

## Convolutional Neural Network (CNN) untuk Klasifikasi Citra Penyakit Diabetes Retinopathy

Muslih<sup>1</sup>, Eko Hari Rachmawanto<sup>2\*</sup>

<sup>1,2</sup> Fakultas Ilmu Komputer, Teknik Informatika, Universitas Dian Nuswantoro, Semarang, Indonesia

E-mail: <sup>1</sup>muslih@dsn.dinus.ac.id, <sup>2</sup>eko.hari@dsn.dinus.ac.id

(\* : corresponding author)

### Abstrak

Diabetic Retinopathy (DR) merupakan suatu komplikasi yang terjadi karena adanya kerusakan pada pembuluh darah retina. DR melalui citra retina mata sudah pernah diteliti menggunakan proses peningkatan kualitas citra maupun teknik filtering. Citra DR, memiliki garis tebal dan tipis pada citra fundus dimana tebal tipisnya digunakan untuk menentukan apakah citra fundus tersebut terkategori sebagai citra DR. Biasanya, teknik filtering diperlukan dalam mempertajam garis pada citra fundus. Pada penelitian ini, optimasi dalam klasifikasi citra retina mata yang terdiagnosa retinopati telah dilakukan menggunakan algoritma Convolutional Neural Network (CNN) dengan tujuan pengenalan pembuluh darah pada retina mata terdiagnosa DR. Urgensi dari penelitian ini yaitu melakukan uji performa CNN dalam proses klasifikasi citra DR pada jumlah data yang cukup besar tanpa menggunakan preprosesing apapun sehingga dapat disimpulkan bahwa CNN saja sudah mampu mengklasifikasi objek dengan baik. Citra berasal dari Kaggle database dengan total 88702 citra yang di sortir menjadi 88000 data. Hasil klasifikasi citra benar yaitu 82445 dengan prosentase 93,68% sedangkan citra salah klasifikasi yaitu 5555 citra dengan prosentase kegagalan yaitu 6,32%.

Kata kunci: Diabetic Retinopathy, Kaggle, CNN

### Abstract

*Diabetic Retinopathy (DR) is a complication that occurs due to damage to the retinal blood vessels. DR through retinal images has been investigated using image quality improvement processes and filtering techniques. The DR image has thick and thin lines on the fundus image where the thickness is used to determine whether the fundus image is categorized as a DR image. Usually, a filtering technique is needed to sharpen the lines on the fundus image. In this study, optimization in the classification of retinal images diagnosed with retinopathy has been carried out using the Convolutional Neural Network (CNN) algorithm with the aim of recognizing blood vessels in the retina of eyes diagnosed with DR. The urgency of this research is to test CNN's performance in the DR image classification process on a fairly large amount of data without using any preprocessing so that it can be concluded that CNN alone is able to classify objects well. The images come from the Kaggle database with a total of 88702 images sorted into 88000 data. The results of the correct image classification are 82445 with a percentage of 93.68% while the misclassified image is 5555 images with a failure percentage of 6.32%.*

*Keywords: Diabetic Retinopathy, Kaggle, CNN*

## 1. PENDAHULUAN

Retinopati diabetik adalah salah satu komplikasi diabetes yang paling mengancam yang menyebabkan kebutaan permanen jika tidak diobati [1]–[3]. Banyaknya kasus diabetic retinopathy pada kurun waktu Desember 2021 hingga Februari 2022 seperti diilustrasikan pada Gambar 1. Salah satu tantangan penting adalah deteksi dini, yang sangat penting untuk keberhasilan pengobatan. Identifikasi yang tepat dari tahap retinopati diabetik terkenal rumit [1], [2], [4], [5] dan memerlukan interpretasi manusia ahli dari gambar fundus. Penyederhanaan langkah deteksi sangat penting dan dapat membantu jutaan orang. Jaringan saraf convolutional

(CNN) telah berhasil diterapkan di banyak mata pelajaran yang berdekatan, dan untuk diagnosis retinopati diabetik itu sendiri [5]–[7]. Namun, tingginya biaya kumpulan data berlabel besar, serta inkonsistensi antara dokter yang berbeda, menghambat kinerja metode ini. Dalam makalah ini, dalam penelitian ini telah diimplementasikan metode deep-learning otomatis untuk deteksi jenis retinopati diabetik dengan fotografi tunggal fundus manusia.



