

**KOMBINASI ARSITEKTUR DENSENET  
BOTTLENECK LAYER DAN GATE RECURRENT UNITS (GRU)  
PADA KLASIFIKASI PENYAKIT GLAUKOMA  
MENGGUNAKAN CITRA RETINA**

**SKRIPSI**

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

**Oleh :  
KARINA  
08011182025007**



**JURUSAN MATEMATIKA  
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM  
UNIVERSITAS SRIWIJAYA  
2024**

## LEMBAR PENGESAHAN

### KOMBINASI ARSITEKTUR DENSENET BOTTLENECK LAYER DAN GATE RECURRENT UNITS (GRU) PADA KLASIFIKASI PENYAKIT GLAUKOMA MENGGUNAKAN CITRA RETINA

## SKRIPSI

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

Oleh :

KARINA  
08011182025007

Pembimbing Kedua

  
Novi Rustiana Dewi, S.Si., M.Si.  
NIP. 197011131996032002

Indralaya, Juli 2024  
Pembimbing Utama

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

Mengetahui,  
Ketua Jurusan Matematika



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

## SURAT PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan dibawah ini:

Nama Mahasiswa : Karina

NIM : 08011182025007

Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam/Matematika

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

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

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.

Indralaya, Juli 2024



Karina  
NIM. 08011182025007

## **HALAMAN PERSEMBAHAN**

*Kupersembahkan skripsi ini untuk :*

*Yang Maha Kuasa Allah Subhanahu Wa Ta'ala,*

*Kedua orang tuaku tercinta,*

*Kedua kakakku dan adikku tersayang,*

*Keluarga besarku,*

*Semua guru-guruku dan dosen-dosenku,*

*Teman-teman dekatku dan teman terbaikku,*

*Almamaterku.*

### Motto

*“Rahasia kesuksesan adalah konsistensi dalam upaya”*

*-Benjamin Disraeli*

## KATA PENGANTAR

Puji syukur kehadirat Allah Subhanahu wa Ta'ala yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Kombinasi Arsitektur *DenseNet Bottleneck Layer* dan *Gate Recurrent Units* (GRU) pada Klasifikasi Penyakit Glaukoma Menggunakan Citra Retina” sebagai salah satu syarat memperoleh gelar sarjana sains bidang studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Penulis menyadari bahwa pembuatan skripsi ini merupakan proses pembelajaran yang sangat berharga serta tak lepas dari kekurangan dan keterbatasan. Dengan segala hormat dan kerendahan hati, penulis mengucapkan terima kasih dan penghargaan kepada kedua orang tua tercinta, **Kori** dan **Suhita** yang tak pernah lelah selalu mendidik, membimbing, menasihati, dan mendukung serta terus mendoakan untuk segala hal yang dilakukan anaknya. Terima kasih atas segala perjuangan dan pengorbanan yang telah dilakukan hingga saat ini dan sampai kapanpun. Penulis juga menyampaikan ucapan terima kasih dan penghargaan kepada :

1. Bapak **Prof. Hermansyah, S.Si., M.Si, Ph.D.** selaku Dekan Fakultas MIPA Universitas Sriwijaya, Bapak **Dr. Hasanudin, S.Si., M.Si.** selaku Wakil Dekan I Bidang Akademik, Bapak **Dr. M. Hendri, S.T., M.Si.** selaku Wakil Dekan II Bidang Umum, Keuangan, dan Kepegawaian, dan Bapak **Dr. Fiber Monado, M.Si.** selaku Wakil Dekan III Bidang Kemahasiswaan dan Alumni.

2. Ibu **Dr. Dian Cahyawati Sukanda, M.Si.** selaku Ketua Jurusan Matematika dan dosen pembimbing akademik serta Ibu **Des Alwine Zayanti, S.Si., M.Si.** selaku Sekretaris Jurusan Matematika yang telah membimbing dan mengarahkan dalam urusan akademik selama menempuh perkuliahan di Jurusan Matematika FMIPA Universitas Sriwijaya.
3. Ibu **Dr. Anita Desiani, S.Si., M.Kom.** dan Ibu **Novi Rustiana Dewi, S.Si., M.Si.** selaku Dosen Pembimbing yang telah bersedia meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan, arahan dan didikan yang berharga selama proses pembuatan skripsi, perlombaan, dan proses perkuliahan.
4. Ibu **Prof. Yulia Resti, S.Si., M.Si., Ph.D.**, Bapak **Dr. Bambang Suprihatin, S.Si., M.Si.**, dan Bapak **Drs. Endro Setyo Cahyono, M.Si.** yang telah memberikan tanggapan, saran, masukan, dan kritik yang sangat bermanfaat untuk perbaikan dan penyelesaian skripsi ini.
5. Ibu **Endang Sri Kresnawati, S.Si., M.Si.** selaku ketua dan Ibu **Dra. Ning Eliyati, M.Pd.** selaku sekretaris pelaksana tugas akhir. **Seluruh Dosen di Jurusan Matematika Fakultas MIPA Universitas Sriwijaya** serta **guru-guru** yang telah memberikan ilmu yang sangat bermanfaat bagi Penulis. Bapak **Irwansyah** dan Ibu **Hamidah** selaku staf administrasi di Jurusan Matematika FMIPA Universitas Sriwijaya yang telah membantu penulis selama perkuliahan.
6. Kakak perempuanku **Kartika Sari** dan Kakak laki-lakiku **Firman Syah** dan **Dedi Saputra** yang selalu memberikan semangat, nasihat, dan

dukungan serta mendo'akan untuk kelancaran perkuliahan Penulis. Adik perempuanku **Ria Abella** yang selalu membantu dan menemani hari-hari Penulis selama proses pembuatan skripsi ini. Keponakanku **Kayla Nadhifah Almaira** dan **Muhammad Kaysan Nayaka** yang menjadi penghibur selama proses pembuatan skripsi. Keluarga besarku yang senantiasa mendo'akan dan mendukung proses perkuliahan penulis.

