

# Penerapan Algoritma Convolutional Neural Network Untuk Menentukan Retinopati Hipertensi Melalui Citra Retina Fundus

\*Kana Saputra S<sup>1</sup>, Insan Taufik<sup>2</sup>, Debi Yandra Niska<sup>3</sup>, Raiyan Fairozi<sup>4</sup>, Mhd Hidayat<sup>5</sup>, Mohammed Hafizh Al-Areef<sup>6</sup>

Address : Program Studi Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam,  
Universitas Negeri Medan<sup>1,2,3,5,6</sup>, Poli Klinik, Balai Penjaminan Mutu Pendidikan Provinsi Kalimantan Tengah<sup>4</sup>

Email : kanasaputras@unimed.ac.id<sup>1</sup>, insantauфик@unimed.ac.id<sup>2</sup>, debiyandraniska@unimed.ac.id<sup>3</sup>,  
raiyanfairozi@gmail.ac.id<sup>4</sup>, mhdhidayat@mhs.unimed.ac.id<sup>5</sup>, hafizhalareef@mhs.unimed.ac.id<sup>6</sup>

## Abstrak

Hipertensi merupakan suatu penyakit yang menyebar dalam tubuh manusia yang diakibatkan oleh peningkatan tekanan darah yang melebihi batas normal. Peningkatan terjadi dalam kurun waktu yang cukup lama sehingga menyebabkan komplikasi pada organ tubuh manusia yang tidak dapat terlihat dengan jelas misalnya komplikasi di jantung, ginjal, otak, dan retina. Salah satu gangguan atau komplikasi dari tekanan darah tinggi terdapat pada bagian Retina. Gangguan pada retina tersebut dapat juga dikatakan sebagai retinopati hipertensi. Pasien yang menderita retinopati hipertensi hanya dapat didiagnosa oleh dokter spesialis mata, hal tersebut dikarenakan retinopati hipertensi tidak dapat dilihat dengan kasat mata tanda-tanda yang ditimbulkan, namun salah satu tanda yang paling awal adalah dengan adanya penipisan tempat arteriol-arteriol yang dapat menyebabkan kebutaan. Oleh karena itu, pemrosesan dan penganalisisan citra fundus mata berbantuan komputer untuk mengidentifikasi hipertensi retinopati merupakan hal yang penting untuk dilaksanakan dengan menerapkan algoritma Convolutional Neural Network. Terdapat sembilan arsitektur Convolutional Neural Network yang digunakan, yaitu AlexNet, DenseNet, Inception-V3, InceptionResNetV2, Lenet-5, MobileNetV2, ResNet50, VGG16, dan VGG19. Berdasarkan hasil percobaan diperoleh bahwa dari kesembilan arsitektur Convolutional Neural Network, dua diantaranya yaitu AlexNet dan Lenet-5 memperoleh nilai F1 Measure sebesar 0,66 dan akurasi yang paling tinggi sebesar 0,67.

**Kata Kunci** – Citra Fundus Mata, *Convolutional Neural Network*, Retinopati Hipertensi

## Abstract

Hypertension is a disease that spreads in the human body caused by increased blood pressure that exceeds normal limits. The increase occurs over a long period, causing complications in human organs that cannot be seen clearly, such as complications in the heart, kidneys, brain, and retina. One of the disorders or complications of high blood pressure is in the retina. The disorder in the retina can also be said as hypertensive retinopathy. Patients suffering from hypertensive retinopathy can only be diagnosed by an ophthalmologist; this is because hypertensive retinopathy cannot be seen with the naked eye. However, one of the earliest signs is the thinning of the arterioles, which can cause blindness. Therefore, computer-assisted processing and analysis of eye fundus images to identify hypertensive retinopathy is an important thing to do by applying the Convolutional Neural Network algorithm. There are nine Convolutional Neural Network architectures used, namely AlexNet, DenseNet, Inception-V3, InceptionResNetV2, Lenet-5, MobileNetV2, ResNet50, VGG16, and VGG19. Based on the experimental results, it was found that of the nine Convolutional Neural Network architectures, two of them, namely AlexNet and Lenet-5, obtained an F1 Measure value of 0.66 and the highest accuracy of 0.67.

