

ANALISIS CITRA MEDIS UNTUK IDENTIFIKASI PENYAKIT MATA DENGAN TEKNOLOGI CONVOLUTIONAL NEURAL NETWORKS

Fajar As Shidik¹, Khoirul Musthofa², Aradea Pinkan Kartiningtyas³, Tinuk Agustin⁴

¹²³⁴STMIK Amikom Surakarta
Sukoharjo, Indonesia

Email: ¹fajar.10444@mhs.amikomsolo.ic.id ,
²khoirul.10461@mhs.amikomsolo.ic.id , ³aradea.10445@mhs.amikomsolo.ic.id,
⁴agustin.amikomsolo@gmail.com

Abstract

*Eye diseases such as cataracts, glaucoma, and diabetic retinopathy are the main causes of vision impairment that can lead to blindness if not detected and treated early. The diagnosis of eye diseases traditionally requires a direct examination by an ophthalmologist, which is manual and time-consuming. Along with the development of artificial intelligence (AI) and machine learning (Machine Learning) technology, medical image-based methods, especially Convolutional Neural Networks (CNNs), have proven effective in detecting and classifying eye diseases automatically. CNNs have the ability to extract important features from medical images and recognize the visual patterns that are characteristic of different types of eye diseases. This study aims to develop and evaluate a CNN model that can classify eye diseases based on fundus imagery. Several CNN architectures that have proven effective in image classification tasks, such as DenseNet, ResNet, and MobileNet, are implemented, accompanied by data transfer learning and augmentation techniques to improve model accuracy on limited datasets. The dataset used in this study included images of the fundus of the eye containing several types of eye diseases, including cataracts, glaucoma, and diabetic retinopathy. The ResNet50 architecture, with a learning rate of 0.01, demonstrated superior performance in the classification of eye diseases, including cataracts, glaucoma, and diabetic retinopathy, with an accuracy of **92.27%**. Compared to other architectures such as MobileNet and DenseNet, ResNet50 excels in accuracy and stability. This CNN technology enables automatic detection of eye diseases, accelerates early diagnosis and supports clinical decision-making, which is crucial to prevent blindness due to delayed diagnosis.*

Keywords: Eye diseases, CNN, medical image classification, , cataracts, glaucoma, diabetic retinopathy, transfer learning, data augmentation, eye fundus, artificial intelligence (AI).

Abstraksi

Penyakit mata seperti katarak, glaukoma, dan retinopati diabetik merupakan penyebab utama gangguan penglihatan yang dapat menyebabkan kebutaan jika tidak dideteksi dan diobati secara dini. Diagnosis penyakit mata secara tradisional membutuhkan pemeriksaan langsung oleh dokter spesialis mata, yang bersifat manual dan memakan waktu. Seiring dengan perkembangan teknologi kecerdasan buatan

(Artificial Intelligence/AI) dan pembelajaran mesin (Machine Learning), metode berbasis citra medis, terutama Convolutional Neural Network (CNN), telah terbukti efektif dalam mendeteksi dan mengklasifikasikan penyakit mata secara otomatis. CNN memiliki kemampuan untuk mengekstraksi fitur penting dari gambar medis dan mengenali pola-pola visual yang menjadi ciri khas dari berbagai jenis penyakit mata. Penelitian ini bertujuan untuk mengembangkan dan mengevaluasi model CNN yang dapat mengklasifikasikan penyakit mata berdasarkan citra fundus. Beberapa arsitektur CNN yang telah terbukti efektif dalam tugas klasifikasi gambar, seperti DenseNet, ResNet, dan MobileNet, diterapkan, disertai dengan teknik transfer learning dan augmentasi data untuk meningkatkan akurasi model pada dataset yang terbatas. Dataset yang digunakan dalam penelitian ini mencakup gambar fundus mata yang mengandung beberapa jenis penyakit mata, termasuk katarak, glaukoma, dan retinopati diabetik. Arsitektur ResNet50, dengan learning rate 0.01, menunjukkan performa unggul dalam klasifikasi penyakit mata, termasuk katarak, glaukoma, dan retinopati diabetik, dengan akurasi **92.27%**. Dibandingkan dengan arsitektur lain seperti MobileNet dan DenseNet, ResNet50 unggul dalam akurasi dan stabilitas. Teknologi CNN ini memungkinkan deteksi otomatis penyakit mata, mempercepat diagnosis dini dan mendukung pengambilan keputusan klinis, yang sangat penting untuk mencegah kebutaan akibat keterlambatan diagnosis.

Kata Kunci: Penyakit mata, CNN, klasifikasi citra medis, katarak, glaukoma, retinopati diabetik, kecerdasan buatan (AI).