7. **Kakak-kakak tingkat angkatan 2018 dan 2019 bidang komputasi, Tim Komputasi 2020, dan Keluarga Matematika 2020** yang telah banyak membantu serta berbagi ilmu selama proses perkuliahan dan proses pembuatan skripsi.
8. **Rekan-rekan KEMASS Banyuasin 2021/2022, Himastik 2022/2023, UKM U-READ 2023/2024, dan Tim PKM, PMW, Innovillage, dan rekan-rekan perlombaan lainnya** serta **Teman-teman kos GW** yang telah memberikan banyak cerita dan pengalaman yang berharga selama masa perkuliahan.
9. **Fitri Salamah, Adi Muzakir, dan Muhammad Rizky** yang telah banyak membantu proses pembelajaran selama masa perkuliahan dan proses penyelesaian skripsi ini.
10. **Ananda Azzahra Sundawa** dan **Annisa Nurba Iffah'da** yang selalu bersama kegiatan akademik selama perkuliahan dan bersama proses penyelesaian skripsi ini serta banyak waktu yang tercatat sebagai sebuah memori dalam berbagai kenangan.

11. **Enggar, Nadiyah, dan Ika** yang selalu memberikan dukungan dan menghadirkan tawa bahagia ceria serta berbagai suka duka selama berada di kos **GW**.
12. **Febi** Si paling ekspresif yang selalu bisa mentransfer semangatnya dan memberikan dorongan untuk apa yang Penulis lakukan serta banyak waktu yang kita luangkan di Rumah U-READ tercinta.
13. 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 MIPA Universitas Sriwijaya dan seluruh pihak yang membutuhkan.

Indralaya, Juli 2024

Penulis

**KOMBINASI ARSITEKTUR DENSENET**  
***BOTTLENECK LAYER DAN GATE RECURRENT UNITS (GRU)***  
**PADA KLASIFIKASI PENYAKIT GLAUKOMA**  
**MENGGUNAKAN CITRA RETINA**

By :

**Karina**

**08011182025007**

**ABSTRACT**

Glaucoma is a chronic eye disease that can lead to blindness. Glaucoma detection can be done by classification using the DenseNet architecture. DenseNet provides good model performance, but often suffers from overfitting. Bottleneck layers can be used to prevent overfitting by reducing the feature dimensions before entering deeper layers. However, reducing the feature dimension may lead to the loss of useful features. Another method that can reach features that have been skipped is the Gate Recurrent Units (GRU) architecture. GRU can update features in the *input* data by involving information about the overall state of the network. This research applies DenseNet architecture combined with bottleneck layer and GRU architecture. The results of research with retinal image datasets consisting of 3 classes obtained an accuracy value of 98.181%, sensitivity 97.32%, specificity 98.65%, f1-score 97.25%, and cohen's cappa 95.88%. The *training* graph of the method used proves that this study is able to overcome overfitting. Based on these results, it shows that the combination of DenseNet Bottleneck layer architecture and GRU is able to perform the classification task very well.

Keyword : *Glaucoma, Classification, retinal image, DenseNet, Bottleneck layers, GRU*

**KOMBINASI ARSITEKTUR DENSENET BOTTLENECK  
LAYER DAN GATE RECURRENT UNITS (GRU) PADA  
KLASIFIKASI PENYAKIT GLAUKOMA MENGGUNAKAN  
CITRA RETINA**

Oleh :

**Karina**

**08011182025007**

**ABSTRAK**

Glaukoma adalah penyakit mata kronis yang dapat menyebabkan kebutaan. Pendekripsi glaukoma dapat dilakukan dengan klasifikasi citra menggunakan arsitektur *DenseNet*. *DenseNet* memberikan kinerja model yang bagus, namun sering mengalami *overfitting*. *Bottleneck layer* dapat digunakan untuk mencegah *overfitting* dengan cara mengurangi dimensi fitur sebelum masuk ke lapisan yang lebih dalam. Namun pengurangan dimensi fitur dapat menyebabkan hilangnya fitur-fitur yang berguna. Metode lain yang dapat menjangkau fitur-fitur yang telah dilewati adalah arsitektur *Gate Recurrent Units* (GRU). GRU dapat memperbarui fitur-fitur pada data *input* dengan melibatkan informasi mengenai keadaan jaringan secara keseluruhan. Penelitian ini menerapkan arsitektur *DenseNet* yang dikombinasikan dengan *bottleneck layer* dan arsitektur GRU. Hasil penelitian dengan *dataset* citra retina yang terdiri dari 3 kelas memperoleh nilai akurasi sebesar 98,181%, sensitivitas 97,32%, spesifitas 98,65%, F1-score 97,25%, dan *cohen's kappa* 95,88%. Grafik proses *training* yang digunakan menunjukkan bahwa tidak terjadi *overfitting* pada model yang digunakan. Berdasarkan hasil tersebut, menunjukkan bahwa kombinasi arsitektur *DenseNet Bottleneck layer* dan GRU mampu melakukan tugas klasifikasi dengan sangat baik.

Kata Kunci : Glaukoma, Klasifikasi, Citra retina, *DenseNet*, *Bottleneck layer*, GRU

## DAFTAR ISI

<b>LEMBAR PENGESAHAN .....</b>	ii
<b>HALAMAN PERSEMBAHAN .....</b>	iii
<b>KATA PENGANTAR .....</b>	iv
<b>ABSTRACT .....</b>	viii
<b>ABSTRAK .....</b>	ix
<b>DAFTAR ISI.....</b>	x
<b>DAFTAR TABEL .....</b>	xii
<b>DAFTAR GAMBAR.....</b>	xiii
<b>BAB I PENDAHULUAN.....</b>	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah .....	5
1.3 Batasan Masalah.....	5
1.4 Tujuan.....	5
1.5 Manfaat.....	6
<b>BAB II TINJAUAN PUSTAKA.....</b>	7
2.1 Retina.....	7
2.2 <i>Optic Disc</i> .....	7
2.3 Glaukoma .....	8
2.4 Citra Digital .....	9
2.5 Klasifikasi Citra.....	10
2.6 Data <i>Preprocessing</i> .....	10
2.6.1 Augmentasi.....	11
2.6.2 Konversi citra RGB menjadi citra <i>Grayscale</i> .....	11
2.6.3 Normalisasi.....	12
2.7 <i>Convolutional Neural Network (CNN)</i> .....	13
2.7.1 <i>Convolutional Layer</i> .....	14
2.7.2 <i>Batch Normalization</i> .....	17
2.7.3 Fungsi Aktivasi.....	18
2.7.4 <i>Pooling Layer</i> .....	20
2.7.5 <i>Concatenate layer</i> .....	21
2.7.6 <i>Loss Function Categorical Cross Entropy</i> .....	22
2.7.7 <i>Optimization Function : Adaptive Moment Estimation (Adam)</i> ....	23
2.8 <i>DenseNet</i> .....	24

