

Klasifikasi *Diabetic Retinopathy* Menggunakan CNN dengan Arsitektur yang Dimodifikasi

Kevyn Alifian Hernanda Wibowo, Alamsyah*

Program Studi Teknik Informatika, FMIPA, Universitas Negeri Semarang, Indonesia
Gedung D5 Lt.2, Kampus Sekaran Gunungpati, Semarang 50229
E-mail: alamsyah@mail.unnes.ac.id

Diterima 3 Februari 2023 Disetujui 6 Maret 2023 Dipublikasikan 20 April 2023

Abstrak

Diabetic Retinopathy (DR), juga dikenal sebagai penyakit mata diabetes, terjadi karena kerusakan pada retina akibat diabetes melitus yang berkepanjangan. DR dapat diklasifikasikan melalui gambar fundus retina. Namun, klasifikasi retinopati diabetik membutuhkan waktu yang tidak sedikit dan belum ada model yang memiliki performa tinggi dalam mengklasifikasikan DR. Tujuan dari penelitian ini mengusulkan model yang diharapkan memiliki tingkat akurasi yang lebih tinggi daripada penelitian sebelumnya. Metode yang digunakan adalah *Convolutional Neural Network* (CNN). Hasil evaluasi menunjukkan klasifikasi DR menggunakan CNN berarsitektur VGG-16 Net menghasilkan akurasi 96,24% sedangkan klasifikasi DR menggunakan CNN berarsitektur yang dimodifikasi menghasilkan akurasi 96,45%. Pada penelitian ini, akurasi model klasifikasi dapat ditingkatkan dengan menggunakan metode CNN berarsitektur termodifikasi.

Kata kunci: diabetik, *diabetic retinopathy*, *convolutional neural network*, *modified architecture*, VGG-16 Net.

Abstract

Diabetic Retinopathy (DR), also known as *diabetic eye disease*, occurs due to damage to the retina caused by prolonged diabetes mellitus. DR can be classified through retinal fundus images. However, the classification of diabetic retinopathy takes a lot of time and there is no model that has high performance in classifying DR. The purpose of this study is to propose a model that is expected to have a higher accuracy rate than previous studies. The method used is *Convolutional Neural Network* (CNN). The evaluation results show that DR classification using CNN with VGG-16 Net architecture produces 96.24% accuracy while DR classification using CNN with modified architecture produces 96.45% accuracy. In this study, the accuracy of the classification model can be improved by using the modified architecture CNN method.

Keywords: *diabetic*, *diabetic retinopathy*, *convolutional neural network*, *modified architecture*, VGG-16 Net

How to cite:

Wibowo K. A. H., Alamsyah. (2023). Klasifikasi diabetic retinopathy menggunakan CNN dengan arsitektur yang dimodifikasi. *Indonesian Journal of Mathematics and Natural Sciences*, 46(1), 45-52.

PENDAHULUAN

Menurut World Health Organization (WHO) diabetes diperkirakan menempati urutan ketujuh yang termasuk penyakit fatal (Shankar *et al.*, 2020). Pada tahun 2019, International Diabetes Federation (IDF) menyatakan bahwa sekitar 463 juta orang yang berusia antara 20 hingga 79 tahun telah terkena diabetes. Sejak tahun 2000, WHO telah memperkirakan bahwa peningkatan 5% pada kematian dini disebabkan oleh diabetes (Nahiduzzaman *et al.*, 2021). Diabetes adalah penyakit yang disebabkan oleh tingginya kadar glukosa dalam darah. Jika penyakit ini berlangsung dalam jangka waktu yang lama, maka akan menyebabkan beberapa penyakit yang berkelanjutan seperti gagal ginjal, kehilangan penglihatan, gusi berdarah, kejang pada tungkai bawah, luka pada kaki, dan kerusakan saraf (Shanthi & Sabeenian, 2019). Pada pasien diabetes, pankreas tidak dapat memproduksi insulin

yang dibutuhkan tubuh. Hormon insulin menstimulasi penyerapan dan memproses glukosa menjadi energi. Glukosa yang tidak terserap ini dapat menyebabkan berbagai gangguan pada organ tubuh. Berbagai komplikasi timbul akibat diabetes, salah satunya adalah *diabetic retinopathy* (DR) atau dikenal dengan penyakit mata diabetes, yaitu kerusakan pada retina yang menyebabkan kebutaan. DR banyak terjadi di kalangan lansia dan menjadi masalah medis global selama beberapa dekade terakhir (Menaouer *et al.*, 2022). Diagnosis retinopati diabetik dilakukan dengan cara pemeriksaan fundus mata yang biasa dilakukan oleh dokter spesialis mata, namun proses ini rumit dan membutuhkan waktu yang tidak sedikit.

