CNN dengan berbagai modelnya terbukti mampu mendeteksi citra dengan tingkat akurasi tinggi berkisar 86% - 99,13%. Namun terdapat beberapa kekurangan baik terkait model yang diterapkan maupun dataset yang sedikit dan tidak diaugmentasi. Terdapat juga model yang belum ada penelitiannya pada dataset

yang berbeda yaitu dataset citra digital kamera. Melihat dari kekurangan yang terdapat pada penelitian terkait, penelitian ini akan menerapkan *CataractNet* dengan dataset citra digital kamera dan jumlah lebih banyak dengan penerapan augmentasi.

2.3 Matriks Penelitian

Tabel 2.2 merupakan matriks penelitian yang menunjukkan penelitian-penelitian yang telah dilakukan terkait deteksi citra pada penyakit katarak. Pada matriks penelitian ini memberikan informasi terkait penulis, tahun publikasi dan model yang digunakan.

Tabel 2. 2 Matriks penelitian

Penulis	Dataset Penelitian			Ruang Lingkup										
				Penerapan Algoritma										
	Citra Digital Kamera Katarak	Citra Fundus Katarak	Citra Fundus Penyakit Mata	<i>CNN</i>	<i>VGG-16</i>	<i>AlexNet</i>	<i>ResNet</i>	<i>DenseNet</i>	<i>U-Net</i>	<i>GoogleNet</i>	<i>MobileNet</i>	<i>KNN</i>	<i>EfficientNet-B3</i>	<i>CataractNet</i>
(Widyawati dkk., 2025)	✓				✓									
(Mulyasari dkk., 2024)		✓				✓								
(Wardhani dkk., 2024)			✓	✓								✓		
(Rachmawanto dkk., 2024)			✓	✓										
(V. Wulandari & Putra, 2024)			✓	✓										
(Jatmoko dkk., 2024)			✓					✓					✓	
(Ramadhani dkk., 2023)	✓			✓										
(Firdaus dkk., 2022)	✓			✓										
(Simanjuntak dkk., 2022)		✓		✓			✓			✓	✓			

Penulis	Dataset Penelitian			Ruang Lingkup										
				Penerapan Algoritma										
	Citra Digital Kamera Katarak	Citra Fundus Katarak	Citra Fundus Penyakit Mata	<i>CNN</i>	<i>VGG-16</i>	<i>AlexNet</i>	<i>ResNet</i>	<i>DenseNet</i>	<i>U-Net</i>	<i>GoogleNet</i>	<i>MobileNet</i>	<i>KNN</i>	<i>EfficientNet-B3</i>	<i>CataractNet</i>
(Jayachitra dkk., 2021)	✓							✓	✓					
(Junayed dkk., 2021)		✓												✓
Penelitian Ini	✓													✓

Berdasarkan penelitian pada Tabel 2.2, seluruh penelitian sebelumnya memiliki fokus beragam dengan penerapan berbagai arsitektur CNN seperti *VGG-16*, *AlexNet*, *ResNet*, *DenseNet*, *U-Net*, *GoogleNet*, *MobileNet*, *EfficientNet*, dan *CataractNet*. Meskipun model-model tersebut menunjukkan akurasi tinggi, penerapannya masih terbatas pada jenis dataset tertentu. *CataractNet* sendiri memiliki akurasi sangat tinggi, namun hanya diuji pada citra fundus dengan jumlah data 1.187. Oleh karena itu, penelitian ini menerapkan *CataractNet* pada dataset citra digital kamera mata katarak dan normal. Selain memperluas variasi data melalui augmentasi, penelitian ini juga melakukan optimasi *hyperparameter* menggunakan *grid search* untuk memperoleh konfigurasi pelatihan terbaik guna meningkatkan akurasi dan stabilitas model.