

Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)

Reihan Rafi Rahmadtulloh¹, Nugroho Bimantoro²

¹Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: ¹*reihanrafi31@gmail.com, ²nugjimbbzz@gmail.com

Abstrak – Penyakit mata dapat menurunkan kualitas hidup sehingga diperlukan skrining yang cepat dan konsisten. Penelitian ini mengembangkan sistem klasifikasi penyakit mata berbasis Convolutional Neural Network (CNN) yang diimplementasikan pada aplikasi skrining berbasis web. Dataset disusun ke dalam data latih, validasi, dan uji, kemudian citra diproses melalui penyesuaian ukuran 224×224, normalisasi, serta augmentasi pada data latih. Model dibangun menggunakan arsitektur MobileNetV3 Small dengan keluaran lima kelas, yaitu Normal, Cataract, Conjunctivitis, Eyelid, dan Uveitis. Sistem juga menerapkan validasi input untuk memastikan prediksi hanya dilakukan pada mata manusia sebelum proses inferensi. Hasil pengujian pada 350 data uji menunjukkan akurasi sebesar 90,29% dengan performa per kelas yang bervariasi, di mana kesalahan klasifikasi masih terjadi pada kelas-kelas yang memiliki kemiripan ciri visual. Hasil ini menunjukkan CNN efektif untuk mendukung skrining awal penyakit mata dan dapat ditingkatkan melalui penambahan data serta optimasi pelatihan pada penelitian selanjutnya.

Kata Kunci — *penyakit mata, CNN, klasifikasi citra, MobileNetV3, skrining.*

1. PENDAHULUAN

Penyakit mata merupakan salah satu masalah kesehatan yang berpotensi menurunkan kualitas hidup karena berhubungan langsung dengan fungsi penglihatan. Deteksi dini menjadi penting agar penanganan dapat dilakukan lebih cepat, mengingat beberapa gangguan pada mata sering kali tidak mudah dikenali pada tahap awal. Oleh karena itu, diperlukan upaya skrining yang lebih cepat dan konsisten dengan bantuan sistem komputasi, sehingga proses identifikasi dapat dilakukan secara lebih terstandar sebagai dukungan awal dalam layanan kesehatan [1].

Perkembangan deep learning mendorong penggunaan Convolutional Neural Network (CNN) dalam klasifikasi citra medis karena CNN mampu mempelajari pola dan fitur penting secara otomatis dari data citra. Pendekatan ini relevan untuk klasifikasi penyakit mata karena karakteristik visual pada area mata dapat dibedakan melalui representasi fitur yang dipelajari model. Penelitian sebelumnya menunjukkan bahwa CNN dapat diterapkan untuk klasifikasi penyakit mata dan menghasilkan performa yang baik pada beberapa kelas, sehingga pendekatan CNN layak dijadikan dasar dalam pengembangan sistem skrining penyakit mata berbasis citra [2].

Pada implementasinya, citra fundus sering dimanfaatkan untuk membantu proses identifikasi kondisi mata karena memuat informasi visual yang dapat digunakan sebagai dasar klasifikasi. Namun, analisis citra secara manual berpotensi memerlukan waktu dan dipengaruhi perbedaan penilaian, sehingga pendekatan klasifikasi otomatis menjadi penting untuk mendukung skrining yang lebih konsisten. Studi pada citra fundus menunjukkan penerapan CNN dapat digunakan untuk mendeteksi penyakit mata dan menjadi dasar pengembangan sistem skrining berbasis citra [3].

Salah satu tantangan dalam penerapan CNN adalah kebutuhan data latih yang memadai agar model mampu melakukan generalisasi dengan baik. Untuk mengatasi keterbatasan data, transfer learning banyak digunakan dengan memanfaatkan model yang telah dilatih pada dataset besar, kemudian dilakukan penyesuaian (fine-tuning) pada data target. Pendekatan ini terbukti efektif pada klasifikasi penyakit mata berbasis citra dan dapat meningkatkan efisiensi pelatihan sekaligus mempertahankan performa klasifikasi [4].