Berdasarkan data penelitian yang dilakukan di beberapa daerah di Indonesia, perkiraan prevalensi DR adalah 42,6%. Setidaknya akan ada 24.600 orang yang menderita DR dan sekitar 10% diantaranya akan mengalami kebutaan. Jumlah ini diperkirakan akan meningkat pada tahun 2030 dengan perkiraan 98.400 orang menderita diabetes dan sekitar 11.000 diantaranya akan mengalami kebutaan. Sebagian besar kebutaan akibat DR merupakan kondisi yang bersifat permanen dan tidak dapat diobati. Deteksi dini DR sangat penting untuk prognosis klinis dalam rangka memberikan pengobatan dan mengurangi perkembangan penyakit. DR dikategorikan ke dalam empat klasifikasi, yaitu non-retinopati, ringan, sedang, berat, dan proliferatif yang memiliki karakteristik masing-masing pada setiap tingkatannya (Bhardwaj *et al.*, 2021). Karakteristik utama dari setiap kelas DR yaitu *microaneurysms* (MA), *hemorrhages* (HM), *exudates* (EX), *venous loops* (VL), *venous reduplication* (VR), dan *neovascularization* (NV) (Abdelmaksoud *et al.*, 2021).

Tahap awal DR disebut *non-proliferative diabetic retinopathy* (NPDR), selanjutnya terdapat tahap ringan, tahap sedang, tahap parah, dan tahap *proliferative diabetic retinopathy* (PDR). *Bi-annual* atau *annual screening* pada retina direkomendasikan untuk pasien diabetes (Jena *et al.*, 2023). Tahap ringan ditandai dengan munculnya satu MA yang merupakan titik merah melingkar kecil di ujung pembuluh darah. Pada stadium sedang, MA akan meluas ke lapisan yang lebih dalam dan membentuk perdarahan berbentuk api di retina. Stadium berat mengandung lebih dari 20% perdarahan intraretina pada masing-masing kuadran, berupa perdarahan vena dengan kelainan mikrovaskular intraretina yang menonjol. PDR adalah stadium lanjut DR yang ditandai dengan munculnya NV, yaitu pembentukan sel pembuluh darah baru secara alamiah dalam bentuk jaringan mikrovaskuler fungsional di permukaan bagian dalam retina (Qummar *et al.*, 2019) sebagaimana yang disajikan pada Tabel 1.

Tabel 1. Klasifikasi tingkat DR (Sambyal *et al.*, 2023)

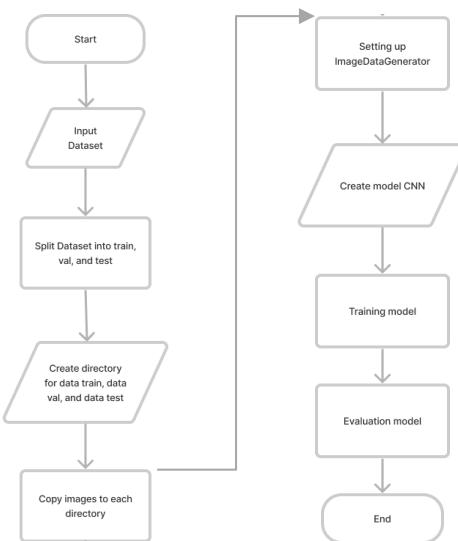
No	Tingkat	Temuan pada retina
1	Normal	Retina yang sehat
2	Ringan	Timbulnya Mikro-Aneurisma (MA)
3	Sedang	Semakin banyak Mikro-Aneurisma (MA) yang timbul
4	Berat	Terjadi pendarahan vena intraretina
5	Proliferative	Timbulnya neovaskularisasi

