

DETEKSI PENYAKIT DIABETES *RETINOPATHY* MENGGUNAKAN CITRA DIGITAL DENGAN METODE *CONVOLUTIONAL NEURAL NETWORK (CNN)*

Nurohman¹, Rudi Heriansyah², Dwi Asa Verano³, Zaid Romegar Mair⁴

^{1,2,3,4}Program Studi Teknik Informatika Fakultas Ilmu Komputer dan Sains

e-mail:¹2020110021@students.uigm.ac.id, ²rudi@uigm.ac.id, ³dwiasa@uigm.ac.id, ⁴zaidromegar@uigm.ac.id

ABSTRACT

Diabetic retinopathy (DR) is a serious complication of diabetes that can lead to blindness if not detected and treated early. Conventional screening methods involve fundus examination by trained medical personnel, which is time-consuming and costly. This study proposes an automated detection approach for diabetic retinopathy using digital fundus images and Convolutional Neural Network (CNN) methods. CNN, a deep learning architecture, is utilized to automatically learn and extract features from retinal fundus images. The dataset used for detection and classification consists of 5 classes: mild, moderate, no DR, proliferative, and severe. The image training process employs the VGG-19 model trained for 100 epochs, achieving a commendable accuracy of 72% with a dataset of 3000 fundus images split into a 70:30 ratio for training and validation (70% for training, 30% for validation). The diagnosis results include 2160 images classified as DR and 840 images classified as NDR. Training with an 80:20 data split (80% for training, 20% for validation) yielded an accuracy of 69%, with 2070 images diagnosed as DR and 930 images as NDR.

Keywords: *Diabetic Retinopathy, Digital Image, Convolutional Neural Network (CNN), VGG-19.*

INTISARI

Diabetic retinopati (DR) merupakan komplikasi serius dari diabetes yang dapat menyebabkan kebutaan jika tidak dideteksi dan diobati secara dini. Metode skrining konvensional melibatkan pemeriksaan fundus oleh tenaga medis terlatih membutuhkan waktu dan biaya yang besar. Penelitian ini mengusulkan pendekatan deteksi otomatis retinopati diabetik menggunakan citra digital fundus dan metode Convolutional Neural Network (CNN). CNN adalah salah satu arsitektur deep learning, dimanfaatkan untuk secara otomatis mempelajari dan mengekstraksi fitur-fitur dari citra fundus retina. Dataset yang digunakan dalam proses deteksi dan klasifikasi mempunyai 5 kelas yaitu: mild, moderate, no DR, proliferative, dan severe. Proses pelatihan citra menggunakan model VGG-19 dengan pelatihan 100 epoch mendapat hasil akurasi yang cukup baik yaitu 72% dengan jumlah data 3000 citra fundus yang dibagi menjadi 70:30, 70% untuk data train dan 30% untuk data validasi. Hasil diagnosa DR sebanyak 2160 citra dan NDR sebanyak 840 citra. Pada pelatihan menggunakan rasio data 80:20 yaitu 80% data train dan 20% data validasi, rasio ini mendapat hasil akurasi 69% dengan hasil diagnosa DR sebanyak 2070 citra dan NDR sebanyak 930 citra.

Kata kunci: *Diabetes Retinopati, Citra Digital, Convolutional Neural Network (CNN), VGG-19.*

1. PENDAHULUAN

Diabetes mellitus (*DM*) adalah penyakit kronis yang semakin meningkat prevalensinya di seluruh dunia, dengan salah satu komplikasi mikrovaskulernya yang paling umum adalah *Diabetic Retinopathy (DR)*. *DR* terjadi akibat kerusakan pembuluh darah pada retina yang disebabkan oleh hiperglikemia kronis, dan jika tidak terdeteksi secara dini, dapat menyebabkan kebutaan. Data global menunjukkan bahwa prevalensi *DR* mencapai 34,6%, menjadikannya salah satu penyebab utama gangguan penglihatan pada pasien diabetes. *DR* seringkali tidak menimbulkan gejala pada tahap awal, sehingga banyak pasien yang tidak menyadari adanya kerusakan pada retina hingga kondisinya sudah parah. Meskipun pemeriksaan rutin sangat penting untuk deteksi dini, banyak pasien yang tidak melakukan pemeriksaan mata secara teratur, dan diagnosis *DR* masih bergantung pada pemeriksaan manual oleh ahli oftalmologi yang membutuhkan keterampilan tinggi, waktu, dan biaya yang tidak sedikit (Purnama, 2023).