2.9	<i>Bottleneck Layer</i> .....	27
2.10	<i>Gate Recurrent Units (GRU)</i> .....	28
2.11	<i>Confusion Matrix</i> .....	30
<b>BAB III METODOLOGI PENELITIAN</b>	.....	35
3.1	Tempat.....	35
3.2	Waktu .....	35
3.3	Bahan dan Alat .....	35
3.4	Metode Penelitian.....	36
<b>BAB IV HASIL DAN PEMBAHASAN</b>	.....	42
4.1	Deskripsi Data .....	42
4.2	<i>Preprocessing Data</i> .....	43
4.2.1	Augmentasi Citra .....	43
4.2.2	Konversi Citra RGB ke <i>Grayscale</i> .....	44
4.2.3	Normalisasi Data .....	45
4.3	Implementasi Kombinasi Arsitektur <i>DenseNet Bottleneck layer</i> dan GRU	47
4.4	Operasi Manual Arsitektur .....	51
4.4.1	<i>DenseNet</i> .....	51
4.4.2	<i>Bottleneck layer</i> .....	69
4.4.3	<i>Gate Recurrent Units (GRU)</i> .....	72
4.5	<i>Training</i> .....	75
4.6	<i>Testing</i> .....	79
4.7	Evaluasi .....	82
4.8	Analisis dan Interpretasi Hasil.....	91
<b>BAB V KESIMPULAN DAN SARAN</b>	.....	94
5.1	Kesimpulan.....	94
5.2	Saran .....	94
<b>DAFTAR PUSTAKA</b>	.....	95

## **DAFTAR TABEL**

Tabel 2. 1 Kategori nilai akurasi .....	31
Tabel 2. 2 Interpretasi nilai <i>cohen's cappa</i> .....	34
Tabel 4. 1 Data sampel citra retina.....	42
Tabel 4. 2 Contoh citra hasil augmentasi .....	44
Tabel 4. 3 Contoh hasil konversi citra RGB ke grayscale .....	45
Tabel 4. 4 Hasil <i>confusion matrix</i> .....	79
Tabel 4. 5 Perbandingan hasil nilai akurasi dan sensitivitas dengan penelitian lain .....	91
Tabel 4. 6 Perbandingan hasil nilai akurasi dan sensitivitas dengan penelitian lain .....	92

## DAFTAR GAMBAR

Gambar 2. 1 Gambaran <i>optic disc</i> .....	7
Gambar 2. 2 Tingkat keparahan glaukoma .....	8
Gambar 2. 3 Representasi citra digital .....	9
Gambar 2. 4 Ilustrasi proses konvolusi .....	16
Gambar 2. 5 Macam-macam <i>pooling layer</i> .....	20
Gambar 2. 6 Ilustrasi operasi <i>concatenate layer</i> .....	21
Gambar 2. 7 Ilustrasi arsitektur <i>DenseNet</i> .....	25
Gambar 2. 8 Ilustrasi <i>transition layer</i> .....	26
Gambar 2. 9 Ilustrasi <i>bottleneck layer</i> .....	27
Gambar 2. 10 Ilustrasi arsitektur GRU .....	29
Gambar 4. 1 Ilustrasi kombinasi arsitektur <i>DenseNet Bottleneck layer</i> dan GRU	48
Gambar 4. 2 Contoh proses <i>average pooling</i> .....	60
Gambar 4. 3 Contoh proses <i>concatenate layer</i> .....	62
Gambar 4. 4 Hasil <i>training</i> model kombinasi arsitektur <i>DenseNet Bottleneck layer</i> dan GRU .....	76
Gambar 4. 5 Grafik akurasi proses <i>training</i> .....	77
Gambar 4. 6 Grafik <i>loss</i> proses <i>training</i> .....	78

# **BAB I**

## **PENDAHULUAN**

### **1.1 Latar Belakang**

Glaukoma merupakan salah satu dari penyakit mata kronis yang dapat menyebabkan kebutaan jika tidak terdeteksi tahap awal (Salam et al., 2016). Glaukoma ditandai dengan adanya kerusakan *optic disc* pada retina mata. Berdasarkan data dari Rumah Sakit Mata Kim's di Korea Selatan, glaukoma dapat dikelompokkan menjadi tiga tingkat keparahan yaitu glaukoma stadium lanjut, glaukoma dini, dan mata normal (Ahn et al., 2018). Pendekslsian glaukoma dapat dilakukan menggunakan sistem otomatis yang dibantu komputer yaitu klasifikasi citra. Metode yang paling efisien untuk melakukan klasifikasi citra dapat dilakukan dengan menggunakan *Convolutional Neural Network* (CNN) (Anwar et al., 2018; Bhatt et al., 2021). CNN adalah salah satu pengembangan *deep learning* yang bekerja berdasarkan lapisan konvolusi yang dapat mengekstraksi ciri penting dari setiap citra (Ghosh et al., 2019). Salah satu pengembangan metode CNN yang dapat digunakan untuk melakukan klasifikasi penyakit glaukoma adalah arsitektur *DenseNet*.

*DenseNet* merupakan arsitektur CNN yang struktur utama jaringannya terdiri dari beberapa *dense-block* yang memiliki sejumlah lapisan konvolusi  $3\times 3$  yang terhubung secara langsung ke semua lapisan (Chen et al., 2020; Hasan et al., 2021). Oleh karena itu *DenseNet* memiliki pola konektivitas model yang lebih unggul dibanding arsitektur CNN lainnya (Alzubaidi et al., 2021). (Kumar Shukla, 2020) melakukan klasifikasi penyakit glaukoma menggunakan arsitektur *DenseNet*

memperoleh akurasi sebesar 85,95%. Namun, nilai *precision*, *recall*, dan F1-*score* hanya 75%, 71%, dan 71%. (Elangovan et al., 2021) melakukan klasifikasi penyakit glaukoma menggunakan arsitektur *DenseNet* memperoleh hasil akurasi sebesar 96,48%, sensitivitas 98,88%, spesifisitas 92,1%, dan F1-1 *score* 97,28%. Namun klasifikasi penyakit glaukoma yang hanya menggunakan 2 kelas yaitu glaukoma dan non-glaukoma. (Azeroual et al., 2023) melakukan klasifikasi penyakit glaukoma menggunakan arsitektur *DenseNet* memperoleh akurasi sebesar 96,90%. Namun tidak mengukur nilai sensitivitas, spesifisitas, dan F1-*score*.

