

Implementasi *Convolutional Neural Network* Pada Deteksi Penyakit Retina Menggunakan Citra Fundus Mata

Reimon Aldin¹

¹Sistem Komputer, Universitas Handayani Makassar

reimon@karyakesehatan.ac.id*

Abstract

This study aims to develop an efficient system for detecting retinal diseases from fundus eye images by applying Deep Learning with Convolutional Neural Networks (CNN). The proposed model is designed to assist ophthalmologists in making accurate and timely diagnoses, enabling appropriate treatment and improving patient outcomes. The research emphasizes the role of CNN-based Deep Learning as a reliable method for classifying retinal disorders. A quantitative approach was employed, utilizing numerical and descriptive data such as images, observations, and secondary sources. The research procedure covered several stages: image preprocessing, CNN model design, training, validation, evaluation, and system testing. The experimental results demonstrated that the developed system achieved an accuracy of 97%. Evaluation metrics confirmed high performance with classification results as follows: Myopia (precision 1.00, recall 1.00, f1-score 1.00), Cataract (precision 0.88, recall 1.00, f1-score 0.93), Diabetic Retinopathy (precision 1.00, recall 1.00, f1-score 1.00), and Glaucoma (precision 1.00, recall 0.95, f1-score 0.97). These findings show that the CNN architecture with VGG16 demonstrates excellent capability in detecting and classifying retinal diseases using fundus images. Therefore, the model can be recommended as a practical tool for early detection of retinal disorders, particularly within the context of healthcare services in Kendari City, Southeast Sulawesi.

Keywords: CNN, VGG16, retinal disease, eye fundus image

Abstrak

Penelitian ini bertujuan mengembangkan sistem yang efisien untuk mendeteksi penyakit retina dari citra fundus mata dengan menerapkan teknologi Deep Learning menggunakan Convolutional Neural Networks (CNN). Model yang dikembangkan dirancang untuk membantu dokter spesialis mata dalam melakukan diagnosis yang cepat dan akurat sehingga dapat memberikan penanganan yang tepat serta meningkatkan hasil kesehatan pasien. Fokus penelitian ini adalah penerapan CNN sebagai metode andal dalam klasifikasi penyakit retina. Metode penelitian yang digunakan adalah pendekatan kuantitatif dengan memanfaatkan data numerik dan deskriptif, seperti citra, hasil observasi, serta data sekunder. Tahapan penelitian meliputi praproses citra, perancangan model CNN, pelatihan, validasi, evaluasi, serta pengujian sistem. Hasil uji coba menunjukkan bahwa sistem yang dikembangkan mencapai tingkat akurasi sebesar 97%. Evaluasi kinerja berdasarkan metrik klasifikasi menunjukkan hasil yang sangat baik, dengan detail sebagai berikut: Miopia (precision 1.00, recall 1.00, f1-score 1.00), Katarak (precision 0.88, recall 1.00, f1-score 0.93), Retinopati Diabetik (precision 1.00, recall 1.00, f1-score 1.00), dan Glaukoma (precision 1.00, recall 0.95, f1-score 0.97). Temuan ini membuktikan bahwa arsitektur CNN dengan VGG16 memiliki kemampuan yang sangat baik dalam mendeteksi dan mengklasifikasi penyakit retina dari citra fundus. Dengan demikian, model ini dapat direkomendasikan sebagai alat praktis untuk deteksi dini penyakit retina, khususnya pada layanan kesehatan di Kota Kendari, Sulawesi Tenggara.

Kata kunci: CNN, VGG16, penyakit retina, citra fundus mata

©This work is licensed under a Creative Commons Attribution - ShareAlike 4.0 International License

1. Pendahuluan

Deteksi dini dan pengobatan kelainan mata merupakan langkah krusial untuk mencegah progresivitas penyakit yang dapat berujung pada kebutaan. World Health Organization (WHO) mencatat bahwa sebagian besar kasus kebutaan sebenarnya dapat dicegah apabila proses diagnosis dilakukan sejak dini. Namun, pada praktiknya, diagnosis manual terhadap penyakit retina seringkali memerlukan waktu yang lama, bersifat monoton, serta sulit direproduksi secara konsisten oleh tenaga medis. Kondisi ini menimbulkan kebutuhan akan sistem pendukung keputusan berbasis teknologi yang mampu membantu proses deteksi secara lebih cepat, akurat, dan konsisten.