Pada pengembangan sistem klasifikasi citra medis, kualitas data dan tahapan pra-pemrosesan turut berpengaruh terhadap performa model. Penelitian klasifikasi pneumonia menunjukkan bahwa penambahan pra-pemrosesan (standard deviasi) dapat meningkatkan akurasi dibanding CNN tanpa pra-pemrosesan, sehingga menegaskan pentingnya strategi pemrosesan citra sebelum inferensi/training [5]. Selain itu, pengembangan model AI berbasis CNN pada citra medis juga menekankan bahwa peningkatan akurasi dapat dilakukan melalui perbaikan kualitas citra, penambahan jumlah dataset, serta iterasi pelatihan yang lebih mendalam [6]. Berdasarkan hal tersebut, penelitian ini menyusun sistem Klasifikasi Penyakit Mata menggunakan CNN yang diimplementasikan pada

aplikasi skrining berbasis web, sekaligus menambahkan mekanisme validasi input agar prediksi hanya dilakukan pada mata manusia sehingga keluaran sistem lebih terkontrol pada skenario penggunaan skrining.

2. METODE PENELITIAN

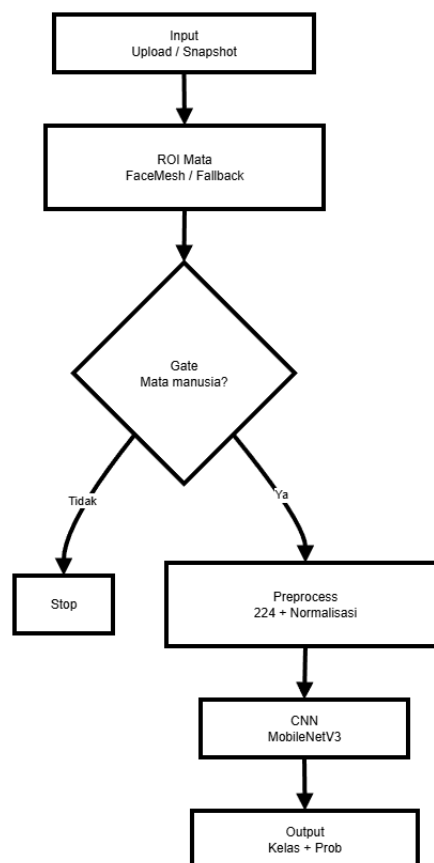
Metode penelitian pada sistem Klasifikasi Penyakit Mata menggunakan Convolutional Neural Network (CNN) disusun secara bertahap mulai dari analisis kebutuhan, penyusunan dataset, perancangan arsitektur sistem, pelatihan model, hingga implementasi aplikasi skrining berbasis web. Alur ini bertujuan memastikan model yang dibangun mampu melakukan klasifikasi dengan baik dan aplikasi hanya memproses mata manusia melalui mekanisme validasi input sebelum inferensi.

2.1 Analisis Masalah

Pada tahap ini dilakukan identifikasi kebutuhan fungsional dan non-fungsional dari sistem skrining. Kebutuhan fungsional meliputi: (1) pengguna dapat memasukkan citra melalui unggah foto atau snapshot kamera, (2) sistem mendeteksi ROI (region of interest) area mata, (3) sistem menjalankan validasi input untuk memastikan citra adalah mata manusia (bukan objek lain), dan (4) sistem menampilkan hasil klasifikasi beserta nilai probabilitas tiap kelas. Kebutuhan non-fungsional meliputi kemudahan penggunaan antarmuka, waktu inferensi yang cepat, serta keluaran yang bersifat indikatif untuk skrining awal.

