

**IMPLEMENTASI AUGMENTASI DAN MODIFIKASI  
ARSITEKTUR *DENSENET-DWS* DALAM  
KLASIFIKASI PENYAKIT GLAUKOMA  
PADA CITRA RETINA**

**SKRIPSI**

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

**Oleh :**

**Teddi Pranata**

**NIM 08011181823006**



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

**2022**

**LEMBAR PENGESAHAN**

**IMPLEMENTASI AUGMENTASI DAN MODIFIKASI ARSITEKTUR  
DENSENET-DES DALAM KLASIFIKASI PENYAKIT GLAUKOMA  
PADA CITRA RETINA**

**SKRIPSI**

**Sebagai Salah Satu Syarat untuk Memperoleh Gelar Sarjana Matematika**

**Oleh**

**TEDDI PRANATA  
08011181823006**

**Indralaya, 6 Juni 2022**

**Pembimbing Kedua**



**Drs. Sugandi Yahdin, M.M  
NIP. 195807271986031003**

**Pembimbing Utama**



**Anita Desiani, M.Kom  
NIP. 19771211 2003122002**

**Mengetahui,  
Ketua Jurusan Matematika**



**Drs. Sugandi Yahdin, M.M  
NIP. 195807271986031003**

## PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Teddi Pranata

NIM : 08011181823006

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 pemenuhan persyaratan untuk memperoleh gelar kesarjanaan srata (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain. Semua informasi yang dimuat dalam skripsi ini berasal dari penullis 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, 9 Juli 2022  
Penulis



Teddi Pranata  
NIM.08011181823006

**HALAMAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK  
KEPENTINGAN AKADEMIS**

Sebagai Civitas Akademik Universitas Sriwijaya, yang bertanda tangan di bawah ini :

Nama Mahasiswa : Teddi Pranata  
NIM : 08011181823006  
Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam/Matematika  
Jenis Karya : Skripsi

Demi pengembangan ilmu pengetahuan, saya menyetujui untuk memberikan kepada Universitas Sriwijaya “Implementasi Augmentasi dan Modifikasi Arsitektur *DesneNet-DWS* dalam Klasifikasi Penyakit Glaukoma pada Citra Retina”. Dengan hak bebas royalti non-eksklusif ini Universitas Sriwijaya berhak menyimpan, mengalih, edit/memformatkan, mengelola dalam bentuk pangkalan data (*database*), merawat, dan mempublikasikan tugas akhir atau skripsi saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan sebagai pemilik hak cipta.

Demikian pernyataan ini saya buat dengan sesungguhnya.

Indralaya, 9 Juli 2022

Penulis



Teddi Pranata

NIM.08011181823006

## **HALAMAN PERSEMBAHAN**

*Kupersembahkan skripsi ini untuk:*

*Yang Maha Kuasa Allah Subhanahu Wa Ta'ala*

*Kedua Orang tuaku Tersayang*

*Saudara-saudaraku tercinta*

*Keluarga besarku,*

*Semua guru dan dosenku,*

*Sahabat-sahabatku,*

*Almamaterku*

### **Motto**

*“Sesulit apapun jalan yang dilalui tetaplah berjalan mencapai tujuan”*

## KATA PENGANTAR

Puji syukur kehadirat Allah Subhanahu Wa Ta'ala yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi yang berjudul “Implementasi Metode Augmentasi dan Modifikasi Arsitektur *DenseNet-DWS* dalam Klasifikasi Penyakit Glaukoma pada Citra Retina” sebagai salah satu syarat memperoleh gelar sarjana sains bidang studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Penulis menyadari bahwa proses 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 tuaku tercinta, Arti Maladewi dan Darmawi, yang tak pernah lelah mendidik, menasehati, membimbing, mendukung dan tersu mendo'akan anaknya. Semoga semua yang telah dilakukan menjadi amal ibadah. Penulis juga mengucapkan terima kasih kepada :

1. Bapak Drs Sugandi Yahdin, M.M selaku Ketua Jurusan Matematika FMIPA Universitas Sriwijaya dan Pembimbing Pembantu yang telah memberikan arahan dan motivasi kepada penulis selama proses perkuliahan dan bimbingan skripsi ini dan Ibu Dr. Dian Cahyawati Sukanda, M.Si selaku Sekretaris Jurusan Matematika FMIPA Universitas Sriwijaya yang telah mengarahkan urusan akademik kepada penulis.

