

**MODIFIKASI ARSITEKTUR *UNET-INCEPTION* DENGAN
PENAMBAHAN *BATCH NORMALIZATION* DALAM
SEGMENTASI EKSUDAT PADA CITRA RETINA PENYAKIT
*DIABETIC RETINOPATHY***

SKRIPSI

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar
Sarjana Sains Bidang Studi Matematika**

Oleh:

IRA RAYANI

NIM 08011181924115



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SRIWIJAYA
2023**

LEMBAR PENGESAHAN

**MODIFIKASI ARSITEKTUR *UNET-INCEPTION* DENGAN
PENAMBAHAN *BATCH NORMALIZATION* DALAM SEGMENTASI
EKSUDAT PADA CITRA RETINA PENYAKIT *DIABETIC
RETINOPATHY***

SKRIPSI

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar
Sarjana Sains Bidang Studi Matematika**

Oleh

**IRA RAYANI
NIM 08011181924115**

Pembimbing Kedua



**Irmeilyana, S.Si., M.Si
NIP. 197405171999032003**

**Indralaya, Agustus 2023
Pembimbing Utama**



**Dr. Anita Desiani, S.Si., M.Kom
NIP. 197712112003122002**

Mengetahui,

an. Ketua

Sekretaris Jurusan Matematika



**Dr. Dian Cahyawati S, S.Si., M.Si
NIP. 197303212000122001**

PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Ira Rayani
NIM : 08011181924115
Fakultas/Jurusan : MIPA/Matematika

Menyatakan bahwa skripsi ini adalah hasil karya saya sendiri dan karya ilmiah ini belum pernah diajukan sebagai pemenuhan persyaratan untuk memperoleh gelar kesarjanaan starata satu (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain.

Semua informasi yang dimuat dalam skripsi ini berasal dari penulis lain baik yang dipublikasikan atau tidak telah diberikan penghargaan dengan mengutip nama sumber penulis secara benar. Semua isi dari skripsi ini sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.

Indralaya, Agustus 2023



Penulis

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk:

Yang Maha Kuasa Allah Subhanahu Wa Ta'ala,

Kedua Orang Tuaku Tersayang,

Keluarga besarku,

Semua guru dan dosenku,

Sahabat-sahabatku,

Almamaterku

Moto

“Memang baik menjadi orang penting, tapi lebih penting menjadi orang baik”

KATA PENGANTAR

Puji syukur kehadiran Allah Subhanahu Wa Ta'ala yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Modifikasi Arsitektur *UNet-Inception* dengan Penambahan *Batch Normalization* dalam Segmentasi Eksudat pada Citra Retina Penyakit *Diabetic Retinopathy*” sebagai salah satu syarat memperoleh gelar sarjana sains bidang studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Penulis menyadari bahwa proses pembuatan skripsi merupakan proses pembelajaran yang sangat berharga serta tak lepas dari kekurangan dan keterbatasan. Dengan segala hormat dan kerendahan hasil, penulis mengucapkan terima kasih dan penghargaan kepada:

1. Kepada kedua orang tuaku tercinta, **Darni Minarti** dan **Madra Sain** terimakasih telah mendidik, menasehati, membimbing, dan mendukung serta terus mendoakan.
2. Bapak **Drs. Sugandi Yahdin, M.M** dan Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Ketua dan Sekretaris Jurusan Matematika FMIPA Universitas Sriwijaya yang telah memberikan arahan dan motivasi selama proses perkuliahan.
3. Ibu **Dr. Anita Desiani, S.Si., M.Kom** dan Ibu **Irmeilyana, S.Si., M.Si** selaku dosen pembimbing yang telah bersedia meluangkan waktu, tenaga, pikiran untuk memberikan bimbingan, pengarahan, dan didikan berharga selama proses pembuatan skripsi, dan perjalanan perkuliahan ini.

4. Bapak **Drs. Endro Setyo Cahyono, M.Si** dan Ibu **Dr. Evi Yuliza, S.Si., M.Si** selaku dosen pembahas dan penguji yang telah memberikan kritik dan saran yang sangat bermanfaat untuk perbaikan dan penyelesaian skripsi ini.
5. Bapak **Drs. Putra Bahtera Jaya Bangun, M.Si** selaku dosen pembimbing akademik yang telah membimbing dan mengarahkan urusan akademik.
6. **Seluruh Dosen di Jurusan Matematika FMIPA** yang telah memberikan ilmu, nasihat, motivasi, serta bimbingan selama proses perkuliahan.
7. **Semua sahabat seperjuangan, Kakak-kakak tingkat angkatan 2017 dan 2018 bidang minat Komputasi, Komputasi 2019, Keluarga Matematika 2019, Keluarga Trikora, Keluarga Aksi, dan Keluarga Rubik Laskarika,** terima kasih sudah menjadi orang-orang baik yang selalu mendukung, membantu dengan tulus, dan memberi energi positif.
8. Semua pihak yang tidak dapat penulis sebutkan satu per satu. Semoga segala kebaikan yang diberikan mendapatkan balasan terbaik dari Allah SWT.