2.2 Arsitektur Sistem

Arsitektur sistem dibangun dalam dua komponen utama, yaitu pipeline pelatihan model (training) dan aplikasi skrining (deployment). Pada sisi pengguna, sistem menerima citra dari unggah file atau snapshot kamera. Citra kemudian diproses untuk mendeteksi ROI (region of interest) mata. Setelah ROI diperoleh, sistem menjalankan tahap validasi input (human-eye gate) untuk memastikan area yang diproses benar-benar berasal dari mata manusia. Jika validasi lolos, ROI dinormalisasi dan diubah ukurannya menjadi 224×224 piksel, kemudian dimasukkan ke model CNN untuk menghasilkan prediksi kelas penyakit mata. Hasil akhir ditampilkan pada antarmuka berupa label prediksi dan probabilitas setiap kelas, sehingga pengguna dapat melihat kecenderungan hasil skrining secara jelas.




Gambar 1. Arsitektur Sistem

Diagram alur pada gambar 1 menjelaskan tahapan kerja sistem skrining klasifikasi penyakit mata dari awal hingga menghasilkan prediksi. Proses dimulai dari Input berupa gambar yang diperoleh melalui upload atau snapshot kamera. Selanjutnya sistem melakukan deteksi ROI Mata menggunakan FaceMesh sebagai metode utama, dan fallback digunakan apabila deteksi utama tidak berhasil, sehingga area yang diproses tetap terfokus pada bagian mata. Setelah ROI diperoleh, sistem menjalankan tahap Gate “Mata manusia?” untuk memvalidasi bahwa ROI benar-benar berasal dari mata manusia; apabila hasil validasi tidak terpenuhi maka proses dihentikan (Stop) agar model tidak melakukan prediksi pada objek non-mata atau citra di luar domain. Jika validasi ya, ROI masuk ke tahap preprocess berupa penyesuaian ukuran menjadi 224×224 dan normalisasi agar format input sesuai kebutuhan model. Tahap berikutnya adalah inferensi menggunakan model CNN MobileNetV3, kemudian sistem menghasilkan output berupa kelas prediksi dan probabilitas (confidence) sebagai hasil skrining.

2.3 Dataset dan Pra-pemrosesan

Dataset yang digunakan berupa citra penyakit mata dengan lima kelas, yaitu Normal, Cataract, Conjunctivitis, Eyelid, dan Uveitis. Data disusun ke dalam tiga bagian, yaitu data latih (train), data validasi (val), dan data uji (test) untuk memastikan evaluasi model dilakukan secara objektif. Sebelum pelatihan, setiap citra diproses dengan penyesuaian ukuran menjadi 224×224 piksel agar seragam dan sesuai dengan input model. Pada data latih, diterapkan augmentasi berupa horizontal flip, rotasi ringan, serta penyesuaian kecerahan dan kontras untuk meningkatkan keragaman data dan memperbaiki kemampuan generalisasi model. Selanjutnya citra dinormalisasi agar distribusi piksel lebih stabil selama pelatihan dan inferensi.



Gambar 2. Data set

2.4 Perancangan Model CNN

Model klasifikasi dibangun menggunakan pendekatan Convolutional Neural Network (CNN) dengan backbone MobileNetV3 Small karena arsitektur ini relatif ringan dan cocok untuk kebutuhan inferensi cepat pada aplikasi skrining. Citra masukan berukuran $224 \times 224 \times 3$ diproses melalui rangkaian lapisan konvolusi pada backbone untuk mengekstraksi fitur penting dari area mata. Selanjutnya, pada bagian classifier dilakukan penyesuaian jumlah neuron pada lapisan keluaran menjadi 5 kelas sesuai label penelitian (Normal, Cataract, Conjunctivitis, Eyelid, dan Uveitis). Dengan rancangan tersebut, model dapat memetakan fitur visual citra mata menjadi probabilitas tiap kelas, lalu menentukan kelas dengan probabilitas tertinggi sebagai hasil prediksi.

2.5 Proses Pelatihan Model

Proses pelatihan dilakukan menggunakan data latih dan dipantau menggunakan data validasi. Model dilatih selama beberapa epoch dengan optimizer Adam untuk mempercepat konvergensi pembelajaran. Untuk menjaga stabilitas pelatihan, digunakan pengaturan learning rate dan weight decay sebagai regularisasi. Selain itu diterapkan early stopping berdasarkan performa validasi untuk mencegah overfitting, yaitu pelatihan dihentikan ketika akurasi validasi tidak meningkat dalam sejumlah epoch tertentu. Untuk mengatasi ketidakseimbangan jumlah data antar kelas, digunakan weighted sampling pada data latih agar proses pembelajaran tidak terlalu didominasi oleh kelas yang jumlah datanya lebih besar.

