



DOI: <https://doi.org/10.38035/jemsi.v6i1>
<https://creativecommons.org/licenses/by/4.0/>

Implementasi *Convolutional Neural Network* (CNN) untuk Deteksi Katarak pada Citra Mata

Yudha Jarod Krisnawan¹, Wahyudi Setiawan²

¹Universitas Trunojoyo, Jawa Timur, Indonesia, 190441100117@student.trunojoyo.ac.id

²Universitas Trunojoyo, Jawa Timur, Indonesia, wsetiawan@trunojoyo.ac.id

Corresponding Author: 190441100117@student.trunojoyo.ac.id¹

Abstract: *This study aims to develop a Convolutional Neural Network (CNN) model capable of detecting cataracts in eye images. Cataracts are the leading cause of blindness in Indonesia and worldwide, characterized by clouding of the eye lens. In this study, 600 eye images were used, comprising 300 normal and 300 cataract images from a public dataset. The images were subjected to preprocessing, including resizing, normalization, and augmentation to increase data variation. The CNN model was built with three convolutional layers, three pooling layers, and two fully connected layers, and trained using the 5-Fold Cross-Validation technique. Hyperparameter optimization involved testing two optimizers, Adam and RMSprop, along with adjustments to the learning rate, batch size, and number of epochs to enhance model accuracy. The results showed that using the Adam optimizer with a learning rate of 0.001, a batch size of 32, and 50 epochs, the CNN model achieved a test accuracy of 97%, precision of 95%, recall of 100%, and an F1-score of 97% in detecting cataracts.*

Keyword: *Convolutional Neural Network (CNN), Cataract, Eye Image Detection*

Abstrak: Penelitian ini bertujuan untuk mengembangkan model *Convolutional Neural Network* (CNN) yang mampu mendeteksi katarak pada citra mata. Katarak adalah penyebab utama kebutaan di Indonesia dan dunia, yang ditandai dengan kekeruhan pada lensa mata. Dalam penelitian ini, digunakan 600 citra mata yang terdiri dari 300 citra mata normal dan 300 citra mata katarak yang diambil dari dataset publik. Data citra melalui *preprocessing* yang mencakup *resizing*, normalisasi, dan augmentasi untuk meningkatkan variasi data. Model CNN dibangun dengan tiga lapisan konvolusi, tiga lapisan *pooling*, dan dua lapisan *fully connected*, serta dilatih menggunakan teknik *5-Fold Cross-Validation*. Optimasi *hyperparameter* dilakukan melalui pengujian terhadap dua *optimizer*, yaitu Adam dan RMSprop, serta penyesuaian *learning rate*, *batch size*, dan jumlah *epoch* untuk meningkatkan akurasi model. Hasil penelitian menunjukkan bahwa dengan kombinasi *hyperparameter optimizer* Adam, *learning rate* 0.001, *batch size* 32, dan jumlah *epoch* 50, model CNN mampu mencapai akurasi pengujian sebesar 97%, *precision* 95%, *recall* 100%, dan *F1-score* 97% dalam mendeteksi katarak.

Kata Kunci: *Convolutional Neural Network (CNN), Katarak, Deteksi Citra Mata*

PENDAHULUAN

Katarak adalah salah satu penyebab kebutaan terbesar di dunia, termasuk di Indonesia, di mana sekitar 1,8% penduduk mengalami gangguan penglihatan akibat katarak. Katarak terjadi ketika lensa mata mengalami kekeruhan yang menghalangi cahaya masuk, sehingga menyebabkan penglihatan buram dan, jika tidak segera diobati, dapat berujung pada kebutaan total (Amin Nurdin et al., 2020). Pada tahun 2020, Organisasi Kesehatan Dunia memperkirakan bahwa lebih dari 100 juta orang di seluruh dunia mengalami penyakit katarak. Sementara itu, di Indonesia, menurut data Riskesdas 2018, katarak menjadi penyebab utama kebutaan pada Masyarakat (Ariani et al., 2023). Mengingat pentingnya masalah ini, diperlukan metode deteksi katarak yang cepat dan akurat untuk mendukung tindakan medis sedini mungkin.