Perkembangan teknologi artificial intelligence (AI), khususnya deep learning, telah memberikan kontribusi signifikan dalam bidang Computer-Aided Diagnosis (CAD). Pemanfaatan arsitektur Deep Convolutional Neural Networks (DCNN) dan Vision Transformers (ViTs) terbukti menunjukkan performa yang menjanjikan dalam mendeteksi berbagai patologi retina, seperti glaukoma, retinopati diabetik, serta degenerasi makula terkait usia. Meskipun demikian, tantangan besar masih muncul akibat kompleksitas lesi retina yang beragam. Sebagian besar penelitian terdahulu cenderung berfokus pada klasifikasi satu jenis penyakit tertentu, sementara pendekatan multi-label atau multi-class masih relatif terbatas. Selain itu, penelitian yang ada masih jarang mengkaji penerapan arsitektur ensemble CNN untuk meningkatkan akurasi serta robustnes sistem. Di

sisi lain, aspek interpretabilitas model deep learning juga masih menjadi persoalan penting. Sebagian besar algoritma yang dikembangkan berperan layaknya black box, sehingga sulit dipahami oleh tenaga medis. Padahal, tingkat kepercayaan dokter dan pasien terhadap teknologi baru sangat dipengaruhi oleh transparansi hasil prediksi yang diberikan. Dengan demikian, pengembangan model yang tidak hanya akurat, tetapi juga explainable merupakan tantangan sekaligus peluang penelitian selanjutnya. Secara kontekstual, kesenjangan penelitian juga tampak di wilayah Indonesia, khususnya Provinsi Sulawesi Tenggara.

Di Kota Kendari, keterbatasan fasilitas kesehatan, minimnya peralatan pencitraan retina, serta terbatasnya sumber daya teknologi informasi menjadi kendala utama dalam upaya deteksi dini penyakit mata. Sebagian besar penelitian terdahulu dilakukan di pusat-pusat kesehatan dengan fasilitas lengkap, sehingga kurang merepresentasikan kondisi di daerah dengan keterbatasan sarana. Oleh sebab itu, penerapan teknologi berbasis CNN dalam konteks lokal ini sangat relevan untuk diangkat sebagai solusi praktis.

Berdasarkan uraian tersebut, penelitian ini mengangkat topik “Implementasi Convolutional Neural Network pada Deteksi Penyakit Retina Menggunakan Citra Fundus Mata”. Penelitian ini berupaya mengisi kesenjangan yang ada dengan menghadirkan model CAD berbasis CNN yang dapat diterapkan dalam kondisi keterbatasan fasilitas kesehatan. Kontribusi penelitian ini terletak pada aspek implementasi praktis CNN dalam mendeteksi penyakit retina melalui citra fundus mata, dengan harapan mampu mendukung upaya deteksi dini, menurunkan risiko kebutaan, serta membuka peluang penelitian lanjutan terkait klasifikasi multi-label dan peningkatan interpretabilitas model.

2. Metode Penelitian

Dalam penelitian ini digunakan pendekatan kuantitatif, di mana peneliti mengumpulkan data yang bersifat deskriptif, meliputi angka, fakta, citra, karakteristik, maupun informasi kualitatif yang dapat merepresentasikan objek penelitian. Data tersebut diperoleh melalui berbagai teknik, seperti survei atau observasi, percobaan laboratorium, serta analisis data sekunder.


Metode penelitian ini mengadopsi pendekatan experimental research dengan desain supervised learning. Citra fundus mata digunakan sebagai variabel input, sementara label kelas penyakit retina (katarak, retinopati diabetik, miopia, dan glaukoma) menjadi variabel target. Model CNN berbasis VGG16 dilatih untuk mempelajari hubungan antara fitur visual citra dengan label kelas, sehingga mampu melakukan klasifikasi otomatis pada data uji.

Tahapan penelitian dilakukan secara sistematis, dimulai dari pengumpulan dataset citra fundus dari sumber terpercaya. Selanjutnya dilakukan tahap pre-processing yang mencakup standarisasi format, resizing, cropping,

normalisasi, dan enhancement untuk memastikan citra siap diproses oleh arsitektur CNN. Setelah itu, dataset dibagi menjadi tiga subset, yaitu data latih (training set), data validasi (validation set), dan data uji (testing set), dengan proporsi tertentu agar evaluasi model lebih objektif.

Proses pelatihan model dilakukan menggunakan metode transfer learning dengan memanfaatkan bobot pretrained VGG16 dari ImageNet. Bobot awal pada lapisan awal dipertahankan untuk mengekstraksi fitur umum, sementara lapisan akhir dimodifikasi agar sesuai dengan jumlah kelas penyakit retina. Selama pelatihan, digunakan algoritma optimasi Adam dengan fungsi loss categorical cross-entropy dan metrik evaluasi berupa akurasi, precision, recall, serta F1-score. Tahap pengujian dilakukan dengan mengimplementasikan model pada data uji yang tidak pernah digunakan pada proses pelatihan sebelumnya. Hal ini bertujuan menilai kemampuan generalisasi model terhadap data baru. Selain itu, dilakukan juga analisis confusion matrix untuk melihat distribusi klasifikasi setiap kelas, sehingga dapat diketahui kekuatan dan kelemahan model dalam membedakan masing-masing penyakit retina.

Metode penelitian ini juga mencakup uji coba implementasi model dalam bentuk aplikasi sederhana. Aplikasi ini dirancang agar pengguna dapat mengunggah citra fundus dan memperoleh hasil klasifikasi secara otomatis. Uji coba ini penting untuk menilai aspek praktis dari penelitian, yaitu kelayakan sistem jika digunakan oleh tenaga medis dalam proses skrining awal penyakit retina.