Mengingat pentingnya deteksi dini untuk mencegah kebutaan akibat *DR*, diperlukan solusi yang lebih efisien dan akurat. Salah satu cara untuk mengatasi masalah ini adalah dengan menggunakan teknologi machine learning,

khususnya *Convolutional Neural Network (CNN)*, untuk menganalisis citra fundus retina. *CNN* telah terbukti efektif dalam berbagai aplikasi medis, termasuk dalam mendiagnosis penyakit mata, karena kemampuannya untuk menangkap pola visual yang halus dan kompleks dalam citra. Dengan menggunakan model *CNN*, diharapkan dapat meningkatkan akurasi deteksi dan mempercepat proses diagnosis, sehingga membantu praktisi medis dalam mengidentifikasi tingkat keparahan *DR* secara lebih cepat dan tepat (RIZAL et al., 2020).



Gambar 1. Fundus Retina (WHO)

Penelitian ini bertujuan untuk mengembangkan dan mengimplementasikan model *CNN* yang dapat secara otomatis mendeteksi dan mengklasifikasikan tingkat keparahan *DR* berdasarkan citra fundus retina. Model ini diharapkan dapat memberikan solusi yang lebih efisien dalam deteksi dini dan klasifikasi *DR*, yang selama ini masih mengandalkan pemeriksaan manual oleh tenaga medis. Hipotesis utama penelitian ini adalah bahwa penerapan *CNN*, khususnya dengan teknik *transfer learning* menggunakan model yang sudah dilatih sebelumnya seperti *VGG-19*, dapat meningkatkan akurasi deteksi dan klasifikasi *DR*, meskipun dengan variasi kualitas citra yang ada. Dengan demikian, model *CNN* ini tidak hanya diharapkan dapat meningkatkan kecepatan diagnosis, tetapi juga memberikan hasil yang lebih akurat dan dapat diandalkan dalam menangani kasus *DR* (Anisa Nur Azizah, 2021).

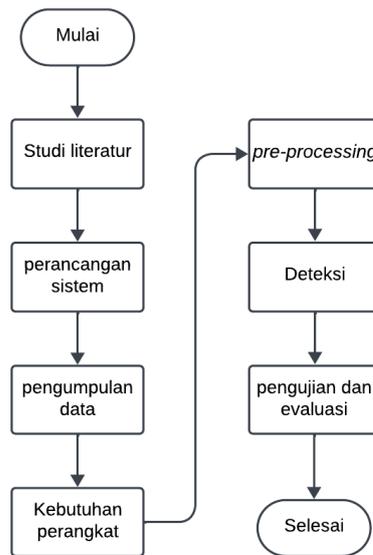
Relevansi literatur yang ada menunjukkan bahwa penggunaan *CNN* dalam deteksi *DR* sudah banyak dibahas, dengan hasil yang menunjukkan keunggulan teknologi ini dalam memproses citra medis. Berbagai model *CNN*, seperti *AlexNet*, *VGG*, dan *ResNet*, telah terbukti efektif dalam mengidentifikasi tanda-tanda *DR* pada citra retina. Selain itu, teknik *transfer learning* memungkinkan pemanfaatan model yang sudah dilatih sebelumnya untuk meningkatkan kinerja pada dataset yang terbatas. Dengan menggunakan pendekatan ini, penelitian ini bertujuan untuk mengisi kekosongan dalam penerapan *CNN* untuk deteksi *DR* secara lebih luas, sekaligus memberikan kontribusi dalam pengembangan sistem diagnosis otomatis yang lebih efisien dan akurat. Demikian, penelitian ini diharapkan dapat memberikan dampak signifikan dalam pencegahan kebutaan akibat retinopati diabetik, serta mendukung pengelolaan penyakit diabetes secara lebih efektif (Ardyansyah & Gunawansyah, 2023).

2. METODE PENELITIAN

Penelitian ini dilakukan dengan mengikuti kerangka kerja supaya penelitian dilakukan dengan terstruktur. Kerangka kerja adalah tahapan-tahapan proses penelitian yang terurut berdasarkan langkah-langkah yang saling berkaitan seperti Gambar 1.