Semoga skripsi ini dapat menambah pengetahuan dan bermanfaat bagi mahasiswa/mahasiswi Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya dan seluruh pihak yang membutuhkan.

Indralaya, Agustus 2023

Penulis

MODIFICATION OF THE UNET-INCEPTION ARCHITECTURE WITH THE ADDITION BATCH NORMALIZATION IN EXUDATE SEGMENTATION IN RETINA IMAGES OF DIABETIC RETINOPATHY

By:

**Ira Rayani
08011181924115**

ABSTRACT

Diabetic retinopathy is an effect of diabetes which is characterized by exudate. The segmentation process is needed to separate the exudate on the retinal image, to get clear exudate objects. The algorithm that is widely used in the segmentation process is the Convolutional Neural Network (CNN). The popular CNN architecture used for image segmentation process is UNet. However, the UNet architecture uses a large kernel size resulting in a large number of parameters. The UNet architecture consists of encoder lines and decoder lines connected by bridges. The bridge section usually uses a dense layer, which has a skip connection feature which results in missing feature information. Unlike the Inception module which does not implement a skip connection but replaces it with a parallel structure, the Inception module also implements a kernel with a smaller size to handle the large number of parameters. In this study, the exudate segmentation process on retinal images used a modification of the UNet-Inception architecture with the addition of batch normalization to make the weights converge more quickly. The results of the study yielded accuracy, sensitivity, f1-score, and Intersection over Union (IoU) values above 90%, which indicated that the model performance, prediction of exudate pixels, and prediction of segmentation results with ground truth were very good, and the specificity value was still below 85% is also in the good category in predicting background pixels.

Keyword : Segmentation, Exudate, Diabetic Retinopathy, Unet, Inception.

**MODIFIKASI ARSITEKTUR *UNET-INCEPTION* DENGAN
PENAMBAHAN *BATCH NORMALIZATION* DALAM SEGMENTASI
EKSUDAT PADA CITRA RETINA PENYAKIT *DIABETIC
RETINOPATHY***

Oleh:

**Ira Rayani
08011181924115**

ABSTRAK

Diabetic retinopathy merupakan efek dari diabetes yang ditandai dengan eksudat. Proses segmentasi diperlukan untuk memisahkan eksudat pada citra retina, untuk mendapatkan objek eksudat secara jelas. Algoritma yang banyak digunakan pada proses segmentasi adalah *Convolutional Neural Network* (CNN). Arsitektur CNN yang populer digunakan untuk proses segmentasi citra adalah *UNet*. Namun, arsitektur *UNet* menggunakan kernel dengan ukuran yang besar sehingga menghasilkan jumlah parameter yang besar. Arsitektur *UNet* terdiri dari jalur *encoder* dan juga jalur *decoder* yang dihubungkan dengan *bridge*. Bagian *bridge* biasanya menggunakan *dense layer*, yang memiliki fitur *skip connection* yang mengakibatkan adanya informasi fitur yang terlewatkan. Berbeda dengan modul *Inception* yang tidak menerapkan *skip connection* tetapi menggantinya dengan struktur paralel, modul *Inception* juga menerapkan kernel dengan ukuran yang lebih kecil untuk mengatasi jumlah parameter yang besar. Pada penelitian ini melakukan proses segmentasi eksudat pada citra retina menggunakan modifikasi arsitektur *UNet-Inception* dengan penambahan *batch normalization* untuk membuat bobot lebih cepat konvergen. Hasil penelitian menghasilkan nilai akurasi, sensitivitas, *f1-score*, dan *Intersection over Union (IoU)* diatas 90%, yang menunjukkan bahwa performa model, prediksi piksel eksudat, maupun prediksi hasil segmentasi dengan *ground truth* sudah sangat baik, serta nilai spesifisitas yang masih dibawah 85% juga sudah masuk kategori baik dalam memprediksi piksel *background*.

Kata Kunci : Segmentasi, Eksudat, *Diabetic Retinopathy*, *UNet*, *Inception*.