Gambar 1. Tren diagnosa penyakit diabetic retinopathy

DR berkembang dengan empat tahap [1]:

1. Retinopati non-proliferatif ringan, tahap paling awal, di mana hanya mikroaneurisma yang dapat terjadi;
2. Retinopati non-proliferatif sedang, suatu tahap yang dapat digambarkan dengan hilangnya kemampuan pembuluh darah untuk mengangkut darah karena distorsi dan pembengkakannya seiring dengan perkembangan penyakit;
3. Retinopati non-proliferatif yang parah mengakibatkan berkurangnya suplai darah ke retina karena peningkatan penyumbatan lebih banyak pembuluh darah, sehingga memberi sinyal retina untuk pertumbuhan pembuluh darah segar;
4. Retinopati diabetik proliferasi adalah stadium lanjut, di mana ciri pertumbuhan yang disekresikan oleh retina mengaktifkan proliferasi pembuluh darah baru, tumbuh di sepanjang lapisan dalam retina dalam beberapa gel vitreus, mengisi mata.

Setiap tahap memiliki karakteristik dan sifat tertentu, sehingga dokter mungkin tidak dapat mempertimbangkan beberapa di antaranya, dan dengan demikian membuat diagnosis yang salah. Jadi ini mengarah pada ide penciptaan solusi otomatis untuk deteksi DR. Pada saat yang sama, dokter akan paling sering setuju ketika lesi terlihat. Selain itu, cara diagnosis yang ada saat ini cukup tidak efisien karena durasinya yang lama, dan jumlah dokter mata yang termasuk dalam solusi masalah pasien. Sumber ketidaksepakatan seperti itu menyebabkan diagnosis yang salah dan kebenaran dasar yang tidak stabil untuk solusi otomatis, yang disediakan untuk membantu dalam tahap penelitian [8], [9]. Dengan demikian, algoritma untuk deteksi DR mulai muncul. Algoritma pertama didasarkan pada algoritma klasik yang berbeda dari visi komputer dan pengaturan ambang batas. Namun demikian, dalam beberapa tahun terakhir, pendekatan pembelajaran mendalam telah membuktikan keunggulannya dibandingkan algoritma lain dalam tugas klasifikasi dan deteksi objek. Secara khusus, Convolutional Neural Network (CNN) telah berhasil diterapkan di banyak mata pelajaran yang berdekatan dan untuk diagnosis retinopati diabetik itu sendiri.

Menurut penelitian yang dilakukan oleh Manoj Raju [10] yang menggunakan pendekatan berbasis Convolutional Neural Network (CNN) untuk diagnosis otomatis diabetes retinopathy dan melatih dataset Kaggle yang tersedia untuk umum. Sekitar 35.000 citra digunakan untuk melatih jaringan, yang mengamati sensitivitas 80,28% dan spesifisitas 92,29% pada 53.000 gambar. Menggunakan 8.810 citra, jaringan dilatih untuk mendeteksi lateralitas mata dan mengamati citra dengan hasil akurasi 93,28%. Penelitian lain yang juga menggunakan deep learning oleh Michael David Abr`amoff [2], menggunakan standar referensi konsensus yang dilaporkan sebelumnya untuk DR yang didefinisikan sebagai Klasifikasi Klinis Internasional Retinopati Diabetik sedang, nonproliferatif berat, DR proliferasi, dan/atau edema makula. Pengujian dilakukan menggunakan perhitungan Sensitivitas, spesifisitas, nilai prediksi negatif, area di bawah kurva (AUC), dan interval kepercayaan (CI) dihitung. Diperoleh sensitivitas 96,8% (95% CI: 93,3%–98,8%),

spesifisitas adalah 87,0% (95% CI: 84,2%–89,4%), dengan negatif palsu 6/874, menghasilkan nilai prediksi negatif sebesar 99,0 % (95% CI: 97,8%–99,6%). Pada penelitian yang dilakukan oleh Sohini [11], dengan mengeksplorasi model klasifikasi multinomial, dan menunjukkan bahwa kesalahan terutama terjadi pada kesalahan klasifikasi penyakit ringan sebagai normal karena ketidakmampuan CNN untuk mendeteksi fitur penyakit yang tidak kentara. Prapemrosesan dengan kontras membatasi pemerataan histogram adaptif dan memastikan verifikasi masing-masing label citra. Proses training pada model GoogLeNet dan AlexNet yang telah dilatih sebelumnya dari ImageNet untuk meningkatkan akurasi pengujian puncak menjadi 74,5%, 68,8%, dan 57,2%.

