

Optimasi Klasifikasi Retinopati Diabetik Berbasis Transfer Learning dengan Citra Digital

Fachri Ayudi Fitrony^{1*}, Senjaya Machfudi Zulkif², Muhamad Arief Muhaimin³

^{1,2,3}Universitas Nahdlatul Ulama Pasuruan, Pasuruan, Indonesia

Email Corresponding: fahri@unupasuruan.ac.id^{*}

Abstrak. Diabetic Retinopathy (DR) atau Retinopati Diabetik merupakan komplikasi serius dari diabetes melitus yang menyebabkan kerusakan retina dan berisiko pada kehilangan penglihatan permanen jika tidak dideteksi secara dini. Proses diagnosa manual saat ini memakan waktu, biaya yang besar, serta rentan terhadap kesalahan manusia (human error). Seiring pesatnya perkembangan kecerdasan buatan, Deep Learning menjadi metode unggulan dalam analisis citra medis, khususnya melalui arsitektur Convolutional Neural Networks (CNN). Penelitian ini menerapkan teknik Transfer Learning, yaitu sebuah metode pembelajaran mesin di mana model yang telah dilatih sebelumnya (pre-trained model) pada dataset skala besar digunakan kembali sebagai titik awal untuk tugas klasifikasi baru. Teknik ini memungkinkan model mencapai konvergensi yang lebih cepat dan akurasi yang lebih tinggi meskipun dengan keterbatasan data medis. Dengan menggunakan dataset sebanyak 5.590 citra yang mencakup lima tahapan Diabetic Retinopathy (*healthy, mild, moderate, severe*, dan *proliferative*), penelitian ini mengusulkan model MobileNetV2. Melalui pengujian validasi silang, model ini berhasil mencapai akurasi rata-rata 93,20%, presisi 91,61%, recall 90,07%, dan f1-score 85,02%. Selain itu, penyediaan citra termal dalam penelitian ini diharapkan dapat membantu tenaga medis dalam mengevaluasi dampak kerusakan retina secara lebih komprehensif pada setiap tahapan penyakit.

Kata kunci: Retinopati Diabetik, Deep Learning, Convolutional Neural Networks, Transfer Learning, Citra Medis

1. PENDAHULUAN

Saat ini, perawatan kesehatan menjadi salah satu perhatian utama, dan deteksi dini serta pengobatan penyakit menjadi sangat penting. Diabetes adalah penyakit yang meningkatkan jumlah glukosa dalam darah tubuh akibat kekurangan insulin [1]. Diabetes memengaruhi organ seperti retina, jantung, dan saraf.

Retinopati Diabetik adalah komplikasi diabetes yang menyebabkan pembuluh darah retina membengkak dan mengeluarkan cairan serta darah [2]. Pasien dapat kehilangan penglihatan jika penyakitnya memburuk. Pemeriksaan retina diperlukan untuk pasien diabetes agar dapat diobati tepat waktu pada tahap awal. Tahapan penyakit terdiri dari empat tahap: nonproliferatif ringan, nonproliferatif sedang, nonproliferatif berat, dan proliferasif [3].

Pada tahap pertama, akan terjadi pembengkakan seperti balon di area kecil pembuluh darah di retina. Pada tahap kedua, yang dikenal sebagai retinopati nonproliferatif sedang, beberapa pembuluh darah di retina akan tersumbat. Pada tahap ketiga, retinopati nonproliferatif berat membawa serta lebih banyak pembuluh darah yang tersumbat, yang menyebabkan area retina tidak lagi menerima aliran darah yang memadai. Tanpa aliran darah yang tepat, retina tidak dapat menumbuhkan pembuluh darah baru untuk menggantikan yang rusak [4]. Tahap keempat atau tahap akhir dikenal sebagai retinopati proliferasif. Ini adalah tahap lanjut dari penyakit ini. Pembuluh darah baru tambahan akan mulai tumbuh di retina, tetapi pembuluh darah tersebut akan rapuh dan abnormal. Karena itu, pembuluh darah tersebut dapat bocor darah yang akan menyebabkan kehilangan penglihatan dan kemungkinan kebutaan [5].

Diagnosis menggunakan mata telanjang rentan terhadap kesalahan diagnosis dan membutuhkan lebih banyak pengalaman dan upaya. Dalam praktiknya, diagnosis retinopati diabetik melalui pemeriksaan citra fundus mata menghadapi tantangan besar. Proses diagnosis manual yang dilakukan oleh tenaga ahli oftalmologi memerlukan ketelitian tinggi, memakan waktu yang lama, serta biaya yang relatif mahal. Selain itu, keterbatasan jumlah tenaga ahli di beberapa daerah menyebabkan adanya risiko kesalahan diagnosis manusia (*human error*) akibat kelelahan atau subjektivitas penilaian. Hal ini menuntut adanya sebuah sistem otomatis yang mampu melakukan klasifikasi tahap keparahan Retinopati Diabetik secara cepat dan akurat [6].