2.6 Implementasi Aplikasi Skrining

Model terbaik hasil pelatihan diimplementasikan pada aplikasi skrining berbasis Streamlit. Aplikasi menyediakan dua sumber input, yaitu unggah foto dan snapshot kamera. Setelah citra dimasukkan, sistem mendeteksi ROI mata dan menjalankan validasi input untuk memastikan yang diproses adalah mata manusia. Jika validasi terpenuhi, ROI diproses (resize 224×224 dan normalisasi) lalu dilakukan inferensi menggunakan model CNN. Hasil prediksi ditampilkan pada antarmuka berupa kelas prediksi dan grafik probabilitas tiap kelas sehingga

mudah dipahami pengguna. Apabila validasi tidak terpenuhi, sistem menghentikan proses dan memberikan notifikasi bahwa input bukan mata manusia, sehingga prediksi tidak dilakukan pada objek di luar domain skrining.

3. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil pengujian dan pembahasan terhadap kinerja model Convolutional Neural Network (CNN) pada sistem klasifikasi penyakit mata. Evaluasi dilakukan menggunakan data uji untuk mengetahui tingkat ketepatan klasifikasi, kemudian dianalisis melalui confusion matrix dan metrik per kelas guna melihat pola kesalahan antar kategori penyakit. Selain itu, ditampilkan pula hasil pelatihan model serta implementasi pada aplikasi skrining berbasis web untuk menunjukkan keterkaitan antara performa model dan penerapannya pada sistem.

3.1 Hasil Pengujian Model

Berdasarkan pengujian pada data uji sebanyak 350 citra, model menghasilkan prediksi benar sebanyak 316 citra, sehingga diperoleh akurasi pengujian sebesar 90,29%. Confusion matrix menunjukkan sebagian besar kelas dapat dikenali dengan baik, terutama pada kelas Normal dan Cataract yang memiliki jumlah prediksi benar tinggi. Namun, masih terdapat beberapa kesalahan prediksi antar kelas yang memiliki karakteristik visual mirip, misalnya pertukaran antara Normal dengan Cataract/Eyelid, serta pertukaran antara Conjunctivitis dengan Uveitis.

3.2 Analisis Confusion Matrix

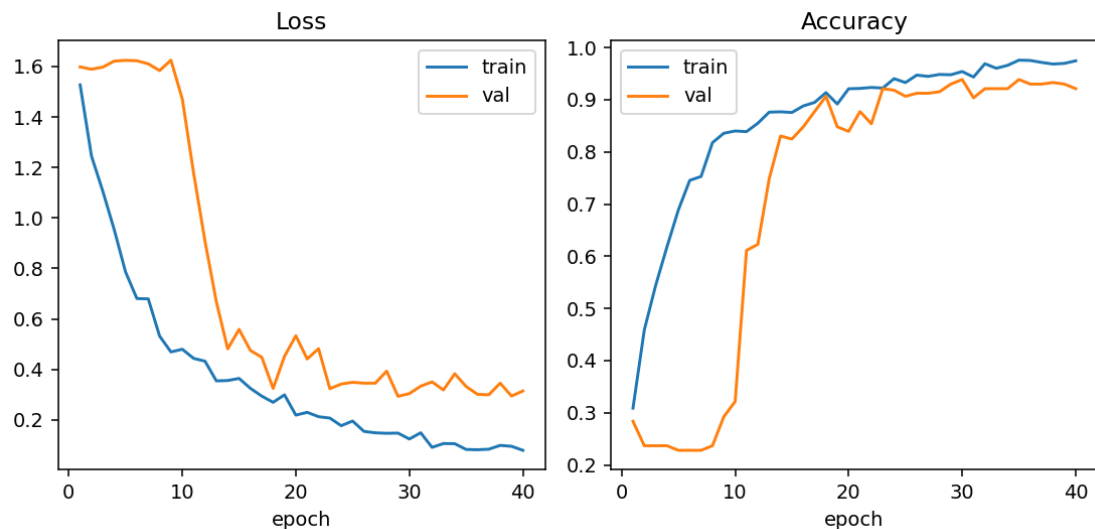
		Confusion Matrix				
True	Normal	87	6	1	3	1
	Cataract	1	77	0	4	1
	Conjunctivitis	0	0	48	2	5
	Eyelid	1	1	1	74	3
	Uveitis	0	1	1	2	30
		Predicted				
		Normal	Cataract	Conjunctivitis	Eyelid	Uveitis