Gambar 1. Flowchart Tahapan Penelitian

2.1. Pengumpulan Data

Sumber data dalam penelitian ini berasal dari data primer berupa citra fundus mata yang diperoleh di Klinik Mata Kendari. Dataset disusun berdasarkan hasil pemeriksaan pasien, dengan pemilihan citra yang memperhatikan kualitas resolusi, ketajaman, serta kelayakan visual. Pertimbangan utama dalam pemilihan citra adalah ketersediaan jumlah kasus pada tiap kategori penyakit dan kesesuaian untuk analisis otomatis berbasis deep learning.

Berdasarkan hasil seleksi, dataset penelitian ini terdiri dari 400 citra fundus mata yang terbagi menjadi empat kelas penyakit, masing-masing 100 citra, yaitu: katarak, retinopati diabetik, miopia, dan glaukoma.

Tabel 1. Dataset Penelitian

Kelas Penyakit	Jumlah Citra
Katarak	100
Diabetik reinopati	100
Miopia	100
Glokoma	100

2.2. Pre-Pemrosesan Data

Tahap pre-processing pada citra fundus dilakukan melalui beberapa prosedur utama, yaitu:

1. Format Standarisasi: seluruh citra dikonversi ke format JPEG agar kompatibel dengan framework deep learning.
2. Resizing: citra diubah ke ukuran 224×224 piksel sesuai dengan masukan arsitektur VGG16, sekaligus menurunkan kompleksitas komputasi.
3. Cropping: dilakukan pemotongan bagian citra yang tidak relevan untuk mempertahankan area retina.
4. Normalisasi: nilai piksel dinormalisasi ke rentang $[0,1]$ agar mempercepat proses pelatihan model.
5. Enhancement: peningkatan kualitas visual dilakukan melalui metode Histogram Equalization untuk menyeimbangkan distribusi intensitas piksel dan memperjelas struktur retina.

Selain tahapan di atas, penelitian ini juga melakukan augmentasi data (data augmentation) sebagai bagian dari pre-processing lanjutan. Teknik augmentasi meliputi rotasi acak, flipping horizontal/vertikal, zooming, dan brightness adjustment. Tujuan augmentasi adalah memperbanyak variasi data pelatihan secara sintesis sehingga model lebih robust terhadap variasi orientasi maupun kondisi pencahayaan pada citra fundus di dunia nyata.

Selanjutnya, dilakukan pula proses color normalization menggunakan Contrast Limited Adaptive Histogram Equalization (CLAHE). Teknik ini dianggap lebih baik daripada histogram equalization biasa karena mampu meningkatkan kontras lokal tanpa menimbulkan noise berlebihan. Dengan CLAHE, pembuluh darah, makula, dan optic disc pada retina dapat terlihat lebih jelas, sehingga memudahkan CNN dalam menangkap pola visual yang relevan untuk klasifikasi penyakit.

Untuk memastikan kualitas data yang digunakan, dilakukan juga tahap pembersihan data (data cleaning) dengan mengeliminasi citra buram, terlalu gelap, atau mengandung artefak yang berpotensi menurunkan kinerja model. Langkah ini memastikan hanya citra dengan kualitas baik yang masuk dalam proses pelatihan maupun pengujian.

Secara keseluruhan, strategi pre-processing ini tidak hanya bertujuan menyiapkan citra sesuai kebutuhan arsitektur CNN, tetapi juga meningkatkan kualitas representasi visual sehingga model dapat belajar secara lebih efektif. Kombinasi antara resizing, cropping, normalisasi, enhancement, dan augmentasi membuat dataset lebih konsisten, informatif, serta representatif terhadap variasi kondisi retina yang ditemui pada kasus nyata.

2.3. Desain Arsitektur CNN

Penelitian ini menggunakan arsitektur VGG16 yang dikenal efektif dalam ekstraksi fitur mendalam pada citra medis. VGG16 terdiri dari 13 lapisan konvolusi dengan kernel berukuran kecil (3×3) dan 3 lapisan fully connected. Pemilihan VGG16 didasarkan pada keunggulannya dalam menghasilkan representasi fitur yang detail, stabil, dan terbukti unggul pada banyak penelitian klasifikasi citra medis.

Setiap lapisan konvolusi pada VGG16 menggunakan filter dengan ukuran tetap 3×3 dan stride 1, yang memungkinkan model menangkap detail spasial kecil dari citra fundus mata. Setelah beberapa lapisan konvolusi, diterapkan operasi max pooling dengan ukuran kernel 2×2 untuk mereduksi dimensi fitur, sekaligus mempertahankan informasi penting dari citra. Pendekatan ini membuat arsitektur VGG16 lebih efisien dalam menangani citra beresolusi tinggi tanpa kehilangan karakteristik utama yang relevan untuk klasifikasi penyakit retina.

Arsitektur ini juga memiliki kedalaman yang cukup (16 lapisan yang dapat dilatih), sehingga mampu mengekstraksi pola kompleks dari struktur retina, seperti perbedaan tekstur, pola pembuluh darah, maupun kelainan pada makula dan lensa. Pada bagian akhir, tiga lapisan fully connected berperan dalam melakukan proses klasifikasi berdasarkan fitur yang diekstrak. Lapisan terakhir menggunakan fungsi aktivasi softmax untuk menghasilkan probabilitas pada empat kelas target, yaitu Myopia, Cataract, Diabetic Retinopathy, dan Glaucoma.