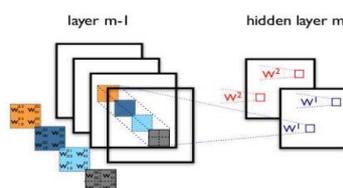
DR juga pernah diteliti menggunakan algoritma lain yaitu Bayesian, Mahalanobis dan KNN seperti pada penelitian Piyush Samanth [12], melakukan pengujian pada 134 citra retina. Pengklasifikasi Mahalanobis memiliki hasil terbaik: mikroaneurisma, perdarahan, eksudat, dan bercak kapas terdeteksi dengan sensitivitas masing-masing 69, 83, 99, dan 80%. Proses perbandingan CNN dengan SVM telah dilakukan oleh Dinial Utami Nurul Qomariah [9]. Penelitian ini mengusulkan metode deep learning untuk mengekstraksi fitur dan klasifikasi menggunakan Support Vector Machine. Fitur tingkat tinggi dari lapisan yang terhubung penuh terakhir berdasarkan pembelajaran transfer dari Convolutional Neural Network (CNN) sebagai fitur input untuk klasifikasi menggunakan Support Vector Machine (SVM). Metode ini mengurangi waktu komputasi yang dibutuhkan oleh proses klasifikasi menggunakan CNN dengan finetuning. Metode yang diusulkan diuji menggunakan 77 dan 70 citra retina dari database Messidor masing-masing basis 12 dan basis 13. Dari hasil percobaan didapatkan nilai akurasi tertinggi masing-masing sebesar 95,83% dan 95,24% untuk base 12 dan base 13.

Deep learning (DL) adalah cabang dari teknik pembelajaran mesin yang melibatkan lapisan hierarkis tahap pemrosesan non-linier untuk pembelajaran fitur yang tidak terawasi serta untuk mengklasifikasikan pola [13]. DL adalah salah satu metode diagnosis medis berbantuan komputer. Aplikasi DL untuk analisis citra medis meliputi klasifikasi, segmentasi, deteksi, pengambilan, dan registrasi citra. Baru-baru ini, DL telah banyak digunakan dalam deteksi dan klasifikasi DR. Ada banyak metode berbasis DL seperti Mesin Boltzmann terbatas, jaringan saraf convolutional (CNNs), auto encoder, dan sparse coding. Performa CNN meningkat ketika jumlah data pelatihan meningkat karena peningkatan fitur yang dipelajari tidak seperti metode pembelajaran mesin [5]. Selain itu, metode DL tidak memerlukan ekstraksi fitur buatan tangan. Berdasarkan keunggulan yang dimiliki oleh CNN, maka dalam penelitian ini digunakan CNN sebagai algoritma klasifikasi citra DR.