DAFTAR ISI

HALAMAN JUDUL	i
LEMBAR PENGESAHAN	ii
HALAMAN PERSEMBAHAN	iii
KATA PENGANTAR.....	iv
ABSTRACT	vi
ABSTRAK	vii
DAFTAR ISI.....	viii
DAFTAR TABEL	x
DAFTAR GAMBAR.....	xi
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah.....	4
1.3 Pembatasan Masalah	5
1.4 Tujuan.....	5
1.5 Manfaat.....	5
BAB II TINJAUAN PUSTAKA.....	6
2.1 Citra Digital	6
2.2 Retina.....	6
2.3 <i>Preprocessing</i>	7
2.4 Segmentasi Citra Biner.....	7
2.5 <i>Convolutional Neurol Network (CNN)</i>	8
2.5.1 <i>Convolutional Layer</i>	8
2.5.2 <i>Batch Normalization</i>	10
2.5.3 Fungsi Aktivasi	11
2.5.4 <i>Max Pooling</i>	12
2.5.5 <i>Upsampling Layer</i>	13
2.5.6 <i>Concatenate Layer</i>	14
2.5.7 <i>Loss Function : Binary Cross Entropy</i>	16
2.5.8 <i>Optimization : Adaptive Moment Estimation (Adam)</i>	16
2.6 <i>UNet</i>	18

2.7 <i>Inception</i>	19
2.8 <i>Confusion Matrix</i>	20
BAB III METODOLOGI PENELITIAN	22
3.1 Tempat.....	22
3.2 Waktu	22
3.3 Alat	22
3.4 Tahap Penelitian	22
BAB IV HASIL DAN PEMBAHASAN	26
4.1 Deskripsi Data	26
4.2 <i>Preprocessing</i> Data	27
4.3 Modifikasi Arsitektur <i>UNet-Inception</i>	28
4.4 Ilustrasi Operasi Manual <i>Convolutional Neural Network</i> (CNN).....	31
4.4.1 <i>Convolutional Layer</i>	31
4.4.2 <i>Batch Normalization</i>	33
4.4.3 Fungsi Aktivasi	36
4.4.4 <i>Max Pooling</i>	37
4.4.5 <i>Upsampling</i>	38
4.4.6 <i>Concatenate</i>	39
4.4.7 <i>Loss Function : Binary Cross Entropy</i>	39
4.4.8 <i>Optimization : Adaptive Moment Estimation (Adam)</i>	41
4.5 <i>Training</i>	43
4.6 <i>Testing</i>	47
4.7 Evaluasi	49
4.8 Analisis dan Interpretasi Hasil	51
BAB V KESIMPULAN DAN SARAN	53
5.1 Kesimpulan.....	53
5.2 Saran	53
DAFTAR PUSTAKA	54

DAFTAR TABEL

Tabel 2.1. <i>Confusion Matrix</i>	20
Tabel 2.2. Kategori Nilai Evaluasi Kinerja Model.....	21
Tabel 4.1. Sampel Dataset Eksudat.....	26
Tabel 4.2. Perbandingan <i>Cropping</i> , <i>Ground Truth</i> , dan Hasil Segmentasi.....	48
Tabel 4.3. <i>Confusion Matrix</i> dari Proses <i>Testing</i>	49
Tabel 4.4. Perbandingan Hasil Evaluasi Kinerja dengan Penelitian Lainnya.....	51

DAFTAR GAMBAR

Gambar 2.1. Eksudat pada Citra Retina.....	6
Gambar 2.2. Ilustrasi Proses <i>Convolutional Layer</i>	9
Gambar 2.3. Ilustrasi Proses <i>Max Pooling</i>	13
Gambar 2.4. Ilustrasi Proses <i>Upsampling Layer</i>	14
Gambar 2.5. Ilustrasi Proses <i>Concatenate Layer</i>	15
Gambar 2.6. Arsitektur <i>UNet</i>	18
Gambar 2.7. Modul <i>Inception</i>	19
Gambar 4.1. Citra Asli dan <i>Ground Truth</i>	27
Gambar 4.2. Hasil <i>Preprocessing</i>	28
Gambar 4.3. Arsitektur <i>UNet-Inception</i> dengan Penambahan <i>Batch Normalization</i>	28
Gambar 4.4. Hasil <i>Training</i> Model Arsitektur <i>UNet-Inception</i> dengan Penambahan <i>Batch Normalization</i>	44
Gambar 4.5. Grafik Akurasi Proses <i>Training</i> pada data <i>Training</i> dan Validasi dalam Segmentasi Eksudat Menggunakan Arsitektur <i>UNet-Inception</i> dengan Penambahan <i>Batch Normalization</i>	45
Gambar 4.6. Grafik <i>Loss</i> Proses <i>Training</i> pada data <i>Traning</i> dan Validasi dalam Segmentasi Eksudat Menggunakan Arsitektur <i>UNet-Inception</i> dengan Penambahan <i>Batch Normalization</i>	46
Gambar 4.7. Grafik <i>Recall</i> dan <i>f1-score</i> dalam Segmentasi Eksudat Menggunakan Arsitektur <i>UNet-Inception</i> dengan Penambahan <i>Batch Normalization</i>	46
Gambar 4.8. Grafik ROC Hasil Segmentasi Eksudat Menggunakan Arsitektur <i>UNet-Inception</i> dengan Penambahan <i>Batch Normalization</i>	47