Berdasarkan penelitian-penelitian diatas, penerapan arsitektur *DenseNet* pada klasifikasi penyakit glaukoma telah memberikan kinerja model yang bagus dengan nilai diatas 90%, namun arsitektur *DenseNet* juga sering mengalami *overfitting* akibat jumlah parameter yang besar (Xu et al., 2023). Adanya pola konektivitas yang dimiliki *DenseNet* membuat setiap lapisan menerima *output* dari semua lapisan sebelumnya dalam *dense-block*, akibatnya terjadi peningkatan jumlah dimensi *input* untuk operasi konvolusi (Hess, 2018). Secara khusus, konvolusi  $3 \times 3$  di setiap lapisan menambah jumlah parameter secara signifikan karena *input* setiap lapisan mencakup semua *output* lapisan sebelumnya dalam *dense-block* (Hess, 2018).

Dalam upaya mencegah terjadinya *overfitting*, salah satu cara yang dapat dilakukan adalah menggunakan *bottleneck layer*. *Bottleneck layer* adalah sebuah lapisan pada CNN yang dirancang untuk mengurangi jumlah dimensi *input* yang jauh lebih sedikit dibandingkan dengan lapisan sebelum dan sesudahnya (Sandler et al., 2018). Lapisan utama pada *bottleneck layer* adalah lapisan konvolusi  $3 \times 3$

yang memiliki jumlah kernel yang lebih sedikit sementara lapisan sebelum dan sesudahnya adalah lapisan konvolusi  $1\times 1$  (Chen et al., 2020). Dengan demikian pengurangan dimensi *input* yang dilakukan *bottleneck layer* dapat mengurangi jumlah parameter, sehingga dapat mencegah terjadinya *overfitting* (Chen et al., 2020).

(Ajitha & Judy, 2020) menerapkan *bottleneck layer* pada arsitektur *Resnet50* untuk klasifikasi penyakit glaukoma yang terdiri dari dua kelas yaitu glaukoma dan non-glaukoma. Hasil akurasi yang diperoleh sudah sangat baik yaitu sebesar 90% namun nilai spesifisitas masih berada dibawah 85%. (Ilham et al., 2023) menerapkan *bottleneck layer* pada arsitektur *MobileNetV2* untuk klasifikasi penyakit glaukoma yang terdiri dari dua kelas yaitu glaukoma dan normal. Penelitian ini memperoleh nilai akurasi sebesar 88%, namun nilai sensitivitas masih berada dibawah 80%. Meskipun penerapan *bottleneck layer* pada arsitektur CNN memberikan kinerja model yang bagus, namun pengurangan dimensi *input* yang dilakukan *bottleneck layer* dapat menyebabkan terlewatnya atau hilangnya fitur-fitur yang berguna dalam proses klasifikasi citra (Chen et al., 2020; Koonce, 2021). Untuk mencegah hilangnya fitur-fitur tersebut, perlu dilakukan penggunaan kembali fitur-fitur yang telah dilewati (Wang et al., 2018).

Penggunaan kembali fitur-fitur yang telah dilewati dapat dilakukan oleh arsitektur *Gate Recurrent Units* (GRU). GRU bukan merupakan arsitektur dari CNN, melainkan arsitektur yang berbasis *Recurrent Neural Network* (RNN). Berbeda dengan CNN yang bekerja berdasarkan lapisan konvolusi, RNN memiliki alur kerja yang berulang menggunakan mekanisme *hidden state* (Bauer, 2023).

*Hidden state* mencerminkan informasi fitur-fitur pada lapisan yang sedang diproses dengan mengkombinasikan informasi fitur-fitur pada lapisan sebelumnya yang relevan dengan *input* pada lapisan yang sedang diproses (Chung et al., 2014). Dengan demikian, setiap pembaruan fitur-fitur pada lapisan akan melibatkan informasi fitur-fitur mengenai keadaan jaringan secara keseluruhan (Dey & Salem, 2017).

(Prieto, 2021) mengkombinasikan arsitektur GRU dengan arsitektur *MobileNetV2* untuk klasifikasi penyakit glaukoma. Penelitian ini memperoleh hasil akurasi sebesar 87%. Ukuran kinerja model seperti sensitivitas dan F1-score juga memberikan nilai dengan rata-rata hanya 87%. (V. Kumar et al., 2023) mengkombinasikan arsitektur GRU dan arsitektur *ResNet* untuk klasifikasi penyakit glaukoma. Hasil akurasi yang diperoleh sebesar 85,85%, namun tidak mengukur nilai spesifisitas, sensitivitas, F1-score, dan *cohen's kappa*. (Ashtari-Majlan et al., 2024) melakukan klasifikasi penyakit glaukoma dengan mengkombinasikan arsitektur GRU dengan arsitektur ViT. Penelitian ini memperoleh hasil akurasi sebesar 90,27%, sensitivitas 94%, dan F1-score 93,8%, sayangnya nilai spesifisitas hanya 78,18%. Penelitian-penelitian ini juga hanya melakukan klasifikasi penyakit glaukoma menggunakan 2 kelas.

Pada penelitian ini klasifikasi penyakit glaukoma pada citra retina dilakukan berdasarkan 3 kelas. Arsitektur yang digunakan adalah *DenseNet* yang dikombinasikan dengan *bottleneck layer* dan arsitektur GRU. Pada setiap lapisan dalam *dense-block* pada arsitektur *DenseNet* lapisan konvolusi  $3 \times 3$  diganti dengan *bottleneck layer* kemudian dilanjutkan dengan arsitektur GRU. Penggunaan

*bottleneck layer* bertujuan untuk mengurangi parameter model pada arsitektur *DenseNet* agar dapat mencegah terjadinya *overfitting*. Penambahan arsitektur GRU setelah *bottleneck layer* bertujuan untuk memperbarui fitur-fitur citra pada lapisan berikutnya. Keberhasilan dari kinerja model menggunakan kombinasi arsitektur *DenseNet Bottleneck layer* dan arsitektur GRU dalam melakukan klasifikasi penyakit glaukoma menggunakan citra retina akan diukur berdasarkan nilai akurasi, sensitivitas, spesifisitas, F1-score, dan cohen's cappa.