**Keywords** – *Convolutional Neural Network*, *Eye Fundus Images*, *Hypertensive Retinopathy*

## 1. Latar Belakang

Hipertensi merupakan suatu penyakit yang menyebar dalam tubuh manusia yang diakibatkan oleh peningkatan tekanan darah yang melebihi batas normal. Peningkatan terjadi dalam kurun waktu yang cukup lama sehingga menyebabkan komplikasi pada organ tubuh manusia yang tidak dapat terlihat dengan jelas misalnya komplikasi di jantung, ginjal, otak, dan retina [1]–[3]. Salah satu gangguan atau komplikasi dari tekanan darah tinggi terdapat pada bagian Retina. Gangguan pada retina tersebut dapat juga dikatakan sebagai Retinopathy Hipertensi (HR) [4], [5]. HR menunjukkan kerusakan organ akhir pada saraf mata akibat dari terjadinya hipertensi [2]. Pasien yang menderita HR hanya dapat didiagnosa oleh dokter spesialis mata, hal tersebut dikarenakan HR tidak dapat dilihat dengan kasat mata tanda-tanda yang ditimbulkan, namun salah satu tanda yang paling awal adalah dengan adanya penipisan tempat arteriol-arteriol yang dapat menyebabkan kebutaan [6]. Oleh karena itu, penting untuk mengidentifikasi dan mendiagnosis HR pada tahap awal untuk mencegah kebutaan akibat dari tekanan darah tinggi.

Pengidentifikasian Retinopati Hipertensi (HR) hanya dapat dilakukan pada proses pemeriksaan mata dengan teknik funduskopi menggunakan kamera fundus untuk menilai secara langsung segmen posterios mata seperti gambaran papil, nervus optikus, pembuluh darah, retina, makula dan fovea [7]. Namun di Indonesia jumlah dokter mata masih tergolong rendah. Berdasarkan masalah tersebut diharapkan dokter umum juga dapat mengidentifikasi dan mendiagnosa tahapan awal pasien yang menderita HR.

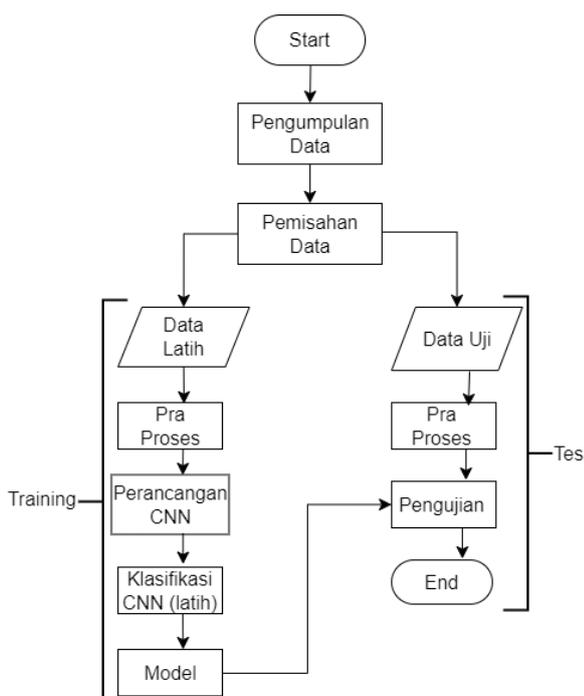
Retinopati Hipertensi memiliki klasifikasi 4 stadium yaitu stadium I yang memiliki karakteristik tortuositas arteriolar retina atau dapat dikatakan kelainan pada arteriolar retina yang mengecil dan berliku atau pembuluh darah yang sedikit sejak lahir yang mengakibatkan sirkulasi darah menurun, stadium II mempunyai karakteristik penyempitan pembuluh darah pada retina, stadium III dimana munculnya salah satu karakteristik retinopati seperti cotton-wol spot (bercak putih), arteriosclerosis (pengerasan pembuluh darah akibat penumpukan plak), dan pecahnya pembuluh darah, serta stadium IV yaitu munculnya edema neuroretinal termasuk papilledema atau proses pembengkakan saraf yang ada di mata sehingga dapat mengakibatkan kebutaan, munculnya garis siegrest, serta elschig spot atau proses pengecilan retina pigmen epitel yang tidak dapat kembali seperti semula [8]. Pada stadium awal HR sulit untuk dideteksi, hal ini dikarenakan munculnya gejala berupa perubahan dua pembuluh darah pada retina yang tidak dapat dilihat dengan mudah [9]. Oleh karena itu, pentingnya pemrosesan dan penganalisan

citra fundus mata menggunakan alat bantu berupa komputer dalam melengkapi dan mengidentifikasi retinopati hipertensi.