Gambar 3. Confusion Matrix Hasil Pengujian

Berdasarkan confusion matrix, sebagian besar kelas berhasil dikenali dengan baik, namun masih terdapat kesalahan prediksi pada kelas-kelas yang memiliki karakteristik visual mirip. Kesalahan yang sering muncul adalah pertukaran antara Normal dengan Cataract/Eyelid, serta pertukaran antara Conjunctivitis dengan Uveitis. Pola ini menunjukkan bahwa beberapa kondisi memiliki kemiripan tekstur dan tingkat kemerahan pada area mata, sehingga model dapat memberikan prediksi yang saling tertukar ketika kualitas citra kurang baik atau ROI tidak sepenuhnya menangkap fitur utama penyakit.

3.3 Hasil Pelatihan Model (Kurva Training–Validation)

Kurva pelatihan menunjukkan nilai loss pada data latih menurun secara bertahap dan akurasi meningkat hingga mendekati nilai optimal, sementara performa pada data validasi cenderung stabil. Pola ini mengindikasikan model mampu mempelajari representasi fitur dengan baik. Adanya selisih kecil antara performa train dan validation menunjukkan masih terdapat potensi overfitting ringan yang wajar pada dataset citra medis, sehingga pemantauan validasi dan mekanisme penghentian dini (early stopping) menjadi penting untuk menjaga generalisasi model.



Gambar 4. Kurva Loss dan Akurasi Training-Validation

Gambar 4 menampilkan perkembangan nilai loss dan akurasi pada proses pelatihan model, baik untuk data training maupun validation. Kurva loss training menunjukkan penurunan secara bertahap seiring bertambahnya epoch, yang menandakan model semakin mampu mempelajari pola dari data latih. Pada saat yang sama, loss validation juga cenderung menurun dan kemudian stabil, menunjukkan bahwa model tidak hanya menghafal data latih, tetapi masih mampu mempertahankan performa pada data yang tidak dilatih. Kurva akurasi memperlihatkan akurasi training meningkat hingga mencapai nilai tinggi, sedangkan akurasi validation meningkat dan relatif stabil pada kisaran yang sedikit lebih rendah dibanding training. Selisih kecil antara kurva training dan validation mengindikasikan adanya kecenderungan overfitting ringan yang masih wajar pada dataset terbatas, namun secara umum model menunjukkan kemampuan generalisasi yang baik karena akurasi validation tidak mengalami penurunan tajam pada epoch-epoch akhir.

3.4 Evaluasi Per Kelas

Evaluasi per kelas diperlukan untuk melihat performa model secara lebih detail, karena nilai akurasi total belum tentu mencerminkan kemampuan model pada setiap kelas. Dari hasil pengujian, kelas Normal dan Cataract cenderung memiliki performa tinggi, sedangkan kelas Uveitis relatif lebih rendah dibanding kelas lain. Hal ini dapat dipengaruhi oleh jumlah data per kelas dan kemiripan fitur visual antara Uveitis dengan kondisi mata lain yang memiliki kemerahan atau peradangan.