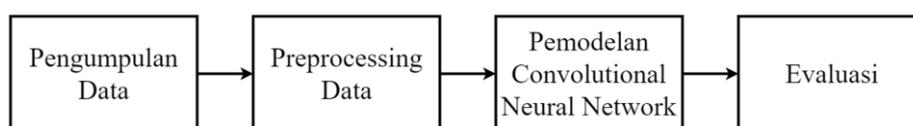
Perkembangan teknologi kecerdasan buatan, khususnya *Convolutional Neural Network* (CNN), menawarkan solusi baru dalam bidang pengenalan citra, termasuk deteksi katarak pada citra mata. CNN telah terbukti efektif dalam mengekstraksi fitur kompleks dari gambar, yang membuatnya unggul dalam tugas-tugas seperti klasifikasi citra dan deteksi objek (Nurona Cahya et al., 2021). Beberapa penelitian sebelumnya menunjukkan bahwa penerapan CNN pada deteksi katarak berhasil mencapai akurasi yang sangat tinggi, dengan model yang mampu mendeteksi katarak secara otomatis pada citra mata (Farahdiva et al., 2023; Nurona Cahya et al., 2021).

Penelitian ini bertujuan untuk mengembangkan model *Convolutional Neural Network* (CNN) yang dapat mendeteksi katarak pada citra mata dengan akurasi tinggi. Dengan optimasi arsitektur dan *hyperparameter*, diharapkan model ini dapat lebih akurat dan efisien dibandingkan metode deteksi tradisional. Hasil penelitian ini diharapkan tidak hanya memberikan kontribusi pada bidang diagnosa medis, tetapi juga menjadi langkah maju dalam pengembangan teknologi berbasis kecerdasan buatan untuk aplikasi di bidang Kesehatan (Pradana et al., 2022; Putra et al., 2021).

Teori pendukung yang digunakan dalam penelitian ini meliputi *Deep Learning*, khususnya arsitektur *Convolutional Neural Network* (CNN), yang dikenal sangat baik dalam mengenali pola visual pada gambar (Setiawan & Damayanti, 2020). CNN bekerja dengan mengekstraksi fitur dari gambar secara bertahap melalui lapisan-lapisan konvolusi dan *pooling*, yang memungkinkan deteksi fitur-fitur yang sulit dikenali oleh metode tradisional. Arsitektur CNN terbagi menjadi dua bagian utama, yaitu *Feature Learning* dan *Classification* (Satoto et al., 2020). CNN juga menggunakan fungsi aktivasi seperti ReLU dan *optimizer* seperti Adam untuk meningkatkan akurasi model (Prasetyo et al., 2023). Penggunaan CNN dalam penelitian ini didasarkan pada kesuksesan metode ini dalam berbagai aplikasi pengenalan citra medis, termasuk deteksi katarak dan gangguan mata lainnya (Hananta Firdaus et al., 2022).

METODE

Penelitian ini merupakan penelitian eksperimental dengan pendekatan kuantitatif, yang terdiri dari empat tahap utama untuk mengembangkan dan menguji model *Convolutional Neural Network* (CNN) dalam mendeteksi katarak pada citra mata. Alur penelitian ini dapat dilihat pada Gambar 1, yang menggambarkan tahapan dari pengumpulan data hingga evaluasi model.



Gambar 1. Alur penelitian

Pengumpulan Data

Tahap pengumpulan data bertujuan untuk memperoleh dataset gambar mata normal dan mata katarak, yang relevan dan memadai untuk pelatihan serta pengujian model. Dataset yang

digunakan dalam penelitian ini diperoleh dari platform Kaggle, terdiri dari 600 citra yang terbagi dalam dua kelas: normal dan katarak. Pembagian dataset ditunjukkan pada Tabel 1.