1. PENDAHULUAN

Penyakit mata merupakan salah satu masalah kesehatan global yang signifikan, dengan jutaan orang di seluruh dunia mengalami berbagai gangguan penglihatan hingga kebutaan [1]. Berdasarkan laporan dari Organisasi Kesehatan Dunia (WHO), lebih dari 2,2 miliar orang mengalami gangguan penglihatan, dan sekitar setengahnya disebabkan oleh kondisi yang dapat dicegah atau diobati, seperti katarak, glaukoma, retinopati diabetik, serta degenerasi makula terkait usia [2]. Deteksi dini memainkan peran krusial dalam pengelolaan penyakit mata. Banyak penyakit mata, seperti glaukoma dan retinopati diabetik, berkembang secara perlahan dan sering kali tidak menunjukkan gejala pada tahap awal, sehingga sulit untuk dikenali tanpa pemeriksaan medis. Dengan kemajuan teknologi medis, metode deteksi berbasis citra medis menjadi sangat relevan dalam mendukung diagnosis dini dan pengambilan keputusan klinis [3]. Teknik konvensional yang digunakan dalam diagnosis penyakit mata biasanya melibatkan pemeriksaan langsung oleh dokter spesialis mata dengan menggunakan alat-alat seperti oftalmoskop atau slit lamp untuk melihat struktur mata, terutama retina. Meskipun teknik ini telah terbukti efektif, proses manual ini cenderung memakan waktu, memerlukan keterampilan dan pengalaman khusus, serta dapat bersifat subjektif karena bergantung pada interpretasi dokter [4]. Di sinilah peran teknologi kecerdasan buatan (Artificial Intelligence/AI) dan pembelajaran mesin (Machine Learning) mulai memainkan peran penting dalam meningkatkan kecepatan dan akurasi diagnosis medis [5]. AI, terutama dalam bentuk Deep Learning, telah menunjukkan potensi besar dalam berbagai bidang, termasuk pengenalan pola, klasifikasi gambar, dan pengambilan

keputusan klinis berbasis data [6]. Salah satu algoritma deep learning yang paling populer dan efektif dalam pengolahan citra medis adalah Convolutional Neural Network (CNN) [7]. CNN dirancang khusus untuk mengenali pola visual yang kompleks, yang membuatnya sangat cocok untuk analisis gambar medis seperti citra retina atau fundus mata [8]. CNN dapat secara otomatis mengekstraksi fitur penting dari gambar medis, yang memungkinkan model untuk mengenali dan membedakan berbagai jenis penyakit mata berdasarkan pola-pola spesifik yang ada pada citra [9].

CNN bekerja dengan cara membangun lapisan-lapisan konvolusi yang secara progresif mengekstraksi fitur-fitur dari gambar, mulai dari fitur sederhana seperti tepi atau garis, hingga fitur yang lebih kompleks seperti bentuk atau pola yang terkait dengan penyakit[9]. Dalam konteks klasifikasi penyakit mata, CNN telah digunakan dalam berbagai penelitian untuk mendeteksi penyakit seperti retinopati diabetik, degenerasi makula, katarak, dan glaukoma dengan tingkat akurasi yang cukup tinggi [10]. Dataset-dataset ini memungkinkan peneliti untuk melatih model CNN dengan data yang cukup beragam, sehingga model dapat lebih robust dan mampu menangani variasi yang ada dalam citra medis nyata, seperti perbedaan kualitas gambar, variasi pencahayaan, atau adanya artefak pada gambar [11]. Meskipun CNN dapat membuat prediksi yang sangat akurat, proses pengambilan keputusan yang dilakukan oleh jaringan saraf ini cenderung bersifat black box, artinya sulit untuk memahami secara intuitif bagaimana model tersebut mencapai kesimpulannya [12]. Ini menjadi masalah dalam konteks medis, di mana interpretasi yang jelas dan dapat dijelaskan sangat penting untuk mendukung keputusan klinis yang tepat. Selain itu, kualitas citra medis yang digunakan untuk melatih model CNN juga memainkan peran penting dalam performa model [13]. Citra dengan kualitas rendah, pencahayaan yang buruk, atau yang memiliki noise dapat mengurangi akurasi prediksi model. Penggunaan CNN juga memerlukan infrastruktur komputasi yang canggih, termasuk GPU (Graphics Processing Unit) yang kuat untuk melatih model dalam skala besar [14]. Penelitian ini bertujuan mengembangkan model CNN untuk mengklasifikasikan penyakit mata dengan akurasi tinggi menggunakan citra fundus. Kami menguji beberapa arsitektur CNN, termasuk DenseNet, ResNet, dan MobileNet, serta membandingkan kinerjanya dalam mendeteksi penyakit seperti katarak, glaukoma, dan retinopati diabetik. Diharapkan, sistem klasifikasi berbasis CNN ini dapat diterapkan dalam lingkungan klinis sebagai alat bantu diagnosis yang efisien, cepat, dan akurat, memberikan akses lebih luas terhadap diagnosis dini, terutama di daerah kekurangan tenaga ahli mata, serta berkontribusi pada penurunan angka kebutaan dan gangguan penglihatan yang dapat dicegah.