BAB I

PENDAHULUAN

1.1 Latar Belakang

Diabetic retinopathy disebabkan oleh penyakit diabetes yang mengakibatkan terjadinya akumulasi cairan dan kerusakan pembuluh darah pada retina, sehingga dapat mengakibatkan kebutaan sampai kematian (Erdiansyah *et al.*, 2022). *Diabetic retinopathy* ditandai dengan adanya satu atau beberapa lesi pada retina yang disebut sebagai eksudat. Eksudat terbagi menjadi dua jenis yang terdiri dari eksudat lunak dan eksudat keras. Eksudat lunak berbentuk bintik-bintik kapas berwarna kuning atau putih sedangkan eksudat keras berbentuk seperti bercak cairan lilin berwarna kuning (Mateen *et al.*, 2020).

Proses segmentasi diperlukan untuk memisahkan eksudat pada citra retina, sehingga bisa mendapatkan objek eksudat secara jelas (Alqazzaz *et al.*, 2019). Pemanfaatan proses segmentasi pada eksudat menggunakan metode *deep learning* sudah banyak digunakan (Benzamin & Chakraborty, 2019; Oktavia *et al.*, 2022; Geng *et al.*, 2020). Segmentasi merupakan proses pemisahan objek yang dibutuhkan dengan latar belakang.

Pemanfaatan Metode *deep learning* yaitu *Convolutional Neural Network* (CNN) banyak digunakan dalam proses segmentasi (Desiani *et al.*, 2021). CNN memiliki kemampuan untuk mendeteksi dan mengenali objek pada citra digital (Hashemi, 2019). Salah satu arsitektur CNN adalah arsitektur *UNet* yang populer digunakan dalam proses segmentasi citra. Arsitektur *UNet* terdiri dari banyak

saluran fitur sehingga memungkinkan dapat menghasilkan nilai akurasi lebih tinggi. (Du *et al.*, 2020). Namun, menggunakan kernel berukuran besar sehingga juga dapat menghasilkan jumlah parameter yang besar (Han *et al.*, 2022). Geng *et al.* (2020) menerapkan arsitektur *UNet* dalam segmentasi eksudat pada citra retina dengan nilai sensitivitas yang sudah cukup baik, namun akurasi dan spesifisitas masih dibawah 85%. Albahli & Yar (2022) juga menerapkan arsitektur *UNet VGG* dalam segmentasi eksudat pada citra retina, namun hanya menghitung nilai akurasi dengan hasil diatas 85%.

Arsitektur *UNet* terdiri dari jalur *encoder*, *decoder* dan dihubungkan dengan *bridge* (Du *et al.*, 2020). Bagian *encoder* adalah *contracting path* yang terdiri dari konvolusi, fungsi aktivasi, dan *max pooling* yang berfungsi untuk melakukan segmentasi citra dengan mengambil fitur penting. Bagian *decoder* adalah *expanding path* yang terdiri dari *up convolution*, konvolusi, dan aktivasi *ReLU* yang digunakan untuk menyatukan kembali citra dan membuat sebuah *layer* warna pada *output* (Ariana, 2016). Bagian *bridge* biasanya menggunakan *dense layer*. *Dense layer* berfungsi untuk mengabungkan hasil dari *layer* sebelumnya dengan *layer* saat ini. Namun, pemanggilan kembali *layer* dapat menyebabkan *overfitting* karna *input* yang digunakan lebih besar, sehingga membuat jumlah parameter lebih besar, jaringan lebih kompleks, dan waktu yang dibutuhkan untuk proses *training* lebih lama. (Rahman *et al.*, 2017). *Dense layer* menggunakan *skip connection* untuk mengatasi akibat dari pemanggilan kembali *layer*. *Skip connection* bekerja dengan cara hanya mengambil beberapa *layer* dari *layer* sebelumnya. Namun, *skip connection* yang melewati beberapa

layer dari arsitektur dapat mengakibatkan adanya informasi fitur yang terlewatkan (Wu *et al.*, 2020).

Modul yang mempunyai kemiripan dengan *dense layer* adalah modul *Inception*. Modul *Inception* tidak menerapkan *skip connection* tetapi menggantinya dengan struktur paralel, sehingga dapat mengekstrak fitur dengan skala yang berbeda dan mendapatkan lebih banyak informasi fitur tanpa adanya informasi yang terlewat (Ren *et al.*, 2022). Namun, modul *Inception* yang menggunakan struktur paralel membuat jumlah parameter lebih besar, sehingga modul *Inception* menerapkan kernel dengan ukuran yang lebih kecil untuk mengatasi jumlah parameter yang besar (Wang *et al.*, 2021). Qadir *et al.* (2019) menggabungkan *Inception ResNet* dalam segmentasi polip dengan nilai *presicion* sangat baik, namun nilai *recall* masih dibawah 80% dan tidak menghitung nilai evaluasi kinerja lain. Zhang *et al.* (2020) menggabungkan *Dense-Inception* dalam segmentasi pembuluh darah pada citra retina, namun hanya menghitung nilai akurasi.