2. **Ibu Anita Desiani, S.Si, M.Kom selaku dosen Pembimbing Utama, Ibu Endang Sri Kresnawati, M.Si, dan Bapak Drs. Ali Amran, M.T selaku dosen pembahas skripsi yang telah bersedia meluangkan waktu, tenaga, pikiran untuk memberikan bimbingan, pengarahan dan didikan berharga selama proses pembuatan skripsi, kompetisi atau program mahasiswa, dan perjalanan perkuliahan ini. Insya Allah, semua yang telah bapak ibu berikan kepada penulis akan menjadi manfaat untuk penulis dan orang disekitar.**
3. **Bapak Drs. Putra Bahtera Jaya Bangun, M.Si, selaku dosen pembimbing akademik yang telah membimbing dan mengarahkan urusan akademik penulis. Seluruh Dosen di Jurusan Matematika FMIPA yang telah memberikan ilmu, nasihat, serta bimbingan selama proses perkuliahan. Pak Irwansyah selaku admin dan Ibu Hamidah selaku pegawai tata usaha Jurusan Matematika FMIPA yang telah membantu penulis selama perkuliahan.**
4. **Kakak perempuanku tersayang Septi Handayani, serta adik-adikku tersayang Azizah Zulaika dan Muhammad Al Ghifari.**
5. **Kakak-kakak tingkat angkatan 2016 dan 2017 bidang minat komputasi yang telah banyak membantu serta berbagi ilmu selama proses skripsi.**
6. **Anak *Homesick* yang tidak pernah lelah menemani penulis selama proses skripsi ini.**
7. **Semua sahabat seperjuangan selama masa perkuliahan dan skripsi ini. Terima kasih sudah menjadi orang-orang baik dan yang menjadi**

**penyemangat disekeliling penulis yang selalu mendukung, membantu, dan memberikan semangat kepada penulis.**

- 8. Keluarga Matematika 2018, BPH Himastik Gelora Karya, Anggota Legislatif DPM KM UNSRI Parlemen Lebah Merah, BPH Kosmic 2019/2020, dan Asisten Laboratorium Komputasi 2019/2020 dan 2020/2021 selama perkuliahan.**
- 9. Serta semua pihak yang tidak dapat penulis sebutkan satu per satu, semoga segala kebaikan yang diberikan mendapat balasan terbaik dari Allah.**

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

**Indralaya, 4 Juni 2022**

**Penulis**



# **IMPLEMENTATION OF AUGMENTATION METHODS AND MODIFICATION OF DENSENET-DWS ARCHITECTURE IN CLASSIFICATION OF GLAUCOMA DISEASE IN RETINA IMAGE**

By  
**Teddi Pranata**  
**08011181823006**

## **ABSTRACT**

Convolutional Neural Network (CNN) is a method that is often used in the process of image classification. CNN requires large and balanced data for each class in the training process, but the data used in this study is still relatively small and the number in each class is still not balanced, so we need a method to increase data, namely augmentation. DenseNet architecture is part of the CNN method that can be used to classify glaucoma disease, but DenseNet applies dense network exploitation that can increase the number of parameters, thereby reducing computational efficiency. Addition of depthwise separable convolution and dense layer at the end of the model will again increase the computational efficiency. The stages of the research carried out include data description, data augmentation, image repaired, training, testing, model evaluation, analysis and interpretation of results, and conclusion. The results of the evaluation of the model obtained are the values of accuracy, sensitivity, specificity, f1-score, and Cohens kappa respectively 90.32%, 85.63%, 92.82%, 85.45%, and 78.23%. Based on the results of the evaluation of the model, it was found that the augmentation and modification of the DenseNet architecture was able to classify the glaucoma disease in the image given well.