a. Studi Literatur

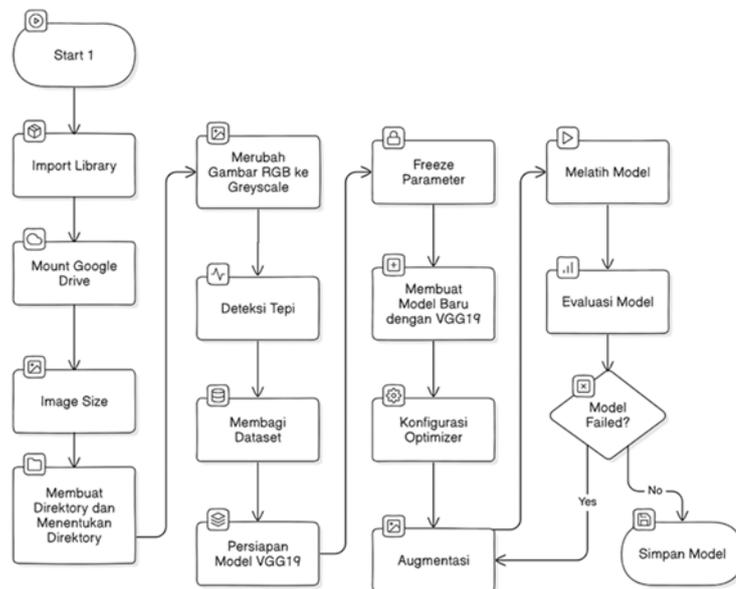
Studi literatur dilakukan dengan membaca dan menganalisis buku, artikel, dan jurnal ilmiah yang berkaitan dengan klasifikasi dan deteksi diabetes retinopati, serta konsep *machine learning*, *deep learning*, dan *Convolutional Neural Networks (CNN)*. Tujuan dari studi ini adalah untuk mengumpulkan referensi yang relevan dan membangun landasan teori yang kuat, sehingga mendukung pemahaman mendalam terhadap topik penelitian dan membantu dalam merumuskan metodologi yang tepat untuk implementasi solusi dalam mendeteksi penyakit diabetes retinopati.



Gambar 2. Tahapan Penelitian

b. Perancangan Sistem

Sistem yang dirancang adalah untuk mengklasifikasikan menjadi 5 kelas yaitu *No_DR*, *mild*, *moderate*, dan *severe proliferative DR*. Serta mendeteksi *DR nonproliferative* dan *DR proliferative Input* sistem berupa citra fundus retina yang diperoleh dari RS Khusus Mata Prov. Sumsel. Citra retina berupa citra berwarna yang diambil menggunakan kamera fundus dengan format .jpeg. Perancangan sistem secara lengkap pada penelitian ini diilustrasikan dengan blok diagram yang di tunjukan pada Gambar 2.



Gambar 3. Blok Diagram Sistem

Berikut penjelasan proses algoritma Pada Gambar 4 :

1. Mulai
2. *Import Library*, bertujuan untuk mempersiapkan library yang dibutuhkan dalam metode *CNN* dengan model *VGG-19*.
3. *Mount Google Drive*, menyambungkan *Google Colab* ke *Google Drive* bertujuan untuk pemanggilan direktori.

4. *Image size*, untuk menentukan ukuran gambar yang akan di deteksi.
5. Membuat direktori dan menentukan direktori, bertujuan untuk memanggil dataset yang akan digunakan.
6. Membuat gambar *RGB* ke *Greyscale*.
7. Mendeteksi tepi citra retina.
8. Membagi dataset dengan jumlah data latih 80% dan validasi 20% dengan pembagian acak
9. Mempersiapkan model *VGG-19*.
10. *Freeze* parameter, bertujuan untuk menetapkan parameter agar tidak dilatih kembali.
11. Membuat model baru dengan *VGG-19*.
12. Menentukan dan mengkonfigurasi *optimizer* yang akan digunakan dalam proses pelatihan model *neural network* menggunakan *framework* Keras.
13. Augmentasi data digunakan untuk meningkatkan jumlah dan variasi data pelatihan dengan cara artifisial. Seperti rotasi, *flipping*, pergeseran, *zoom*, atau perubahan warna pada gambar, atau manipulasi teks seperti penambahan sinonim atau pemotongan kata.
14. Melatih model yang akan digunakan dengan epoch 100
15. Evaluasi model, bertujuan untuk melihat apakah model berhasil mencapai akurasi yang diinginkan atau tidak.
16. Pengulangan, jika model gagal maka akan dilakukan pelatihan ulang ke proses augmentasi dan dilakukan pelatihan model kembali. Jika proses pelatihan berhasil mencapai akurasi yang diinginkan maka model akan lanjut ke proses berikutnya.
17. Simpan model.

c. Pengumpulan Data

Penelitian ini menggunakan data berupa citra retina mata yang terindikasi penyakit diabetes retinopati dengan jumlah 3000 citra retina. Citra berukuran 244 x 244 *pixel* dengan format *jpg/jpeg*. Data yang diambil merupakan data sekunder diperoleh dari RS Khusus Mata Prov. Sumsel yang diambil menggunakan perangkat *DIRECT OPHTHALMOLOGICAL*. *Direct ophthalmoscope* adalah alat esensial dalam praktik oftalmologi yang digunakan untuk pengambilan foto dan pemeriksaan struktur dalam mata, seperti retina dan saraf optik.

d. Data Preprocessing

Data *preprocessing* adalah serangkaian langkah yang dilakukan untuk membersihkan, mempersiapkan, dan mentransformasi data mentah menjadi bentuk yang lebih cocok untuk analisis atau pemodelan data. Langkah-langkah umum dalam data *preprocessing* meliputi:

1. Data *cleaning*: Pertama-tama, dalam proses *preprocessing* data, langkah kritis yang harus dilakukan adalah membersihkan data. Dalam tahap ini, data mentah yang diperoleh disaring kembali untuk menghindari kesalahan yang dapat mempengaruhi hasil analisis data lebih lanjut.
2. Data *integration*: Karena data *preprocessing* akan menggabungkan beberapa data dalam suatu dataset, maka harus mengecek data yang datang dari berbagai sumber tersebut supaya memiliki format yang sama.
3. Transformasi data: Proses berikutnya yang harus dilakukan adalah transformasi data atau menyamakan seluruh data yang terkumpul supaya dapat mempermudah proses analisis data.
4. Mengurangi data, Tahap terakhir yang esensial adalah melakukan pengurangan data. Tujuannya adalah untuk mengurangi jumlah sampel data yang diambil tanpa mengubah hasil analisis. Terdapat tiga teknik yang dapat digunakan dalam proses ini, yaitu pengurangan dimensi (*dimensionality reduction*), pengurangan jumlah (*numerosity reduction*), dan kompresi data (*data compression*).

Pembagian dataset dilakukan dengan membagi data citra dengan rasio 80:20 dan 70:30 yang bertujuan untuk menentukan seberapa banyak citra dalam folder train dan validasi yang akan digunakan dalam pelatihan model *CNN*. Data yang telah diproses akan dibagi menjadi dua jenis yaitu data latih dan data validasi. Rasio pembagian data adalah 80% data latih dan 20% data validasi, data dibagi secara acak. Pada pembagian data dengan rasio 70:30 prosesnya sama seperti pembagian 80:20. Selanjutnya akan dilakukan proses deteksi pada citra yang telah dibagi sebelumnya.

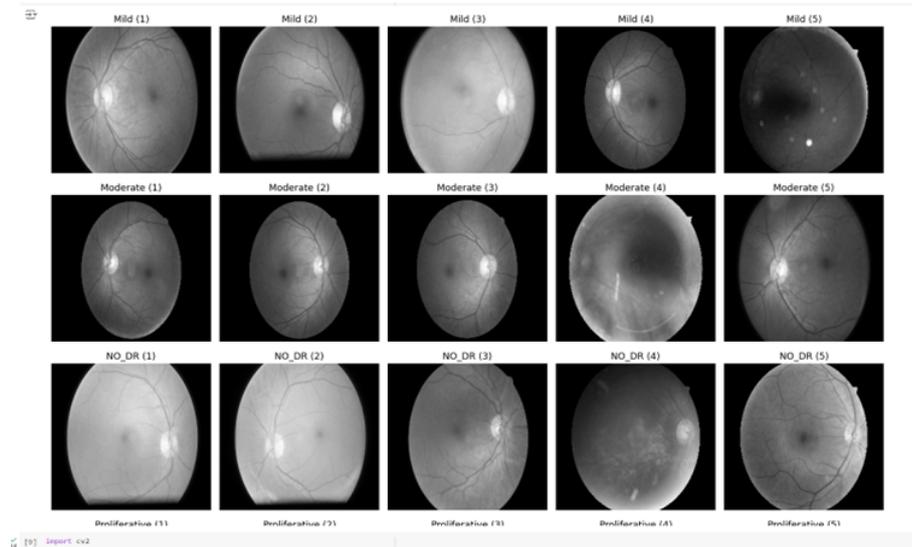
3. HASIL DAN PEMBAHASAN

Penelitian ini dilakukan menggunakan *Google Colab* sebagai alat untuk membuat model deteksi dan klasifikasi penyakit diabetes retinopati. Klasifikasi dan deteksi dilakukan menggunakan arsitektur *Visual Geometri Group-19 (VGG-19)* menggunakan *transfer learning* dan optimasi *Gradient Descent* dengan epochs 100 menggunakan rasio data 70:30 dan 80:20 dengan 3000 data citra yang dibagi menjadi 600 perkelas. Dataset tersebut divalidasi pada RS Khusus Mata Prov. Sumsel.

Dataset pada penelitian ini berupa citra yang diperoleh dari pemeriksaan dokter spesialis mata pada pasien RS Khusus Mata Prov. Sumsel yang beralamat Jl. Kolonel H. Barlian No.KM 6, Suka Bangun, Kec. Sukarami, Kota Palembang, Sumatera Selatan 30961.