Tabel 1. Pembagian dataset

Kelas	Latih	Uji	Total
Normal	245	55	300
Katarak	245	55	300

Preprocessing Data

Tahap *preprocessing* dilakukan untuk mempersiapkan dataset agar siap digunakan oleh model. Sebagaimana ditunjukkan dalam kode yang ditampilkan pada Gambar 2, gambar diubah menjadi ukuran 224×224 piksel dan dinormalisasi ke rentang 0 hingga 1 untuk mempercepat konvergensi selama pelatihan. Teknik augmentasi data diterapkan guna meningkatkan variasi data, seperti rotasi hingga 10 derajat, *flipping* horizontal, dan *zoom* hingga 0.5, tanpa mengubah karakteristik fisiologis mata (Andreas et al., 2023). Proses ini bertujuan agar model mampu melakukan generalisasi dengan baik pada data baru.

```
target_size = (224, 224)
datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=10,
    horizontal_flip=True,
    zoom_range=0.5
)
```

Gambar 2. Preprocessing Data

Pemodelan *Convolutional Neural Network*

Model *Convolutional Neural Network* (CNN) dikembangkan dengan beberapa lapisan, meliputi tiga lapisan konvolusi, tiga lapisan *pooling*, dan dua lapisan *fully connected*, yang dirancang untuk mempelajari fitur-fitur citra dan melakukan klasifikasi menjadi dua kategori: normal dan katarak. Proses pelatihan dilakukan menggunakan teknik *5-Fold Cross-Validation*, yang membagi data menjadi 80% pelatihan dan 20% validasi, dengan tujuan memperoleh model dengan performa terbaik dari lima variasi pembagian data serta meminimalkan *overfitting* (Setiawan et al., 2024). Proses pelatihan model juga dioptimalkan melalui beberapa *hyperparameter*, seperti jenis *optimizer* yang digunakan, nilai *learning rate*, *batch size*, serta jumlah *epoch*. Optimasi ini dilakukan untuk mencari kombinasi yang dapat meningkatkan akurasi dan stabilitas model selama pelatihan.

Model ini menerima input gambar berukuran 224×224 piksel dengan 3 *channel* warna *Red*, *Green*, dan *Blue* (RGB). Seperti yang terlihat pada Gambar 3, model CNN ini diawali dengan lapisan konvolusi (Conv2D) yang menggunakan 32 *filter* berukuran 3×3 dan fungsi aktivasi ReLU untuk mengekstraksi fitur awal dari citra. Lapisan ini diikuti oleh lapisan *max pooling* 2×2 untuk mereduksi dimensi data. Lapisan konvolusi kedua memiliki 64 *filter* berukuran 3×3 dengan fungsi aktivasi ReLU, diikuti oleh lapisan *max pooling* 2×2 . Pada lapisan konvolusi ketiga, model menggunakan 128 *filter* dengan ukuran 3×3 , juga dengan fungsi aktivasi ReLU, yang kemudian dilanjutkan dengan lapisan *max pooling* 2×2 . Proses *feature learning* ini memungkinkan model untuk menangkap pola-pola visual penting dari citra, mulai dari fitur sederhana seperti tepi dan tekstur hingga pola yang lebih kompleks pada citra mata. Setelah serangkaian lapisan konvolusi dan *pooling*, citra diubah menjadi vektor satu dimensi melalui lapisan *flatten*. Vektor ini kemudian diteruskan ke lapisan *Dense* yang terdiri dari 256 unit neuron, dengan fungsi aktivasi ReLU. Model diakhiri dengan lapisan *Dense* dengan 1 neuron sebagai *output* yang memanfaatkan fungsi aktivasi sigmoid untuk mengklasifikasikan citra menjadi dua kelas: normal atau katarak.

```

image_size = (224, 224, 3)
model = Sequential([
    Input(shape=image_size),
    Conv2D(32, (3, 3), activation='relu'),
    MaxPooling2D((2, 2)),
    Conv2D(64, (3, 3), activation='relu'),
    MaxPooling2D((2, 2)),
    Conv2D(128, (3, 3), activation='relu'),
    MaxPooling2D((2, 2)),
    Flatten(),
    Dense(256, activation='relu'),
    Dense(1, activation='sigmoid')
])
    
```

Gambar 3. Pemodelan *Convolutional Neural Network*

Evaluasi

Evaluasi model dilakukan pada dataset uji yang tidak digunakan selama pelatihan, dengan menggunakan metrik *accuracy*, *precision*, *recall*, dan *F1-score* untuk mengukur kinerja model dalam klasifikasi. *Confusion matrix* juga digunakan untuk memvisualisasikan distribusi prediksi model, memberikan pemahaman yang lebih mendalam mengenai efektivitas model CNN dalam klasifikasi citra mata.