Algoritma klasifikasi dapat digunakan untuk membantu para ahli medis dalam mendiagnosis suatu penyakit (Alamsyah & Fadila, 2021; Prihanditya & Alamsyah, 2020; Handarko & Alamsyah, 2015). Algoritma ini merupakan bagian dari kecerdasan buatan. Kecerdasan buatan atau yang biasa disebut *artificial intelligence* (AI) adalah teknologi komputer yang dirancang untuk meniru kecerdasan manusia dan berfikir secara rasional dalam belajar dan memecahkan masalah. *Machine learning* (ML) dan *deep learning* (DL) adalah bidang AI (Prasetyo *et al.*, 2020) yang semakin banyak digunakan untuk menganalisis maupun mengklasifikasikan data medis (Guo *et al.*, 2023). Dengan kemajuan teknologi komputasi, DL menjadi semakin penting dalam bidang pengenalan pola. Salah satunya adalah *convolutional neural network* (CNN) yang menunjukkan kemampuan luar biasa dalam banyak tugas, seperti pengenalan tindakan, klasifikasi citra, segmentasi semantik, dan pelabelan adegan. Berbeda dengan metode *machine learning* lainnya, CNN digerakkan oleh data dan secara otomatis dapat mengekstrak fitur yang dibutuhkan. Selain itu, CNN biasanya berisi banyak lapisan konvolusi dan lapisan aktivasi (Hua *et al.*, 2022). Perkembangan CNN memberikan banyak dampak pada penelitian sistem pencitraan biomedik khususnya untuk analisis dan interpretasi citra (Mansour, 2018).

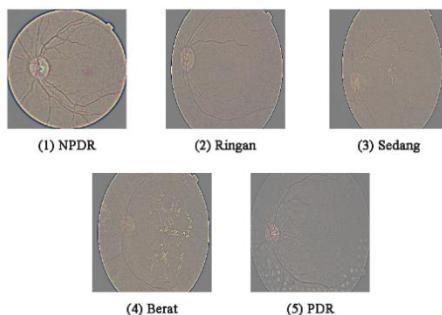
Tes medis untuk menguji tingkat DR membutuhkan banyak waktu dan biaya. Oleh karena itu, keunggulan metode CNN yang dimodifikasi dimungkinkan dapat mengklasifikasi tingkat *diabetic retinopathy* (DR) berdasarkan karakteristiknya masing-masing.

METODE

Flowchart untuk model CNN yang diusulkan untuk klasifikasi DR dapat dilihat pada Gambar 1. Dataset yang digunakan dalam penelitian ini adalah *Diabetic Retinopathy 224x224 Gaussian Filtered* yang diperoleh dari Kaggle (Gambar 3). Dataset ini berisi 3664 gambar fundus retina dengan lima kelas dari DR dan file csv yang terdiri dari kolom id code dan diagnosis berskala 0 hingga 4 yang membantu dalam proses klasifikasi DR.



Gambar 1. Diagram alir model yang diusulkan



Gambar 2. *Diabetic Retinopathy 224x224 Gaussian Filtered*

Dataset ini masih belum dibagi menjadi data pelatihan, data validasi, dan data uji, sehingga diperlukan sebuah proses untuk membagi dataset tersebut sesuai dengan tingkat DR. Rasio perbandingan yang digunakan yaitu 80:20 yang dimana 20% untuk data uji maupun data validasi dan 80% untuk data pelatihan yang nantinya akan digunakan untuk melatih dan menguji model. Setelah dibagi menjadi data pelatihan, data validasi, dan data uji. Sebuah direktori diperlukan untuk menyimpan dataset yang telah dibagi berdasarkan tingkat DR. Direktori ini nantinya yang akan digunakan sebagai ruang kerja model tersebut. Dataset dan direktori siap digunakan. Selanjutnya, salin dataset yang telah diproses ke dalam direktori yang akan digunakan sebagai ruang kerja model.