Perkembangan teknologi kecerdasan buatan, khususnya Deep Learning, telah membawa transformasi besar dalam bidang kesehatan. Convolutional Neural Networks (CNN) telah terbukti menjadi metode yang sangat efektif dalam memproses dan mengenali pola pada citra digital. Dalam konteks medis yang seringkali memiliki

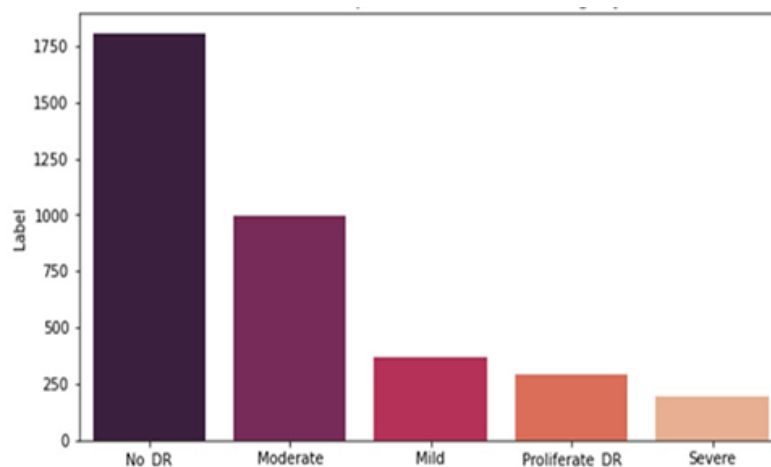
kendala pada keterbatasan jumlah data berlabel, teknik Transfer Learning muncul sebagai solusi. Dengan memanfaatkan pre-trained model yang telah dilatih pada jutaan gambar, model dapat mengenali fitur dasar citra dan menyesuaikannya untuk tugas spesifik seperti klasifikasi Retinopati Diabetik, yang pada akhirnya mempercepat waktu pelatihan dan meningkatkan akurasi. Metode diagnostik otomatis dapat menghemat lebih banyak biaya dan waktu serta lebih efektif daripada metode diagnostik normal [7].

Penelitian terbaru yang mengevaluasi metode otomatis Retinopati Diabetik menggunakan pembelajaran mendalam untuk mendeteksi dan mengklasifikasikan Retinopati Diabetik. Nurohman dkk. menciptakan CNN jalur berbobot yang disebut WP-CNN untuk mengklasifikasikan gambar Retinopati Diabetik yang dapat dirujuk dalam dataset pribadi dengan akurasi (ACC) sebesar 91,23% [8]. Ali dkk. mengusulkan dua CNN independen untuk mengklasifikasikan gambar menjadi gambar normal atau Retinopati Diabetik dengan ACC sebesar 92,7% pada dataset DIARETDB1 [9]. Khairi, S.H dkk. membuat CNN jalur berbobot untuk mengklasifikasikan gambar Retinopati Diabetik yang dapat dirujuk dalam APTOS 2019 dengan ACC sebesar 83,09% [10]. Khan dkk. mengusulkan metode untuk mendeteksi tahap Retinopati Diabetik dari dataset pribadi mereka dengan ACC sebesar 96,5% [11]. Mereka melakukan fine-tuning InceptionV3, ResNet50V2, Xception, InceptionResNetV2, dan DenseNets kemudian menggabungkan CNN terkuat [12]. Faurina et al mengusulkan empat CNN independen untuk mengklasifikasikan dataset pribadi gambar dengan ACC sebesar 96,5% [13]. Dalam penelitian ini, model MobileNetV2 diusulkan untuk mengklasifikasikan tahapan Retinopati Diabetik dengan empat tahapan penyakit dan kasus sehat menggunakan model pra-pelatihan.