3.1. Mengubah gambar RGB ke Greyscale

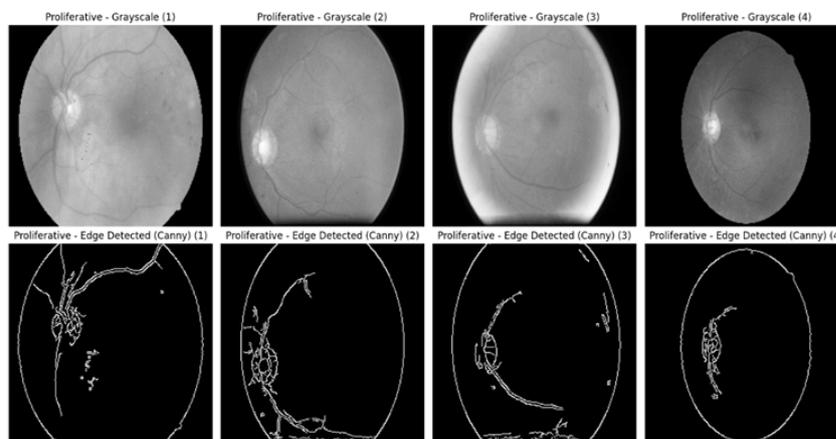
Data yang sudah diambil selanjutnya akan diubah menjadi greyscale menggunakan program *Python 3.11.3*, Hasil output pada kode menunjukkan bahwa gambar *RGB* diubah menjadi greyscale dengan mengambil contoh 5 gambar utama dari direktori setiap kelas, dapat dilihat pada Gambar 4 dibawah.



Gambar 4. Citra Greyscale

3.2. Deteksi Tepi

Dataset yang telah di rubah menjadi *greyscale* kemudian akan dideteksi tepi dengan menggunakan metode deteksi operator *canny*. Deteksi tepi menggunakan metode *canny* pada citra retina merupakan teknik yang efektif untuk mengidentifikasi fitur-fitur penting, seperti pembuluh darah dan lesi, yang terkait dengan diabetes retinopati, dengan memanfaatkan operator *gradient* untuk mendeteksi perubahan intensitas secara lokal; proses ini melibatkan pra-pemrosesan untuk mengurangi *noise*, penerapan kernel *canny* untuk menghitung *gradien*, serta *thresholding* untuk mengekstrak tepi yang signifikan, sehingga menghasilkan analisis yang lebih akurat dan informatif dalam diagnosis penyakit serta mendukung pengembangan metode pengolahan citra medis yang lebih canggih. Hasil deteksi tepi *canny* dapat dilihat pada Gambar 5.



Gambar 5. Deteksi Tepi Model Canny

3.3. Membagi Data

Pembagian data train dan data validasi dengan rasio pembagian 80:20, 80% data latih dan 20% data validasi. Data citra akan dibagi secara acak pada setiap kelas dan menghasilkan keluaran hasil pembagian acak, berikut Gambar 6 hasil keluaran dari program pembagian acak.

```
↕ Jumlah Train mild = 480
   Jumlah Train moderate = 480
   Jumlah Train NO_DR = 480
   Jumlah Train proliferative = 480
   Jumlah Train severe = 480
-----
   Jumlah validasi mild = 120
   Jumlah validasi moderate = 120
   Jumlah validasi NO_DR = 120
   Jumlah validasi proliferative = 120
   Jumlah validasi severe = 120
```

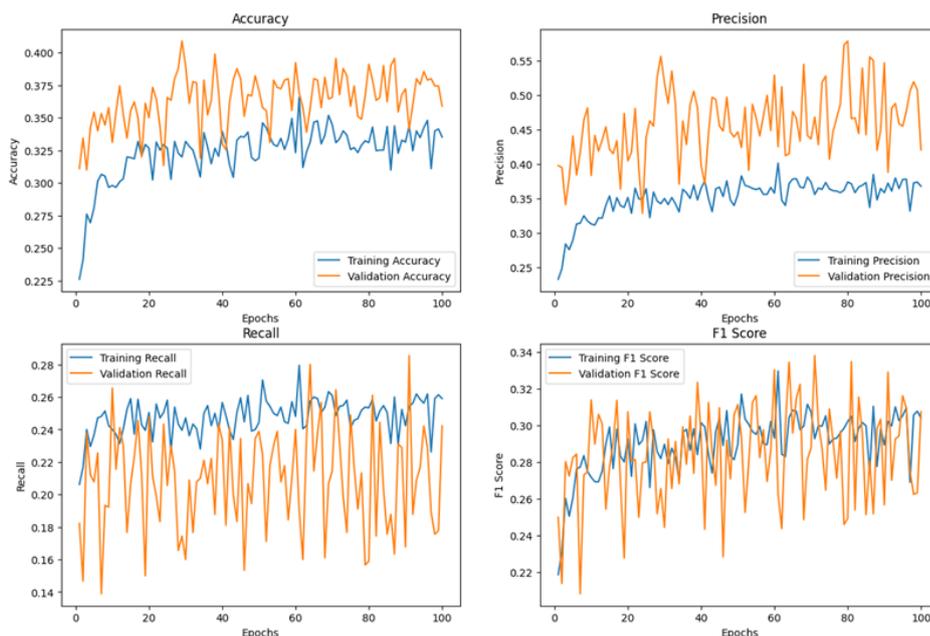
Gambar 6. Hasil Pembagian Data Secara Acak