Keyword : Classification, Glaucoma, DenseNet, Augmentation

# IMPLEMENTASI AUGMENTASI DAN MODIFIKASI ARSITEKTUR *DENSENET-DWS* DALAM KLASIFIKASI PENYAKIT GLAUKOMA PADA CITRA RETINA

Oleh:  
Teddi Pranata  
08011181823006

## ABSTRAK

*Convolutional Neural Network* (CNN) merupakan metode yang sering digunakan dalam proses klasifikasi citra. CNN membutuhkan data yang besar dan seimbang pada setiap kelasnya dalam proses *training*, akan tetapi jumlah data pada penelitian ini masih tergolong sedikit dan jumlah pada setiap kelasnya masih belum seimbang, sehingga dibutuhkan suatu metode untuk memperbanyak data, yaitu augmentasi. Arsitektur *DenseNet* merupakan bagian dari metode CNN yang dapat digunakan untuk mengklasifikasi penyakit glaukoma, namun *DenseNet* menerapkan eksploitasi jaringan padat yang dapat meningkatkan jumlah parameter sehingga menurunkan efisiensi komputasi. Penambahan *depthwise separable convolution* dan *dense layer* di akhir model akan kembali meningkatkan efisiensi komputasi. Tahapan penelitian yang dilakukan antara lain deskripsi data, augmentasi data, perbaikan citra, *training*, *testing*, evaluasi model, analisis dan interpretasi hasil, serta pengambilan kesimpulan. Hasil evaluasi model yang didapatkan yaitu nilai akurasi, sensitivitas, spesifisitas, *f1-score*, dan *cohens kappa* masing-masing sebesar 90,32%, 85,63%, 92,82%, 85,45%, dan 78,23%. Berdasarkan hasil evaluasi model yang diperoleh bahwa augmentasi dan modifikasi arsitektur *DenseNet* mampu melakukan klasifikasi penyakit glaukoma citra yang diberikan dengan baik.

Kata Kunci : Klasifikasi, Glaukoma, *DenseNet*, Augmentasi

## DAFTAR ISI

<b>HALAMAN JUDUL .....</b>	<b>i</b>
<b>HALAMAN PENGESAHAN .....</b>	<b>ii</b>
<b>HALAMAN PENGESAHAN .....</b>	<b>iii</b>
<b>KATA PENGANTAR.....</b>	<b>iv</b>
<b>ABSTRACT .....</b>	<b>vii</b>
<b>ABSTRAK .....</b>	<b>viii</b>
<b>DAFTAR ISI.....</b>	<b>ix</b>
<b>DAFTAR TABEL .....</b>	<b>xi</b>
<b>DAFTAR GAMBAR.....</b>	<b>xii</b>
<b>BAB I PENDAHULUAN.....</b>	<b>1</b>
1.1. Latar Belakang .....	1
1.2. Perumusan Masalah .....	3
1.3. Pembatasan Masalah.....	3
1.4. Tujuan .....	3
1.5. Manfaat .....	3
<b>BAB II TINJAUAN PUSTAKA.....</b>	<b>5</b>
2.1. Glaukoma.....	5
2.2. Citra Digital .....	5
2.3. Perbaikan Citra .....	6
2.4. Augmentasi .....	6
2.5. Klasifikasi Citra .....	6
2.6. <i>Convolution Neural Network</i> .....	7
a. Lapisan Konvolusi ( <i>Covolution Layer</i> ) .....	7
b. <i>Pooling Layer</i> .....	9
c. Fungsi Aktivasi.....	10
d. <i>Batch Normalization</i> .....	11
e. <i>Concatenate Layer</i> .....	12
f. <i>Loss Function: Categorical Cross Entropy</i> .....	13
g. <i>Optimization Function: Adam (Adaptive Momen Estimation)</i> .....	13
2.7. <i>Multi Layer Perceptron</i> .....	15
2.8. <i>DenseNet</i> .....	15
2.9. <i>Depthwise Separable Convolution</i> .....	16
2.10. <i>Confusion Matrix</i> .....	17
<b>BAB III METODOLOGI PENELITIAN .....</b>	<b>20</b>
3.1. Tempat .....	20
3.2. Waktu.....	20
3.3. Alat.....	20
3.4. Tahapan Penelitian.....	20

<b>BAB IV HASIL DAN PEMBAHASAN .....</b>	<b>25</b>
4.1. Deskripsi Data.....	25
4.2. Augmentasi Data.....	25
4.3. Perbaikan Citra .....	26
4.4. Modifikasi Arsitektur <i>DenseNet</i> dengan <i>Depthwise Separable Convolution</i> .....	27
4.5. Contoh Operasi Manual pada <i>Convolution Neural Network (CNN)</i> .....	29
4.6. <i>Training</i> .....	39
4.7. <i>Testing</i> .....	42
4.8. Evaluasi.....	44
4.9. Analisis dan Interpretasi Hasil .....	47
<b>BAB V KESIMPULAN DAN SARAN .....</b>	<b>49</b>
5.1. Kesimpulan .....	49
5.2. Saran .....	49
<b>DAFTAR PUSTAKA .....</b>	<b>51</b>
<b>LAMPIRAN.....</b>	<b>59</b>