Salah satu metode analisis citra fundus mata berbantuan komputer atau teknologi yaitu dengan penggunaan Deep Learning dalam mengidentifikasi tahapan awal retinopati hipertensi untuk membantu dokter umum dalam mengenali gambaran jaringan pembuluh darah retina [7]. Setelah itu, fitur-fitur tersebut dievaluasi secara kuantitatif untuk memeriksa kelainan dan akhirnya, mendeteksi penyakit HR atau non-HR [4]. Saat ini hasil klasifikasi citra terbaik diperoleh dengan menggunakan algoritma Deep Learning berbasis *Convolutional Neural Networks* (CNN), yang memiliki ribuan bahkan jutaan parameter yang dapat diatur [10]. Deep Learning merupakan subbidang Artificial Intelligence (AI) atau kecerdasan buatan yang dapat meniru sistem kecerdasan manusia dalam pengolahan data dan menghasilkan pola tersendiri yang dapat digunakan dalam pengambilan keputusan [11]. Deep Learning juga kuat untuk ekstraksi fitur karena lebih unggul dalam memberikan informasi gambar yang lebih dalam [12]. Berdasarkan penjelasan tersebut, peneliti akan menerapkan algoritma *Convolutional Neural Network* (CNN) yang merupakan salah satu bagian dari Deep Learning untuk mengidentifikasi Retinopati Hipertensi melalui citra retina fundus secara cepat dan tepat.

## 2. Metode

Metode untuk mengklasifikasi Retinopati Hipertensi menggunakan Algoritma CNN diawali dengan pengumpulan data yang akan dipisah menjadi dua bagian data yaitu data latih dan data uji, kemudian praproses setiap data sebagai perbaikan kualitas citra, perancangan CNN, dan yang terakhir melakukan pengujian model. Tahapan-tahapan dalam metode tersebut dapat dilihat dalam bagan berikut.



Gambar 1. Tahapan Penelitian

### 2.1. Pengumpulan Data

Data diperoleh dari situs *Structured Analysis of the Retina (STARE)* yang dapat diakses melalui link <https://cecas.clemson.edu/~ahoover/stare/>. Data berupa data retina fundus dimana hal tersebut merupakan prosedur pengambilan citra pada bagian fundus mata. Citra fundus dapat menangkap tampilan daerah di bagian belakang mata seperti bagian retina, saraf mata (saraf optikus), makula, dan pembuluh darah di seluruh bagian retina [13].

### 2.2. Pembagian Data

Data yang telah diperoleh kemudian akan dipisahkan menjadi dua bagian yaitu data latih dan data uji. Data latih digunakan untuk membentuk model sebelum proses perancangan, sedangkan data uji digunakan untuk menguji ketepatan klasifikasi dari pola yang telah terbentuk. Perbandingan persentasi dari data training dan data testing yaitu 4:1 atau dapat dikatakan 80% data training dan 20% data testing. Data latih digunakan pada tahapan pemodelan menggunakan model CNN, sedangkan data uji digunakan untuk menguji pola yang telah terbentuk.

### 2.3. Praproses Data

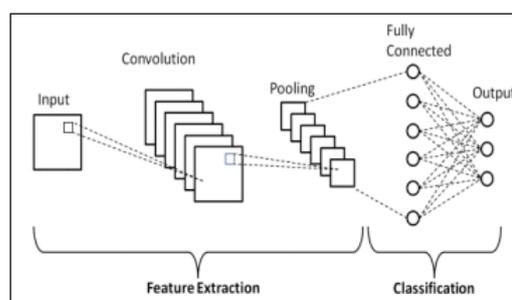
Tahapan praproses data merupakan tahapan untuk perbaikan kualitas citra menggunakan metode *Contrast Limited Adaptive Histogram Equalization (CLAHE)*. CLAHE merupakan proses secara keseluruhan dari metode *Adaptive Histogram Equalization (AHE)*. Metode tersebut

menghasilkan citra yang lebih baik dibandingkan dengan citra awal yang belum dilakukan proses tahapan citra [14]. Performa peningkatan kualitas citra menggunakan metode CLAHE lebih baik dibanding metode *High-Frequency Emphasis (HFE)* [15]. Tahapan metode CLAHE adalah sebagai berikut [14], [16] yaitu, (i) Citra awal akan dibagi menjadi beberapa sub-citra yang akan ditampilkan dalam ukuran  $M \times N$ , (ii) Menghitung *histogram* atau frekuensi yang ditampilkan dalam grafik dari setiap sub-citra, dan (iii) tahapan terakhir yaitu *Clipped histogram* atau proses penyatuan setiap histogram dari setiap citra.