Digunakan kelas *Keras ImageDataGenerator* untuk pra-pemrosesan gambar sehingga meningkatkan jumlah gambar sinar-X (Umer *et al.*, 2022). Pada tahap ini dilakukan *rescale* gambar sehingga menghasilkan nilai piksel yang ternormalisasi dalam rentang 0 hingga 1. Normalisasi ini dapat membantu dalam proses pelatihan model karena membuat seluruh gambar input akan memiliki skala

yang sama dan menghindari perbedaan yang signifikan pada piksel gambar. Kemudian membuat CNN model yang disesuaikan agar memiliki akurasi yang tinggi dalam klasifikasi DR.

Model CNN

Arsitektur model CNN modifikasi yang diusulkan terdiri dari lima jenis lapisan yaitu *Conv2d layer*, *Max_pooling2d layer*, *Batch_normalization layer*, *Dropout layer*, *Flatten layer* dan *Dense layer*. *Conv2d layer* yang digunakan terdiri dari 8, 16, 32, 64 filter dengan masing-masing menggunakan kernel 2x2 dan 128 filter menggunakan kernel 3x3 serta seluruh *Conv2d layer* menggunakan *Rectified Linear Unit Activation* (ReLU). ReLU memiliki ekspresi yaitu $f(x) = \max(0, x)$ sehingga ketika data lebih besar dari nol, fungsi ReLU digunakan untuk menghitung kemampuan yang jarang (Lin & Shen, 2018). *Max_pooling2d layer* dalam model CNN ini menggunakan kernel berukuran 2x2. *Batch_normalization layer* selalu digunakan setelah *MaxPooling2d layer*. *Flatten layer* adalah jenis lapisan dalam arsitektur model *deep learning* yang digunakan untuk meratakan *input* multi-dimensi menjadi larik satu dimensi. *Dense layer* didefinisikan dengan 128 unit dan fungsi aktivasi ReLU. ReLU merupakan fungsi aktivasi yang umumnya digunakan pada lapisan jaringan syaraf karena sederhana dan memungkinkan model untuk belajar dengan cepat. *Dropout layer* didefinisikan dengan tingkat *dropout* sebesar 0.2, yang berarti bahwa 20% dari unit-unit pada lapisan sebelumnya akan diabaikan secara acak selama proses pelatihan. Hal ini membantu mengurangi ketergantungan antara unit-unit di lapisan sebelumnya dan mencegah *overfitting* pada model. *Dense layer* adalah lapisan yang terhubung penuh dengan 2 neuron keluaran. *Dense layer* ini menggunakan parameter *softmax* yang digunakan pada lapisan *output* untuk menjaga nilai *output* tetap berada pada rentang 0 hingga 1 dan menghasilkan probabilitas pada setiap neuron output yang selalu sama dengan 1.

Model Training

Untuk melatih model CNN yang telah dibuat sebelumnya, *optimizer adam* dengan *learning rate* 0,00001 dengan memerlukan 30 iterasi *epoch*. Beragam *optimizer* yang dapat digunakan untuk melatih model ini seperti *SGD*, *Adagrad*, *Adam*, *Nadam*, *Adabound*, dan *RMSProp* namun *optimizer-optimizer* tersebut digunakan sesuai kebutuhannya (Menaka & Vaidyanathan, 2022). *Optimizer adam* memiliki kecepatan *learning rate* hingga 1×10^{-10} , sehingga mampu mengadaptasi setiap parameter dengan lima kali lebih banyak daripada *RMSProp* yang juga merupakan salah satu *optimizer* (Byerly & Kalganova, 2021).