Dalam implementasinya, model VGG16 dimanfaatkan melalui teknik transfer learning. Bobot awal dari jaringan yang telah dilatih pada dataset ImageNet dipertahankan pada lapisan awal untuk menangkap fitur umum, sementara lapisan akhir disesuaikan dengan jumlah kelas penyakit retina pada penelitian ini. Strategi ini memungkinkan model memperoleh performa tinggi meskipun jumlah data terbatas, karena pengetahuan dasar dari citra umum sudah ditransfer ke konteks citra medis.

Selain itu, untuk mencegah overfitting, penelitian ini menerapkan teknik regularization berupa dropout pada lapisan fully connected, serta menggunakan batch normalization pada beberapa lapisan konvolusi untuk menjaga stabilitas distribusi aktivasi. Optimalisasi dilakukan dengan algoritma Adam optimizer dan fungsi kerugian categorical cross-entropy yang sesuai untuk kasus klasifikasi multi-kelas.

Desain arsitektur CNN berbasis VGG16 ini memberikan keseimbangan antara kedalaman jaringan, detail ekstraksi fitur, dan efisiensi komputasi. Hal ini menjadikannya pilihan tepat dalam mendukung proses klasifikasi citra fundus retina yang kompleks, sekaligus dapat diadaptasikan dalam bentuk aplikasi diagnosis berbasis kecerdasan buatan di bidang kesehatan mata.

2.4. Pelatihan Model

Dataset penelitian dibagi menjadi tiga bagian: 70% untuk data training (280 citra), 15% untuk data validation (60 citra), dan 15% untuk data testing (60 citra). Proporsi ini dipilih untuk menjaga keseimbangan antara kebutuhan pelatihan model dan evaluasi performa. Proses pelatihan dilakukan dengan parameter berikut:

1. Jumlah epoch: 100
Dipilih untuk memberikan kesempatan model melakukan konvergensi tanpa berhenti terlalu cepat. Jumlah ini juga berdasarkan praktik umum pada klasifikasi citra medis dengan dataset terbatas.
2. Batch size: 64 Ukuran ini digunakan untuk menjaga efisiensi komputasi sekaligus stabilitas gradien.
3. Optimizer: Adam
Dipilih karena kemampuannya menggabungkan kelebihan RMSProp dan momentum, serta lebih cepat konvergen pada data citra medis.
4. Learning rate: 0.0001
Nilai kecil dipilih untuk menghindari overshooting pada proses update bobot, khususnya karena dataset berukuran terbatas.

Selama proses training, fungsi loss yang digunakan adalah categorical cross-entropy karena masalah ini merupakan klasifikasi multi-kelas. Evaluasi model dilakukan menggunakan akurasi, precision, recall, dan F1-score, baik pada tahap validasi maupun testing.

Dataset yang telah melalui pre-processing dibagi menjadi tiga bagian:

1. Training set (280 citra, 70%) digunakan untuk melatih model.
2. Validation set (60 citra, 15%) digunakan untuk mengevaluasi kinerja model selama proses pelatihan serta mencegah overfitting.
3. Testing set (60 citra, 15%) digunakan pada tahap akhir untuk menilai performa generalisasi model terhadap data baru.

2.5. Validasi dan Evaluasi

Setelah proses pelatihan selesai, model diuji menggunakan data testing. Evaluasi kinerja dilakukan dengan metrik:

- a. *Accuracy* : persentase prediksi benar dari seluruh data uji.
- b. *Precision* : proporsi prediksi positif yang sesuai label sebenarnya.
- c. *Recall* : kemampuan model mendeteksi semua kasus positif.
- d. *F1-Score* : harmonisasi antara precision dan recall, sehingga mencerminkan keseimbangan kinerja model.

Penggunaan metrik ini memungkinkan analisis yang lebih komprehensif terhadap performa model dalam mendeteksi penyakit retina.

2.6. Implementasi pada Data Uji

Tahap akhir adalah implementasi model CNN berbasis VGG16 pada data uji dalam bentuk aplikasi deteksi penyakit retina berbasis citra fundus. Output sistem berupa klasifikasi otomatis ke dalam empat label penyakit: katarak, retinopati diabetik, miopia, dan glaukoma. Implementasi ini bertujuan menilai kelayakan model dalam konteks nyata, sehingga dapat menjadi dasar pengembangan aplikasi diagnosis pendukung bagi tenaga medis di lingkungan klinis.

Pada tahap pengujian ini, dataset uji yang sebelumnya dipisahkan dari data latih dan validasi digunakan untuk mengukur performa sistem secara objektif. Data uji terdiri atas citra fundus mata dengan variasi kondisi pencahayaan, resolusi, serta perbedaan karakteristik individu pasien. Variasi ini penting untuk menguji robustnya model terhadap kondisi data dunia nyata yang seringkali tidak seragam. Dengan demikian, hasil evaluasi dapat merepresentasikan potensi model ketika digunakan secara langsung di lingkungan klinis.