HASIL DAN PEMBAHASAN

Dalam penelitian ini, model *Convolutional Neural Network* (CNN) dikembangkan untuk mendeteksi katarak pada citra mata. Dataset yang digunakan dalam pelatihan terdiri dari 490 citra, yang terbagi ke dalam dua kategori: 245 citra mata normal dan 245 citra mata katarak. Sebelum pelatihan, dilakukan *preprocessing* dan augmentasi untuk meningkatkan variasi data dan memastikan model dapat mempelajari berbagai pola yang ada. Proses pelatihan menggunakan teknik *5-Fold Cross-Validation* guna meminimalkan risiko *overfitting* serta memastikan generalisasi yang baik pada data yang tidak terlihat selama pelatihan.

Hasil pelatihan model CNN disajikan pada Tabel 2, yang menunjukkan performa model dalam berbagai kombinasi *hyperparameter* seperti *optimizer*, *learning rate*, *batch size*, dan jumlah *epoch*.

Tabel 2. Hasil Akurasi Model CNN

Optimizer	Learning Rate	Batch Size	Epoch	Akurasi	
				Pelatihan	Validasi
RMSprop	0.01	32	10	70.2%	82.7%
RMSprop	0.001	32	10	79.6%	86.7%
RMSprop	0.0001	64	10	77.8%	87.8%
RMSprop	0.01	64	30	83.2%	88.8%
RMSprop	0.001	32	30	91.1%	89.8%
RMSprop	0.0001	32	30	84.7%	89.8%
RMSprop	0.01	64	50	87.2%	90.8%
RMSprop	0.001	64	50	94.1%	92.9%
RMSprop	0.0001	32	50	88.3%	93.9%
Adam	0.01	32	10	80.6%	87.8%
Adam	0.001	64	10	81.1%	92.9%
Adam	0.0001	64	10	82.4%	88.8%
Adam	0.01	32	30	85.5%	90.8%
Adam	0.001	32	30	94.9%	92.9%
Adam	0.0001	64	30	87.8%	91.8%
Adam	0.01	64	50	90.1%	86.7%
Adam	0.001	32	50	95.7%	94.9%
Adam	0.0001	32	50	92.1%	93.9%

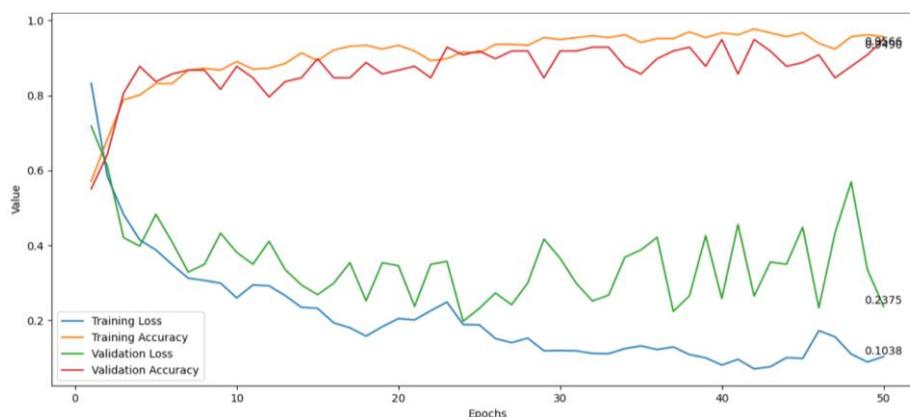
Hasil pelatihan model CNN menunjukkan pengaruh signifikan dari *hyperparameter optimizer*, *learning rate*, dan jumlah *epoch* terhadap akurasi model, baik pada fase pelatihan maupun validasi. Berdasarkan data pada Tabel 2, Adam terbukti lebih efektif dibandingkan RMSprop dalam hal akurasi pelatihan dan validasi. Kombinasi optimal dicapai pada saat Adam diterapkan dengan *learning rate* 0.001, *batch size* 32, dan 50 *epoch*, yang menghasilkan akurasi pelatihan sebesar 95.7% dan akurasi validasi sebesar 94.9%. Ini menegaskan bahwa Adam mampu memaksimalkan pembelajaran model, menghasilkan performa yang konsisten lebih tinggi dibandingkan dengan RMSprop.