Hasil dari pembagian pada Gambar 6 menunjukkan hasil pembagian data train 480 data citra di setiap kelas dan 120 data citra pada data validasi pada setiap kelas. Hasil pembagian data dengan rasio 70:30, 70% untuk data train dan 30% data validasi menghasilkan 420 citra pada setiap kelas train dan 180 citra untuk setiap kelas validasi.

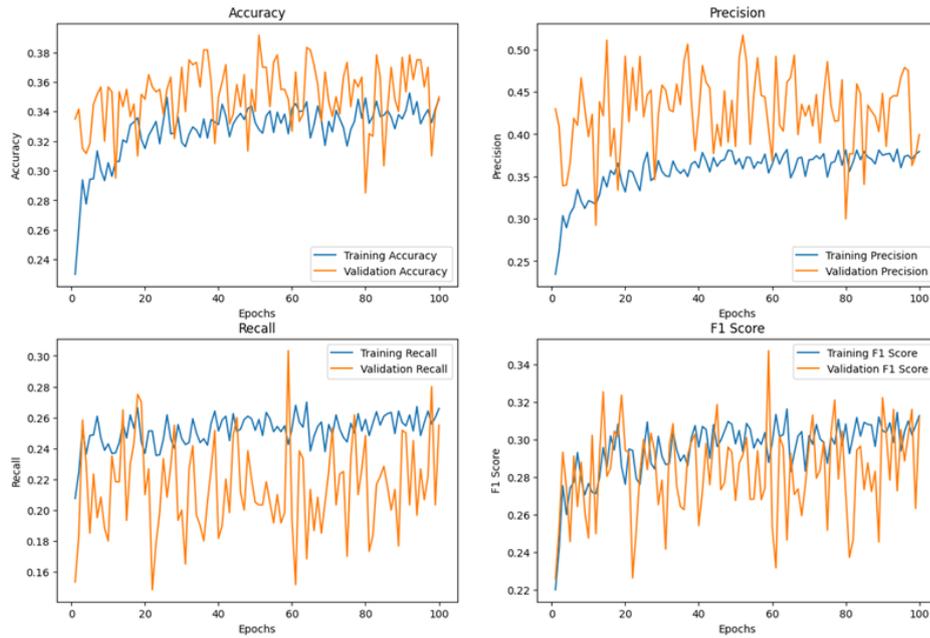
3.4. Evaluasi Model

Mengevaluasi model menggunakan berbagai *library* yang umumnya digunakan untuk evaluasi model klasifikasi. Beberapa *library* yang digunakan termasuk *NumPy* untuk operasi numerik dan manipulasi *array*, *Keras* untuk melakukan pra-pemrosesan pada gambar, *Google Colab* untuk mengunggah file dari *Google Colab*, *scikit-learn* untuk menghitung *confusion matrix*, *Seaborn* untuk visualisasi data, dan *Matplotlib* untuk membuat *plot*.

Visualisasi yang jelas tentang bagaimana performa model *CNN* berubah selama proses pelatihan dan evaluasi terhadap data train dan validasi, sehingga memudahkan untuk mengevaluasi dan memantau kinerja model secara keseluruhan. Hasil akurasi, presisi, *recall*, dan *f1 score* pada model *CNN* dengan rasio 70:30 dan rasio 80:20 menggunakan arsitektur *VGG-19* dapat dilihat pada Gambar 7 dan Gambar .