## 1.2 Rumusan Masalah

Rumusan masalah pada penelitian ini adalah bagaimana penerapan kombinasi arsitektur *DenseNet Bottleneck layer* dan arsitektur GRU pada klasifikasi penyakit glaukoma menggunakan citra retina berdasarkan evaluasi kinerja dengan menghitung nilai akurasi, sensitivitas, spesifisitas, F1-score, dan cohen's cappa.

## 1.3 Batasan Masalah

Pembatasan masalah pada penelitian ini adalah hanya melakukan klasifikasi penyakit glaukoma menggunakan *dataset* citra retina yang terdiri dari 3 kelas yang bersumber dari internet. Ukuran evaluasi kinerja model yang digunakan adalah akurasi, sensitivitas, spesifisitas, F1-score, dan cohen's cappa.

## 1.4 Tujuan

Tujuan dari penelitian ini adalah untuk mendapatkan kombinasi arsitektur baru yang dapat memberikan hasil prediksi dan kinerja model yang lebih baik pada

klasifikasi penyakit glaukoma dengan mengukur hasil evaluasi kinerja model berdasarkan nilai akurasi, sensitivitas, spesifisitas, F1-score, dan *cohen's kappa*.

### **1.5 Manfaat**

1. Memperoleh arsitektur baru yang dapat digunakan untuk klasifikasi citra, khususnya klasifikasi penyakit glaukoma menggunakan citra retina.
2. Dapat menjadi referensi penelitian terkait klasifikasi citra, khususnya klasifikasi penyakit glaukoma menggunakan citra retina.

## DAFTAR PUSTAKA

- Ahn, J. M., Kim, S., Ahn, K. S., Cho, S. H., Lee, K. B., & Kim, U. S. (2018). A Deep Learning Model for the Detection of Both Advanced and Early Glaucoma using Fundus Photography. *PLoS ONE*, 13(11), 1–8. <https://doi.org/10.1371/journal.pone.0207982>
- Ajitha, S., & Judy, M. V. (2020, June 17). *Faster R-CNN Classification for The Recognition of Glaucoma*. First International Conference on Advanceds in Physical Sciences and Materials, Kerala, India. <https://doi.org/10.1088/1742-6596/1706/1/012170>
- Alghifari, F., & Juardi, D. (2021). Penerapan Data Mining Pada Penjualan Makanan Dan Minuman Menggunakan Metode Algoritma Naive Bayes. *Jurnal Ilmiah Informatika (JIF)*, 9(02), 75–81. <https://doi.org/10.33884/jif.v9i02.3755>
- Alsalem, M. A., Zaidan, A. A., Zaidan, B. B., Hashim, M., Albahri, O. S., Albahri, A. S., Hadi, A., & Mohammed, K. I. (2018). Systematic Review of an Automated Multiclass Detection and Classification System for Acute Leukaemia in Terms of Evaluation and Benchmarking, Open Challenges, Issues and Methodological Aspects. *Journal of Medical Systems*, 42(204), 1–36. <https://doi.org/10.1007/s10916-018-1064-9>
- 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(53), 1–74. <https://doi.org/10.1186/s40537-021-00444-8>
- Anwar, S. M., Majid, M., Qayyum, A., Awais, M., Alnowami, M., & Khan, M. K. (2018). Medical Image Analysis using Convolutional Neural Networks: A Review. *Journal of Medical Systems*, 42(226), 1–13. <https://doi.org/10.1007/s10916-018-1088-1>
- Ashtari-Majlan, M., Dehshibi, M. ., & Masip, D. (2024). Spatial-aware Transformer-GRU Framework for Enhanced Glaucoma Diagnosis from 3D OCT Imaging. *Journal Of Biomedical and Health Informatics*, 24(3), 1–9. <https://arxiv.org/abs/2403.05702%0Ahttps://arxiv.org/pdf/2403.05702.pdf>
- Azeroual, A., El Ouahabi, Y., Nsiri, B., Dakil, A., Alaoui, M. H. E. Y., Soulaymani, A., & Benaji, B. (2023). Convolutional Neural Network for Segmentation and Classification of Glaucoma. *International Journal of Online & Biomedical Engineering*, 17(19), 1. <https://doi.org/10.3991/ijoe.v19i17.43029>
- Bauer, C. (2023). *Long Short-Term Memory Based Adaptive Scheduling for Big Data Pipelines Across the Computing Continuum*. Master's Programme Informatics, Alpen-Adria-Universitas-Klagenfurt. <https://netlibrary.aau.at/obvuklhs/content/titleinfo/8885217/full.pdf>
- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K., & Ghayvat, H. (2021). CNN Variants for Computer Vision: History,

- Architecture, Application, Challenges and Future Scope. *Multidisciplinary Digital Publishing Institute (MDPI) Electronics*, 10(20), 1–28. <https://doi.org/10.3390/electronics10202470>
- Cardarilli, G. C., Di Nunzio, L., Fazzolari, R., Giardino, D., Nannarelli, A., Re, M., & Spanò, S. (2021). A Pseudo-Softmax Function for Hardware-based High Speed Image Classification. *Scientific Reports*, 11(1), 1–10. <https://doi.org/10.1038/s41598-021-94691-7>
- Chen, B., Zhao, T., Liu, J., & Lin, L. (2020). Multipath Feature Recalibration DenseNet for Image Classification. *International Journal of Machine Learning and Cybernetics*, 12, 651–660. <https://doi.org/10.1007/s13042-020-01194-4>
- Chicco, D., J, M., Warrens, & Jurman, G. (2021). The Matthews Correlation Coefficient (MCC) is More Informative Than Cohen ' s Kappa and Brier Score in Binary Classification Assessment. *Institute of Electrical and Electronics Engineers (IEEE) Access*, 9, 78368–78381. <https://doi.org/10.1109/ACCESS.2021.3084050>
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling. *Computer Science Neural and Evolutionary Computing*, 14(12), 1–9. <https://doi.org/10.48550/arXiv.1412.3555>
- Coskun, M., Yildirim, O., Ucar, A., & Demir, Y. (2017). An Overview of Popular Deep Learning Methods. *European Journal of Technic (EJT)*, 7(2), 165–176. <https://dergipark.org.tr/en/pub/ejt/issue/34562/403498>
- 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), 1–10. [https://www.iaeng.org/IJCS/issues\\_v48/issue\\_3/IJCS\\_48\\_3\\_37.pdf](https://www.iaeng.org/IJCS/issues_v48/issue_3/IJCS_48_3_37.pdf)
- Dewi, M. S., Kesiman, M. W. A., & Sunarya, I. M. G. (2014). Aplikasi Pembelajaran Pengenal Aksara Bali Menggunakan Metode Template Matching. *Jurnal Nasional Pendidikan Teknik Informatika (JANAPATI)*, 3(1), 41–50. <https://doi.org/10.23887/janapati.v3i1.9795>
- Dey, R., & Salem, F. M. (2017). Gate-Variants of Gated Recurrent Unit (GRU) Neural Networks. *IEEE*, 1597–1600. <https://doi.org/10.1109/MWSCAS.2017.8053243>
- Elangovan, P., Vijayalakshmi, D., & Nath, M. K. (2021). Detection of Glaucoma from Fundus Image using Pre-trained Densenet201 Model. *Indian Journal of Radio and Space Physics*, 50(1), 33–39. <https://nopr.niscpr.res.in/handle/123456789/58080>
- Esengonoul, M., & Cunha, A. (2023). Glaucoma Detection using Convolutional Neural Networks for Mobile Use. *Procedia Computer Science*, 219(2022), 1153–1160. <https://doi.org/10.1016/j.procs.2023.01.396>