2. TINJAUAN PUSTAKA

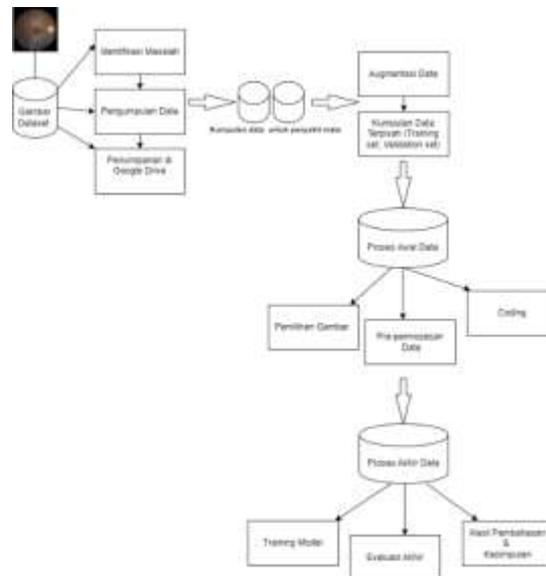
Penelitian tentang penggunaan Convolutional Neural Networks (CNN) dalam mendiagnosis penyakit mata telah berkembang pesat. CNN dikenal efektif dalam menganalisis citra digital, memungkinkan pengenalan pola dan fitur yang penting untuk mendeteksi berbagai kondisi kesehatan mata. Sebagai contoh, penelitian Indraswari et

al., menunjukkan bahwa CNN mampu mendeteksi berbagai jenis penyakit mata dengan tingkat akurasi tinggi melalui metode transfer learning menggunakan arsitektur MobileNetV2. Penggunaan transfer learning membantu mempercepat proses pelatihan model sekaligus meningkatkan akurasi dengan memanfaatkan fitur yang sudah dilatih pada dataset yang lebih besar. Namun, meskipun arsitektur MobileNetV2 menawarkan kinerja yang baik, ada kekurangan dalam menangani variasi dataset yang lebih kompleks, karena model ini cenderung kurang robust terhadap jenis penyakit yang jarang ditemukan [15].

Studi lain yang dilakukan oleh Qulub dan Agustin, menggunakan arsitektur VGG-16 untuk klasifikasi citra fundus mata. Penelitian ini menggunakan dataset yang mencakup penyakit diabetic retinopathy, glaukoma, dan katarak, serta menunjukkan hasil yang akurat dalam membedakan berbagai penyakit tersebut. Kelebihan VGG-16 adalah kemampuannya dalam mendeteksi detail fitur yang sangat kecil di gambar fundus, yang merupakan karakteristik penting untuk klasifikasi penyakit mata. Namun, kekurangan dari arsitektur ini adalah ukurannya yang besar dan kebutuhan komputasi yang tinggi, sehingga kurang efisien bila diterapkan di perangkat dengan sumber daya terbatas [16].

Secara lebih luas, CNN telah menjadi pendekatan populer dalam bidang medis karena kemampuannya dalam mendeteksi berbagai penyakit mata, seperti yang ditunjukkan oleh penelitian Gulshan et al. Mereka mengembangkan model CNN untuk mendeteksi retinopati diabetik dengan tingkat akurasi yang sangat tinggi. Studi ini menyoroti potensi teknologi deep learning sebagai alat yang andal untuk diagnosis medis yang cepat dan akurat di bidang oftalmologi. Walaupun demikian, mereka juga mengidentifikasi beberapa tantangan, seperti kebutuhan untuk meningkatkan generalisasi model agar bisa diterapkan pada populasi yang lebih luas serta pentingnya perlindungan data pasien dalam penerapan teknologi ini di lingkungan klinis [17]. Meskipun teknologi CNN menawarkan banyak keuntungan dalam deteksi dan diagnosa penyakit mata, ada beberapa tantangan yang perlu diperhatikan. Salah satunya adalah akurasi model yang bergantung pada kualitas dan variasi dataset pelatihan. Selain itu, efisiensi model perlu ditingkatkan untuk aplikasi klinis yang memerlukan respon cepat dan aksesibilitas yang luas [18]. Dengan demikian, penelitian sebelumnya menunjukkan potensi besar CNN dalam mendeteksi penyakit mata, meskipun masih diperlukan pengembangan lebih lanjut untuk mencapai hasil yang optimal dalam lingkungan klinis nyata. Hasil dari studi-studi tersebut membentuk dasar bagi penelitian lanjutan yang bertujuan untuk memperbaiki performa dan keandalan model CNN, serta memastikan bahwa teknologi ini dapat mendukung diagnosis medis secara lebih aman, efisien, dan akurat [19].