Proses implementasi dilakukan dengan memanfaatkan antarmuka aplikasi sederhana yang mengizinkan pengguna mengunggah citra fundus. Setelah citra dimasukkan, sistem akan secara otomatis melakukan preprocessing, mengekstraksi fitur, kemudian mengklasifikasikan citra ke dalam salah satu kategori penyakit. Desain antarmuka dibuat agar mudah dipahami oleh tenaga medis, sehingga dapat digunakan sebagai alat bantu cepat dalam proses skrining awal sebelum pasien dirujuk untuk pemeriksaan lanjutan.

Selain menampilkan hasil klasifikasi, sistem juga menyertakan nilai probabilitas (confidence score) untuk setiap prediksi. Informasi ini berguna bagi tenaga medis untuk menilai tingkat keyakinan model terhadap hasil klasifikasinya. Misalnya, apabila nilai probabilitas tinggi, maka hasil prediksi dapat lebih dipercaya, sedangkan pada nilai rendah, dokter dapat mempertimbangkan pemeriksaan tambahan sebelum mengambil keputusan.

Implementasi pada data uji juga menjadi langkah penting untuk mengidentifikasi keterbatasan model. Dalam beberapa kasus, citra dengan kualitas rendah atau adanya noise dapat menurunkan akurasi klasifikasi. Oleh karena itu, hasil uji ini tidak hanya memberikan gambaran performa sistem, tetapi juga menjadi dasar rekomendasi pengembangan lebih lanjut, seperti peningkatan metode preprocessing atau penggunaan arsitektur CNN yang lebih kompleks.

Implementasi pada data uji menunjukkan bagaimana model yang dikembangkan tidak hanya berhenti pada tahap experimental, tetapi juga dapat diadaptasikan dalam bentuk aplikasi praktis. Dengan hasil yang menjanjikan, sistem ini berpotensi besar untuk dikembangkan lebih lanjut menjadi perangkat lunak pendukung diagnosis yang terintegrasi dengan sistem rekam medis elektronik di rumah sakit maupun klinik,

sehingga dapat membantu meningkatkan efisiensi dan akurasi pelayanan kesehatan mata.

3. Hasil dan Pembahasan

Penelitian ini menerapkan Convolutional Neural Network (CNN) dengan arsitektur VGG16, yang dikenal memiliki kedalaman dan kompleksitas tinggi sehingga mampu mengekstraksi fitur penting dari citra fundus mata. Dataset citra fundus dibagi menjadi tiga bagian, yaitu data pelatihan, validasi, dan pengujian. Data pelatihan digunakan untuk membangun model, data validasi untuk mengevaluasi kinerja selama proses pelatihan, sedangkan data pengujian berfungsi mengukur performa akhir model. Selama proses pelatihan, dilakukan augmentasi data untuk meningkatkan variasi dataset sekaligus mengurangi risiko overfitting. Model VGG16 kemudian dilatih secara iteratif dengan menyesuaikan parameter internal agar menghasilkan klasifikasi yang optimal. Hasil evaluasi menunjukkan bahwa model mencapai akurasi 97% dalam mendeteksi penyakit retina. Pengukuran kinerja menggunakan metrik akurasi, presisi, recall, dan F1-score, yang semuanya memberikan hasil memuaskan. Hal ini membuktikan bahwa CNN berbasis VGG16 efektif dalam mengidentifikasi beberapa jenis penyakit retina.

Namun, analisis lebih lanjut menunjukkan adanya perbedaan performa antar kelas penyakit. Misalnya, pada kelas Cataract nilai precision relatif lebih rendah (0,88) dibandingkan kelas lain yang mencapai 1,00. Faktor penyebabnya dapat berasal dari:

1. Jumlah data yang terbatas
Dengan total dataset hanya 400 citra (320 train, 40 valid, 40 test), distribusi tiap kelas menjadi relatif kecil. Hal ini membuat representasi fitur untuk beberapa kelas, termasuk Cataract, kurang memadai untuk melatih model secara optimal.
2. Kompleksitas visual pada citra katarak
Manifestasi katarak pada citra fundus sering kali kurang kontras dibanding penyakit lain seperti Diabetic Retinopathy atau Glaucoma, sehingga lebih sulit dikenali oleh CNN.
3. Kualitas citra
Beberapa citra fundus memiliki pencahayaan tidak merata atau resolusi rendah, yang dapat menyebabkan kesalahan ekstraksi fitur.

Dengan demikian, meskipun model menunjukkan performa tinggi secara keseluruhan, variasi kinerja antar kelas menegaskan pentingnya analisis mendalam terhadap kualitas dan distribusi data.

Selain itu, terdapat keterbatasan dataset yang patut dicatat. Jumlah data yang relatif sedikit (400 citra) berpotensi menimbulkan bias pada model karena kurang merepresentasikan variasi nyata kondisi retina di populasi. Data yang terbatas juga meningkatkan risiko overfitting, di mana model tampil baik pada data uji terbatas tetapi belum tentu mampu mempertahankan performa pada data baru dengan karakteristik berbeda.