### 2.4. Implementasi CNN

Arsitektur yang banyak digunakan untuk pengenalan suatu objek atau image processing yaitu algoritma deep learning atau dapat dikatakan *Convolution Neural Network (CNN)* [17], [18]. Hal ini dikarenakan algoritma CNN dibutuhkan untuk menjalankan sistem yang lebih mendalam dan sesuai dengan harapan peneliti [19]. CNN memiliki beberapa fitur dalam aplikasinya yaitu analisis teks biologis, pendeteksian dan pengenalan objek, serta klasifikasi malware [17]. Oleh karena itu, peneliti akan mendeteksi objek atau gambar dengan cara mengeksploitasi seluruh fitur yang dimiliki oleh CNN.

Proses yang akan dilakukan yaitu fokus pada memproses gambar dengan framework sensor untuk semua jaringan [20] untuk mengidentifikasi tahapan awal retinopati hipertensi sehingga dapat membantu dokter umum dalam mengenali gambaran jaringan pembuluh darah retina [7]. Kemudian, fitur-fitur tersebut dievaluasi secara kuantitatif untuk memeriksa kelainan dan akhirnya, mendeteksi penyakit HR atau non-HR [4]. CNN akan mempelajari bagaimana cara pengoptimalan parameter dan mempelajari input serta label yang akan disesuaikan. Arsitektur CNN yang akan dilakukan dalam penelitian mengadopsi [17] yang dapat dilihat pada Gambar 2.



Gambar 2. Arsitektur CNN

### 2.5. Evaluasi Model CNN

Setelah proses klasifikasi pada tahapan sebelumnya selesai maka harus diuji atau diverifikasi menggunakan *confusion matrix*. *Confusion matrix* merupakan alat

untuk menganalisis sebuah prediksi atau dapat dikatakan sebagai alat evaluasi visual yang menampilkan dan membandingkan nilai prediksi dengan nilai sebenarnya [21]. Pada tahapan evaluasi tersebut akan dilakukan tiga perhitungan sebagai berikut [20].

*Accuracy* untuk menunjukkan seberapa dekat pengukuran dengan yang ditentukan atau diterima. Rumus yang digunakan pada tahapan *accuracy* sebagai berikut.

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

*Recall* untuk melihat tingkat akurasi. *Recall* merupakan kebalikan dari kepastian dimana menghitung kesalahan negatif dan kebenaran positifnya. Rumus yang digunakan pada tahapan *recall* sebagai berikut.

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

*Precision* adalah nilai analitik positif dimana untuk menentukan seberapa akurat pengukurannya bahkan jika hasil yang diperoleh jauh dari nilai yang diterima. Rumus untuk menghitung nilai *Precision* yaitu sebagai berikut.

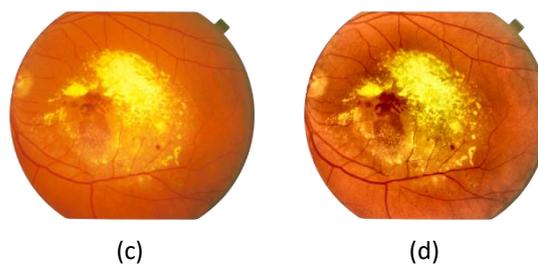
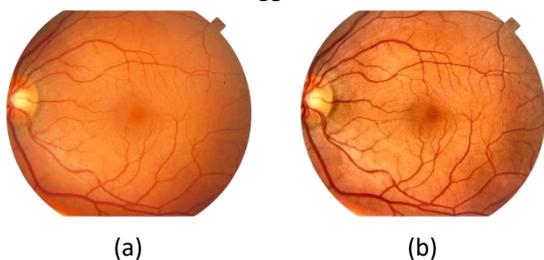
$$Precision = \frac{TP}{TP+FP} \quad (3)$$

### 3. Hasil

Ini harus mencakup temuan penelitian. Hasilnya harus disajikan dalam urutan logis dengan penjelasan tahapan yang digunakan dalam pengujian dengan memuat informasi hasil dalam teks atau bentuk tabel dan grafik.

#### 3.1. Hasil Pelatihan dan Pengujian CNN

Penelitian ini menggunakan 73 data awal citra retina fundus dari *Structured Analysis of the Retina (STARE)* yang terbagi menjadi 40 data normal dan 33 data retinopati hipertensi. Terdapat 2 simulasi yang dilakukan untuk melihat perbandingan hasil klasifikasinya, yaitu simulasi pertama menggunakan data tanpa perbaikan kualitas citra dan simulasi kedua menggunakan data yang telah diperbaiki kualitas citra menggunakan CLAHE. Berikut data citra retina fundus sebelum dan sesudah perbaikan kalitas citra menggunakan CLAHE.