2. METODOLOGI

2.1 Dataset

Dataset yang digunakan dalam penelitian ini adalah dataset open-source di Database Kaggle dengan link url: <https://www.kaggle.com/datasets/sovitraith/diabetic-retinopathy-224x224-gaussian-filtered>. Ini adalah data dari kompetisi Deteksi Kebutaan APTOS 2019 di Kaggle. Dataset besar disediakan dengan serangkaian gambar retina yang diambil menggunakan pencitraan fundus dalam kondisi yang berbeda. Dokter akan mengevaluasi setiap gambar tentang tingkat keparahan retinopati diabetik pada skala 0 hingga 4: 0 – No_DR, 1 - Ringan, 2 - Sedang, 3 - Parah, 4 - DR Proliferasi. Seperti dataset apa pun yang dikumpulkan di lingkungan dunia nyata, akan ada gangguan. Gambar mungkin mengandung informasi yang salah, buram, cahaya redup, atau terlalu besar. Gambar yang dikumpulkan dari banyak klinik berbeda menggunakan berbagai peralatan pencitraan selama periode waktu yang lama akan menciptakan banyak variasi lain dari gambar masukan. Dataset yang digunakan mencakup 5.590 gambar yang sesuai dengan lima tahap berbeda dari retinopati diabetik. Dataset ini terdiri dari 2.409 kasus No_DR, 744 kasus ringan, 1.511 kasus sedang, 401 kasus berat, dan 525 kasus DR proliferasi. 60% dari dataset digunakan untuk pelatihan, 20% untuk validasi, dan 20% untuk pengujian. Semua bentuk diubah ukurannya menjadi 224×224 piksel agar sesuai dengan model. Tabel 1 menyajikan jumlah gambar untuk pelatihan, validasi, dan pengujian.

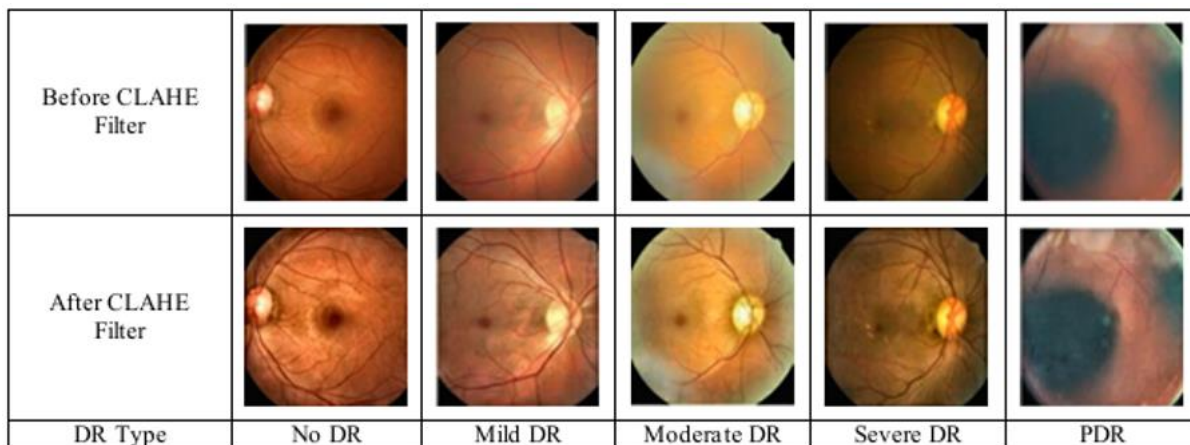


Gambar 1. Sebaran Training Data

Gambar 1 mewakili data pelatihan yang sesuai dengan lima tahapan retinopati diabetik. Gambar ilustrasi dari setiap tahapan ditunjukkan pada Gambar 2.

Tabel 1. Distribusi Data Training, Validation dan Testing

Kelas Level	Training	Validation	Testing	Total
No_DR	1805	302	302	2409
Mild	370	187	187	744
Moderate	999	256	256	1511
Severe	193	104	104	401
Polifereate DR	295	115	115	525



Gambar 2. Gambar Ilustrasi 5 Tahapan Dataset

2.1 Preprocessing Data

Data pelatihan tidak seimbang seperti yang ditunjukkan pada Gambar 1. Hanya ada 193 kasus berat dan 370 kasus ringan, yang jauh lebih sedikit daripada sisanya. Jika data pelatihan ini digunakan, maka model dapat mendeteksi kasus no_DR, moderate, dan prolifereate_DR dengan sangat baik dibandingkan kasus berat dan ringan. Oleh karena itu, akurasi mungkin menjadi tinggi tetapi tidak ada keseimbangan antar lapisan. Untuk mengatasi masalah ini, teknik peningkatan data seperti pergeseran, rotasi, dan pembesaran diimplementasikan agar tidak kehilangan keseimbangan akurasi antar tahapan penyakit, semua tahapan memiliki kepentingan yang sama. Pada saat yang sama, peningkatan data akan membuat model menjadi lebih umum dan menghindari overfitting.