3. METODE PENELITIAN

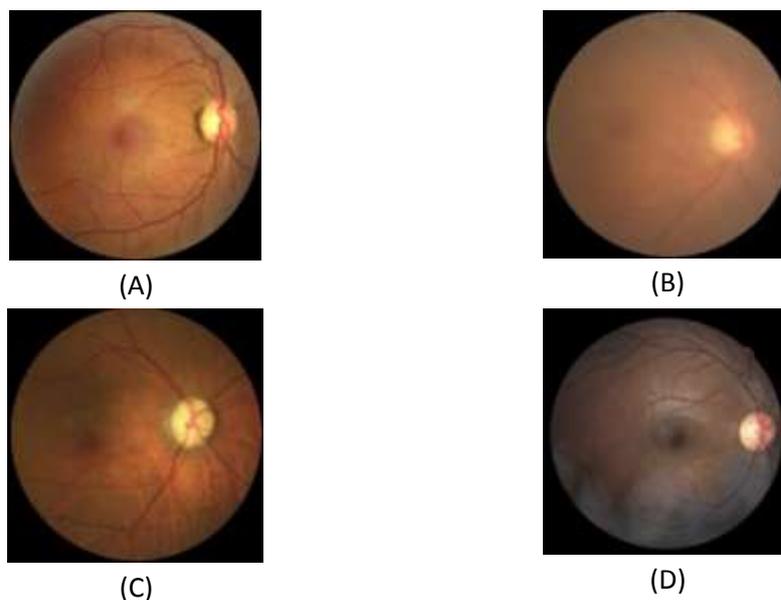


Gambar 1. Alur Penelitian

3.1 Dataset

Dataset citra fundus mata yang digunakan merupakan data sekunder yang diperoleh dari Kaggle, melalui kernel yang tersedia di (<https://www.kaggle.com/datasets/najibhasan/diabetic-eye-disease-retina-dataset>) Dataset ini terdiri dari total 1.034 citra fundus yang digunakan untuk klasifikasi beberapa kondisi kesehatan mata. Citra-citra fundus tersebut terbagi ke dalam empat kelas penyakit mata, yang masing-masing memiliki jumlah data berbeda. Dataset ini terdiri dari empat kelas citra fundus mata yang masing-masing mewakili kondisi kesehatan mata yang berbeda, berguna untuk pengembangan model klasifikasi otomatis dalam deteksi dini dan diagnosis penyakit mata:

1. Normal : Berisi 364 citra mata sehat tanpa indikasi penyakit. Kelas ini berfungsi sebagai referensi kondisi mata normal, penting untuk membantu model dalam mengenali citra tanpa abnormalitas.
2. Cataract : Terdiri dari 105 citra fundus mata yang didiagnosis dengan katarak, kondisi di mana lensa mata menjadi keruh dan mengganggu penglihatan. Citra dalam kelas ini memiliki pola visual yang membantu model mengidentifikasi tanda-tanda katarak.
3. Glaucoma : Terdiri dari 286 citra fundus dengan glaukoma, penyakit yang menyerang saraf optik dan berisiko menyebabkan kebutaan jika tidak ditangani. Citra pada kelas ini menunjukkan karakteristik khusus, seperti perubahan pada disk optik, yang berguna untuk mengenali glaukoma.
4. Diabetic Retinopathy : Terdiri dari 279 citra fundus mata dengan tanda-tanda retinopati diabetik, komplikasi diabetes yang menyerang retina. Citra ini mengandung indikator seperti mikroaneurisma dan hemoragi, membantu model dalam mendeteksi retinopati diabetik.



Gambar 2. Citra Fundus dari kelas (A) normal, (B) cataract, (C) glaucoma, (D) Diabetic Retinopathy

3.2 Convolutional Neural Network (CNN)

CNN (Convolutional Neural Network) merupakan salah satu jenis jaringan saraf tiruan yang dirancang khusus untuk mengolah data berupa gambar. CNN dikenal karena kemampuannya mendeteksi pola dan fitur dalam gambar melalui proses konvolusi multi-lapis [20]. Metode klasifikasi transfer learning CNN melibatkan penggunaan model yang sebelumnya dilatih untuk tugas serupa. Transfer learning menggunakan pengetahuan yang diperoleh dari satu tugas untuk meningkatkan kinerja pada tugas lain yang serupa [21]. Misalnya, model yang dilatih pada kumpulan data besar seperti ImageNet juga dapat dilatih dan digunakan kembali pada kumpulan data tertentu, seperti gambar medis penyakit mata [22]. Hal ini memungkinkan CNN melakukan klasifikasi dengan lebih efisien dan akurat karena model telah memiliki pengetahuan awal tentang fitur umum pada gambar dan hanya perlu beradaptasi dengan data baru. Transfer Learning membantu mengurangi waktu dan sumber daya yang diperlukan untuk melatih model baru dari awal [23]

3.3 ResNet50

ResNet50 dalam klasifikasi penyakit mata dari citra fundus, yang menggunakan pendekatan Convolutional Neural Network (CNN). Sebagai bagian dari keluarga Residual Network (ResNet), ResNet50 dirancang untuk mengatasi masalah vanishing gradient yang sering muncul pada jaringan dalam dengan lapisan yang sangat banyak [24].

3.4 DenseNet121

DenseNet dalam konteks klasifikasi penyakit mata dari citra fundus menunjukkan bagaimana model ini mengatasi tantangan yang ada pada jaringan konvolusional tradisional, terutama dalam hal hilangnya informasi gradien yang sering kali terjadi pada jaringan dengan banyak lapisan [25]. Keunggulan utama dari DenseNet adalah kemampuannya untuk mengoptimalkan ekstraksi fitur dalam dataset yang

terbatas [26]. DenseNet dapat menangani masalah ini dengan efisien karena setiap lapisan menerima informasi dari semua lapisan sebelumnya, yang memperkaya representasi fitur yang dihasilkan [25], [26].

3.5 MobileNet

MobileNet merupakan arsitektur CNN yang dirancang untuk efisiensi tinggi pada perangkat dengan keterbatasan sumber daya, menjadikannya ideal untuk klasifikasi penyakit mata dalam aplikasi real-time atau perangkat mobile. MobileNet menggunakan depthwise separable convolution, yang memisahkan operasi konvolusi menjadi dua tahap untuk mengurangi jumlah parameter dan beban komputasi secara signifikan, sehingga model menjadi lebih ringan tanpa mengorbankan performa klasifikasi secara drastis.

4. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan Google Colab untuk mengevaluasi kinerja tiga arsitektur CNN, yaitu ResNet50, MobileNet, dan DenseNet121, dalam klasifikasi penyakit mata dari citra medis[27]. Hasil menunjukkan bahwa DenseNet121 mencapai akurasi tertinggi 92,27%, sementara ResNet50 unggul dalam aliran gradien berkat koneksi residual, menjadikannya potensial untuk diagnosis. Meskipun ResNet50 menunjukkan kinerja solid, penelitian lebih lanjut diperlukan untuk meningkatkan generalisasi model. Perbandingan ketiga arsitektur ini menempatkan ResNet50 dengan akurasi 92,27% di posisi teratas, diikuti oleh MobileNet dan DenseNet121, yang lebih efisien dalam komputasi dan inferensi, cocok untuk aplikasi mobile dan IoT. Adapun Tabel Perbandingan 3 metode sebagai berikut :

Gambar Tabel 1 dibawah menunjukkan perbandingan kinerja tiga arsitektur CNN, yaitu ResNet50, MobileNet, dan DenseNet121, dalam klasifikasi penyakit mata. Masing-masing model diuji dengan dua nilai learning rate (0.01 dan 0.001), dan hasil akurasi (%) dicantumkan untuk setiap kombinasi. Dari tabel ini:

ResNet50 dengan learning rate 0.01 mencapai akurasi tertinggi, yaitu 92.27%, menunjukkan performa unggul pada pengaturan tersebut.

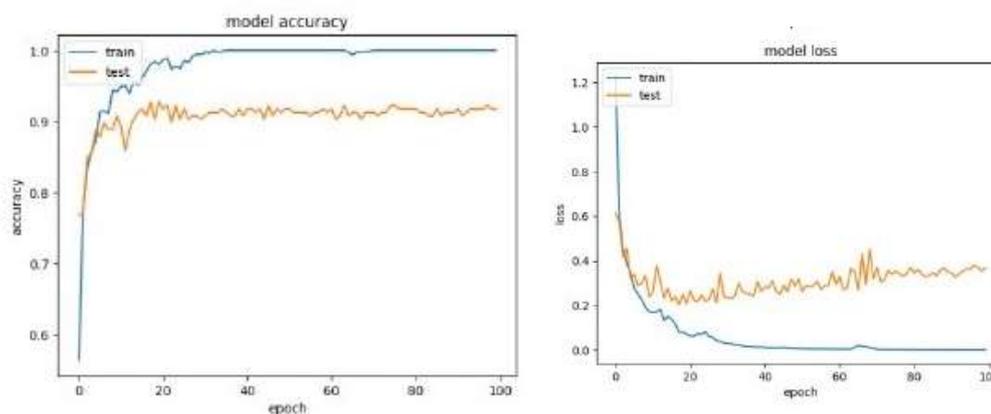
MobileNet dan DenseNet121 memiliki akurasi yang sedikit lebih rendah dibanding ResNet50, tetapi tetap menunjukkan performa yang kompetitif, dengan MobileNet lebih efisien dari segi komputasi.

Secara keseluruhan, tabel ini memperlihatkan bahwa ResNet50 optimal pada learning rate 0.01, sedangkan MobileNet lebih unggul dalam efisiensi model.

Tabel 1. Perbandingan Model CNN ResNet50, MobileNet dan DenseNet121

Model	Learning Rate	Akurasi (%)
ResNet50	0.01	92.27%
ResNet50	0.001	77.78%
MobileNet	0.01	88.89%
MobileNet	0.001	89.86%