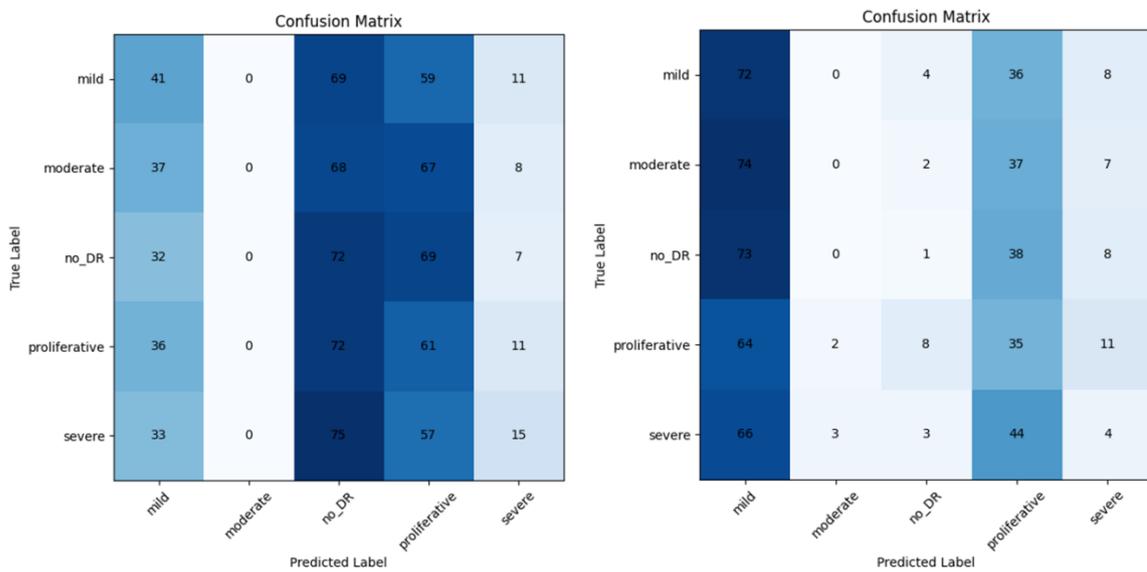


Gambar 7. Plot Hasil Pengujian Dengan Rasio Data 70:30



Gambar 8. Plot Hasil Pengujian Dengan Rasio Data 80:20

Hasil pengujian pada pelatihan *CNN* model *VGG-19* menghasilkan tabel konfuison matrix yang akan digunakan untuk menghitung nilai akurasi, *precision*, *recall* dan *f1_score* pada pelatihan menggunakan epoch 100 berikut adalah Gambar *confusion matrix* rasio 70:30 dan rasio 80:20 dapat dilihat pada Gambar 9.



Gambar 9. Confusion Matrix Rasio 70:30 dan Rasio 80:20

Hasil pelatihan 100 epoch rasio 70:30

Akurasi : Akurasi = $\frac{3789}{5211} \times 100\% = 72\%$
 Presisi : Precision = $\frac{189}{189+711} \times 100\% = 21\%$
 Recall : Recall = $\frac{189}{189+711} \times 100\% = 21\%$
 F1_Score : F1Score = $\frac{2 \times (89+103)}{89+103} \times 100\% = 200\%$

Perhitungan diatas adalah hasil dari keseluruhan pada setiap kelas. Berikut ini adalah tabel hasil perhitungan dari setiap kelas pada rasio data 70:30 dapat dilihat pada Tabel 1.

Tabel 1. Tabel *accuracy*, *precision*, *recall*, dan *f1_score* rasio 70:30

Kelas	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1_score</i>
mild	73%	22%	22%	2%
moderate	80%	0%	0%	0%
no_DR	66%	20%	40%	2%
proliverative	67%	19%	33%	2%
severe	78%	28%	8%	2,5%
Keseluruhan	72%	21%	21%	2%

Hasil pelatihan 100 epoch rasio 80:20

Akurasi : Akurasi = $\frac{2212}{3198} \times 100\% = 69\%$

Presisi : *Precision* = $\frac{112}{112+438} \times 100\% = 20\%$

Recall : *Recall* = $\frac{112}{112+448} \times 100\% = 20\%$

F1_Score : *F1Score* = $\frac{2 \times (57+65)}{57+65} \times 100\% = 200\%$

Berikut ini adalah tabel hasil dari perhitungan akurasi, presisi, *recall*, dan *f1 score* pada pelatihan epoch 100 dengan rasio data 80:20 dapat dilihat pada Tabel 2.

Tabel 2. Tabel *accuracy*, *precision*, *recall*, dan *f1_score* rasio 80:20

Kelas	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1_score</i>
mild	62%	24%	60%	2%
moderate	79%	0%	0%	0%
no_DR	57%	5%	0%	2%
proliverative	68%	18%	22%	2%
severe	76%	10%	3%	2%
Keseluruhan	69%	20%	20%	2%

Hasil pada pelatihan dataset menggunakan perbandingan data 70:30, 70% untuk data train dan 30% untuk data validasi mendapat akurasi yang cukup bagus dengan jumlah akurasi keseluruhan pada setiap kelas yaitu 72%, *precision* 21%, *recall* 21% dan *f1_score* 200%. Sedangkan pada pelatihan dataset dengan rasio 80:20 menggunakan 100 epoch mendapat nilai akurasi yang lebih rendah dibanding dengan pengujian sebelumnya yaitu akurasi 69%, *precision* 20%, *recall* 20% dan *f1_score* 200%.

3.5. Diagnosa

Diagnosa adalah penentuan jenis penyakit dengan cara meneliti (memeriksa) gejala-gejalanya. Berikut ini adalah hasil diagnosa penyakit yang terkena *DR* dan *NDR* dapat dilihat pada Tabel 3 dan Tabel 4.