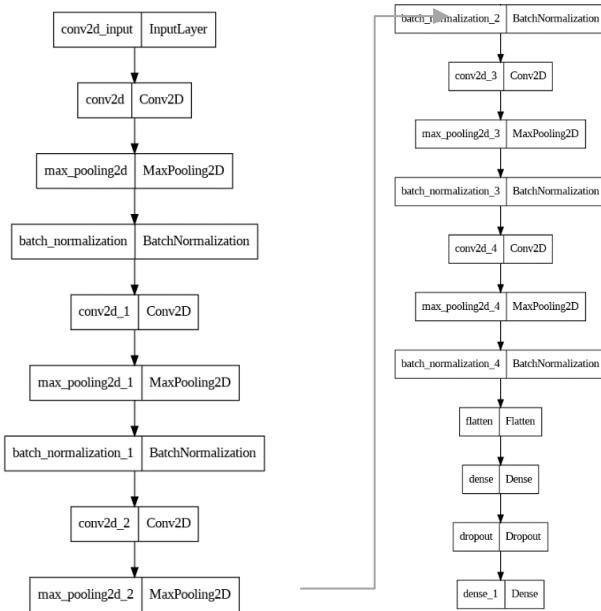
Model Evaluasi

Pada tahap ini, untuk menentukan akurasi dan *loss*-nya digunakan data pengujian dengan mengatur tingkat kecerahan *output* yang dihasilkan menggunakan *verbose* = 1. Persamaan 1 (Muslim *et al.*, 2023), merupakan rumus yang digunakan untuk menentukan akurasi pada data pengujian.

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

TP didefinisikan sebagai jumlah positif sejati (*True Positive*) dan FP didefinisikan sebagai jumlah positif masing-masing (*False Positive*) sedangkan TN didefinisikan sebagai jumlah negatif sejati (*True Negative*) dan FN merupakan negatif palsu (*False Negative*) (Bodapati, 2022). Model yang diusulkan menggunakan arsitektur CNN yang dimodifikasi untuk mendekripsi dan mengklasifikasikan tingkat DR. Detail lapisan-lapisan yang digunakan pada arsitektur CNN yang dimodifikasi dapat dilihat pada Gambar 4.

Conv2d adalah salah satu jenis layer dalam CNN yang sering digunakan untuk memproses data gambar. *Input* untuk lapisan *Conv2d* harus berupa *tensor* 4 dimensi dengan format (*batch_size*, *height*, *width*, *channel*). Lapisan *conv2d* mentransformasi gambar *input* menggunakan kernel untuk mengekstrak informasi dari gambar tersebut. *Max pooling 2D* adalah jenis operasi reduksi spasial yang sering digunakan dalam CNN untuk mengurangi dimensi fitur yang dihasilkan oleh *Convolution layer*. *Max_pooling2d layer* juga menghitung nilai maksimum untuk setiap tampilan data di peta fitur (Garg *et al.*, 2022). *Max_pooling2d* bekerja dengan melakukan pengambilan sampel-sampel yang diberikan dan membagi inputan tersebut menjadi *patch* kecil dan menghitung nilai maksimum dari setiap *patch* tersebut (Gao *et al.*, 2019). *Max_pooling2d* sering digunakan setelah lapisan konvolusi sebagai tahap reduksi dimensi untuk mengurangi jumlah parameter dan menghindari *overfitting*.



Gambar 4. Lapisan-lapisan arsitektur dari CNN yang dimodifikasi

Lapisan *Batch_normalization* pada awalnya dirancang untuk mengurangi masalah pergeseran kovariat internal, masalah yang umum terjadi saat melatih *Deep Learning*. Lapisan ini pertama-tama menstandarkan setiap fitur dalam *batch mini*, dan kemudian mempelajari kemiringan dan bias yang umum untuk setiap *batch mini* (Li *et al.*, 2018). *Batch_normalization* adalah teknik normalisasi data yang sering digunakan dalam CNN untuk meningkatkan kecepatan dan akurasi konvergensi model, serta memperkuat kemampuan generalisasi model. Teknik *batch_normalization* melibatkan normalisasi setiap *batch data* yang dimasukkan ke dalam model dengan memperhitungkan mean dan standar deviasi dari *batch tersebut*.

Dropout merupakan teknik untuk mengeluarkan unit-unit dalam jaringan syaraf (Gayathri *et al.*, 2021). *Dropout layer* secara acak mengabaikan neuron yang dipilih selama pelatihan untuk mencegah *overfitting* (Garg *et al.*, 2022). *Dropout layer* bekerja ketika model mulai dilatih maka lapisan ini akan menetapkan unit input ke 0 dengan frekuensi yang bergantung pada kecepatan yang ditentukan agar tidak terjadi *overfitting* (Khanna *et al.*, 2023). Peran *flatten layer* untuk meratakan beberapa data 2D atau 3D. Keluarannya adalah lapisan perataan berupa vektor satu dimensi (Li *et al.*, 2019). *Flatten layer* berfungsi mengubah data 2D menjadi vektor 1D yang diumpulkan sebagai *input* ke *dense layer* (Vij & Arora, 2023).