2.2 Convolutional Neural Network

Deep learning (DL) adalah cabang teknik pembelajaran mesin yang melibatkan lapisan hierarkis dari tahapan pemrosesan non-linier untuk pembelajaran fitur tanpa pengawasan serta untuk mengklasifikasikan pola [14]. Saat ini, Deep Learning adalah salah satu metode diagnosis medis berbantuan komputer yang paling efektif [15]. Convolutional Neural Network (CNN) berguna dalam tugas-tugas visi komputer. CNN telah membuat kemajuan yang mengesankan di banyak bidang, terutama diagnosis medis.

Tabel 2. Model Arsitektur MobileNetV2

Type/Stride	Filter Shape	Input Size
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw / s1	$3 \times 3 \times 32 \text{ dw}$	$112 \times 112 \times 32$
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw / s2	$3 \times 3 \times 64 \text{ dw}$	$112 \times 112 \times 64$
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw / s1	$3 \times 3 \times 128 \text{ dw}$	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw / s2	$3 \times 3 \times 128 \text{ dw}$	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw / s1	$3 \times 3 \times 256 \text{ dw}$	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$

Conv dw / s2	$3 \times 3 \times 256 \text{ dw}$	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5× Conv dw/ s1	$3 \times 3 \times 512 \text{ dw}$	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw / s2	$3 \times 3 \times 512 \text{ dw}$	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
Conv dw / s2	$3 \times 3 \times 1024 \text{ dw}$	$7 \times 7 \times 1024$
Conv / s1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Avg Pool / s1	Pool 7×7	$7 \times 7 \times 1024$
FC / s1	1024×1000	$5 \times 5 \times 1024$
Softmax / s1	Classifier	$5 \times 5 \times 1024$

Kemajuan ini didasarkan pada kemampuan jaringan CNN untuk mengekstrak fitur dari sumber data input. Dalam penelitian ini, fokus utama jaringan adalah untuk mendeteksi berbagai tahap retinopati diabetik. Terdapat banyak metode berbasis pembelajaran mendalam seperti Restricted Boltzmann Machines, Convolutional Neural Networks (CNN), autoencoder, dan sparse coding [16]. Beberapa model pra-pelatihan yang paling terkenal dan paling banyak digunakan adalah VGG-16, ResNet, Xception, dan MobileNet [17][18]. Secara khusus, MobileNetV2 adalah jaringan saraf yang terdiri dari lapisan yang terakumulasi secara mendalam dan terakumulasi per titik. MobileNetV2 mendapatkan hasil terbaik pada dataset ImageNet diikuti oleh VGG-16 dan ResNet50V2 [19]. Gambar input setelah melakukan pra-pemrosesan adalah 224×224 piksel. MobileNetV2 membuat peta fitur pada objek fitur akhir. Jumlah parameter jaringan MobileNetV2 adalah 3,3 juta $7 \times 7 \times 1024$. MobileNetV2 memiliki kompleksitas komputasi dan parameter yang lebih sedikit dengan menggunakan Depth-wise Separable Convolution. Tabel 2 menunjukkan arsitektur tipikal jaringan MobileNetV2.