Model	Learning Rate	Akurasi (%)
DenseNet121	0.01	90.82%
DenseNet121	0.001	91.79%

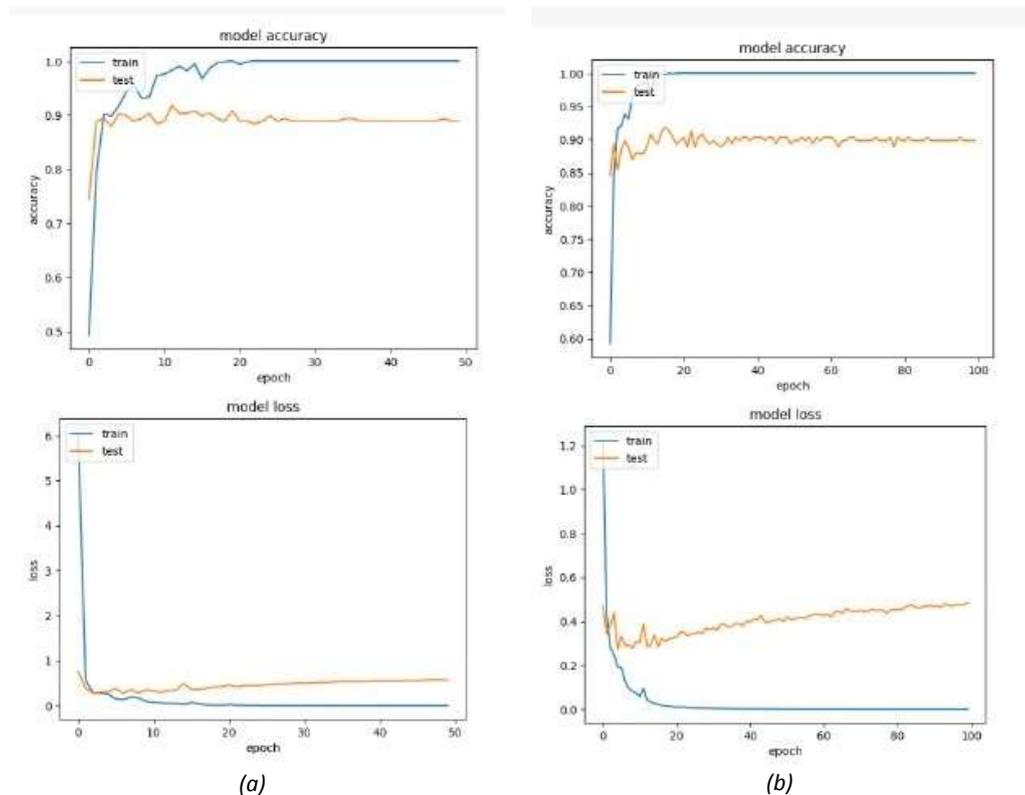


Gambar 3. Grafik DesNet121 learning rate 0.001 epoch 100

Berdasarkan gambar nomer 3 adalah grafik *DesNet121* yang menunjukkan dua nilai learning rate yang berbeda untuk melihat pengaruhnya terhadap akurasi model:

1. Learning rate 0,01: Hasilnya menunjukkan bahwa DenseNet mencapai akurasi sebesar **90,82%**.
2. Learning rate 0,001: Pada nilai ini, DenseNet juga berhasil mencapai akurasi yang sama yaitu **91.79%**.

Hasil penelitian menunjukkan bahwa learning rate 0,001 memberikan performa terbaik untuk DenseNet dalam klasifikasi penyakit mata, dengan akurasi 91,79%. DenseNet terbukti kompetitif dan cocok digunakan bersama arsitektur lain seperti MobileNet dan ResNet. Integrasi DenseNet dalam sistem deteksi dini dapat meningkatkan akurasi dan mempercepat diagnosis, terutama di wilayah dengan keterbatasan akses spesialis mata. Meskipun membutuhkan lebih banyak waktu dan memori, DenseNet121 hampir setara dengan ResNet50 dalam akurasi dan dapat menangani kompleksitas fitur citra fundus, menjadikannya pilihan tepat untuk aplikasi medis yang membutuhkan ketelitian tinggi.

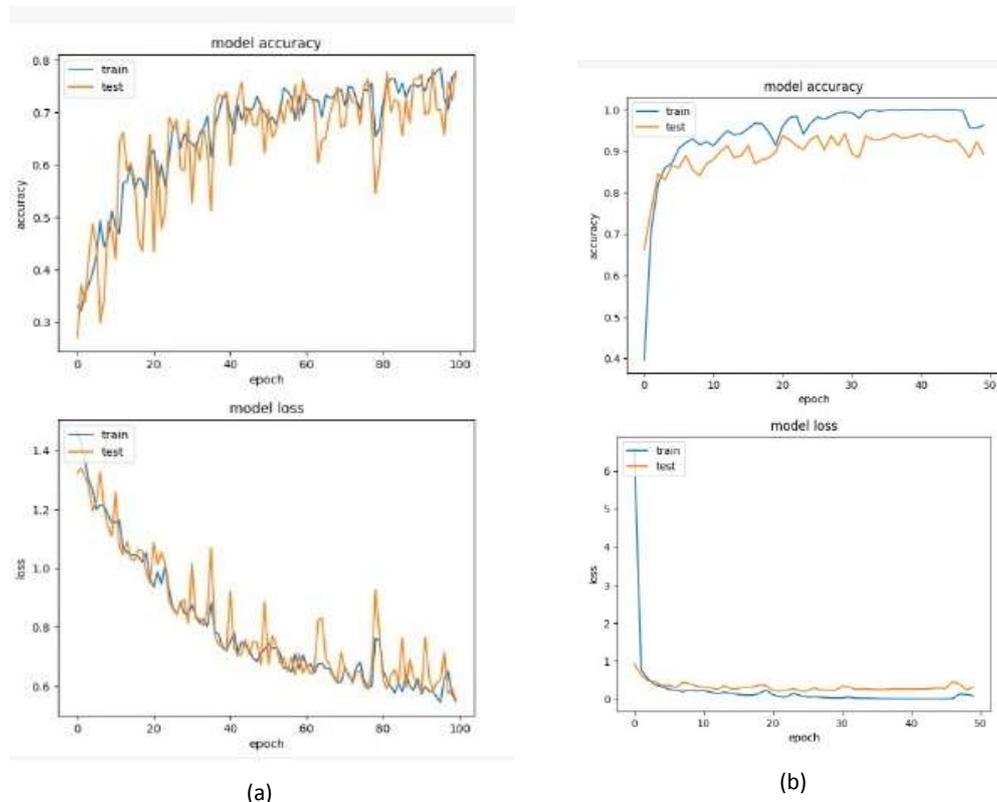


Gambar 4. Grafik mobileNet 0.01 (a), Grafik mobileNet 0.001 (b)

Berdasarkan gambar nomer 4 adalah grafik *MobileNet* yang menunjukkan dua nilai learning rate yang berbeda untuk melihat pengaruhnya terhadap akurasi model:

1. Learning rate 0,01 : Pada nilai ini, *MobileNet* mencapai akurasi sebesar **88,89%**.
2. Learning rate 0,001: Pada nilai ini, *MobileNet* berhasil mencapai akurasi yang lebih tinggi, yaitu **89,86%**.