Dense layer terhubung ke semua neuron dari lapisan sebelumnya dan melakukan perkalian matriks untuk menghasilkan *output* (Garg *et al.*, 2022). *Dense layer* (atau yang biasa dikenal dengan *FC layer*) adalah fitur yang digunakan untuk mengkarakterisasi gambar, dan umumnya menggunakan aktivasi *softmax* dalam melakukan hal tersebut (Khanna *et al.*, 2023).

HASIL DAN PEMBAHASAN

Model yang diusulkan dapat dieksekusi di *Google Collaboratory*. Sistem dikonfigurasi dengan Intel(R) Core i7-11800H @ 2.30GHz, RAM 16 GB, GPU Laptop Nvidia GeForce RTX 3050 TI.

Evaluasi kinerja dengan arsitektur yang dimodifikasi

Untuk melatih dan menguji model yang diusulkan, data pelatihan dan data pengujian digunakan sebagai input yang masing-masing berjumlah 2.196 gambar fundus retina untuk data pelatihan dan data pengujian sebanyak 733 gambar fundus retina. Tabel 2 menunjukkan perbedaan kinerja antara menggunakan arsitektur jaringan VGG-16 yang sudah ada dengan arsitektur yang telah dimodifikasi.

Tabel 2. Analisis komparatif arsitektur VGG-16 net dan arsitektur yang dimodifikasi (Saranya *et al.*, 2022)

Parameter	Arsitektur yang dimodifikasi	VGG-16 Net
Training Accuracy	0,9986	0,9982
Validation Accuracy	0,9645	0,9624
Training Loss	0,0019	0,0186
Validation Loss	0,2426	0,3846
Computational time (s)	2.640,0	1.601,74

Perbandingan model arsitektur VGG-16 net dan model arsitektur yang dimodifikasi

Pada bagian ini ditunjukkan perbedaan penggunaan model CNN dengan arsitektur modifikasi dan VGG-16 net dengan berbagai parameter yang dimana arsitektur modifikasi dilatih dengan 30 iterasi epoch namun pada arsitektur VGG-16 net dilatih dengan 25 iterasi epoch. Model deep learning untuk klasifikasi DR dengan menggunakan VGG-16 net memiliki akurasi pada data pelatihan sebesar 0,9982 dengan tingkat kegagalan pada data pelatihan sebesar 0,0186. Sedangkan untuk akurasi pada data pelatihan sebesar 0,9624 dan tingkat kegagalan pada data pelatihan sebesar 0,3846. Model deep learning untuk klasifikasi DR dengan menggunakan arsitektur yang telah dimodifikasi memiliki akurasi pada data pelatihan sebesar 0,9986 dengan tingkat kegagalan pada data pelatihan sebesar 0,0019. Sedangkan untuk akurasi pada data pengujian sebesar 0,9645 dan tingkat kegagalan pada data pengujian sebesar 0,2426. Waktu komputasi yang dibutuhkan oleh arsitektur yang dimodifikasi hampir 2 kali lipat lebih besar yaitu 2.938 s (48.6 menit), untuk VGG-16 net yaitu 1.601,74 s (26.6 menit).

SIMPULAN

Penggunaan CNN berarsitektur dimodifikasi untuk klasifikasi DR menggunakan gambar fundus retina yang didapat dari *diabetic retinopathy* 224x224 *Gaussian Filter* dapat meningkatkan akurasi pada data pelatihan maupun data pengujian, serta mampu menurunkan tingkat kegagalan pada data pelatihan maupun data pengujian dibandingkan menggunakan arsitektur VGG-16 net. Penggunaan CNN berarsitektur dimodifikasi memiliki kekurangan karena membutuhkan waktu komputasi yang lebih lama dibandingkan arsitektur VGG-16 net. Namun penggunaan CNN berarsitektur dimodifikasi dapat menjadi solusi untuk membantu klasifikasi DR.