Tabel 1. Hasil Evaluasi Precision, Recall, dan F1-Score per Kelas

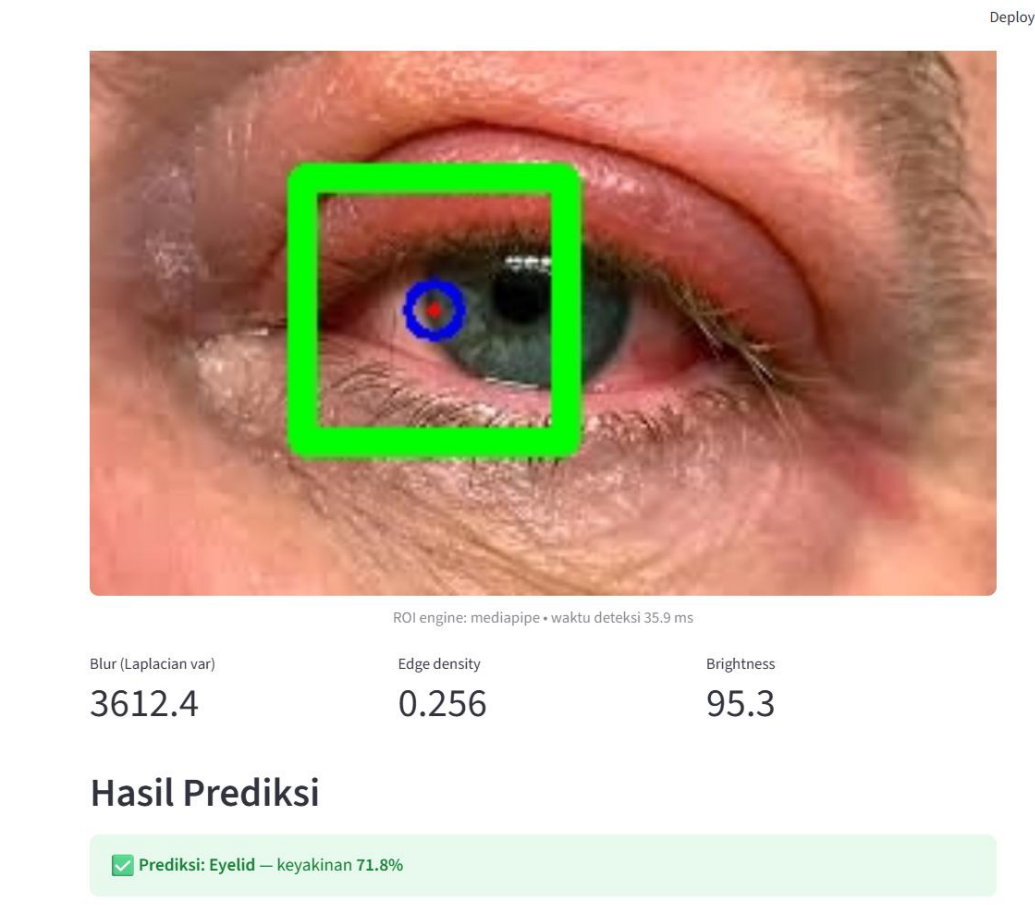
Kelas	Precision (%)	Recall (%)	F1-Score (%)
Normal	97,75	88,78	93,05
Cataract	90,59	92,77	91,67
Conjunctivitis	94,12	87,27	90,57
Eyelid	87,06	92,50	89,70
Uveitis	75,00	88,24	81,08
Rata-rata	88,90	89,11	89,21

Pembahasan pada Tabel 1 menunjukkan bahwa model CNN memiliki performa yang cukup baik dan relatif seimbang pada sebagian besar kelas penyakit mata. Kelas Normal dan Cataract memperoleh nilai precision dan recall yang tinggi, menandakan kemampuan model dalam membedakan kondisi mata normal dan katarak secara konsisten. Kelas Conjunctivitis dan Eyelid juga menunjukkan nilai F1-score yang baik, meskipun masih terdapat beberapa kesalahan prediksi akibat kemiripan ciri visual pada area mata. Sementara itu, kelas Uveitis memiliki nilai precision paling rendah dibandingkan kelas lain, yang mengindikasikan masih adanya prediksi keliru pada kelas ini. Kondisi tersebut kemungkinan dipengaruhi oleh keterbatasan jumlah data serta kemiripan karakteristik visual Uveitis dengan penyakit mata lain yang memiliki gejala peradangan. Secara keseluruhan, nilai rata-rata (macro) F1-score sebesar 89,21% menunjukkan bahwa model mampu melakukan klasifikasi dengan cukup

seimbang pada seluruh kelas, meskipun peningkatan masih diperlukan terutama pada kelas dengan performa terendah.