Hasil penelitian ini menunjukkan bahwa learning rate 0,001 memberikan performa terbaik untuk *MobileNet* dalam klasifikasi penyakit mata, dengan akurasi 89,86%. Meskipun sedikit lebih rendah dari *ResNet50* dan *DenseNet121*, *MobileNet* tetap efektif dalam mendeteksi penyakit mata dan efisien dalam komputasi. Dengan arsitektur ringan, *MobileNet* ideal untuk perangkat dengan sumber daya terbatas, seperti di daerah dengan fasilitas kesehatan terbatas atau perangkat berdaya rendah. Kecepatan inferensi dan efisiensi komputasi membuatnya cocok untuk aplikasi medis yang membutuhkan respons cepat dan konsumsi daya rendah, terutama di perangkat mobile atau sistem IoT.



Gambar 5. Grafik ResNet 0.001 (a), Grafik ResNet 0.01

Berdasarkan gambar nomer 5 adalah grafik ResNet50 yang menunjukkan dua nilai learning rate yang berbeda untuk melihat pengaruhnya terhadap akurasi model:

1. Learning rate 0,01 : Dengan nilai ini, ResNet50 mencapai akurasi **92.27%**.
2. Learning rate 0,001 : Pada nilai ini, akurasi ResNet50 menurun menjadi **77,78%**.

Penelitian ini menunjukkan bahwa learning rate 0,01 memberikan performa optimal untuk ResNet50 dalam klasifikasi penyakit mata, dengan akurasi 92,27%. Meskipun tidak setinggi beberapa arsitektur lain, ResNet50 efektif untuk deteksi dini, terutama di wilayah dengan keterbatasan akses spesialis mata. Dengan residual blocks dan skip connections, ResNet50 dapat mempelajari fitur lebih dalam tanpa kehilangan informasi penting, menjadikannya pilihan tepat untuk aplikasi medis yang membutuhkan akurasi tinggi, meskipun membutuhkan lebih banyak sumber daya.

5. KESIMPULAN

Penelitian ini menunjukkan bahwa metode Convolutional Neural Network (CNN) efektif untuk klasifikasi penyakit mata dari citra fundus, dengan kinerja yang bervariasi sesuai arsitektur. ResNet50 memiliki akurasi tertinggi (92,27%), cocok untuk aplikasi yang memerlukan ketepatan tinggi pada dataset besar. MobileNet unggul dalam efisiensi, dengan ukuran model ringan dan komputasi rendah, ideal untuk perangkat terbatas. DenseNet121 menawarkan keseimbangan antara akurasi dan efisiensi, cocok untuk aplikasi dengan kemampuan komputasi sedang hingga tinggi. Pemilihan model CNN

dapat disesuaikan dengan kebutuhan akurasi dan efisiensi komputasi untuk berbagai platform. Untuk penulisan selanjutnya pengembangan Model Hybrid dan Lightweight untuk Deteksi Penyakit Mata: Menggabungkan arsitektur, seperti MobileNet sebagai feature extractor dan ResNet50 untuk klasifikasi, guna mengoptimalkan akurasi dan efisiensi. Menggunakan augmentasi data dan transfer learning untuk meningkatkan generalisasi, terutama pada dataset kecil. Fokus pada model lightweight untuk perangkat mobile dengan keterbatasan sumber daya, tanpa mengorbankan akurasi. Penelitian ini menegaskan efektivitas CNN dalam deteksi dan klasifikasi penyakit mata dengan model yang fleksibel sesuai kebutuhan aplikasi.

DAFTAR PUSTAKA

- [1] J. Darma and A. Husada, "HUBUNGAN PENGETAHUAN DENGAN TINGKAT KECEMASAN PADA PASIEN PRE-OPERASI KATARAK DI RUMAH SAKIT MATA MENCIRIM TUJUH TUJUH MEDAN," 2024.
- [2] B. Meirawati, D. Ningrum, R. Rosyda, D. Dolifah, P. Studi, and D.-I. Keperawatan, "PENGARUH EDUKASI DENGAN MEDIA AUDIOVISUAL TENTANG PENCEGAHAN GANGGUAN PENGLIHATAN TERHADAP EARLY ADOLESCENT".
- [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)." [Online]. Available: <https://www.kaggle.com/datasets/jr2ngb/cataractdataset>
- [4] S. N. A. Ahmad, W. M. D. Wan Zaki, and N. S. M Zamani, "A Pterygium Disease Screening System for Anterior Segment Photographed Images," *Jurnal Kejuruteraan*, vol. 31, no. 1, pp. 99–105, Apr. 2019, doi: 10.17576/jkukm-2019-31(1)-12.
- [5] "Plagiarism6885".
- [6] N. Yudistira, "Peran Big Data dan Deep Learning untuk Menyelesaikan Permasalahan Secara Komprehensif," *EXPERT: Jurnal Manajemen Sistem Informasi dan Teknologi*, vol. 11, no. 2, p. 78, Dec. 2021, doi: 10.36448/expert.v11i2.2063.
- [7] D. Gunawan and H. Setiawan, "Convolutional Neural Network dalam Analisis Citra Medis," 2022.
- [8] "Naskah-Pidato-Prof.-Hanung".
- [9] Y. Kasnanda Bintang, H. Imaduddin, Y. Kasnanda, and B. Corresponding Author, "JIPI (Jurnal Ilmiah Penelitian dan Pembelajaran Informatika) Journal homepage: <https://jurnal.stkipppgritulungagung.ac.id/index.php/jipi> PENGEMBANGAN MODEL DEEP LEARNING UNTUK DETEKSI RETINOPATI DIABETIK MENGGUNAKAN METODE TRANSFER LEARNING," vol. 9, no. 3, pp. 1442–1455, 2024, doi: 10.29100/jipi.v9i3.5588.