Learning rate merupakan salah satu faktor penting dalam proses pembelajaran model. Pada kedua *optimizer*, *learning rate* 0.001 memberikan hasil terbaik, dengan keseimbangan antara kecepatan konvergensi dan akurasi. *Learning rate* 0.01, meskipun memberikan akurasi pelatihan yang cukup tinggi, sering kali memicu *overfitting*, ditandai dengan perbedaan signifikan antara akurasi pelatihan dan validasi. Sementara itu, *learning rate* 0.0001 menunjukkan hasil yang lebih stabil pada validasi, namun sering kali tidak mencapai akurasi pelatihan yang optimal. Dengan demikian, *learning rate* sebesar 0.001 merupakan nilai yang ideal karena meminimalkan risiko *overfitting* serta tetap mempertahankan akurasi yang tinggi pada kedua fase.

Selain itu, *batch size* juga berperan penting dalam performa model. Pada penelitian ini, *batch size* 32 terbukti lebih efektif dibandingkan *batch size* 64 dalam menghasilkan akurasi validasi yang lebih baik. Pada kombinasi Adam dengan *learning rate* 0.001 dan *batch size* 32, model mencapai akurasi validasi tertinggi sebesar 94.9%, menunjukkan bahwa *batch size* yang lebih kecil memungkinkan pembaruan bobot yang lebih sering, sehingga meningkatkan akurasi pelatihan dan validasi. *Batch size* yang lebih besar, meskipun stabil, cenderung menghasilkan akurasi yang sedikit lebih rendah.

Jumlah *epoch* juga memberikan pengaruh penting dalam optimasi model. Peningkatan jumlah *epoch* hingga 50 secara umum meningkatkan akurasi, terutama pada *optimizer* Adam. Pada kombinasi terbaik (Adam, *learning rate* 0.001, *batch size* 32, 50 *epoch*), model mencapai performa optimal, dengan peningkatan yang cukup signifikan dibandingkan *epoch* lebih rendah. Meskipun demikian, peningkatan dari 30 ke 50 *epoch* menunjukkan bahwa manfaat dari penambahan *epoch* mulai berkurang setelah titik tertentu, dengan hanya sedikit peningkatan pada akurasi validasi. Hal ini mengindikasikan bahwa pada jumlah *epoch* yang lebih tinggi, model mendekati konvergensi optimal.

Berdasarkan hasil yang diperoleh, penggunaan *optimizer* Adam dengan *learning rate* sebesar 0.001, *batch size* 32, dan jumlah *epoch* sebanyak 50 berhasil mencapai akurasi pelatihan sebesar 95.7% serta akurasi validasi sebesar 94.9%. Hasil ini merupakan akurasi terbaik yang dicapai selama pelatihan model, menunjukkan bahwa kombinasi *hyperparameter* tersebut memberikan performa yang paling optimal dalam mengatasi permasalahan klasifikasi ini. Gambar 4 menunjukkan nilai akurasi dan *loss* yang dihasilkan pada kombinasi *hyperparameter* tersebut selama proses pelatihan.