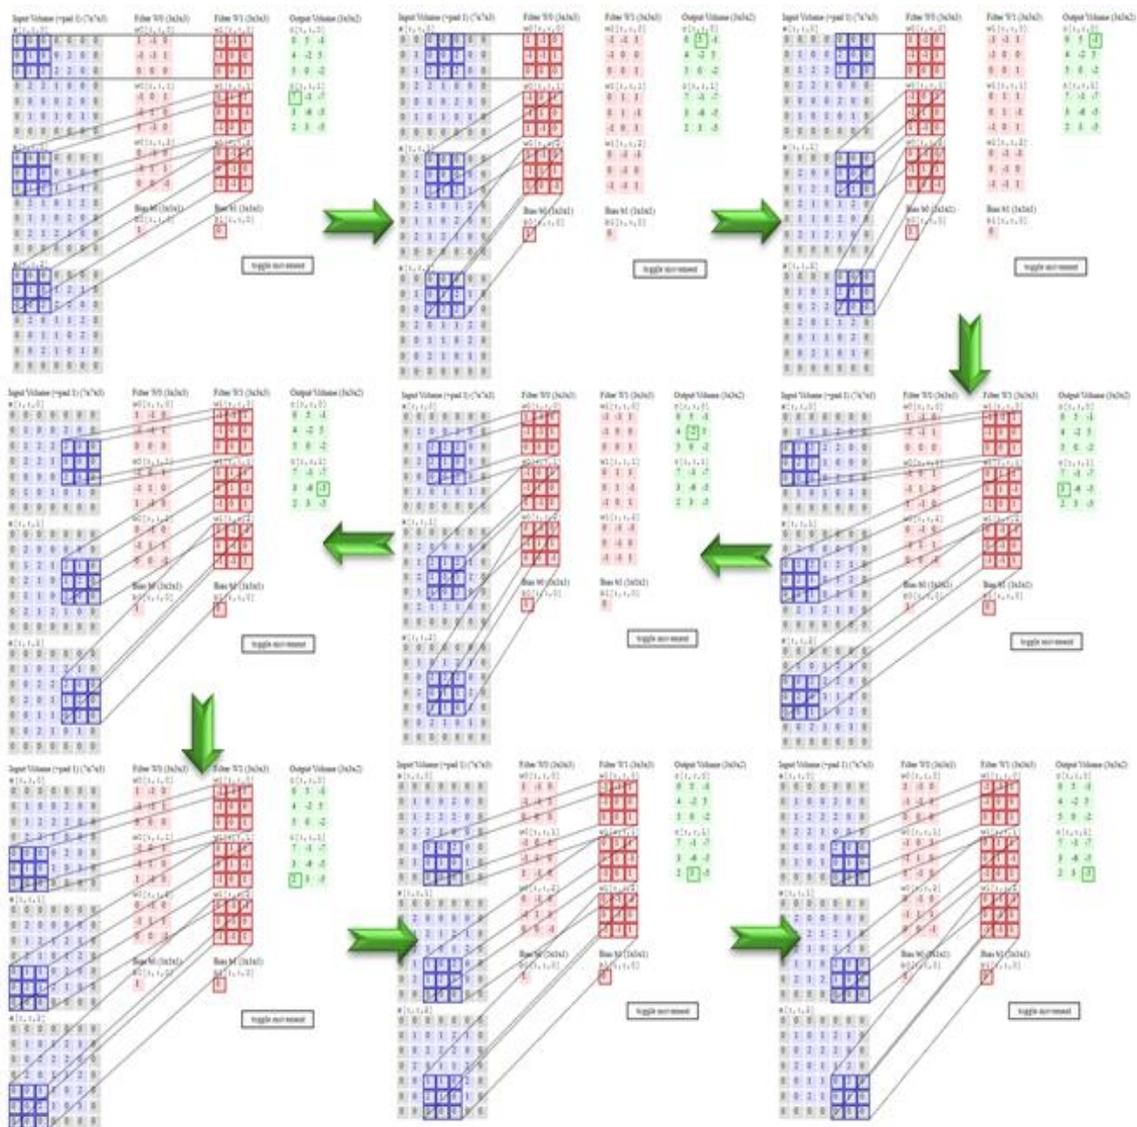
## 2. METODE PENELITIAN

### 2.1. Convolutional Neural Network (CNN)

CNN terdiri dari dua bagian dasar ekstraksi fitur dan klasifikasi. Ekstraksi fitur mencakup beberapa lapisan konvolusi diikuti oleh max-pooling dan fungsi aktivasi. Pengklasifikasi biasanya terdiri dari lapisan yang terhubung penuh. Deep learning adalah proses pelatihan jaringan saraf untuk melakukan tugas yang diberikan [14]–[18]. Algoritme pembelajaran mendalam (CNN) menghitung tingkat keparahan DR dengan menganalisis intensitas piksel pada setiap saluran secara terpisah [2], [6], [8], [19]. Meskipun algoritma tidak mendeteksi lesi pada gambar mata secara eksplisit, algoritma ini belajar mengenalinya menggunakan bobot filter seperti dijelaskan pada Gambar 2.



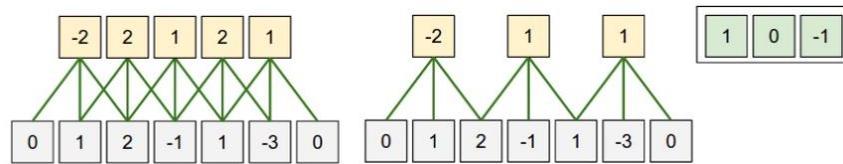
Gambar 2. Konvolusi pada CNN



Gambar 3. Konvolusi Layer dengan Filter RGB

Untuk menilai kekuatan dan keterbatasan CNN, beberapa arsitektur dilatih dan diuji dengan fokus khusus pada model kedalaman 22 lapisan yang disebut GoogLeNet. Jaringan yang sangat efisien ini mencapai akurasi tercanggih menggunakan campuran embedding berdimensi rendah dan filter spasial berukuran heterogen. Peningkatan lapisan konvolusi dan peningkatan pemanfaatan sumber daya komputasi jaringan internal memungkinkan jaringan untuk mempelajari fitur lebih dalam [14], [20]. Misalnya, lapisan pertama mungkin mempelajari tepi sementara lapisan terdalam belajar menafsirkan eksudat keras, fitur klasifikasi DR. Jaringan berisi blok konvolusi dengan aktivasi pada lapisan atas yang mendefinisikan pemetaan fungsional yang kompleks antara input dan variabel respons, diikuti dengan normalisasi batch setelah setiap lapisan konvolusi [8], [21]. Ketika jumlah peta fitur meningkat, satu normalisasi batch per blok diperkenalkan secara berurutan. Proses diskritisasi max pooling berbasis sampel dilakukan dengan ukuran kernel 3x3. Jaringan kemudian diratakan ke satu dimensi setelah blok konvolusi akhir seperti pada Gambar 3 dan Gambar 4. Dropout lapisan jaringan dilakukan hingga mencapai lapisan keluaran lima simpul yang padat, yang menggunakan fungsi aktivasi softmax untuk menghitung probabilitas label klasifikasi [9], [22]. Aktivasi unit linier terkoreksi bocor juga