3.5 Hasil Implementasi pada Aplikasi Skrining

Model yang telah dilatih diintegrasikan ke dalam aplikasi skrining berbasis web menggunakan Streamlit. Pengguna dapat memasukkan citra melalui unggah foto atau snapshot kamera, lalu sistem mendeteksi ROI mata dan melakukan validasi input. Jika validasi terpenuhi, sistem menampilkan prediksi kelas penyakit mata dan probabilitas tiap kelas dalam bentuk visualisasi grafik. Implementasi ini memudahkan pengguna untuk memahami hasil skrining secara cepat dan mendukung penggunaan sistem secara praktis.



Gambar 5. Tampilan Aplikasi Skrining (Input, ROI, dan Output Prediksi)

Gambar 5 menampilkan tampilan aplikasi skrining berbasis web yang digunakan untuk menguji implementasi sistem klasifikasi penyakit mata. Pada bagian input, pengguna dapat memasukkan citra melalui fitur unggah foto atau snapshot kamera. Setelah citra diterima, sistem melakukan deteksi ROI (region of interest) pada area mata yang ditandai dengan kotak/bounding box sebagai area yang akan diproses. Selanjutnya, ROI yang terdeteksi melewati tahap validasi untuk memastikan input merupakan mata manusia sebelum dilakukan inferensi. Pada bagian output, aplikasi menampilkan hasil prediksi berupa kelas penyakit mata dengan nilai keyakinan (probabilitas) tertinggi serta visualisasi probabilitas untuk setiap kelas. Tampilan ini menunjukkan bahwa proses skrining berjalan secara end-to-end mulai dari input citra, penentuan ROI, hingga penyajian hasil prediksi yang mudah dipahami pengguna.

3.6 Pembahasan Mekanisme Validasi Input “Mata Manusia”

Sistem dilengkapi mekanisme validasi input untuk memastikan prediksi hanya dilakukan pada mata manusia, sehingga mengurangi risiko model memberikan prediksi pada objek yang bukan domainnya (misalnya gambar hewan, objek acak, atau bagian wajah selain mata). Validasi dilakukan melalui kombinasi deteksi landmark iris (jika tersedia), deteksi wajah manusia, serta pemeriksaan karakteristik area sekitar ROI. Apabila validasi gagal, sistem menghentikan proses sebelum inferensi dan memberikan notifikasi bahwa input bukan mata manusia.

Mekanisme ini penting dalam konteks skrining agar keluaran sistem lebih terkontrol dan tidak menyesatkan pengguna.

4. SIMPULAN

Bagian simpulan ini menyajikan ringkasan hasil penelitian yang telah dilakukan serta menegaskan capaian utama sistem klasifikasi penyakit mata berbasis Convolutional Neural Network (CNN). Selain itu, disampaikan pula kelebihan dan keterbatasan sistem yang dikembangkan serta kemungkinan arah pengembangan lebih lanjut untuk meningkatkan kinerja dan pemanfaatannya pada aplikasi skrining di masa mendatang.