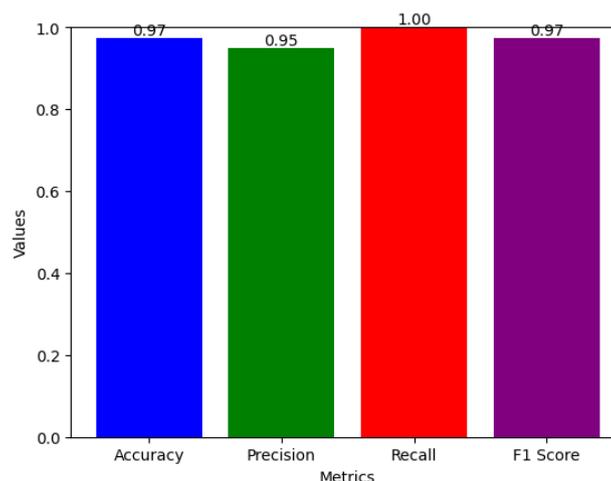


Gambar 4. Visualisasi pelatihan

Hasil pelatihan menunjukkan peningkatan yang signifikan baik pada data latih maupun validasi. Pada *epoch* pertama, akurasi pelatihan tercatat sebesar 54.9% dengan *loss* sebesar 0.9366. Seiring berjalannya pelatihan, akurasi pelatihan terus meningkat secara konsisten, mencapai 95.7% pada *epoch* ke-50, sementara nilai *loss* menurun menjadi 0.1038, menunjukkan bahwa model berhasil belajar dengan baik dari data latih.

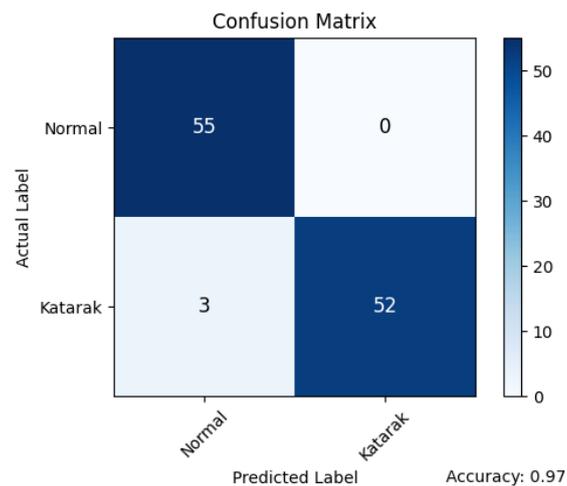
Performa model pada data validasi juga mengalami peningkatan yang stabil. Akurasi validasi yang dimulai dari 55.1% pada *epoch* pertama, secara konsisten meningkat hingga mencapai 94.9% di akhir pelatihan. Penurunan *loss* validasi juga terlihat signifikan dari 0.7181 pada awal pelatihan menjadi 0.2375 pada *epoch* terakhir. Ini menunjukkan bahwa model tidak hanya mampu belajar dari data latih, tetapi juga mampu melakukan generalisasi dengan baik pada data validasi.

Model tersebut kemudian diuji menggunakan data uji untuk mengevaluasi kemampuannya dalam melakukan generalisasi terhadap data baru yang tidak pernah digunakan selama proses pelatihan. Dataset yang digunakan dalam pengujian terdiri dari 110 citra, yang terbagi ke dalam dua kategori: 55 citra mata normal dan 55 citra mata katarak. Evaluasi ini penting untuk memastikan bahwa model tidak hanya efektif pada data pelatihan, tetapi juga dapat melakukan prediksi yang akurat pada data yang belum pernah dilihat sebelumnya. Gambar 5 menampilkan metrik performa model berdasarkan hasil pengujian dengan data uji, yang mencakup *accuracy*, *precision*, *recall*, dan *F1-score*. Berdasarkan hasil evaluasi, model berhasil mencapai *accuracy* sebesar 97%, *precision* sebesar 95%, *recall* sebesar 100%, dan *F1-score* sebesar 97%. Nilai-nilai ini menunjukkan bahwa model mampu melakukan klasifikasi citra mata dengan tingkat akurasi yang sangat tinggi, baik untuk kelas normal maupun katarak.