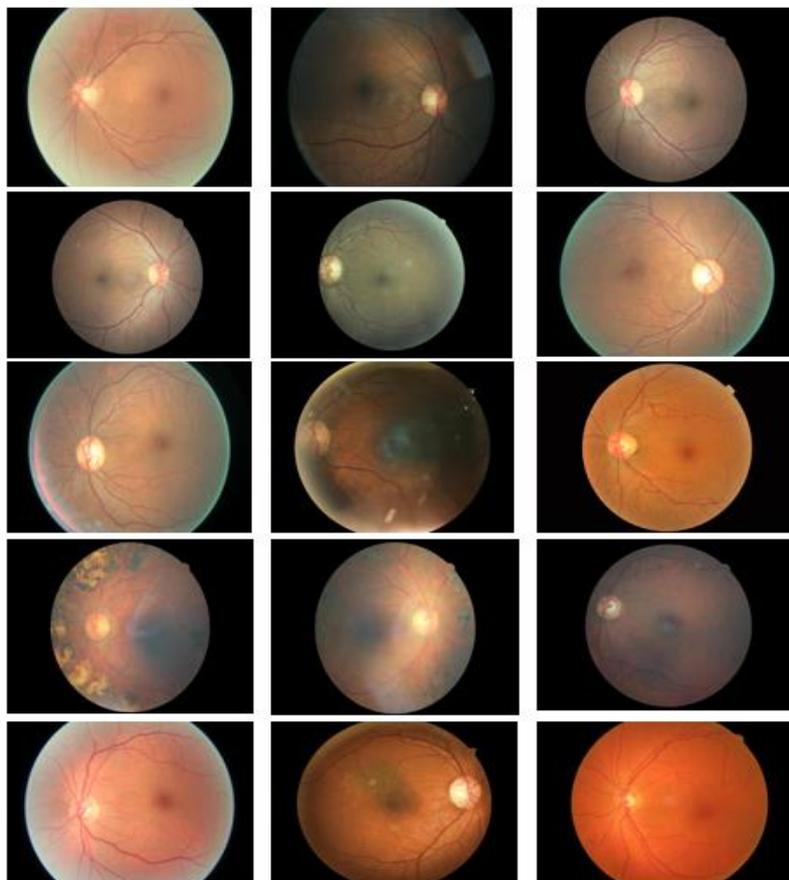
diterapkan dengan nilai gradien 0,01 untuk mengurangi kemacetan neuron mati selama propagasi balik. Jaringan menggunakan regularisasi L2 lapisan convolutional untuk mengurangi model overfitting, kehilangan kesalahan yang dihitung lintas-entropi, dan metode Xavier untuk menginisialisasi bobot.



Gambar 4. Contoh Penataan Ruang Dimensi pada CNN

## 2.2. Dataset Citra Diabetic Retinopathy

Dataset diambil dari Kaggle dan berisi 88.702 citra resolusi tinggi dengan berbagai resolusi, mulai dari 433x289 piksel hingga 5184x3456 piksel seperti pada Gambar 3, dikumpulkan dari kamera yang berbeda. Semua gambar diklasifikasikan ke dalam lima tahap DR. Augmentasi citradibuat untuk meningkatkan ukuran kelas karena jumlah sampel pelatihan yang terbatas untuk beberapa kelas. Kecerahan masing-masing gambar yang dibuat setelah pra-pemrosesan disesuaikan dengan mengubah gambar RGB menjadi representasi mengambang diikuti dengan mengubah menjadi tipe data asli. Ini dilakukan dengan menambahkan nilai delta ke semua komponen citra.



Gambar 5. Sample Dataset Penelitian

Citra diskalakan dengan tepat dan baik gambar maupun delta diubah menjadi mengambang sebelum ditambahkan. Karena penambahan pada gambar dilakukan di representasi floating point,

delta harus dalam kisaran [0,1] sedangkan nilai piksel berada di [0,1]. Gambar asli dan kecerahan yang disesuaikan kemudian diputar 90 dan 180 derajat yang secara inheren meningkatkan ukuran kelas 6 kali. Citra original yang digunakan dalam penelitian ini dapat diilustrasikan sesuai Gambar 5. Sampel citra dataset pada Gambar 5 di bawah ini merupakan bagian dari 88.702 citra yang telah melalui proses pemilihan secara visual (manual). Dari 88.702 citra di pilih 88.000 citra dan dibagi menjadi beberapa model variasi data seperti pada Tabel 1.