## DAFTAR TABEL

Tabel 2.1. Tabel <i>Confusion Matrix</i> Ukuran $3 \times 3$ .....	17
Tabel 2.2. Pengkategorian Nilai Kinerja Model .....	19
Tabel 4.1. Sampel Citra Glaukoma Tiap Kelas .....	25
Tabel 4.2. Hasil Proses Augmentasi .....	26
Tabel 4.3. Hasil Perbaikan Citra .....	27
Tabel 4.4. Bobot untuk Setiap Piksel Citra .....	42
Tabel 4.5. <i>Confusion Matrix Multiclass</i> dari Proses <i>Training</i> .....	43
Tabel 4.6. Perbandingan Hasil Evaluasi pada Setiap kelas.....	47

## DAFTAR GAMBAR

Gambar 2.1. Gambar Glakoma pada Retina .....	5
Gambar 2.2 Ilustrasi Citra Digital.....	6
Gambar 2.3. Ilustrasi <i>Convolution Layer</i> .....	8
Gambar 2.4. Ilustrasi <i>Average Pooling</i> .....	9
Gambar 2.5. Ilustrasi <i>Concatenate Layer</i> .....	12
Gambar 2.6. Ilustrasi Arsitektur <i>DenseNet</i> .....	15
Gambar 2.7. Ilustrasi <i>Depthwise Separable Convolution</i> .....	16
Gambar 3.1. Flowchart Tahapan Metode Penelitian.....	24
Gambar 4.1. Ilustrasi Modifikasi Arsitektur <i>DenseNet</i> .....	24
Gamabr 4.2. Proses Partisi Matriks <i>Average Pooling</i> .....	34
Gambar 4.3. Hasil Proses <i>Concatenate</i> .....	35
Gambar 4.4. Hasil <i>Training</i> Model Modifikasi <i>DenseNet</i> .....	40
Gambar 4.5. Grafik Akurasi pada Proses <i>Training</i> .....	41
Gambar 4.6. Grafik <i>Loss</i> pada Proses <i>Training</i> .....	41

# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang

Ketersediaan jumlah data untuk klasifikasi penyakit glaukoma yang terbatas dapat mempengaruhi proses *training* data pada metode *Convolution Neural Network* (CNN), salah satu dataset yang tersedia adalah koleksi Kim's Eye Hospital, dataset ini hanya memiliki 1544 data dan belum seimbang pada setiap kelasnya, sehingga untuk mengatasi kekurangan data tersebut diperlukan suatu metode yang disebut metode augmentasi. Augmentasi menerapkan teknik *flipping* dan rotasi pada citra asli, sehingga fitur pada citra asli tidak berubah. Hosny *et al* (2019) pada klasifikasi lesi kulit dengan menggunakan data citra gabungan dari *Dermatology Information System* dan *DermQuest* dengan jumlah data sebanyak 2.000 data, kemudian diperbanyak dengan augmentasi menjadi 144.000 data. Hasil tanpa augmentasi memperoleh nilai rata-rata sebesar 87,71%, sedangkan hasil dengan augmentasi memperoleh nilai rata-rata sebesar 96,90%.

Keterbatasan lain dari CNN terletak pada arsitektur yang memiliki lapisan mendalam pada prosesnya, salah satunya arsitektur *DenseNet*. *DenseNet* memiliki kelebihan yang memungkinkan penggunaan kembali fitur lapisan sebelumnya pada lapisan berikutnya. Kelemahan arsitektur *DenseNet* terdapat eksploitasi jaringan padat yang dapat menurunkan efisiensi komputasi penggunaan parameternya yang besar (Khan *et al.*, 2020; Song *et al.*, 2019). Ovreiu *et al* (2020) menggunakan data citra gabungan dari RETINA, ACRIMA dan RIM-ONE

dengan jumlah total data sebanyak 856 data yang diklasifikasi dengan arsitektur *DenseNet* menghasilkan nilai akurasi sebesar dan *f1-score* diatas 95% akan tetapi tidak memberikan nilai evaluasi yang lain. Zhen *et al* (2018) pada klasifikasi glaukoma menggunakan data citra dari koleksi Beijing Tongren Hospital dengan jumlah data 5.978 citra, dengan arsitektur *DenseNet* menghasilkan nilai *recall*, presisi, dan *f1-score* masih dibawah 70%, akan tetapi nilai *cohens kappa* sudah diatas 80%.