Gambar 5. Metrik performa

Untuk memberikan gambaran lebih rinci mengenai distribusi prediksi model, Gambar 6 menyajikan *confusion matrix*, yang memperlihatkan bagaimana model mengklasifikasikan data uji ke dalam kategori normal dan katarak. Hasil dari *confusion matrix* menunjukkan bahwa dari 55 citra mata katarak dalam data uji, 52 citra berhasil dideteksi dengan benar sebagai katarak (*True Positives*, TP), sementara 3 citra diklasifikasikan sebagai mata normal (*False Negatives*, FN). Hal ini menunjukkan bahwa model memiliki tingkat sensitivitas yang tinggi terhadap citra mata katarak. Namun, beberapa citra tidak teridentifikasi sebagai katarak, sehingga menghasilkan *false negatives*. Kondisi ini bisa disebabkan oleh karakteristik citra katarak yang menyerupai citra mata normal atau kurangnya informasi visual yang jelas untuk membedakan keduanya. Di sisi lain, dari 55 citra mata normal, seluruh citra berhasil diklasifikasikan dengan benar sebagai normal (*True Negatives*, TN), tanpa adanya kesalahan (*False Positives*, FP). Hal ini mengindikasikan bahwa model memiliki spesifisitas yang sangat tinggi dalam mengenali citra mata normal, di mana tidak ada citra mata normal yang salah diidentifikasi sebagai katarak.



Gambar 6. Confusion matrix

Penelitian ini bertujuan untuk mengembangkan model *Convolutional Neural Network* (CNN) yang mampu mendeteksi katarak pada citra mata dengan tingkat akurasi yang tinggi. Berdasarkan hasil pelatihan dan pengujian, dapat disimpulkan bahwa CNN memberikan hasil yang cukup baik dalam tugas ini, dengan akurasi pelatihan mencapai 95.7%, akurasi validasi 94.9%, dan akurasi pengujian 97%. Hal ini membuktikan bahwa CNN mampu mengekstraksi fitur kompleks dari citra mata yang diperlukan untuk mendeteksi katarak.

Penggunaan CNN dalam deteksi citra mata telah menunjukkan keunggulannya dibandingkan dengan metode tradisional. Dalam beberapa penelitian sebelumnya, CNN telah digunakan untuk mendeteksi berbagai jenis gangguan mata, termasuk katarak, dengan akurasi yang sebanding. Dalam penelitian ini, penerapan augmentasi data seperti rotasi, *flip*, dan *zoom* membantu meningkatkan kinerja model dengan memperkaya variasi data yang tersedia.

Hasil ini mendukung hipotesis penelitian yang menyatakan bahwa CNN dapat digunakan sebagai alat bantu yang efektif dalam mendeteksi katarak pada citra mata. Dengan optimasi lebih lanjut, termasuk penyesuaian *hyperparameter* seperti *optimizer*, *learning rate*, dan *batch size*, serta peningkatan jumlah dataset, diharapkan akurasi model dapat terus ditingkatkan. Model ini juga berpotensi untuk diintegrasikan dalam aplikasi klinis guna membantu dokter dalam diagnosis dini katarak dan memberikan pengobatan yang lebih cepat.

KESIMPULAN

Tingginya angka gangguan penglihatan akibat katarak menekankan pentingnya pencegahan. Deteksi dini sangat diperlukan agar tindakan preventif dapat dilakukan sebelum kondisi memburuk dan memengaruhi kualitas penglihatan serta aktivitas sehari-hari. Penelitian ini berhasil mengimplementasikan model *Convolutional Neural Network* (CNN) untuk deteksi katarak pada citra mata dengan hasil yang sangat memuaskan. Berdasarkan hasil eksperimen, model CNN yang dirancang dengan arsitektur konvolusi dan *pooling* serta optimasi *hyperparameter* yang tepat, berkontribusi pada peningkatan performa model. Model dengan *optimizer* Adam, *learning rate* sebesar 0.001, *batch size* 32, dan *epoch* sebanyak 50 mencapai akurasi sebesar 97% pada data uji. Metode augmentasi citra dan teknik *5-Fold Cross-Validation* yang diterapkan selama pelatihan memperkaya variasi data dan memastikan evaluasi model yang lebih objektif. Hasil evaluasi menunjukkan nilai *precision* sebesar 95%, *recall* 100%, dan *F1-score* 97%, mencerminkan kemampuan model untuk mendeteksi katarak dengan akurasi tinggi dan kesalahan minimal. Hasil ini memberikan kontribusi penting dalam pengembangan teknologi diagnostik berbasis kecerdasan buatan di bidang kesehatan, memungkinkan deteksi katarak yang lebih cepat dan efisien. Teknologi ini memiliki potensi luas untuk diterapkan dalam berbagai sektor yang memerlukan analisis citra otomatis, terutama dalam layanan medis.