Tabel 1. Variasi Data untuk Proses Pengujian CNN

Model	Prosentase Variasi	Training	Testing
Model1	60 : 40	52800	35200
Model2	70 : 30	61600	26400
Model3	80 : 20	70400	17600

### 3. HASIL DAN PEMBAHASAN

Pada penelitian ini, diimplementasikan fully connected layer dengan bantuan Software Matlab. Dalam pembuatan layer digunakan 28x28x1. Coding dapat dilihat pada Gambar 6 dan Gambar 7, sedangkan hasil percobaan dalam klasifikasi citra menggunakan KNN dapat dilihat pada Tabel 2 dan Tabel 3.

```
function cnnAddActLayer(cnn, activation func name)
cnn.no of layers= cnn.no of layers +1;
l=cnn.no of layers;
cnn.layers{l}.type = 'a';
cnn.layers{l}.act func=activation func name;
cnn.layers{l}.no featuremaps = cnn.layers{l-1}.no featuremaps;
layers = [
    imageInputLayer([28 28 1])
    convolution2dLayer(3,8,'Padding','same')
    batchNormalizationLayer
    reluLayer
    averagePooling2dLayer(2,'Stride',2)
    convolution2dLayer(3,16,'Padding','same')
    batchNormalizationLayer
    reluLayer
    averagePooling2dLayer(2,'Stride',2)
    convolution2dLayer(3,32,'Padding','same')
    batchNormalizationLayer
    reluLayer
    convolution2dLayer(3,32,'Padding','same')
    batchNormalizationLayer
    reluLayer
    dropoutLayer(0.2)
    fullyConnectedLayer(1)
    regressionLayer];
```

Gambar 6. Fungsi Pembuatan Layer Dengan Padding

```

for i=2:cnn.no_of_layers
    cnn1.layers{i}.type = cnn.layers{i}.type;
    if cnn.layers{i}.type == 'c'
        kk=0;

        for j=1:cnn.layers{i}.no_featuremaps
            for k=1:cnn.layers{i-1}.no_featuremaps
                kk = kk+1;
                cnn1.layers{i}.K(:, :,kk)= cnn.layers{i}.K(:, :,kk);
            end
            cnn1.layers{i}.b(j)= cnn.layers{i}.b(j);
        end
        cnn1.layers{i}.act_func= cnn.layers{i}.act_func;
        cnn1.layers{i}.no_featuremaps = cnn.layers{i}.no_featuremaps;
        cnn1.layers{i}.kernel_width = cnn.layers{i}.kernel_width;
        cnn1.layers{i}.kernel_height = cnn.layers{i}.kernel_height;
        cnn1.layers{i}.featuremap_width = cnn.layers{i}.featuremap_width;
        cnn1.layers{i}.featuremap_height = cnn.layers{i}.featuremap_height;
    end
end
    
```

Gambar 7. Fungsi Pembuatan Kernel Dan Feature Map

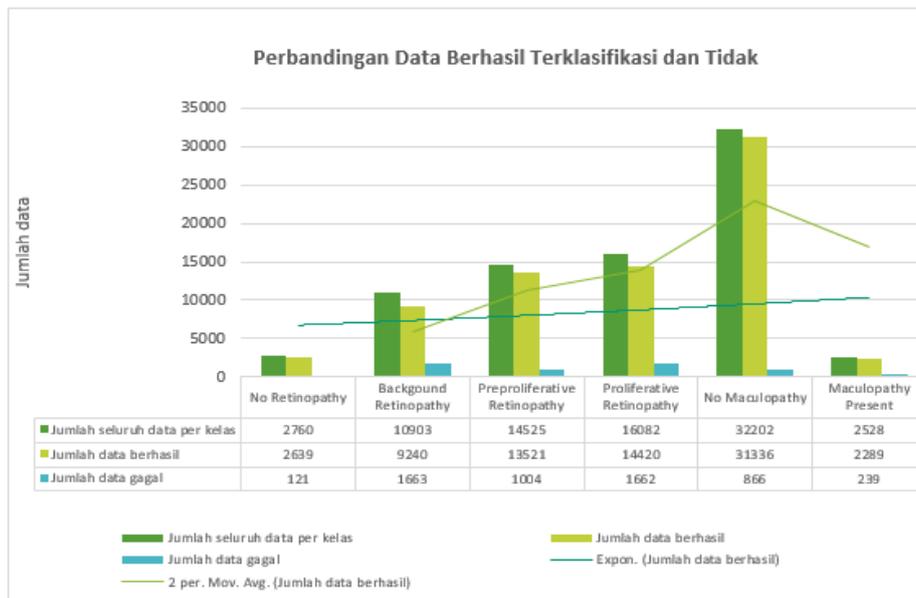
Tabel 2. Akurasi pada Iterasi CNN pada Citra Uji Ukuran 192x192 dengan Kedalaman Citra 3-bit

Layer	Filter	Ukuran filter	Ukuran Hasil
Input			192x192
Konvolusi	32	4x4	96x96
Konvolusi	32	4x4	95x95
Konvolusi	32	4x4	96x96
Max pool		3x3	47x47
Konvolusi	64	4x4	48x48
Konvolusi	64	4x4	47x47
Konvolusi	64	4x4	48x48
Max pool		3x3	21x21
Konvolusi	128	4x4	22x22
Konvolusi	128	4x4	21x21
Konvolusi	128	4x4	22x22
Max pool		3x3	11x11
Konvolusi	256	4x4	12x12
Konvolusi	256	4x4	11x11
Konvolusi	256	4x4	12x12
Max pool		3x3	8x8
Konvolusi	512	4x4	6x6
Konvolusi	512	4x4	5x5
Max pool		3x3	
Dropout			
Fully connected	1024		
Feature pool	512		
Dropout			