- Gao, Y., & Glowacka, D. (2016). Deep Gate Recurrent Neural Network. In R. J. Durrant & K.-E. Kim (Eds.), *JMLR: Workshop and Conference Proceedings*. 63, 350–365.
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2019). Fundamental Concepts of Convolution Neural Network. In *Intelligents Systems Reference Library*. 172, 519–567. [https://link.springer.com/chapter/10.1007/978-3-030-32644-9\\_36](https://link.springer.com/chapter/10.1007/978-3-030-32644-9_36)
- Grossniklaus, H. E., Geisert, E. E., & Nickerson, J. M. (2015). Introduction to the Retina. *Progress in Molecular Biology and Translational Science*, 134, 383–396. <https://doi.org/10.1016/bs.pmbts.2015.06.001>
- Gunes, A., Kalkan, H., & Durmus, E. (2016). Optimizing the color-to-grayscale conversion for image classification. *Signal, Image and Video Processing*, 10(5), 853–860. <https://doi.org/10.1007/s11760-015-0828-7>
- Haleem, M. S., Han, L., van Hemert, J., & Li, B. (2013). Automatic Extraction of Retinal Features from Colour Retinal Images for Glaucoma Diagnosis: A Review. *Computerized Medical Imaging and Graphics*, 37(7–8), 581–596. <https://doi.org/10.1016/j.compmedimag.2013.09.005>
- Hasan, N., Bao, Y., Shawon, A., & Huang, Y. (2021). DenseNet Convolutional Neural Networks Application for Predicting COVID-19 Using CT Image. *SN Computer Science*, 2(389), 1–11. <https://doi.org/10.1007/s42979-021-00782-7>
- Hasnain, M., Pasha, M. F., Ghani, I., Imran, M., Alzahrani, M. Y., & Budiarto, R. (2020). Evaluating Trust Prediction and Confusion Matrix Measures for Web Services Ranking. *Institute of Electrical and Electronics Engineers (IEEE) Access*, 8, 2169–3536. <https://doi.org/10.1109/ACCESS.2020.2994222>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Hess, A. (2018). Exploring Feature Reuse in DenseNet Architectures. *Computer Vision and Pattern Recognition*, 18(06), 1–10. <http://arxiv.org/abs/1806.01935>
- Ho, Y., & Wookey, S. (2020). The Real-World-Weight Cross-Entropy Loss Function: Modeling the Costs of Mislabeling. *Institute of Electrical and Electronics Engineers (IEEE) Access*, 8, 4806–4813. <https://doi.org/10.1109/ACCESS.2019.2962617>
- Huang, G., Maaten, L. Van Der, Weinberger, K. Q., & Liu, Z. (2018). Densely Connected Convolutional Networks. *Computer Vision Foundation*, 44(12), 8704–8716. <https://doi.org/10.1109/TPAMI.2019.2918284>
- Ilham, M., Prihantoro, A., Perdana, I. K., Magdalena, R., & Saidah, S. (2023). Experimenting with the Hyperparameter of Six Models for Glaucoma Classification. *Jurnal Ilmiah Teknik Elektro (JITEKI) Komputer Dan*

- Informatika*, 9(3), 571–584. <https://doi.org/10.26555/jiteki.v9i3.26331>
- Ioffe, S., & Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *Proceedings of the 32nd International Conference on Machine Learning*, 37(6), 448–456. <https://doi.org/10.1109/ICML47.2015.1058180>
- Irfan, D., Rosnelly, R., Wahyuni, M., Samudra, J. T., & Rangga, A. (2022). Perbandingan Optimasi Sgd, Adadelta, Dan Adam Dalam Klasifikasi Hydrangea Menggunakan CNN. *Journal of Science and Social Research*, V(2), 244. <https://doi.org/10.54314/jssr.v5i2.789>
- Jeong, Y., Hong, Y. J., & Han, J. H. (2022). Review of Machine Learning Applications Using Retinal Fundus Images. *Multidisciplinary Digital Publishing Institute (MDPI) Diagnostics*, 12(1), 1–27. <https://doi.org/10.3390/diagnostics12010134>
- Johnson, J. M., & Khoshgoftaar, T. M. (2019). Survey on deep learning with class imbalance. *Journal of Big Data*, 6(27), 1–54. <https://doi.org/10.1186/s40537-019-0192-5>
- Juneja, M., Thakur, N., Thakur, S., Uniyal, A., Wani, A., & Jindal, P. (2020). Gc-Net for Classification of Glaucoma in the Retinal Fundus Image. *Machine Vision and Applications*, 31(38), 1–18. <https://doi.org/10.1007/s00138-020-01091-4>
- Khalifa, N. E., Loey, M., & Mirjalili, S. (2022). A Comprehensive Survey of Recent Trends in Deep Learning for Digital Images Augmentation. *Artificial Intelligence Review*, 55(3), 2351–2377. <https://doi.org/10.1007/s10462-021-10066-4>
- Kirana, K. C. (2020). *Pengolahan Citra Digital Teori dan Penerapan Citra Digital pada Deteksi Wajah.*, Ahlimedia Press. Diakses pada tanggal 1 April 2024, dari : [https://play.google.com/books/reader?id=cN1SEAAAQBAJ&pg=GBS\\_PP1&hl=id](https://play.google.com/books/reader?id=cN1SEAAAQBAJ&pg=GBS_PP1&hl=id)
- Koonce, B. (2021). Convolutional neural networks with swift for tensorflow: Image recognition and dataset categorization. In *Convolutional Neural Networks with Swift for Tensorflow: Image Recognition and Dataset Categorization.*, Apress. Diakses pada tanggal 1 April 2024, dari : <https://doi.org/10.1007/978-1-4842-6168-2>
- Kumar, B. N., Chauhan, R. ., & Dahiya, N. (2016). Detection of Glaucoma using Image processing techniques : A Review. *2016 International Conference on Microelectronics, Computing and Communications (MicroCom)*, 1–6. <https://doi.org/https://doi.org/10.1109/MicroCom.2016.7522515>
- Kumar Shukla, M. (2020). *Classification of Different Stages of Glaucoma Using Deep Learning Approaches.* Msc In Data Analytics Thesis, In National College of Ireland Student, Dublin 1, Irlandia, <https://norma.ncirl.ie/4471/>
- Kumar, V., Harinath Reddy, G., & GiriPrasad, M. N. (2023). A Novel Glaucoma