DAFTAR PUSTAKA

- Abdelmaksoud, E., El-Sappagh, S., Barakat, S., Abuhmed, T., & Elmogy, M. (2021). Automatic diabetic retinopathy grading system based on detecting multiple retinal lesions. *IEEE Access*, 9, 15939-15960. <https://doi.org/10.1109/ACCESS.2021.3052870>
- Alamsyah, & Fadila, T. (2021). Increased accuracy of prediction hepatitis disease using the application of principal component analysis on a support vector machine. *Journal of Physics: Conference Series*. 1968 012016. <https://doi.org/10.1088/1742-6596/1968/1/012016>
- Bhardwaj, C., Jain, S., & Sood, M. (2021). Deep learning-based diabetic retinopathy severity grading system employing quadrant ensemble model. *Journal of Digital Imaging*, 34(2), 440-457. <https://doi.org/10.1007/s10278-021-00418-5>
- Bodapati, J. D. (2022). Stacked convolutional auto-encoder representations with spatial attention for efficient diabetic retinopathy diagnosis. *Multimedia Tools and Applications*, 81(22), 32033-32056. <https://doi.org/10.1007/s11042-022-12811-5>
- Byerly, A., & Kalganova, T. (2021). Homogeneous vector capsules enable adaptive gradient descent in convolutional neural networks. *IEEE Access*, 9, 48519-48530. <https://doi.org/10.1109/ACCESS.2021.3066842>
- Gao, Z., Li, J., Guo, J., Chen, Y., Yi, Z., & Zhong, J. (2019). Diagnosis of diabetic retinopathy using deep neural networks. *IEEE Access*, 7, 3360-3370. <https://doi.org/10.1109/ACCESS.2018.2888639>
- Garg, S., Saxena, A., & Gupta, R. (2022). Yoga pose classification: a CNN and MediaPipe inspired deep learning approach for real-world application. *Journal of Ambient Intelligence and Humanized Computing*. <https://doi.org/10.1007/s12652-022-03910-0>
- Gayathri, S., Gopi, V. P., & Palanisamy, P. (2021). Diabetic retinopathy classification based on multipath CNN and machine learning classifiers. *Physical and Engineering Sciences in Medicine*, 44(3), 639-653. <https://doi.org/10.1007/s13246-021-01012-3>