2.3 Fase Training

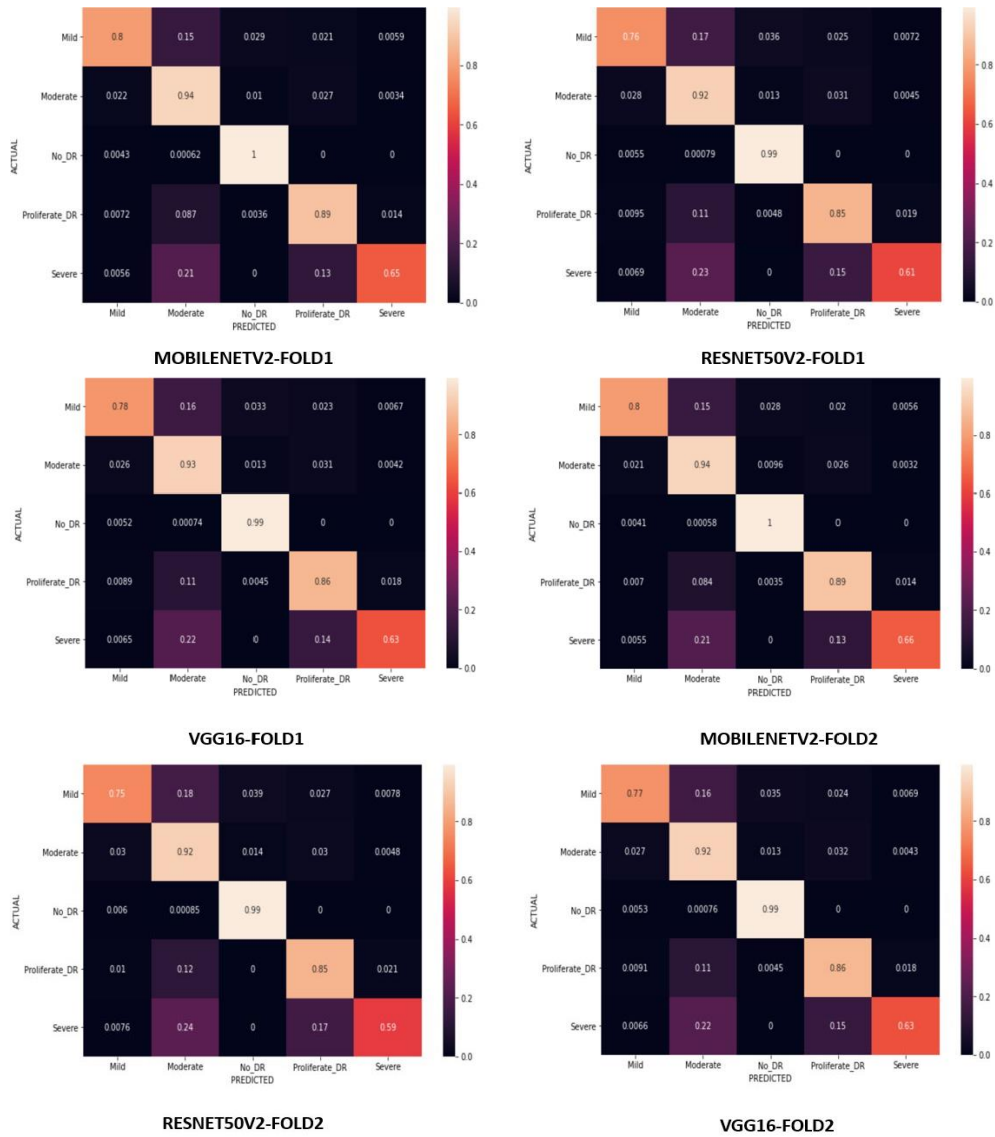
Guna menjamin validitas dan reliabilitas hasil, penelitian ini menerapkan metode validasi silang sebanyak tiga iterasi dengan proporsi pembagian dataset sebesar 80% untuk pelatihan dan 20% untuk validasi pada setiap fasenya. Tiga arsitektur Deep Learning, yakni MobileNetV2, ResNet50V2, dan VGG-16, dilatih menggunakan konfigurasi parameter seragam sebagaimana tercantum pada Tabel 3, yang mencakup penggunaan fungsi Categorical Cross-Entropy dan optimizer Adam dengan learning rate $1e - 4$. Proses pelatihan berlangsung selama 100 epoch per tahap, menghasilkan total 300 epoch untuk setiap model. Khusus pada ResNet50V2 dan VGG-16, batch size ditetapkan pada angka 20 guna menyesuaikan dengan kompleksitas parameter jaringan. Selain itu, teknik augmentasi data diimplementasikan untuk memitigasi risiko overfitting. Seluruh komputasi berbasis pustaka Keras ini dijalankan pada infrastruktur GPU Tesla P100 dan RAM 16GB melalui platform Kaggle [20].

Tabel 3. Parameter dan Fungsi Pelatihan

Training parameters	MobileNetV2	ResNet50V2	VGG-16
Input shape	$224 \times 224 \times 3$	$224 \times 224 \times 3$	$224 \times 224 \times 3$
Batch size	32	20	20
Learning Rate	$1e-4$	$1e-4$	$1e-4$
Optimizer	Adam	Adam	Adam
Loss function	Cross Entropy	Cross Entropy	Cross Entropy
Epoch	100	100	100
Rescale	1/255	1/255	1/255
Honrizontal flipping		Yes	Yes

3. HASIL DAN DISKUSI

3.1 Hasil



Gambar 3. Confusion Matriks Jaringan untuk Lipatan 1 dan 2.

Tabel 4. Metrik Evaluasi Model Setelah Validasi Silang.

Fold	Network	Precision	Recall	f1-score	Support
1	MobileNetV2	0.94	0.91	0.91	2674
	ResNet50V2	0.88	0.88	0.87	2674
	VGG-16	0.89	0.88	0.89	2674
2	MobileNetV2	0.93	0.91	0.89	2674
	ResNet50V2	0.89	0.89	0.88	2674
	VGG-16	0.90	0.87	0.88	2674
3	MobileNetV2	0.94	0.93	0.92	2674
	ResNet50V2	0.87	0.88	0.85	2674
	VGG-16	0.88	0.84	0.85	2674

Kriteria evaluasi model klasifikasi lima kelas berikut:

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

$$Specificity = \frac{TN}{TN + FP} \quad (2)$$

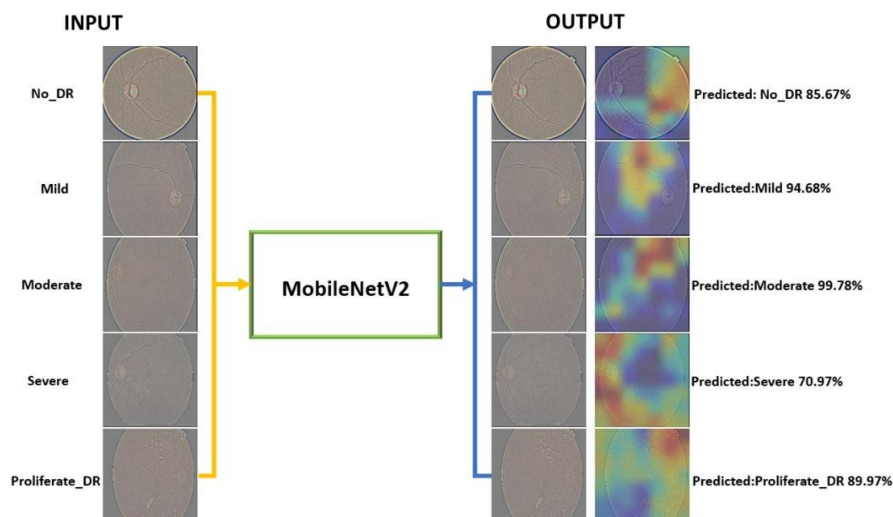
$$Sensitivity = \frac{TP}{TP + FN} \quad (3)$$

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

Gambar 3 menunjukkan confusion matriks jaringan untuk lipatan 1 dan 2. Validasi dilakukan untuk menguji model pada dataset yang terdiri dari 288 kasus ringan, 698 kasus sedang, 1317 kasus tanpa DR, 220 kasus proliferaatif, dan 151 kasus berat. Perlu dicatat bahwa pembelajaran konversi digunakan selama pelatihan. Untuk melatih model, pembobotan ImageNet digunakan sebelum memulai pelatihan dan kemudian pelatihan berdasarkan kondisi dataset [14]. Akurasi diukur pada dataset uji untuk melacak kinerja model dalam menemukan model terbaik. Hasil model disajikan pada Tabel 4.

3.2 Diskusi

Dari confusion matriks yang ditunjukkan pada Gambar 3, akurasi keseluruhan model relatif tinggi. Performa tertinggi adalah model MobileNetV2, diikuti oleh model VGG-16 dan terakhir ResNet50V2. Fitur umum dalam hasil ketiga model ini adalah akurasi antar lapisan. Kasus No_DR diklasifikasikan paling baik dengan akurasi di atas 99%, kasus sedang dengan akurasi di atas 92%, dan kasus parah dengan akurasi di atas 85%. Namun, pada kasus ringan dan berat, akurasi hanya di atas 75% dan 60% karena ketidakseimbangan data meskipun data telah ditingkatkan dengan metode peningkatan. Poin positif di sini adalah bahwa false positive sebagian besar akan diprediksi pada tahap yang berdekatan, tanpa kasus salah prediksi pada tahap yang terpisah. Untuk melakukan validasi kinerja model, Tabel 4 menunjukkan metrik yang bermanfaat saat melakukan metode validasi silang 3-fold. Model MobileNetV2 memiliki nilai presisi rata-rata 94%, recall 92%, dan f1-score 90%. Model ResNet50V2 memiliki nilai presisi rata-rata 88%, recall 88%, dan f1-score 87%. Model VGG-16 memiliki nilai presisi rata-rata 89%, recall 87%, dan f1-score 87%.



Gambar 4. Proses Klasifikasi Gambar Input dan Output pada Citra Termal

Dari hasil statistik matriks kebingungan dan validasi silang, model MobileNetV2 mencapai kinerja klasifikasi terbaik dalam kasus ini. Dalam penelitian ini, kinerja jaringan MobileNetV2 dalam mengklasifikasikan tahapan retinopati diabetik dievaluasi. Sebanyak 5.990 gambar digunakan untuk melatih model. Akurasi

keseluruhan yang diperoleh adalah 93,89% untuk klasifikasi lima tahapan penyakit. Kinerja model MobileNetV2 lebih unggul dibandingkan model lainnya seperti yang ditunjukkan pada Tabel 4. Keunggulan metode ini adalah dapat membantu mengklasifikasikan gambar tanpa menggunakan teknik ekstraksi karakteristik dan merupakan pendekatan efektif yang dapat membantu spesialis diagnostik. Selain itu, citra termal seperti yang ditunjukkan pada Gambar 4 dapat membantu dokter untuk secara efektif menemukan zona pada gambar tahapan retinopati diabetik. Model yang diusulkan dapat mendiagnosis tahapan penyakit dengan akurasi tinggi dan presisi tinggi dengan cepat dalam hitungan detik. Salah satu keterbatasan metode ini adalah ukuran dataset yang dibutuhkan untuk pelatihan. Jadi dataset perlu dikumpulkan secara terus menerus dan perlu dimurnikan untuk menghilangkan gambar berkualitas rendah.