Gambar 3. Citra Retina Fundus (a) Normal Sebelum

Perbaikan (b) Normal Setelah Perbaikan (c) Retinopati Hipertensi Sebelum Perbaikan (d) Retinopati Hipertensi Setelah Perbaikan

Hasil simulasi tersebut dievaluasi berdasarkan tiga perhitungan yaitu *Accuracy*, *Recall*, dan *Precision*. *Accuracy* menunjukkan seberapa dekat pengukuran yang diklasifikasi oleh model. *Recall* menunjukkan tingkat kesalahan atau kebenaran dari tingkat akurasi. *Precision* menunjukkan keakuratan nilai analitik positif. Arsitektur CNN yang digunakan adalah *AlexNet*, *DenseNet*, *Inception-V3*, *InceptionResNetV2*, *Lenet-5*, *MobileNetV2*, *ResNet50*, *VGG16*, dan *VGG19* untuk melihat tingkat keakuratan model dalam mendeteksi citra retina fundus. Untuk simulasi pertama dengan menggunakan data tanpa perbaikan kualitas citra dapat dilihat pada Tabel 1.

Tabel 1. Hasil Pengujian Menggunakan Data Tanpa Perbaikan

Arsitektur	Precision	Recall	F1 Measure	Accuracy
<i>AlexNet</i>	0.59	0.58	0.58	0.58
<i>DenseNet</i>	0.25	0.50	0.33	0.50
<i>Inception-V3</i>	0.50	0.50	0.50	0.50
<i>InceptionResNetV2</i>	0.39	0.42	0.38	0.42
<i>Lenet-5</i>	0.41	0.42	0.41	0.42
<i>MobileNetV2</i>	0.61	0.58	0.56	0.58
<i>ResNet50</i>	0.41	0.42	0.41	0.42
<i>VGG16</i>	0.59	0.58	0.58	0.58
<i>VGG19</i>	0.61	0.58	0.56	0.58

Tabel 1 menunjukkan perbedaan dari kesembilan sistem yang dimiliki oleh CNN dalam mendeteksi tingkat keakuratan data berdasarkan empat perhitungan yaitu *recall*, *accuracy*, *precision* dan *F1 measure*. Hasil yang diperoleh pada dataset original yaitu *Alexnet* dan *MobileNetV2* memperoleh nilai tertinggi dalam tingkat keakuratan data. Namun hasil tersebut harus melalui tahapan perbaikan citra untuk menggunakan metode CLAHE untuk melihat tingkat keakuratan diagnosa menggunakan CNN lebih baik. Berikut merupakan dataset yang telah melalui tahapan perbaikan citra CLAHE.

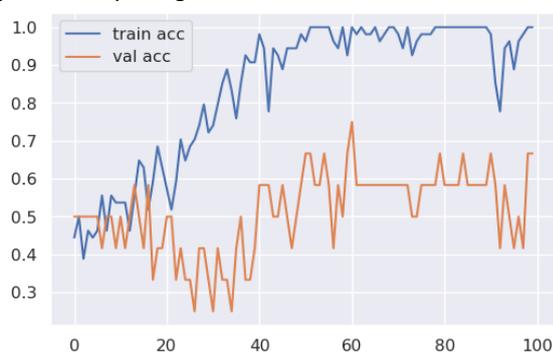
Tabel 2. Hasil Pengujian Menggunakan Data Perbaikan Clahe

Arsitektur	Precision	Recall	F1 Measure	Accuracy
AlexNet	0.69	0.67	0.66	0.67
DenseNet	0.25	0.50	0.33	0.50
Inception-V3	0.50	0.50	0.49	0.50
InceptionResNetV2	0.59	0.58	0.58	0.58
Lenet-5	0.69	0.67	0.66	0.67
MobileNetV2	0.59	0.58	0.58	0.58
ResNet50	0.25	0.50	0.33	0.50
VGG16	0.50	0.50	0.49	0.50
VGG19	0.50	0.50	0.44	0.50

Setelah melalui tahapan perbaikan kualitas citra menggunakan CLAHE, nilai *F1 Measure* dan akurasi yang diperoleh semakin baik untuk beberapa arsitektur. Hal tersebut menunjukkan bahwa perbaikan kualitas citra menggunakan CLAHE memiliki pengaruh. Jika membandingkan kedua tabel tersebut, terjadi peningkatan di beberapa arsitektur CNN setelah melalui tahapan perbaikan kualitas citra.