Oleh karena itu, penelitian lanjutan perlu mengembangkan dataset yang lebih besar dan beragam, baik dari sisi jumlah pasien, variasi jenis penyakit, maupun kualitas citra fundus.

Secara keseluruhan, CNN berbasis VGG16 terbukti mampu mendeteksi penyakit retina dengan tingkat akurasi tinggi. Hasil ini mengindikasikan bahwa CNN memiliki potensi besar sebagai teknologi bantu dalam sistem computer-aided diagnosis (CAD) bidang oftalmologi. Meskipun demikian, optimalisasi parameter, eksplorasi arsitektur alternatif (misalnya ResNet atau EfficientNet), serta peningkatan dataset sangat diperlukan untuk meningkatkan keandalan model dalam konteks klinis yang lebih luas.

3.1 Pengujian

Pengujian model dilakukan menggunakan confusion matrix untuk menganalisis performa klasifikasi terhadap empat kelas penyakit retina, yaitu Myopia, Cataract, Diabetic Retinopathy, dan Glaucoma.

Hasil confusion matrix menunjukkan:

- a. Myopia: 7 true positive
- b. Cataract: 5 true negative, namun jumlah true positive relatif lebih rendah
- c. Diabetic Retinopathy: 7 true positive
- d. Glaucoma: 18 true positive

Hasil evaluasi klasifikasi ditunjukkan pada Tabel 6 berikut.

Tabel 6. Classification Report

Kelas	Precision	Recall	F1-score	Support
Myopia	1.00	1.00	1.00	7
Cataract	0.88	1.00	0.93	7
diabetic_retinopathy	1.00	1.00	1.00	7
glaucoma	0.90	0.95	0.97	19

Akurasi keseluruhan: 97% (40 data uji)

Dari tabel tersebut dapat disimpulkan:

1. Model memiliki kinerja sangat baik untuk kelas Myopia dan Diabetic Retinopathy (precision, recall, F1 = 1.00).
2. Kinerja untuk Cataract relatif lebih rendah, diduga akibat keterbatasan jumlah data, kompleksitas citra, dan variasi kualitas gambar.

Performa Glaucoma cukup baik, meskipun masih terdapat sedikit kesalahan klasifikasi.

Dengan hasil ini, model dapat dikatakan efektif dalam mendeteksi penyakit retina berbasis citra fundus, meskipun perlu pengembangan dataset dan optimisasi model untuk mengatasi kelemahan terutama pada kelas Cataract.

Berdasarkan hasil confusion matrix dan classification report, terlihat bahwa model CNN yang digunakan mampu mencapai tingkat akurasi yang sangat tinggi, yaitu sebesar 97% dari total 40 data uji. Nilai ini menunjukkan bahwa model secara umum berhasil mengenali pola-pola penting pada citra fundus mata dengan sangat baik. Tingkat akurasi yang mendekati

sempurna ini menjadi indikator awal bahwa pendekatan berbasis deep learning yang digunakan efektif dalam menyelesaikan masalah klasifikasi multi-kelas pada deteksi penyakit retina.

Untuk kelas Myopia, model menunjukkan kinerja sempurna dengan nilai precision, recall, dan F1-score masing-masing sebesar 1.00. Artinya, seluruh sampel Myopia pada data uji dapat diprediksi dengan benar tanpa adanya kesalahan klasifikasi. Hasil ini mengindikasikan bahwa karakteristik visual dari Myopia dapat ditangkap dengan baik oleh model, kemungkinan karena pola citra fundus penderita Myopia memiliki ciri khas tertentu yang relatif konsisten.

Kinerja pada kelas Diabetic Retinopathy juga menunjukkan hasil yang sangat optimal, dengan nilai precision, recall, dan F1-score yang sama-sama mencapai 1.00. Keberhasilan ini menunjukkan bahwa model mampu mengenali fitur-fitur spesifik seperti bercak-bercak mikroaneurisma atau perdarahan yang khas pada penderita diabetic retinopathy. Konsistensi hasil ini memperlihatkan potensi besar model untuk digunakan sebagai alat bantu deteksi dini pada kasus diabetic retinopathy, yang sering kali sulit didiagnosis tanpa bantuan teknologi.

Sementara itu, pada kelas Cataract, meskipun nilai recall mencapai 1.00 yang berarti semua kasus katarak berhasil terdeteksi, nilai precision lebih rendah yaitu 0.88. Hal ini menandakan adanya beberapa kasus non-katarak yang diklasifikasikan sebagai katarak (false positive). Kondisi ini kemungkinan besar dipengaruhi oleh keterbatasan jumlah data serta kompleksitas citra katarak yang bervariasi, seperti tingkat kekeruhan lensa yang berbeda-beda. Dengan demikian, diperlukan penambahan variasi data dan mungkin pendekatan augmentasi citra untuk meningkatkan keakuratan model pada kelas ini.