Tabel 3. Hasil Klasifikasi dengan CNN

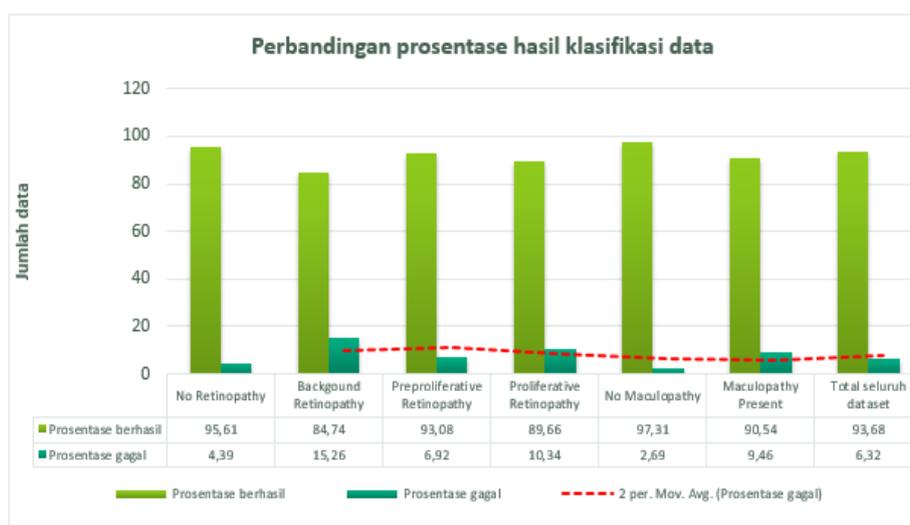
Kelas	Jumlah seluruh data per kelas	Jumlah data berhasil (%)	Prosentase berhasil	Jumlah data gagal	Prosentase gagal (%)
No Retinopathy	2760	2639	95,61	121	4,39

Background Retinopathy	10903	9240	84,74	1663	15,26
Preproliferative Retinopathy	14525	13521	93,08	1004	6,92
Proliferative Retinopathy	16082	14420	89,66	1662	10,34
No Maculopathy	32202	31336	97,31	866	2,69
Maculopathy Present	2528	2289	90,54	239	9,46
Total seluruh dataset	88000	82445	93,68	5555	6,32



Gambar 8. Perbandingan Data Berhasil Terklasifikasi dan Tidak Berhasil

Berdasarkan Gambar 8 dan Gambar 9, dapat di lihat bahwa dari 88000 data yang sudah di uji coba, diketahui bahwa dari 6 jenis DR dalam dataset telah menghasilkan akurasi cukup tinggi dimana pada no maculopathy terdeteksi lebih akurat disbanding dengan jenis DR lain yaitu 97,31% sedangkan yang paling rendah yaitu pada background retinopathy pada 84,74%.



Gambar 9. Perbandingan Prosentase Hasil Klasifikasi Data (%)

#### 4. KESIMPULAN

Pada proses klasifikasi menggunakan CNN, diketahui telah menghasilkan prosentse cukup tinggi pada 93,68% dengan total salah klasifikasi yaitu 6,325. Pada setiap kelas, akurasi cukup tinggi dengan akurasi paling rendah adalah Background Retinopathy yaitu 84,74% dan total data salah klasifikasi yaitu 16,26%. Dalam percobaan yang telah dilakukan, belum dapat menghasilkan akurasi klasifikasi hingga 100%. Penambahan epoch, layer atau fitur ekstraksi mungkin dapat dilakukan untuk menghasilkan akurasi lebih tinggi.