- Guo, J., Cao, W., Nie, B., & Qin, Q. (2023). Unsupervised learning composite network to reduce training cost of deep learning model for colorectal cancer diagnosis. *IEEE Journal of Translational Engineering in Health and Medicine*, 11, 54-59. <https://doi.org/10.1109/JTEHM2022.3224021>
- Handarko, J. L., & Alamsyah, A. (2015). Implementasi fuzzy decision tree untuk mendiagnosa penyakit hepatitis. *UNNES Journal of Mathematics*. 4(2), 157-164
- Hua, W., Zhang, C., Xie, W., & Jin, X. (2022). Polarimetric SAR image classification based on ensemble dual-branch CNN and superpixel algorithm. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 2759-2772. <https://doi.org/10.1109/JSTARS2022.3162953>
- Jena, M., Mishra, D., Mishra, S. P., & Mallick, P. K. (2023). A tailored complex medical decision analysis model for diabetic retinopathy classification based on optimized un-supervised feature learning approach. *Arabian Journal for Science and Engineering*, 48(2), 2087-2099. <https://doi.org/10.1007/s13369-022-07057-0>
- Khanna, M., Singh, L. K., Thawkar, S., & Goyal, M. (2023). Deep learning-based computer-aided automatic prediction and grading system for diabetic retinopathy. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-023-14970-5>
- Li, J., Li, X., & He, D. (2019). A directed acyclic graph network combined with cnn and lstm for remaining useful life prediction. *IEEE Access*, 7, 75464-75475. <https://doi.org/10.1109/ACCESS.2019.2919566>
- Li, Y., Wang, N., Shi, J., Hou, X., & Liu, J. (2018). Adaptive batch normalization for practical domain adaptation. *Pattern Recognition*, 80, 109-117. <https://doi.org/10.1016/j.patcog.2018.03.005>
- Lin, G., & Shen, W. (2018). Research on convolutional neural network based on improved Relu piecewise activation function. *Procedia Computer Science*, 131, 977-984. <https://doi.org/10.1016/j.procs.2018.04.239>
- Mansour, R. F. (2018). Deep-learning-based automatic computer-aided diagnosis system for diabetic retinopathy. *Biomedical Engineering Letters*, 8(1), 41-57. <https://doi.org/10.1007/s13534-017-0047-y>
- Menaka, D., & Vaidyanathan, S. G. (2022). Chromenet: a CNN architecture with comparison of optimizers for classification of human chromosome images. *Multidimensional Systems and Signal Processing*, 33(3), 747-768. <https://doi.org/10.1007/s11045-022-00819-x>
- Menaouer, B., Dermane, Z., El Houda Kebir, N., & Matta, N. (2022). Diabetic retinopathy classification using hybrid deep learning approach. *SN Computer Science*, 3(5). <https://doi.org/10.1007/s42979-022-01240-8>
- Muslim, M. A., Nikmah, T. L., Pertiwi, D. A. A., Subhan, Jumanto, Dasril, Y., & Iswanto. (2023). New model combination meta-learner to improve accuracy prediction P2P lending with stacking ensemble learning. *Intelligent Systems with Applications*, 18. <https://doi.org/10.1016/j.iswa.2023.200204>
- Nahiduzzaman, M., Islam, M. R., Islam, S. M. R., Goni, M. O. F., Anower, M. S., & Kwak, K. S. (2021). Hybrid CNN-SVD based prominent feature extraction and selection for grading diabetic retinopathy using extreme learning machine algorithm. *IEEE Access*, 9, 152261-152274. <https://doi.org/10.1109/ACCESS.2021.3125791>
- Prasetyo, B., Alamsyah, Muslim, M. A., Subhan, & Baroroh, N. (2020). Artificial neural network model for banckruptcy prediction. *Journal of Physics: Conference Series*. 1567 032022. <https://doi.org/10.1088/1742-6596/1567/3/032022>
- Prihanditya, H. A., & Alamsyah. (2020). The implementation of z-score normalization and boosting techniques to increase accuracy of C4.5 algorithm in diagnosing chronic kidney disease. *Journal of Soft Computing Exploration*, 1(1), 63-69. <https://doi.org/10.52465/josce.v1i1.8>
- Qummar, S., Khan, F. G., Shah, S., Khan, A., Shamshirband, S., Rehman, Z. U., Khan, I. A., & Jadoon, W. (2019). A deep learning ensemble approach for diabetic retinopathy detection. *IEEE Access*, 7, 150530-150539. <https://doi.org/10.1109/ACCESS.2019.2947484>
- Sambyal, N., Saini, P., Syal, R., & Gupta, V. (2023). Modified residual networks for severity stage classification of diabetic retinopathy. *Evolving Systems*, 14(1), 17-35. <https://doi.org/10.1007/s12530-022-09427-3>
- Saranya, P., Prabakaran, S., Kumar, R., & Das, E. (2022). Blood vessel segmentation in retinal fundus images for proliferative diabetic retinopathy screening using deep learning. *Visual Computer*, 38(3), 977-992. <https://doi.org/10.1007/s00371-021-02062-0>

- Shankar, K., Perumal, E., & Vidhyavathi, R. M. (2020). Deep neural network with moth search optimization algorithm-based detection and classification of diabetic retinopathy images. *SN Applied Sciences*, 2(4). <https://doi.org/10.1007/s42452-020-2568-8>
- Shanthi, T., & Sabreenian, R. S. (2019). Modified Alexnet architecture for classification of diabetic retinopathy images. *Computers and Electrical Engineering*, 76, 56-64. <https://doi.org/10.1016/j.compeleceng.2019.03.004>
- Umer, M., Ashraf, I., Ullah, S., Mehmood, A., & Choi, G. S. (2022). COVINet: a convolutional neural network approach for predicting COVID-19 from chest X-ray images. *Journal of Ambient Intelligence and Humanized Computing*, 13(1), 535-547. <https://doi.org/10.1007/s12652-021-02917-3>
- Vij, R., & Arora, S. (2023). A novel deep transfer learning based computerized diagnostic systems for multi-class imbalanced diabetic retinopathy severity classification. *Multimedia Tools and Applications*. <https://doi.org/10.1007/s11042-023-14963-4>