- Detection Model using Unet++-Based Segmentation and ResNet with GRU-based Optimized Deep Learning. *Biomedical Signal Processing and Control*, 86, 105069–105084. <https://doi.org/10.1016/j.bspc.2023.105069>
- Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D., & Chen, M. (2014). Medical Image Classification with Convolutional Neural Network. *2014 13th International Conference on Control Automation Robotics and Vision, ICARCV 2014*, 844–848. <https://doi.org/10.1109/ICARCV.2014.7064414>
- Luo, H. (2018). Shorten Spatial-spectral RNN with Parallel-GRU for Hyperspectral Image Classification. *Computer Science Machine Learning*, 18(10), 1–5. <https://doi.org/10.48550/arXiv.1810.12563>
- Luo, P., Wang, X., Shao, W., & Peng, Z. (2019). Towards Understanding Regularization in Batch Normalization. *International Conference on Learning Representations*, 1–23. <https://doi.org/10.48550/arXiv.1809.00846>
- Luque, A., Carrasco, A., Martín, A., & Heras, A. de las. (2019). The Impact of Class Imbalance in Classification Performance Metrics Based on The Binary Confusion Matrix. *Pattern Recognition*, 91, 216–231. <https://doi.org/10.1016/j.patcog.2019.02.023>
- Maison, Lestari, T., & Luthfi, A. (2019). Retinal Blood Vessel Segmentation using Gaussian Filter. *Journal of Physics: Conference Series*, 1376(1), 1–9. <https://doi.org/10.1088/1742-6596/1376/1/012023>
- 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), 1–14. <https://doi.org/10.1117/12.2217959>
- Nasution, D. A., Khotimah, H. H., & Chamidah, N. (2019). Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN. *CESS (Journal of Computer Engineering System and Science)*, 4(1), 78–82. <https://doi.org/10.24114/cess.v4i1.11458>
- Nath, S. S., Kar, J., Mishra, G., & Chakraborty, S. (2014). A Survey of Image Classification Methods and Techniques. *2014 International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT) A*, 554–557. <https://doi.org/10.1109/ICCICCT.2014.6993023>
- Nawaz, M., Nazir, T., Javed, A., Tariq, U., Yong, H. S., Khan, M. A., & Cha, J. (2022). An Efficient Deep Learning Approach to Automatic Glaucoma Detection Using Optic Disc and Optic Cup Localization. *Multidisciplinary Digital Publishing Institute (MDPI) Sensors*, 22(434), 1–18. <https://doi.org/10.3390/s22020434>
- Parashar, D., & Agrawal, D. (2020). Automated Classification of Glaucoma using Retinal Fundus Images. *2020 1st IEEE International Conference on Measurement, Instrumentation, Control and Automation, ICMICA 2020*, 4–5. <https://doi.org/10.1109/ICMICA48462.2020.9242702>

- Patro, S. G. K., & Sahu, K. K. (2015). Normalization: A Preprocessing Stage. *International Advanced Research Journal in Science, Engineering and Technology*, 3(2), 20–22. <https://doi.org/10.17148/IARJSET.2015.2305>
- Peng, Y., Ying, L., Kamel, M. M. A., & Wang, Y. (2021). Mesoscale Fracture Analysis of Recycled Aggregate Concrete Based on Digital Image Processing Technique. *International Federation for Structural Concrete*, 22(11172015), 1–15. <https://doi.org/10.1002/suco.201900338>
- Perez, J., Diaz, J., Garcia-Martin, J., & Tabuenca, B. (2020). Systematic Literature Reviews in Software Engineering—Enhancement of the study Selection Process using Cohen’s Kappa Statistic. *Journal of Systems and Software*, 168, 110657. <https://doi.org/10.1016/j.jss.2020.110657>
- Rahayu, P. W., Sudeda, I. G. I., Suryani, S., Surachman, A., Ridwan, A., Darmawiguna, I. G. M., Sutoyo, M. N., Slamet, I., Harlina, S., & Maysanjaya, I. M. D. (2024). *Buku Ajar Data Mining* (Efitra (ed.)), PT. Sonpedia Publishing Indonesia. Diakses pada tanggal 1 April 2024, dari : <https://books.google.co.id/books?id=vCruEAAAQBAJ&lpg=PA97&dq=Normalisasi%20data%20adalah%20proses%20transformasi%20data%20yang%20berujuan%20untuk%20mengubah%20skala%20data%20sehingga%20data%20berada%20dalam%20rentang%20atau%20distribusi%20tertentu.%20&hl=id&pg=PA97#v=onepage&q=normalisasi&f=false>
- Rana, R. (2016). Gated Recurrent Unit (GRU) for Emotion Classification from Noisy Speech. *Computer Science Human-Computer Interaction*, 16(12), 1–9. <https://doi.org/10.48550/arXiv.1612.07778>
- Salam, A. A., Khalil, T., Akram, M. U., Jameel, A., & Basit, I. (2016). Automated Detection of Glaucoma Using Structural and Non Structural Features. *SpringerPlus*, 5(1519), 1–21. <https://doi.org/10.1186/s40064-016-3175-4>
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted Residuals and Linier Bottlenecks. *Institute of Electrical and Electronics Engineers (IEEE) Conference on Computer Vision Foundation (CVPR)*, 4510–4520. <https://doi.org/10.48550/arXiv.1801.04381>
- Sibarani, J. N., Sirait, D. R., & Ramadhanti, S. S. (2023). Intrusion Detection Systems pada Bot-IoT Dataset Menggunakan Algoritma Machine Learning. *Jurnal Masyarakat Informatika*, 14(1), 38–52. <https://doi.org/10.14710/jmasif.14.1.49721>
- Setiawan, W. (2020). *Deep Learning menggunakan Convolutional Neural Network Teori dan Aplikasi.*, Media Nusa Creative. Diakses pada tanggal 2 April 2024, tersedia di : [https://books.google.co.id/books?id=sE9LEAAAQBAJ&newbks=1&newbks\\_redir=0&lpg=PP1&hl=id&pg=PP1#v=onepage&q&f=false](https://books.google.co.id/books?id=sE9LEAAAQBAJ&newbks=1&newbks_redir=0&lpg=PP1&hl=id&pg=PP1#v=onepage&q&f=false)
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(60), 1–48. <https://doi.org/10.1186/s40537-019-0197-0>