Membangun arsitektur CNN baru membutuhkan banyak usaha dan waktu, sementara penggunaan model pra-pelatihan yang mudah digunakan dan mempercepat proses pengembangan. Mengklasifikasikan tahapan retinopati diabetik tetap menjadi tantangan utama bagi para peneliti yang membutuhkan lebih banyak penelitian untuk memperjelas masalah ini. Penelitian ini membuka jalan untuk membangun sistem pemantauan otomatis lengkap untuk DR, yang merupakan penyakit jangka panjang. Pemantauan tahapan penyakit akan membantu pasien agar tidak buta dan membatasi gangguan penglihatan. Dalam penelitian kami di masa mendatang, YOLOv4 dan YOLOv5 dapat digunakan untuk mendeteksi semua lesi DR untuk mendapatkan manfaatnya, seperti akurasi dan kecepatan.

4. KESIMPULAN

Peningkatan prevalensi diabetes secara global berdampak langsung pada tingginya angka komplikasi retinopati diabetik, yang klasifikasi stadiumnya ditentukan berdasarkan jenis kerusakan pada retina. Deteksi dini menjadi krusial mengingat diagnosis pada stadium lanjut berisiko tinggi menyebabkan kebutaan permanen. Di tengah melonjaknya jumlah pasien, metode diagnosis manual dianggap kurang efisien, sehingga otomatisasi melalui sistem skrining berbantuan komputer (CAD) menjadi solusi strategis untuk mengoptimalkan waktu, tenaga, dan biaya. Penelitian ini mengusulkan penggunaan arsitektur Convolutional Neural Network (CNN) berbasis MobileNetV2 yang berhasil mencapai akurasi 93,89% dengan tingkat reliabilitas tinggi. Untuk menjamin stabilitas performa terhadap variasi dataset, diterapkan skema validasi silang sebanyak tiga kali. Selain itu, penggunaan peta termal (*heatmap*) diintegrasikan untuk membantu tenaga medis dalam mengevaluasi progresivitas penyakit. Hasil eksperimen membuktikan efektivitas model deep learning ini dalam deteksi retinopati diabetik, meskipun pengembangan di masa depan masih memerlukan integrasi dataset yang lebih luas demi mencapai keseimbangan data serta peningkatan presisi yang lebih optimal

Referensi

- [1] M. K. Jabbar, J. Yan, H. Xu, Z. U. Rehman, and A. Jabbar, "Transfer Learning-Based Model for Diabetic Retinopathy Diagnosis Using Retinal Images," *Brain Sci.*, vol. 12, no. 5, 2022, doi: 10.3390/brainsci12050535.
- [2] A. M. Mutawa, K. Sabti, B. S. Sundaram Thankaleela, and S. Raizada, "Bio-Inspired Optimization of Transfer Learning Models for Diabetic Macular Edema Classification," *AI*, vol. 6, no. 10, pp. 1–30, 2025, doi: 10.3390/ai6100269.
- [3] Firman Ardiansyah, Yunita Sari, and Fahrul Nurzaman, "Rancang Bangun Sistem Deteksi Penyakit Diabetes Retinopati Dengan Transfer Learning Inception V3," *IKRA-ITH Inform. J. Komput. dan Inform.*, vol. 9, no. 3, pp. 78–82, 2025, doi: 10.37817/ikraith-informatika.v9i3.5680.
- [4] I. M. J. R. L. M. M. Z. M. Y. P. Herdiana Nurul Utami, "Lombok Medical Journal," *Crohn Dis. Pathophysiol. Diagnosis Manag.*, vol. 2, no. 2, pp. 1–4, 2023.
- [5] Febriansyah, M. Nur Rahmah, M. Jabal Nur, P. Nasir Hamzah, and S. Irmandha Kusumawardhani, "Narrative Review: Pathogenesis and Management Of Diabetic Retinopathy," *Eff. Muhasabah Acad. Achiev. Prof. Med. Progr. Students Narrat. Rev.*, vol. 15, no. 04, p. 897, 2024, doi: 10.54209/eduhealth.v15i04.
- [6] A. K. Kavuru, R. K. Patjoshi, and R. Panigrahi, "An Enhanced Diabetic Retinopathy Classification Using ResNet-DenseNet Hybrid Model," *Int. J. Eng. Trends Technol.*, vol. 73, no. 8, pp. 262–272, 2025, doi: 10.14445/22315381/IJETT-V73I8P123.
- [7] A. Jabbar *et al.*, "Deep Transfer Learning-Based Automated Diabetic Retinopathy Detection Using Retinal Fundus Images in Remote Areas," *Int. J. Comput. Intell. Syst.*, vol. 17, no. 1, 2024, doi: 10.1007/s44196-024-00520-w.
- [8] Nurohman, Rudi Heriansyah, Dwi Asa Verano, and Zaid Romegar Mair, "Deteksi Penyakit Diabetes