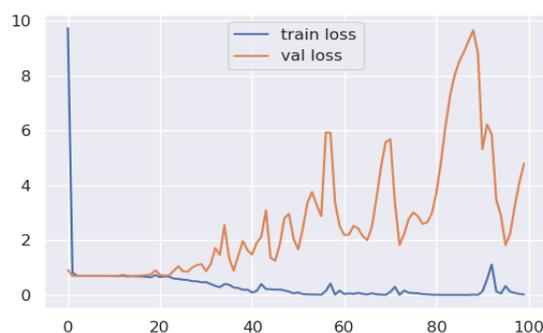
Tabel 2 menunjukkan dua dari sembilan arsitektur CNN memperoleh nilai paling tinggi yaitu *AlexNet* dan *Lenet-5*. Untuk *AlexNet* diperoleh nilai *precision* 0,69, nilai *recall* 0,67, nilai *F1 measure* 0,66, dan nilai *accuracy* 0,67. Sementara itu, untuk *Lenet-5* diperoleh nilai *precision* sebesar 0,69, nilai *recall* sebesar 0,67, nilai *F1 measure* sebesar 0,66, dan nilai *accuracy* sebesar 0,67. Kedua arsitektur tersebut menunjukkan tingkat keakuratan yang sama dalam mengidentifikasi retinopati hipertensi.

Hasil pelatihan dan pengujian pada arsitektur *AlexNet* dapat dilihat pada grafik berikut.



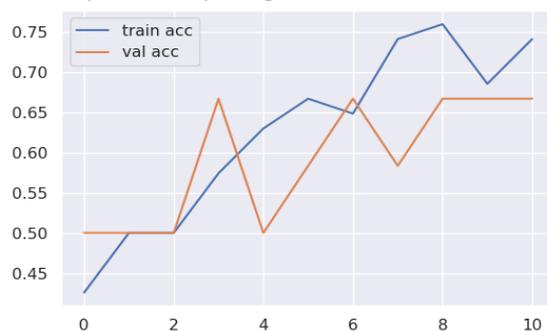
Gambar 4. Grafik nilai akurasi hasil pelatihan *AlexNet*

Serta kurva kesalahan selama proses pelatihan dapat dilihat pada Gambar 5.



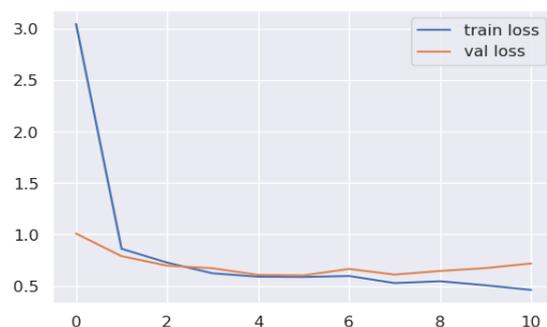
Gambar 5. Grafik tingkat kesalahan hasil pelatihan *AlexNet*

Sedangkan hasil pelatihan dan pengujian pada arsitektur *Lenet-5* dapat dilihat pada gambar berikut.



Gambar 6. Grafik nilai akurasi hasil pelatihan *Lenet-5*

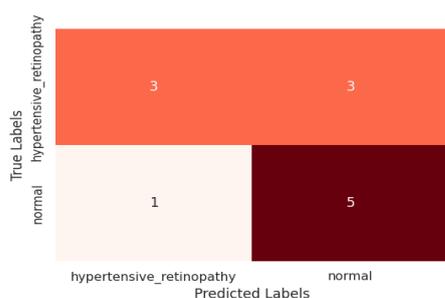
Serta grafik kesalahan selama proses pelatihan dapat dilihat pada Gambar 7.



Gambar 7. Grafik tingkat kesalahan hasil pengujian *Lenet-5*

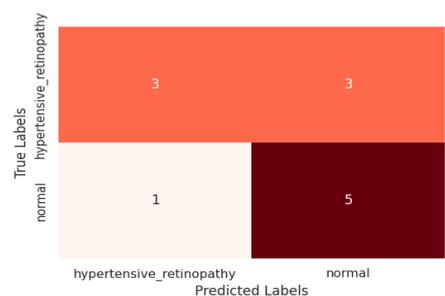
### 3.2. Hasil Validasi *Confusion Matrix*

Hasil validasi pada tahapan *confusion matrix* merupakan tahapan untuk melihat tingkat keberhasilan dan kegagalan pada pengujian yang telah diuji coba pada tahapan sebelumnya. Hasil dari tahapan tersebut untuk arsitektur *AlexNet* dapat dilihat pada Gambar 8.