Arsitektur *UNet* dan modul *Inception* yang memiliki berlapis-lapis *layer* membuat pembangkitan bobot sulit konvergen karna lapisan yang terlalu besar. Salah satu teknik untuk membuat bobot cepat konvergen dan tidak terlalu jauh dari bobot sebenarnya adalah teknik *batch normalization* (Thakkar & Tewary, 2018). *Batch normalization* adalah teknik untuk menormalisasi aktivasi pada setiap *layer*, sehingga dapat mempercepat proses *training* dan memberikan ketepatan yang lebih baik (Huangi *et al.*, 2018). Thakkar & Tewary (2018) menerapkan *batch normalization* pada *Inception* untuk segmentasi hewan, namun

hanya mengukur nilai akurasi dengan hasil masih dibawah 90%. Tiwari & Saraswat (2023) menerapkan *batch normalization* pada arsitektur *UNet* untuk segmentasi kendaraan, namun hanya mengukur nilai akurasi dengan hasil masih dibawah 85%.

Penelitian ini menerapkan arsitektur *UNet* dan modul *Inception*, dengan mengambil keunggulan pada arsitektur *UNet* dan modul *Inception* untuk memperoleh arsitektur baru. Arsitektur *UNet-Inception* dilakukan modifikasi dengan tetap mempertahankan bagian *encoder* dan *decoder* pada arsitektur *UNet*, namun mengganti *dense layer* dibagian *bridge* pada arsitektur *UNet* dengan menggunakan modul *Inception* serta melakukan penambahan *batch normalization* pada modul *Inception* karna bagian ini yang paling besar menerima informasi fitur. Hasil kinerja arsitektur *UNet-Inception* dalam segmentasi eksudat pada citra retina akan di ukur hasil evaluasi kinerja yaitu nilai akurasi, *f1-score*, *Intersection over Union (IoU)*, sensitivitas, dan spesifisitas. yang diperoleh dari arsitektur tersebut.

1.2 Perumusan Masalah

Rumusan masalah dari penelitian adalah bagaimana menerapkan modifikasi arsitektur *UNet-Inception* dengan penambahan *batch normalization* dalam proses segmentasi eksudat pada citra retina dan mengukur hasil evaluasi kinerja dengan menghitung nilai akurasi, *f1-score*, *IoU*, sensitivitas, dan spesifisitas.

1.3 Pembatasan Masalah

Beberapa pembatasan masalah pada penelitian ini:

1. Penelitian hanya membahas segmentasi biner eksudat pada citra retina menggunakan modifikasi arsitektur *UNet-Inception* dengan penambahan *batch normalization*.
2. Penelitian ini hanya menggunakan data eksudat pada citra retina yang berasal website Kaggle.

1.4 Tujuan

Tujuan dari penelitian adalah menerapkan modifikasi arsitektur *UNet-Inception* dengan penambahan *batch normalization* dalam segmentasi eksudat pada citra retina dan mengukur hasil evaluasi kinerja dengan menghitung nilai akurasi, *f1-score*, *IoU*, sensitivitas, dan spesifisitas.

1.5 Manfaat

Manfaat dari penelitian:

1. Dapat digunakan sebagai referensi penelitian terkait segmentasi eksudat pada citra retina.
2. Hasil segmentasi dapat digunakan untuk proses klasifikasi penyakit *diabetic retinopathy*.