#### DAFTAR PUSTAKA

- [1] W. Zhou, C. Wu, Y. Yi, and W. Du, "Automatic Detection of Exudates in Digital Color Fundus Images Using Superpixel Multi-Feature Classification," *IEEE Access*, vol. 5, no. 1, pp. 17077–17088, 2017.
- [2] M. D. Abràmoff *et al.*, "Improved automated detection of diabetic retinopathy on a publicly available dataset through integration of deep learning," *Investig. Ophthalmol. Vis. Sci.*, vol. 57, no. 13, pp. 5200–5206, 2016.
- [3] W. L. Alyoubi, W. M. Shalash, and M. F. Abulkhair, "Diabetic retinopathy detection through deep learning techniques: A review," *Informatics Med. Unlocked*, vol. 20, p. 100377, 2020.
- [4] M. Iglicki, D. Zur, and A. Loewenstein, "Detection of diabetic retinopathy using deep learning analysis," *Retin. Today*, vol. 2021, September, pp. 42–46, 2021.
- [5] R. Ghosh, K. Ghosh, and S. Maitra, "Automatic detection and classification of diabetic retinopathy stages using CNN," *2017 4th Int. Conf. Signal Process. Integr. Networks, SPIN 2017*, pp. 550–554, 2017.
- [6] B. Tymchenko, P. Marchenko, and D. Spodarets, "Deep learning approach to diabetic retinopathy detection," *ICPRAM 2020 - Proc. 9th Int. Conf. Pattern Recognit. Appl. Methods*, pp. 501–509, 2020.
- [7] S. Aulia, S. Hadiyoso, and D. N. Ramadan, "Analisis Perbandingan KNN dengan SVM untuk Klasifikasi Penyakit Diabetes Retinopati berdasarkan Citra Eksudat dan Mikroaneurisma," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 3, no. 1, p. 75, 2015.
- [8] K. Xu, D. Feng, and H. Mi, "Deep convolutional neural network-based early automated detection of diabetic retinopathy using fundus image," *Molecules*, vol. 22, no. 12, 2017.
- [9] D. U. N. Qomariah, H. Tjandrasa, and C. Fatichah, "Classification of diabetic retinopathy and normal retinal images using CNN and SVM," *Proc. 2019 Int. Conf. Inf. Commun. Technol. Syst. ICTS 2019*, pp. 152–157, 2019.
- [10] M. Raju, V. Pagidimarri, R. Barreto, A. Kadam, V. Kasivajjala, and A. Aswath, "Development of a deep learning algorithm for automatic diagnosis of diabetic retinopathy," *Stud. Health Technol. Inform.*, vol. 245, pp. 559–563, 2017.
- [11] S. Roychowdhury, D. D. Koozekanani, and K. K. Parhi, "DREAM: Diabetic Retinopathy Analysis Using Machine Learning," *IEEE J. Biomed. Heal. Informatics*, vol. 18, no. 5, pp. 1717–1728, 2014.
- [12] P. Samant and R. Agarwal, "Machine learning techniques for medical diagnosis of diabetes using iris images," *Comput. Methods Programs Biomed.*, vol. 157, pp. 121–128, Apr. 2018.
- [13] A. Mahmood, M. Bennamoun, S. An, F. Sohel, and F. Boussaid, "ResFeats: Residual network based features for underwater image classification," *Image Vis. Comput.*, vol. 93, Jan. 2020.
- [14] D. M. Mahalakshmi and S. Sumathi, "Brain Tumour Segmentation Strategies Utilizing Mean Shift Clustering and Content Based Active Contour Segmentation," *ICTACT J. Image Video Process.*, vol. 9, no. 4, pp. 2002–2008, 2019.
- [15] N. Ani Brown Mary and D. Dharma, "Coral reef image classification employing Improved LDP for feature extraction," *Journal of Visual Communication and Image Representation*,

- vol. 49. Academic Press Inc., pp. 225–242, 01-Nov-2017.
- [16] M. J. Schaap, N. J. Cardozo, A. Patel, E. M. G. J. de Jong, B. van Ginneken, and M. M. B. Seyger, “Image-based automated Psoriasis Area Severity Index scoring by Convolutional Neural Networks,” *J. Eur. Acad. Dermatology Venereol.*, vol. 36, no. 1, pp. 68–75, Jan. 2022.
- [17] J. Amin, M. Sharif, N. Gul, M. Yasmin, and S. A. Shad, “Brain tumor classification based on DWT fusion of MRI sequences using convolutional neural network,” *Pattern Recognit. Lett.*, vol. 129, pp. 115–122, Jan. 2020.
- [18] H. Shah, R. Rajasekaran, and J. Masih, “A Comparative Study of Classification Algorithms with Varying Training Dataset Sizes on Cursive Hiragana Characters,” *J. Xi’an Univ. Archit. Technol.*, vol. XII, no. Viii, pp. 1388–1396.
- [19] S. Mishra, R. Sachan, and D. Rajpal, “Deep Convolutional Neural Network based Detection System for Real-time Corn Plant Disease Recognition,” *Procedia Comput. Sci.*, vol. 167, pp. 2003–2010, 2020.
- [20] I. Gogul and V. S. Kumar, “Flower species recognition system using convolution neural networks and transfer learning,” *2017 4th Int. Conf. Signal Process. Commun. Networking, ICSCN 2017*, pp. 1–6, 2017.
- [21] H. Riaz, et al, “Deep and densely connected networks for classification of diabetic retinopathy,” *Diagnostics*, vol. 10, no. 1, pp. 1-15, 2020.
- [22] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” *Commun. ACM*, vol. 60, no. 6, pp. 84–90, 2017.