REFERENSI

- Amin Nurdin, M., Cahya Wihandika, R., & Utamingrum, F. (2020). Deteksi Pergerakan Arah Mata menggunakan Convolution Neural Network berdasarkan Facial Landmark. *Jurnal Pengembangan Teknologi Informasi Dan Ilmu Komputer*, 4(10), 3338–3345. <http://j-ptiik.ub.ac.id>
- Andreas, E., Widhiarso, W., Kunci, K., & Mata Katarak, P. (2023). Klasifikasi Penyakit Mata Katarak menggunakan Convolutional Neural Network dengan Arsitektur Inception V3. *2nd MDP Student Conference (MSC) 2023 Universitas Multi Data Palembang*, 1, 107–113. <https://www.kaggle.com/jr2ngb/cataractdataset>
- Ariani, N. M., Dewi, N. L. P. T., & Antara, D. K. A. S. (2023). Gambaran Kualitas Hidup Pasien Post Operasi Katarak di Poliklinik RS Mata Bali Mandara Provinsi Bali. *Jurnal Keperawatan SUMBA*, 2(1), 32–38. <https://jurnal.poltekkeskupang.ac.id/index.php/jks>
- Farahdiva, Z., Maisarah Disrinama, A., & Adianto. (2023). Screening Awal Penyakit Katarak dengan Image Processing menggunakan Metode Convolutional Neural Network pada Penyakit Akibat Kerja Pengelasan. *7th Conference on Safety Engineering and It's Application*.
- Hananta Firdaus, D., Imran, B., Darmawan Bakti, L., & Suryadi, E. (2022). Klasifikasi Penyakit Katarak pada Mata menggunakan Metode Convolutional Neural Network (CNN) berbasis Web. *Jurnal Kecerdasan Buatan Dan Teknologi Informasi (JKBTI)*, 1(3), 18–26.
- Nurona Cahya, F., Hardi, N., Riana, D., & Hadiani, S. (2021). Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN). *SISTEMASI: Jurnal Sistem Informasi*, 10(3). <http://sistemasi.ftik.unisi.ac.id>
- Pradana, A. I., Abdullah, R. W., & Harsanto. (2022). Deteksi Ketepatan Penggunaan Masker Wajah Dengan Algoritma CNN Dan Haar Cascade. *Jurnal Teknik Informatika Dan Sistem Informasi*, 3.
- Prasetyo, A. R., Sussi, & Aditya, B. (2023). Analisis Perbandingan Algoritma Support Vector Machine (SVM) dan Convolutional Neural Network (CNN) untuk Sistem Deteksi Katarak. *Jurnal Ilmiah Teknik Mesin, Elektro Dan Komputer*, 3(1), 1–10.
- Putra, F. S., Kusriani, & Kurniawan, M. P. (2021). Deteksi Otomatis Jerawat Wajah Menggunakan Metode Convolutional Neural Network (CNN). *JIFoTech (Journal of Information Technology)*, 1(2).
- Satoto, B. D., Utoyo, M. I., Rulaningtyas, R., & Koendhori, E. B. (2020). Custom Convolutional Neural Network with Data Augmentation to Predict Pneumonia COVID-19. *IBIOMED 2020 - Proceedings of the 37th International Conference on Biomedical Engineering*, 71–76. <https://doi.org/10.1109/IBIOMED50285.2020.9487567>
- Setiawan, W., & Damayanti, F. (2020). Layers Modification of Convolutional Neural Network for Pneumonia Detection. *Journal of Physics: Conference Series*, 1477(5). <https://doi.org/10.1088/1742-6596/1477/5/052055>
- Setiawan, W., Saputra, Moch. A., Koeshardianto, M., & Rulaningtyas, R. (2024). Transfer Learning and Fine Tuning in Modified VGG for Haploid Diploid Corn Seed Images Classification. *Revue d'Intelligence Artificielle*, 38(2), 483–490. <https://doi.org/10.18280/ria.380211>