DAFTAR PUSTAKA

- Albahli, S., & Yar, G. N. A. H. (2022). Automated detection of Diabetic Retinopathy Using Custom Convolutional Neural Network. *Journal of X-Ray Science and Technology*, 30(2), 275–291. <https://doi.org/10.3233/XST-211073>.
- Alqadi, Z., Khrisat, M., Hindi, A., & Dwairi, M. O. (2020). Features Analysis of RGB Color Image Based on Wavelet Packet Information. *International Journal of Computer Science and Mobile Computing*, 9(3), 149–156. <https://www.researchgate.net/publication/340249851>.
- Alqazzaz, S., Sun, X., Yang, X., & Nokes, L. (2019). Automated Brain Tumor Segmentation on Multi-Modal MR Image Using SegNet. *Computational Visual Media*, 5(2), 209–219. <https://doi.org/10.1007/s41095-019-0139-y>.
- 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), 53-74. <https://doi.org/10.1186/s40537-021-00444-8>.
- Amrin, A., & Saiyar, H. (2018). Tuberculosis Diagnostic Application Using Data Mining Algorithm. *Computer Research Journal*, 5(5), 498–502. <http://ejournal.bsi.ac.id/ejurnal/index.php/paradigma>.
- Ansari, S. U., Javed, K., Qaisar, S. M., Jillani, R., & Haider, U. (2021). Multiple Sclerosis Lesion Segmentation in Brain MRI Using Inception Modules Embedded in A Convolutional Neural Network. *Journal of Healthcare Engineering*, 1(21), 1-10. <https://doi.org/10.1155/2021/4138137>.
- Ariana, R. (2016). Detection Images Blood in Convolutional Neural Network With Architecture UNet. *ITENAS*, 1(28), 1-16. <https://doi.org/11.1016/j.ceh.2016.11.001>.
- Astuti, T., & Setiawan, G.A. (2021). Image Analysis of Diabetic Retinopathy Disease Based on Artificial Neural Network Algorithm. *Journal RESTI*, 1(3), 201–209. <https://doi.org/12.1005/2021/4128117>.
- Benzamin, A., & Chakraborty, C. (2019). Detection of Hard Exudates in Retinal Fundus Images Using Deep Learning. *ICIEV-IVPR*, 1(18), 465–469. <https://doi.org/10.1109/ICIEV.2018.8641016>.
- Chen, Q., & Xiong, Q. (2020). Garbage Classification Detection Based on Improved YOLOV4. *Journal of Computer and Communications*, 08(12), 285–294. <https://doi.org/10.4236/jcc.2020.812023>.
- Chen, W., Sun, Q., Wang, J., Dong, J. J., & Xu, C. (2018). A Novel Model Based

- on AdaBoost and Deep CNN for Vehicle Classification. *IEEE Access*, 6(c), 1–10, 60445–60455. <https://doi.org/10.1109/ACCESS.2018.2875525>.
- Desai, M., & Shah, M. (2021). An Anatomization on Breast Cancer Detection and Diagnosis Employing Multi-Layer Perceptron Neural Network (MLP) and Convolutional Neural Network (CNN). *IEEE Access*, 4(2021), 1–11. <https://doi.org/10.1016/j.ceh.2020.11.002>.
- Desiani, A., Erwin, M., Suprihatin, B., Yahdin, S., Putri, A. I., & Husein, F. R. (2021). Bi-path Architecture of CNN Segmentation and Classification Method for Cervical Cancer Disorders Based on Pap-smear Images. *IAENG International Journal of Computer Science*, 48(3), 1–9. https://www.iaeng.org/IJCS/issues_v48/issue_3/IJCS_48_3_37.
- Desiani, A., Zayanti, D. A., Primatha, R., Efriliyanti, F., & Andriani, N. A. (2021). Variasi Thresholding untuk Segmentasi Pembuluh Darah Citra Retina. *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, 7(2), 255. <https://jurnal.untan.ac.id/index.php/jepin/article/view/47205/75676590315>.
- Dharmawan, D. A., & Listyalina, L. (2019). Retinal Blood Vessel Segmentation as a Tool to Detect Diabetic Retinopathy. *Journal of Electrical Technology UMY*, 3(2), 44–49. <https://doi.org/10.18196/jet.3253>.
- Du, G., Cao, X., Liang, J., Chen, X., & Zhan, Y. (2020). Medical Image Segmentation Based on U-Net: A Review. *Journal of Imaging Science and Technology*, 64(2), 1–12. <https://doi.org/10.2352/J.ImagingSci.Technol.202-0.64.2.020508>.
- Erdiansyah, U., Lubis, A. I., & Syahputra, G. (2022). Classification of Diabetic Retinopathy Using Multilayer Perceptron. *JAISE : Journal of Artificial Intelligence and Software Engineering*, 1(1), 1–6. <https://doi.org/21.2243/2021/2341771>.
- Fikri, M. I., Sabrila, T. S., & Azhar, Y. (2020). Comparison of Naïve Bayes Method and Support Vector Machine in Twitter Sentiment Analysis. *Smatika Jurnal*, 10(02), 71–76. <https://doi.org/10.32664/smatika.v10i02.455>.
- Futrega Michałand Milesi, A., & Marcinkiewicz Michałand Ribalta, P. (2022). Optimized U-Net for Brain Tumor Segmentation. In A Crimi & S Bakas, Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. *Springer International Publishing*, 1(1), 15–29. <https://doi.org/21.033/2022/411567>.
- Geng, L., Che, H., Xiao, Z., & Liu, Y. (2020). Extracting Retinal Anatomy and Pathological Structure Using Multiscale Segmentation. *IEEE Access*, 9(18), 1-15. <https://doi.org/10.3390/app9183669>.