Tabel 3. Tabel diagnosa hasil deteksi rasio data 70:30

Diagnosa	Rasio data	Presentase	Jumlah data
<i>DR</i>	70:30	72%	2160 Citra
<i>NO_DR</i>		28%	840 Citra

Tabel 4. Tabel diagnosa hasil deteksi rasio data 80:20

Diagnosa	Rasio data	Presentase	Jumlah data
DR	80:20	69%	2070 Citra
NO_DR		31%	930 Citra

Hasil diagnosa pada DR dan NDR dengan rasio data 70:30 pada Tabel 3 data citra yang berhasil mendeteksi DR sebanyak 2160 citra dan data yang tidak terdeteksi penyakit DR sebanyak 840 citra. Sedangkan hasil diagnosa pada proses deteksi DR menggunakan rasio data 80:20 pada Tabel 4 mendapat penurunan presentase dibandingkan dengan pelatihan sebelumnya sehingga didapat hasil deteksi DR sebanyak 2070 citra sedangkan deteksi pada NDR sebanyak 930 citra.

4. KESIMPULAN

Berdasarkan hasil penelitian yang telah dijelaskan pada bab sebelumnya, maka didapat kesimpulan sebagai berikut:

1. Algoritma CNN menggunakan arsitektur VGG-19 berhasil melakukan deteksi dan klasifikasi penyakit diabetes retinopati.
2. Hasil dari penulis didapatkan akurasi sebesar 72% pada pelatihan data menggunakan 100 epoch dengan rasio 70:30 yang menggunakan total data 3000 citra. Hasil diagnosa dalam mendeteksi DR mendapat 2160 citra dan NDR mendapat 840 citra.
3. Hasil dari pelatihan menggunakan epoch 100 dengan perbandingan rasio data 80:20 mendapat nilai akurasi 69%. Dengan data yang berhasil didiagnosa terdeteksi DR sebanyak 2070 citra dan hasil deteksi NDR sebanyak 930 citra.

DAFTAR PUSTAKA

- Anisa Nur Azizah. (2021). *Klasifikasi Penyakit Diabetic Retinopathy Menggunakan Metode Convolutional Neural Network (CNN) Model Deep Residual Network (Resnet)*.
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8(1).
- Frangky Handono, S., Tri Anggraeny, F., & Rahmat, B. (2020). Implementasi Convolutional Neural Network (CNN) Untuk Deteksi Retinopati Diabetik. In *Jurnal Informatika dan Sistem Informasi (JIFoSI)* (Vol. 1, Issue 1).
- Ardyansyah, M. A., & Gunawansyah. (2023). Sistem Deteksi Level Diabetic Retinopathy Melalui Citra Fundus Mata dengan Menggunakan Metode CNN (Convolutional Neural Network). *G-Tech: Jurnal Teknologi Terapan*, 7(4), 1673–1682. <https://doi.org/10.33379/gtech.v7i4.3332>
- Purnama, R. F. N. (2023). Retinopati Diabetik : Manifestasi Klinis, Diagnosis, Tatalaksana dan Pencegahan. *Lombok Medical Journal*, 2(1), 39–42. <https://doi.org/10.29303/lmj.v2i1.2410>
- Rizal, S., Ibrahim, N., Pratiwi, N. K. C., Saidah, S., & Fu'adah, R. Y. N. (2020). Deep Learning untuk Klasifikasi Diabetic Retinopathy menggunakan Model EfficientNet. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 8(3), 693.
- Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. In *SN Computer Science* (Vol. 2, Issue 6). Springer.
- Sulaeman, A. A., & Dwi, N. (2022). Implementasi Neural Network Untuk Mendeteksi Penyakit Diabetes Pada Retinopati. *Jurnal Teknologi Pelita Bangsa*, 13(4).
- Zahir, M., & Adi Saputra, R. (2024). *Deteksi Penyakit Retinopati Diabetes Menggunakan Citra Mata Dengan Implementasi Deep Learning CNN* (Vol. 18, Issue 1).
- Z. R. Mair, W. Cholil, E. Yulianti, D. Marcelina, Theresiawati, and I. N. Isnainiyah, "Convolutional Neural Network Analysis on Handwriting Patterns and Its Relationship to Personality: A Systematical Review," in *2023 International Conference on Informatics, Multimedia, Cyber and Informations System (ICIMCIS)*, Jakarta Selatan, Indonesia, 2023.
- Z. R. Mair and M. H. Irfani, "Permainan INGBAS (Gunting, Batu, Kertas) Menggunakan Arsitektur Convolutional Neural Network," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 10, no. 1, pp. 4322, Mar. 2023, JATISI.