- 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. *Institute of Electrical and Electronics Engineers (IEEE) Access*, 7, 71696–71717. <https://doi.org/10.1109/ACCESS.2019.2920616>
- Sreng, S., Maneerat, N., Hamamoto, K., & Win, K. Y. (2020). Deep Learning for Optic Disc Segmentation and Glaucoma Diagnosis on Retinal Images. *Multidisciplinary Digital Publishing Institute (MDPI) Applied Sciences*, 10(14), 4916–4934. <https://doi.org/10.3390/app10144916>
- Suwanda, A. E., & Juniati, D. (2022). Klasifikasi Penyakit Mata Berdasarkan Citra Fundus Retina Menggunakan Dimensi Fraktal Box Counting Dan Fuzzy K-Means. *Jurnal Penelitian Matematika Dan Pendidikan Matematika*, 5(1), 10–18. <https://doi.org/10.30605/proximal.v5i1.1623>
- Tang, S., Yuan, S., & Zhu, Y. (2020). Data Preprocessing Techniques in Convolutional Neural Network Based on Fault Diagnosis Towards Rotating Machinery. *Institute of Electrical and Electronics Engineers (IEEE) Access*, 8, 149487–149496. <https://doi.org/10.1109/ACCESS.2020.3012182>
- Thakur, N., & Juneja, M. (2018). Survey on Segmentation and Classification Approaches of Optic Cup and Optic Disc for Diagnosis of Glaucoma. *Biomedical Signal Processing and Control*, 42, 162–189. <https://doi.org/10.1016/j.bspc.2018.01.014>
- Urolagin, S., Sharma, N., & Datta, T. K. (2021). A Combined Architecture of Multivariate LSTM with Mahalanobis and Z-Score Transformations for Oil Price Forecasting. *Energy*, 231(120963), 1–13. <https://doi.org/10.1016/j.energ.y.2021.120963>
- Velpula, V. K., & Sharma, L. D. (2023). Multi-stage glaucoma classification using pre-trained convolutional neural networks and voting-based classifier fusion. *Frontiers in Physiology*, 14, 1–17. <https://doi.org/10.3389/fphys.2023.1175881>
- Wan, Y., & Xie, Q. (2016, August 27-28). A Novel Framework for Optimal RGB to Grayscale Image Conversion. Proceedings - 2016 8th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC), Hangzhou, China. <https://doi.org/10.1109/IHMSC.2016.201>
- Wang, Y., Liao, W., & Chang, Y. (2018). Gated Recurrent Unit Network-Based Short-Term Photovoltaic Forecasting. *Energies*, 11(8), 1–14. <https://doi.org/10.3390/en11082163>
- Wu, K., Zhang, S., & Xie, Z. (2020). Monocular Depth Prediction With Residual DenseASPP Network. *Institute of Electrical and Electronics Engineers (IEEE) Access*, 8, 129899–129910. <https://doi.org/10.1109/ACCESS.2020.3006704>
- Xu, C., Coen-Pirani, P., & Jiang, X. (2023). Empirical Study of Overfitting in Deep Learning for Predicting Breast Cancer Metastasis. *Cancers* 2023, 15(7), 1–18. <https://doi.org/10.3390/cancers15071969>

- Yendrizal. (2021). *Monograf Algoritma C4.5 Pada Teknik Klasifikasi Penyusutan Volume Pupuk* (S. Moh (ed.)). Azka Pustaka., Diakses pada tanggal 2 April 2024, dari :[https://play.google.com/books/reader?id=gsldeAAAQBAJ&pg=G\\_BS.PR1&hl=id](https://play.google.com/books/reader?id=gsldeAAAQBAJ&pg=G_BS.PR1&hl=id)
- Yi, D., Ahn, J., & Ji, S. (2020). An Effective Optimization Method for Machine Learning based on ADAM. *Applied Sciences (Switzerland)*, 10(1073), 1–20. <https://doi.org/10.3390/app10031073>
- Zhou, F., Hang, R., Liu, Q., & Yuan, X. (2018). Integrating Convolutional Neural Network and Gated Recurrent Unit for Hyperspectral Image Spectral-Spatial Classification. In *Lecture Notes in Computer Science (LNIP)*. 11259, 409–420. [https://doi.org/10.1007/978-3-030-03341-5\\_34](https://doi.org/10.1007/978-3-030-03341-5_34)
- Zhou, T., Ye, X., Lu, H., Zheng, X., Qiu, S., & Liu, Y. (2022). Dense Convolutional Network and Its Application in Medical Image Analysis. *BioMed Research International*, 2022, 1–22. <https://doi.org/10.1155/2022/2384830>
- Zhu, Y., Luo, H., Zhao, F., & Chen, R. (2021). Indoor/Outdoor Switching Detection Using Multisensor DenseNet and LSTM. *Institute of Electrical and Electronics Engineers (IEEE) Internet of Things Journal*, 8(3), 1544–1556. <https://doi.org/10.1109/JIOT.2020.3013853>
- Zulqarnain, M., Ishak, S. A., Ghazali, R., & Nawi, N. M. (2020). An Improved Deep Learning Approach Based on Variant Two-state Gated Recurrent Unit and Word Embeddings for Sentiment Classification. *International Journal of Advanced Computer Science and Applications*, 11(1), 594–603. <https://doi.org/10.14569/ijacsa.2020.0110174>