- Han, Z., Jian, M., & Wang, G.-G. (2022). ConvUNeXt: An efficient convolution neural network for medical image segmentation. *Knowledge-Based Systems*, 253, 109512. <https://doi.org/21.2243/2022/2003472>.
- Hashemi, M. (2019). Enlarging Smaller Images Before Inputting Into Convolutional Neural Network: Zero-Padding vs Interpolation. *Journal of Big Data*, 6(1), 13-98. <https://doi.org/10.1186/s40537-019-0263-7>.
- Huang, L., Yang, D., Lang, B., & Deng, J. (2018). Decorrelated Batch Normalization. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1(1), 791–800. <https://doi.org/10.1109/CVPR.2018.00089>.
- Ioffe, S., & Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. In F. Bach & D. Blei. *Proceedings of the 32nd International Conference on Machine Learning*, 37(1), 448–456. PMLR. <https://proceedings.mlr.press/v37/loff-15.html>.
- Irfan, D., Rosnelly, R., Wahyuni, M., Samudra, J. T., & Ranga, A. (2022). Optimization Comparison of Sgd, Adadelta, and Adam in Hydrangea Classification Using CNN. *Journal of Science and Social Research*, 5(2), 244. <https://doi.org/10.54314/jssr.v5i2.789>.
- Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D., & Chen, M. (2014). Medical Image Classification with Convolutional Neural Network. *International Conference on Control Automation Robotics and Vision*, 14(1), 844–848. <https://doi.org/10.1109/ICARCV.2014.7064414>.
- Lian, S., Li, L., Lian, G., Xiao, X., Luo, Z., & Li, S. (2021). A Global and Local Enhanced Residual U-Net for Accurate Retinal Vessel Segmentation. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 18(3), 852–862. <https://doi.org/10.1109/TCBB.2019.2917188>.
- Mateen, M., Wen, J., Nasrullah, N., Sun, S., & Hayat, S. (2020). Exudate Detection for Diabetic Retinopathy Using Pretrained Convolutional Neural Networks. *Complexity*, 20(1), 1-11. <https://doi.org/10.1155/2020/5801870>.
- Mishra, S., Vanli, O. A., Huffer, F. W., & Jung, S. (2016). Regularized Discriminant Analysis for Multi-Sensor Decision Fusion and Damage Detection with Lamb Waves. *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems*, 9803(850), 9803-98032. <https://doi.org/10.1117/12.2217959>.
- Nasution, D. L. (2019). Image Quality Improvement of Maps Using Contrast Limited Adaptive Histogram Equalization (CLAHE) Method. *IEEE Access*, 3(1), 49–56. <https://doi.org/10.30865/komik.v3i1.1566>.

- Negi, S. S., & Bhandari, Y. S. (2014). A Hybrid Approach to Image Enhancement Using Contrast Stretching on Image Sharpening and The Analysis of Various Cases Arising Using Histogram. *International Conference on Recent Advances and Innovations in Engineering*, 3(1), 1-6. <https://doi.org/10.1109-ICRAIE.2014.6909232>.
- Oktavia, F., Andreswari, D., & Susilo, B. (2022). Diaretdb1 Image Segmentation in Diabetic Retinopathy Hemorrhages Areas Using the Region Growing Method. *Recursive: Journal of Informatics*, 10(1), 1–11. <https://doi.org/10.33369/rekursif.v10i1.20669>.
- Normawati, D., & Prayogi, S. A. (2021). Implementation of Naïve Bayes Classifier and Confusion Matrix on Text-Based Sentiment Analysis on Twitter. *Jurnal Sains Komputer & Informatika (J-SAKTI)*, 5(9), 697–711. <https://tu-nasbangsa.ac.id/ejurnal/index.php/jsakti>.
- Patil, A., & Rane, M. (2021). Convolutional Neural Networks: An Overview and Its Applications in Pattern Recognition. *Smart Innovation, Systems and Technologies*, 195(1), 1-11. https://doi.org/10.1007/978-981-15-7078-0_3.
- Porwal, P., Pachade, S., Kamble, R., Kokare, M., Deshmukh, G., Sahasrabuddhe, V., & Meriaudeau, F. (2018). Indian Diabetic Retinopathy Image Dataset. *IEEE Access*, 3(3), 1–8. <https://doi.org/10.3390/data3030025>.
- Pratiwi, B. P., Handayani, A. S., & Sarjana, S. (2021). Air Quality System Performance Measurement Using Wsn Technology Using Confusion Matrix. *JIU*, 6(2), 66–75. <https://doi.org/10.26877/jiu.v-6i2.6552>.
- Qadir, H. A., Shin, Y., Solhusvik, J., Bergsland, J., Aabakken, L., & Balasingham, I. (2019). Polyp Detection and Segmentation Using Mask R-CNN: Does A Deeper Feature Extractor CNN Always Perform Better. *International Symposium on Medical Information and Communication Technology, ISMICT*, 19(5) 1–6. <https://doi.org/10.1109/ISMICT.2019.8743694>.
- Rahman, M. M., Tan, Y., Xue, J., & Lu, K. (2017). RGB-D Object Recognition with Multimodal Deep Convolutional Neural Networks. *Proceedings - IEEE International Conference on Multimedia and Expo*, 1(1), 991–996. <https://doi.org/10.1109/ICME.2017.8019538>.
- Ren, R., Vanitha, N. S., & Valarmathy, S. (2022). The Pre-Processing Techniques for Breast Cancer Detection in Mammography Images. *International Journal of Image, Graphics and Signal Processing*, 5(5), 47–54. <https://doi.org/10.5815/ijigsp.2013.05.06>.
- Sanjaya, Y. C., Gunawan, A. A. S., & Irwansyah, E. (2020). Semantic Segmentation for Aerial Images: A Literature Review. *Engineering, Mathematics and Computer Science (EMACS) Journal*, 2(3), 133–139. <https://doi.org/10.21512/emacsjournal.v2i3.6737>.