Gambar 8. *Confusion Matrix* hasil pengujian *AlexNet*

Sedangkan pada arsitektur *Lenet-5* hasil pengujian dapat dilihat pada Gambar 9.



Gambar 9. *Confusion Matrix* hasil pengujian *Lenet-5*

Berdasarkan Gambar 8 dan Gambar 9 menunjukkan bahwa hasil pengujian terhadap arsitektur *AlexNet* dan *Lenet-5* memiliki tingkat akurasi yang sama. Untuk data normal, terdapat 1 kesalahan prediksi, sedangkan untuk data retinopati hipertensi terdapat 3 kesalahan prediksi. Ini menunjukkan bahwa model yang diperoleh masih membutuhkan data yang lebih banyak agar tingkat kesalahan terus menurun, khususnya data retinopati hipertensi.

#### 4. Kesimpulan

Berdasarkan hasil dan pembahasan tersebut menunjukkan bahwa dari kesembilan arsitektur CNN yang diujicobakan, dua diantaranya yaitu *AlexNet* dan *Lenet-5* memperoleh nilai yang paling tinggi tingkat keakuratannya dimana nilai akurasi yang diperoleh 0,67. Pada *confusion matrix* juga terlihat jelas bahwa arsitektur CNN dapat mengidentifikasi data normal dan data Retinopati Hipertensi melalui citra retina fundus secara tepat, namun masih membutuhkan tambahan data lagi agar tingkat akurasi meningkat. Oleh karena itu, CNN dapat digunakan sebagai alat diagnosa awal untuk membantu tenaga kesehatan khususnya dokter umum dalam mendiagnosa tahapan awal pasien yang menderita Retinopati Hipertensi.

#### References

[1] R. Amin, P. Purwanita, R. Erna, P. M. Sari, E. Rahmadini, and V. Hestika, "Skrining retinopati

hipertensi di layanan kesehatan primer di Palembang," *Jurnal Pengabdian Masyarakat: Humanity and Medicine*, vol. 1, no. 3, pp. 117–124, 2020, doi: 10.32539/hummed.v1i3.37.

- [2] A. Hanna and K. Sayuti, "Artikel Penelitian Gambaran Karakteristik Penderita Retinopati Hipertensi Yang," vol. 7, no. 2, pp. 258–266, 2018.
- [3] B. Karadag, T. Ozyigit, Z. Serindag, A. Ilhan, and B. Ozben, "Blood pressure profile is associated with microalbuminuria and retinopathy in hypertensive nondiabetic patients," *Wien Klin Wochenschr*, vol. 130, no. 5–6, pp. 204–210, 2018, doi: 10.1007/s00508-017-1270-3.
- [4] Q. Abbas and M. E. A. Ibrahim, "DenseHyper: an automatic recognition system for detection of hypertensive retinopathy using dense features transform and deep-residual learning," *Multimed Tools Appl*, vol. 79, no. 41–42, pp. 31595–31623, 2020, doi: 10.1007/s11042-020-09630-x.
- [5] M. R. Faheem and Mui-zzud-Din, "Diagnosing Hypertensive Retinopathy through Retinal Images," *Biomedical Research and Therapy*, vol. 2, no. 10, pp. 385–388, 2015, doi: 10.7603/s40730-015-0025-x.
- [6] R. Rodiah *et al.*, *Pengolahan Citra Fundus Diabetik Retinopati edisi 2 Penerbit*, no. January. 2019.
- [7] M. Y. Kipti, Wiharto, and E. Suryani, "Deteksi Awal Penyakit Retinopati Hipertensi dengan Pendekatan Analisis Fraktal Citra Fundus Retina," *Academia*, 2015.
- [8] A. Chopra, A. Sharma, S. Singh, and V. Bahl, "Changing Perspectives in Classifications of Hypertensive Retinopathy," 2014. [Online]. Available: [www.iosrjournals.org](http://www.iosrjournals.org)
- [9] Bintoro Siswo Nugroho, Yayuk Susilowati, and Nurhasanah, "Aplikasi Metode Analisis Fraktal dan K-Means Clustering untuk Identifikasi Retinopati Diabetik dan Retinopati Hipertensi menggunakan Citra Fundus Mata," *JEPIN (Jurnal Edukasi dan Penelitian Informatika)*, vol. 8, no. 1, pp. 128–133, 2022.
- [10] D. Argüeso *et al.*, "Few-Shot Learning Approach for Plant Disease Classification using Images Taken in the Field," *Comput Electron Agric*, vol. 175, no. January, 2020, doi: 10.1016/j.compag.2020.105542.
- [11] S. S. A.-N. Belal A.M. Ashqar, Bassem S. Abu-Nasser, "Plant Seedlings Classification Using Deep Learning," *International Journal of Academic Information Systems Research (IJAIRS)*, vol. 46, no. 3, pp. 745–749, 2019.
- [12] J. W. Tan, S. W. Chang, S. Abdul-Kareem, H. J. Yap, and K. T. Yong, "Deep Learning for Plant Species Classification Using Leaf Vein Morphometric,"