1. Sistem klasifikasi penyakit mata berbasis Convolutional Neural Network (CNN) berhasil dibangun dan diintegrasikan ke aplikasi skrining berbasis web, sehingga proses klasifikasi dapat dilakukan secara praktis melalui unggah foto maupun snapshot.
2. Hasil pengujian menunjukkan model mampu mengklasifikasikan lima kelas penyakit mata dengan akurasi 90,29%, serta performa per kelas yang umumnya tinggi, namun masih terdapat kelas yang lebih menantang (terutama Uveitis) karena kemiripan ciri visual dengan kelas lain.
3. Kelebihan sistem terletak pada penerapan validasi input (mata manusia) sebelum inferensi, sehingga prediksi tidak dilakukan pada objek non-mata atau citra di luar domain, yang membuat keluaran sistem lebih terkontrol untuk skenario skrining.
4. Kekurangan sistem saat ini adalah masih adanya kesalahan klasifikasi pada kelas-kelas yang memiliki karakteristik visual mirip dan kemungkinan dipengaruhi oleh variasi kualitas citra, kondisi pencahayaan, serta ketidakseimbangan jumlah data pada beberapa kelas.
5. Pengembangan selanjutnya dapat dilakukan dengan memperkaya dan menyeimbangkan dataset (terutama kelas yang performanya lebih rendah), melakukan optimasi pra-pemrosesan, serta mencoba strategi pelatihan/arsitektur lain agar model lebih robust pada variasi kondisi citra dan meningkatkan konsistensi prediksi.

5. SARAN

Bagian saran ini disusun sebagai arahan pengembangan penelitian selanjutnya dengan tujuan menutup keterbatasan yang masih ditemukan pada sistem klasifikasi penyakit mata yang dikembangkan. Saran difokuskan pada aspek metodologis dan teknis penelitian agar hasil yang diperoleh pada penelitian berikutnya dapat lebih optimal dan akurat.

1. Menambah dan menyeimbangkan jumlah dataset pada setiap kelas, terutama kelas yang performanya masih lebih rendah (misalnya Uveitis), agar model memiliki representasi fitur yang lebih kuat dan mengurangi kesalahan klasifikasi.
2. Melakukan standarisasi kualitas citra (pencahayaan, fokus, dan jarak pengambilan) serta mengembangkan pra-pemrosesan yang lebih konsisten pada ROI mata untuk meningkatkan kestabilan prediksi pada kondisi input yang bervariasi.
3. Menguji variasi strategi pelatihan dan arsitektur CNN (misalnya transfer learning dan fine-tuning bertahap) untuk meningkatkan generalisasi model, khususnya pada kelas-kelas yang memiliki kemiripan ciri visual.
4. Mengembangkan evaluasi lanjutan pada skenario penggunaan nyata dengan variasi perangkat kamera dan lingkungan berbeda, sehingga diketahui tingkat robust sistem sebelum digunakan pada kondisi operasional yang lebih luas.

DAFTAR PUSTAKA

- [1] E. Hartati, “KLASIFIKASI PENYAKIT MATA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK MODEL RESNET-50,” 2024.
- [2] F. Nurona Cahya, N. Hardi, D. Riana, and S. Hadiani, “SISTEMASI: Jurnal Sistem Informasi Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN),” 2021. [Online]. Available: <http://sistemasi.ftik.unisi.ac.id>
- [3] R. Indraswari, W. Herulambang, and R. Rokhana, “Deteksi Penyakit Mata Pada Citra Fundus Menggunakan Convolutional Neural Network (CNN) Ocular Disease Detection on Fundus Images Using Convolutional Neural Network (CNN),” 2022. [Online]. Available: <https://www.kaggle.com/datasets/jr2ngb/cataractdataset>
- [4] R. Gunawan *et al.*, “Pendekatan Transfer Learning untuk Klasifikasi Penyakit Mata Menggunakan Citra dengan CNN InceptionV3,” *Jurnal CoSciTech (Computer Science and Information Technology)*, vol. 6, no. 1, pp. 60–67, May 2025, doi: 10.37859/coscitech.v6i1.8509.
- [5] U. P. Sanjaya *et al.*, “Optimasi Convolutional Neural Network dengan Standard Deviasi untuk Klasifikasi Pneumonia pada Citra X-rays Paru,” 2023.
- [6] E. Putra Syarif Hidayat, K. Anwar, D. Hermawan, S. Izzuddin, and P. I. Kemenkes Jakarta, “Development of AI Models from Mammography Images for Early Detection of Breast Cancer,” 2024.