- Santoso, M., Indriyani, T., & Putra, R. E. (2017). Detection of Microaneurysms in Retina Images of the Eye Using Matched Filters. *INTEGER: Journal of Information Technology*, 2(2), 59–68. <https://doi.org/10.31284/j.integer.-2017.v2i2.180>.
- Sathananthavathi, V., & Indumathi, G. (2021). Encoder Enhanced Atrous (EEA) Unet architecture for Retinal Blood vessel segmentation. *Cognitive Systems Research*, 67(1), 84–95. <https://doi.org/10.1016/j.cogsys.2021.01.003>.
- Sisodia, D. S., Nair, S., & Khobragade, P. (2017). Diabetic Retinal Fundus Images: Preprocessing and Feature Extraction for Early Detection of Diabetic Retinopathy. *Biomedical and Pharmacology Journal*, 10(2), 615–626. <https://doi.org/10.13005/bpj/1148>.
- Soomro, T. A., Afifi, A. J., Zheng, L., Soomro, S., Gao, J., Hellwich, O., & Paul, M. (2019). Deep Learning Models for Retinal Blood Vessels Segmentation: A Review. *IEEE Access*, 7(c), 71696–71717. <https://doi.org/10.1109/ACCESS.2019.2920616>.
- Sumardiyono, B. (2022). VOC Archive Paleography Digital Image Segmentation using Thresholding Method. *Information Engineering Journal*, 11(1), 17–23. <https://doi.org/09.12022/bpj/1418>.
- Thakkar, V & Tewary, S. (2018). Batch Normalization in Convolutional Neural Networks – A Comparative Study with CIFAR-10 Data. *Fifth International Conference on Emerging Applications of Information Technology (EAIT)*, 1(5), 1–5. <https://doi.org/10.02018/001/0481>.
- Tiwari, T., & Saraswat, M. (2023). A New Modified-Unet Deep Learning Model For Semantic Segmentation. *IEEE Access*, 82(3), 3605–3625. <https://doi.org/10.1007/s11042-022-13230-2>
- Trevethan, R. (2017). Sensitivity, Specificity, and Predictive Values: Foundations, Pliabilities, and Pitfalls in Research and Practice. *Frontiers in Public Health*, 5(11), 1–7. <https://doi.org/10.3389/fpubh.2017.00307>.
- Wang, J., He, X., Faming, S., Lu, G., Cong, H., & Jiang, Q. (2021). A Real-Time Bridge Crack Detection Method Based on an Improved Inception-Resnet-v2 Structure. *IEEE Access*, 9(1), 93209–93223. <https://doi.org/10.1109/ACCESS.2021.3093210>.
- Wu, K., Zhang, S., & Xie, Z. (2020). Monocular Depth Prediction with Residual DenseASPP Network. *IEEE Access*, 8(1), 129899–129910. <https://doi.org/10.1109/ACCESS.2020.3006704>.
- Zhang, Y., Mehta, S., & Caspi, A. (2021). Rethinking Semantic Segmentation Evaluation for Explainability and Model Selection. *IEEE Access*, 21(1), 1-14. <http://arxiv.org/abs/2101.08418>.

Zhang, Z., Wu, C., Coleman, S., & Kerr, D. (2020). Computer Methods and Programs in Biomedicine DENSE-INception U-net for Medical Image Segmentation. *Computer Methods and Programs in Biomedicine*, 20(1), 1-15. <https://doi.org/10.1016/j.cmpb.2020.105395>.