- [10] M. S. Qulub and S. Agustin, "INDENTIFIKASI PENYAKIT MATA DENGAN KLASIFIKASI CITRA FOTO FUNDUS MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN)," 2024.
- [11] "0731164000010-Undergraduate_Thesis".
- [12] S. T. Iwan Sonjaya, M. T. Edwin Ariesto Umbu Malahina, S. Kom, and M. T. Asmara, "KECERDASAN ARTIFISIAL."
- [13] R. Sandra and Y. Zebua, "FENOMENA ARTIFICIAL INTELLIGENCE (AI)," 2023. [Online]. Available: <https://www.researchgate.net/publication/371491224>
- [14] B. Rahmat, S. Si, B. Nugroho, S. Kom, and M. Kom, *Dilengkapi Kamera Kinect Xbox 360, Pemrograman Deep Learning dengan Python dan Koneksi Internet of Things (IoT) PEMROGRAMAN ROBOT CERDAS DENGAN ARDUINO*. 2020. [Online]. Available: www.indomediapustaka.com
- [15] 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)." [Online]. Available: <https://www.kaggle.com/datasets/jr2ngb/cataractdataset>
- [16] M. S. Qulub and S. Agustin, "INDENTIFIKASI PENYAKIT MATA DENGAN KLASIFIKASI CITRA FOTO FUNDUS MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN)," 2024.
- [17] B. Retinopati Diabetika Dan Kebutaan, P. Penguahan Jabatan Guru Besar dalam Bidang Ilmu Kesehatan Mata pada Fakultas Kedokteran, K. Masyarakat, dan Keperawatan Universitas Gadjah Mada Disampaikan pada Penguahan Guru Besar, and dr Muhammad Bayu Sasongko, "IMPLEMENTASI SKRINING BERBASIS TELE-OFTALMOLOGI UNTUK MENURUNKAN."
- [18] S. Pemanfaatan, K. Buatan, S. Diagnosa, M. Berbasis, G. Rizki, and A. Febriani, "Utilization Of Artificial Intelligence In Image-Based Medical Diagnosis."
- [19] "admin,+Meningkatkan+Keamanan+Data+pada+Attendance+System+Berbasis+Face+Recognition+-+ISBN+FullBook".
- [20] M. Malik Ibrahim, R. Rahmadewi, and L. Nurpulaela, "PENDETEKSIAN NOMINAL UANG PADA GAMBAR MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK: INTEGRASI METODE PRA-PEMROSESAN CITRA DAN KLASIFIKASI BERBASIS CNN," 2023.
- [21] Handoko Adji Pangestu and Kusriani, "Peningkatan kinerja arsitektur ResNet50 untuk Menangani Masalah Overfitting dalam Klasifikasi Penyakit Kulit," *TEMATIK*, vol. 11, no. 1, pp. 65–71, Jun. 2024, doi: 10.38204/tematik.v11i1.1876.
- [22] S. O. Daffa and A. Rahman, "DETEKSI KATARAK MELALUI GAMBAR MATA MENGGUNAKAN TRANSFER LEARNING."
- [23] G. P. H. P. Gusti, E. Haerani, F. Syafria, F. Yanto, and S. K. Gusti, "Implementasi Algoritma Convolutional Neural Network (Resnet-50) untuk Klasifikasi Kanker Kulit Benign dan Malignant," *MALCOM: Indonesian Journal of Machine Learning*

- and Computer Science*, vol. 4, no. 3, pp. 984–992, Jun. 2024, doi: 10.57152/malcom.v4i3.1398.
- [24] M. H. Athallah, “IMPLEMENTASI MODEL HYBRID CNN-SVM UNTUK DETEKSI LEUKOCORIA SKRIPSI Oleh.”
- [25] “Naskah-Pidato-Prof.-Hanung (1)”.
- [26] R. A. Mas’ud and Junta Zeniarja, “Optimasi Convolutional Neural Networks untuk Deteksi Kanker Payudara menggunakan Arsitektur DenseNet,” *Edumatic: Jurnal Pendidikan Informatika*, vol. 8, no. 1, pp. 310–318, Jun. 2024, doi: 10.29408/edumatic.v8i1.25883.
- [27] “654-Article Text-3123-1-10-20240930”.