- IEEE/ACM Trans Comput Biol Bioinform*, vol. 17, no. 1, pp. 82–90, 2020, doi: 10.1109/TCBB.2018.2848653.
- [13] D. Juniati and A. E. Suwanda, "Klasifikasi Penyakit Mata Berdasarkan Citra Fundus Retina Menggunakan Dimensi Fraktal Box Counting Dan Fuzzy K-Means," *Proximal: Jurnal Penelitian Matematika dan Pendidikan Matematika*, vol. 5, no. 1, pp. 10–18, 2022, doi: 10.30605/proximal.v5i1.1623.
- [14] M. M. Sebatubun, "Peningkatan Kualitas Citra X-Ray Paru - paru Menggunakan Contrast Limited Adaptive Histogram Equalization dan Gaussian Filter," in *Seminar Riset Teknologi Informasi (SRITI)*, 2016, pp. 241–247.
- [15] A. I. Zakaria, E. Ernawati, A. Vatesia, and W. K. Oktoeberza, "Perbandingan Metode High-Frequency Emphasis (HFE) Dan Contrast Limited Adaptive Histogram Equalization (CLAHE) Dalam Perbaikan Kualitas Citra Penginderaan Jauh (Remote Sensing)," *Jurnal Pseudocode*, vol. 6, no. 2, pp. 125–137, 2019, doi: 10.33369/pseudocode.6.2.125-137.
- [16] S. Kana Saputra, I. Taufik, M. Hidayat, and D. F. Dharma, "Pneumonia identification based on lung texture analysis using modified k-nearest neighbour," *J Phys Conf Ser*, vol. 2193, no. 1, 2022, doi: 10.1088/1742-6596/2193/1/012070.
- [17] V. R. Allugunti, "Breast cancer detection based on thermographic images using machine learning and deep learning algorithms," *International Journal of Engineering in Computer Science*, vol. 4, no. 1, pp. 49–56, 2022.
- [18] I. M. Erwin, R. Risnandar, E. Prakarsa, and B. Sugiarto, "Kayu7net: Identifikasi dan Evaluasi F-Measure Citra Kayu berbasis Deep Convolutional Neural Network (DCNN)," *Jurnal Teknologi Informasi dan Ilmu Komputer*, vol. 7, no. 6, p. 1089, 2020, doi: 10.25126/jtiik.2020712663.
- [19] B. Yanto, L. Fimawahib, A. Supriyanto, B. H. Hayadi, and R. R. Pratama, "Klasifikasi Tekstur Kematangan Buah Jeruk Manis Berdasarkan Tingkat Kecerahan Warna dengan Metode Deep Learning Convolutional Neural Network," *INOVTEK Polbang - Seri Informatika*, vol. 6, no. 2, p. 259, 2021, doi: 10.35314/isi.v6i2.2104.
- [20] M. Altun, H. Gürüler, O. Özkaraca, F. Khan, J. Khan, and Y. Lee, "Monkeypox Detection Using CNN with Transfer Learning," *Sensors*, vol. 23, no. 4, 2023, doi: 10.3390/s23041783.
- [21] J. Xu, Y. Zhang, and D. Miao, "Three-way confusion matrix for classification: A measure driven view," *Inf Sci (N Y)*, vol. 507, pp. 772–794, 2020, doi: 10.1016/j.ins.2019.06.064.



**Kana Saputra S** lahir di Kota Sigli, tanggal 16 Agustus 1990. Saya melanjutkan pendidikan tinggi ke jenjang Sarjana di Prodi Pend. Matematika, Universitas Syiah Kuala dan jenjang Magister di Prodi Ilmu Komputer, Institut Pertanian Bogor.