- Retinopathy Menggunakan Citra Digital Dengan Metode Convolutional Neural Network (Cnn),” *Pros. Snast*, no. November, pp. 311–320, 2024, doi: 10.34151/prosidingsnast.v1i1.5120.
- [9] A. Mustopa *et al.*, “DIABETIK ON-DEVICE MENGGUNAKAN MODEL MOBILENETV2 PADA,” vol. 14, no. 1, pp. 618–626.
- [10] M. Y. Khairi, E. A. M. Sampetoding, and Y. S. Pongtambing, “Studi Literatur Penerapan Deep Learning dalam Analisis Citra Medis di Indonesia,” *Heal. J. PUBLIC Heal. Perspect. Vol.*, vol. 01, no. 01, pp. 15–24, 2024.
- [11] M. B. Khan, M. Ahmad, S. B. Yaakob, R. Shahrir, M. A. Rashid, and H. Higa, “Automated Diagnosis of Diabetic Retinopathy Using Deep Learning: On the Search of Segmented Retinal Blood Vessel Images for Better Performance,” *Bioengineering*, vol. 10, no. 4, 2023, doi: 10.3390/bioengineering10040413.
- [12] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision,” *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, vol. 2016-Decem, pp. 2818–2826, 2016, doi: 10.1109/CVPR.2016.308.
- [13] R. Faurina, E. P. Purwandari, M. T. Pratama, and I. Agustian, “Klasifikasi Level Non-Proliferatif Retinopati Diabetik Dengan Ensemble Convolutional Neural Network,” *Pseudocode*, vol. 8, no. 1, pp. 1–10, 2021, doi: 10.33369/pseudocode.8.1.1-10.
- [14] E. N. Arrofiqoh and Harintaka, “IMPLEMENTASI METODE CONVOLUTIONAL NEURAL NETWORK UNTUK KLASIFIKASI TANAMAN PADA CITRA RESOLUSI TINGGI (The Implementation of Convolutional Neural Network Method for Agricultural Plant Classification in High Resolution Imagery),” *Geomatika*, vol. 24, no. 2, pp. 61–68, 2018.
- [15] S. D. Pamuja, “Perbandingan Model CNN Transfer Learning untuk Deteksi Tumor Otak Berbasis Citra MRI,” vol. 01, no. 2, pp. 47–53, 2025.
- [16] Hendra Irawan Wijaya Kusuma and Bagus Satrio Waluyo Poetro, “Deteksi Diabetic Retinopathy Menggunakan Convolutional Neural Network Berbasis Efficientnet Dan Grad-Cam Pada Citra Fundus Retina,” *J. Rekamaya Sist. Inf. dan Teknol.*, vol. 3, no. 1, pp. 126–138, 2025, doi: 10.70248/jrsit.v3i1.2896.
- [17] K. Anwar, R. Maruf, F. Susanto, and M. B. Ryando, “Analisis Performa Deteksi Penyakit Paru-Paru dengan Model Klasifikasi Gambar Menggunakan LSTM Deep Learning,” *J. Ilm. Univ. Batanghari Jambi*, vol. 25, no. 1, p. 972, 2025, doi: 10.33087/jiubj.v25i1.5697.
- [18] H. Fakhri, T. Badriyah, I. Syarif, and R. Sigit, “Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network,” pp. 65–79, 2024.
- [19] M. A. Sayedelahl, A. G. Gad, R. M. Essa, Z. G. Hussein, and A. A. Abohany, “A Unified Deep Learning Framework for Robust Multi-Class Tumor Classification in Skin and Brain MRI,” *Technologies*, vol. 13, no. 9, pp. 1–27, 2025, doi: 10.3390/technologies13090401.
- [20] F. Uysal and M. Erkan, “Multiclass Classification of Brain Tumors with Various Deep Learning Models †,” *Eng. Proc.*, vol. 27, no. 1, 2022, doi: 10.3390/ecsa-9-13367.