Untuk kelas Glaucoma, model menghasilkan nilai precision sebesar 0.90 dan recall sebesar 0.95 dengan F1-score 0.97. Meskipun kinerjanya tidak setinggi Myopia dan Diabetic Retinopathy, hasil ini tetap menunjukkan performa yang sangat baik. Kesalahan kecil dalam prediksi pada kelas ini menunjukkan adanya tumpang tindih fitur dengan kelas lain, mengingat citra fundus glaucoma sering kali memiliki variasi bentuk disk optik yang mirip dengan kondisi lain. Namun demikian, performa tinggi pada kelas ini tetap mendukung keandalan model dalam mendeteksi glaucoma secara otomatis.

Secara keseluruhan, hasil pengujian menunjukkan bahwa model CNN mampu bekerja secara konsisten dalam mengklasifikasikan penyakit retina dengan tingkat akurasi tinggi. Keunggulan kinerja pada kelas Myopia dan Diabetic Retinopathy memperlihatkan kekuatan model dalam menangkap pola visual yang jelas, sedangkan tantangan yang muncul pada kelas Cataract dan Glaucoma membuka peluang pengembangan lebih lanjut melalui perbaikan dataset maupun optimisasi arsitektur model. Dengan capaian ini, model tidak hanya layak dijadikan prototipe sistem

deteksi dini penyakit retina, tetapi juga berpotensi mendukung proses skrining klinis secara lebih efisien dan akurat.

4. Kesimpulan

Hasil penelitian ini menunjukkan bahwa implementasi Convolutional Neural Network (CNN) dengan arsitektur VGG16 pada citra fundus mata mampu mencapai akurasi tinggi sebesar 97%, dengan nilai precision, recall, dan F1-score yang konsisten pada hampir semua kelas penyakit retina, yaitu Myopia, Cataract, Diabetic Retinopathy, dan Glaucoma. Temuan ini mengindikasikan bahwa VGG16 efektif digunakan dalam mendukung proses klasifikasi penyakit retina berbasis citra medis. Kebaruan dari penelitian ini terletak pada penerapan VGG16 secara spesifik pada kasus deteksi multi-kelas penyakit retina di Kota Kendari, Provinsi Sulawesi Tenggara, sehingga berkontribusi pada upaya peningkatan deteksi dini dan mendukung pelayanan kesehatan berbasis teknologi kecerdasan buatan.

Meskipun hasil yang diperoleh sudah menunjukkan performa sangat baik, penelitian ini masih memiliki ruang pengembangan lebih lanjut. Beberapa potensi pengembangan ke depan antara lain memperluas dataset dengan jumlah sampel yang lebih besar dan seimbang, menambahkan kelas citra retina normal agar sistem mampu membedakan antara kondisi sehat dan sakit, serta mengeksplorasi arsitektur model lain seperti ResNet, DenseNet, atau Vision Transformer. Dengan langkah tersebut, diharapkan sistem klasifikasi penyakit retina dapat lebih robust, akurat, dan siap diimplementasikan pada skala yang lebih luas.

Penelitian ini juga memberikan kontribusi nyata dalam bidang teknologi kesehatan, khususnya dalam pemanfaatan artificial intelligence untuk mendukung proses diagnosis medis. Implementasi CNN berbasis VGG16 dapat dijadikan fondasi bagi pengembangan aplikasi berbasis komputer yang mampu membantu tenaga medis melakukan skrining awal secara cepat, objektif, dan efisien. Dengan demikian, sistem ini berpotensi menjadi alat bantu penting dalam menekan angka keterlambatan diagnosis serta meningkatkan kualitas layanan kesehatan mata di masyarakat.

Selain itu, hasil penelitian ini membuka peluang integrasi dengan sistem informasi rumah sakit atau aplikasi telemedicine, yang dapat memperluas jangkauan pelayanan kesehatan hingga ke daerah dengan keterbatasan tenaga dokter spesialis. Hal ini sejalan dengan kebutuhan transformasi digital di bidang kesehatan, yang menekankan pentingnya pemanfaatan teknologi kecerdasan buatan untuk meningkatkan pemerataan akses dan mutu layanan kesehatan.

Penelitian ini menegaskan bahwa penggunaan CNN dengan arsitektur VGG16 bukan hanya memberikan performa tinggi secara teknis, tetapi juga relevan secara praktis untuk mendukung program deteksi dini penyakit retina. Dengan pengembangan lebih lanjut, sistem yang

dihasilkan berpotensi menjadi salah satu solusi inovatif dalam pencegahan kebutaan dan peningkatan kesehatan masyarakat, khususnya di wilayah Indonesia.

Ucapan Terima Kasih

Penulis menyampaikan penghargaan yang setinggi-tingginya kepada Klinik Mata Kota Kendari, Provinsi Sulawesi Tenggara, yang telah memberikan izin lokasi penelitian serta memfasilitasi penyediaan dataset citra fundus yang menjadi fondasi penting dalam proses analisis dan pengembangan model deteksi penyakit retina berbasis teknologi kecerdasan buatan. Dukungan ini tidak hanya memperlancar jalannya penelitian, tetapi juga berkontribusi dalam pengembangan ilmu pengetahuan di bidang kesehatan mata, khususnya pemanfaatan deep learning untuk mendukung diagnosis dini dan peningkatan layanan oftalmologi. Semoga sinergi antara dunia akademik dan layanan kesehatan ini dapat terus berlanjut demi menghadirkan inovasi yang bermanfaat bagi masyarakat luas.

Daftar Rujukan

- [1] N. R. Ester Grace S.A. Guming, "The Lancet," Komisi Kesehat. Glob. Lancet Mengenai Kesehat. Mata Glob., 2021.
- [2] F. N. Cahya, N. Hardi, D. Riana, and S. Hadiyanti, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)," *Sistemasi*, vol. 10, no. 3, p. 618, 2021, doi: 10.32520/stmsi.v10i3.1248.
- [3] S. Frangky Handono, F. Tri Anggraeny, and B. Rahmat, "Implementasi Convolutional Neural Network (CNN) Untuk Deteksi Retinopati Diabetik," *J. Inform. dan Sist. Inf.*, vol. 1, no. 1, pp. 669–678, 2020.
- [4] A. A. Pertiwi and A. N. Utomo, "Implementation of Support Vector Machine (Svm) Method on Fundus Image of Retina of the Eye for the Detection of Glaucoma," *J. Rekeyasa Inf.*, vol. 12, no. 1, pp. 19–27, 2023.
- [5] K. Tingkat Keparahan Retinopati Diabetik Berdasarkan Citra Fundus Menggunakan, M. A. Hendriyawan, and W. R. Saputro, "Diabetic Retinopathy Severity Level Classification Based on Fundus Image Using Convolutional Neural Network (CNN)," *Semin. Nas. Inform.*, vol. 1, no. 1, pp. 173–185, 2021, [Online]. Available: <http://www.jurnal.upnyk.ac.id/index.php/semnasif/article/view/6071>
- [6] J. Penelitian et al., "Penerapan Algoritma Convolutional Neural Network Untuk Menentukan Retinopati Hipertensi Melalui Citra Retina Fundus," vol. 6, pp. 143–149, 2023.
- [7] S. Wangko, "Histofisiologi Retina," *J. Biomedik*, vol. 5, no. 3, 2014, doi: 10.35790/jbm.5.3.2013.4342
- [8] M. A. Amrullah and M. I. Irawan, "Implementasi Jaringan Saraf Konvolusional dengan Inception-V3 untuk Deteksi Katarak Menggunakan Gambar Digital Funduskopi," *J. Sains dan Seni ITS*, vol. 12, no. 1, 2023, doi: 10.12962/j23373520.v12i1.106807.
- [9] Y. A. Suwitono and F. J. Kaunang, "Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Daun Dengan Metode Data Mining SEMMA Menggunakan Keras," *J. Komtika (Komputasi dan Inform.)*, vol. 6, no. 2, pp. 109–121, 2022, doi: 10.31603/komtika.v6i2.8054
- [10] M. N. Fadlurrahman, A. E. Minarno, and Y. Azhar, "Klasifikasi COVID-19 Menggunakan Algoritma CNN," *Repositor*, vol. 5, no. 2, pp. 699–708, 2023.
- [11] I. Hartono, A. Noertjahyana, and L. W. Santoso, "Deteksi Masker Wajah dengan Metode Convolutional Neural Network," *J. Infra*, 2022, [Online]. Available: <https://publication.petra.ac.id/index.php/teknik-informatika/article/view/12042>
- [12] M. R. Alwanda, R. P. K. Ramadhan, and D. Alamsyah, "Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle," *J. Algoritma*, vol. 1, no. 1, pp. 45–56, 2020, doi: 10.35957/algoritme.v1i1.434.
- [13] P. A. Nugroho, I. Fenriana, and R. Arijanto, "Implementasi Deep Learning Menggunakan Convolutional Neural Network (Cnn) Pada Ekspresi Manusia," *Algor*, vol. 2, no. 1, pp. 12–21, 2020.
- [14] N. Dipu, S. Shohan, and K. M. A. Salam, "Ocular Disease Detection Using Advanced Neural Network Based Classification Algorithms," *ASIAN J. Conver. Technol.*, vol. 7, pp. 91–99, Aug. 2021, doi: 10.33130/AJCT.2021v07i02.019.
- [15] W. Wijaya Kusuma, R. Rizal Isnanto, A. Fauzi, and P. Korespondensi, "DenseNet121 Menggunakan Kerangka Kerja TensorFlow untuk Deteksi Jenis Hewan," *J. Tek. Komput.*, vol. 1, no. 4, pp. 141–147, 2023, doi: 10.14710/jtk.v1i4.37009
- [16] M. A. Hasan, Y. Riyanto, and D. Riana, "Grape leaf image disease classification using CNN-VGG16 model," *J. Teknol. dan Sist. Komput.*, vol. 9, no. 4, pp. 218–223, 2021, doi: 10.14710/jtsiskom.2021.14013.
- [17] K. A. H. Wibowo and A. Alamsyah, "Klasifikasi Diabetic Retinopathy Menggunakan CNN dengan Arsitektur yang Dimodifikasi," *Indones. J. Math. Nat. Sci.*, vol. 46, no. 1, pp. 45–52, 2023, doi: 10.15294/ijmns.v46i1.4