*Depthwise Separable Convolutions* (DWS) memiliki 2 kali proses konvolusi yang dapat mengurangi komputasi dan membangun jaringan yang ringan (W. C. Chen *et al.*, 2019). Kassani *et al* (2020) memodifikasi arsitektur *DenseNet* dengan DWS pada *MobileNet* pada klasifikasi Biopsi Histopatologi dengan data BreakHis yang berjumlah 7.909 data menghasilkan nilai evaluasi model diatas 98%. Q. Li *et al* (2021) yang memodifikasi *DenseNet* dan DWS pada klasifikasi penyakit *COVID-19* menggunakan data citra gabungan *COVID-SIRM*, *COVID-Seg*, and *COVID19-CT* yang berjumlah 2.541 data menghasilkan nilai evaluasi model diatas 99%. Kedua penelitian tersebut memberikan hasil yang cukup baik, akan tetapi tidak memberikan nilai *cohens kappa*.

Berdasarkan kebutuhan data yang banyak dan keterbatasan dari arsitektur *DenseNet*, maka pada penelitian ini berfokus pada implementasi augmentasi dan modifikasi arsitektur *DenseNet* dengan *Depthwise Separable Convolution* atau disebut *DenseNet-DWS* untuk mendapatkan nilai evaluasi model yang lebih akurat pada klasifikasi penyakit glaukoma dengan memperhatikan hasil akurasi, sensitivitas, spesifisitas, *f1-score*, dan *cohens kappa*.



## 1.2. Perumusan Masalah

Bagaimana implementasi augmentasi dan model modifikasi arsitektur *DenseNet-DWS* dalam klasifikasi penyakit glaukoma.

## 1.3. Batasan Masalah

Penelitian ini hanya terbatas pada data yang bersumber dari koleksi Kim's Eye Hospital yang dapat diakses melalui link : <https://dataverse.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/1YRRAC> yang diperbanyak menggunakan metode augmentasi dengan operasi *flipping* dan rotasi. Nilai evaluasi model yang digunakan hanya nilai akurasi, sensitivitas, spesifisitas, *f1-score*, dan *cohens kappa*.

## 1.4. Tujuan

Tujuan dari penelitian ini adalah untuk mendapatkan hasil akurasi, sensitivitas, spesifisitas, *f1-score*, dan *cohens kappa* yang terbaik dalam klasifikasi penyakit glaukoma.

## 1.5. Manfaat

Manfaat dari hasil penelitian ini:

1. Dapat diperoleh model yang mampu mengklasifikasi penyakit glaukoma yang lebih akurat dari citra retina yang baru.

- 
2. Dapat digunakan sebagai referensi bagi peneliti yang akan melakukan penelitian pada bidang klasifikasi, khususnya dalam klasifikasi penyakit glaukoma dan pengembangan *Deep Learning*.

## DAFTAR PUSTAKA

- Badriyah, T., Santoso, D. B., Syarif, I., & Syarif, D. R. (2019). Improving stroke diagnosis accuracy using hyperparameter optimized deep learning. *International Journal of Advances in Intelligent Informatics*, 5(3), 256–272. <https://doi.org/10.26555/ijain.v5i3.427>
- Bubb, L., Mathews, D., Oehring, D., & Harper, R. A. (2021). *Ophthalmic nurse practitioner assessment of glaucoma: evaluating agreement within an initiative to enhance capacity in glaucoma clinics*. 3258–3265. <https://doi.org/10.1038/s41433-021-01394-4>
- Burana-anusorn, C., Kongprawechnon, W., Kondo, T., & Sintuwong, S. (2013). Image Processing Techniques for Glaucoma Detection Using the Cup-to-Disc Ratio. *Science & Technology Asia*, 18(1), 22–34.
- Chen, C., Chuah, J. H., Ali, R., & Wang, Y. (2021). Retinal vessel segmentation using deep learning: A review. *IEEE Access*, 9, 111985–112004. <https://doi.org/10.1109/ACCESS.2021.3102176>
- Chen, W. C., Chang, C. C., & Lee, C. R. (2019). Knowledge Distillation with Feature Maps for Image Classification. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics): Vol. 11363 LNCS*. Springer International Publishing. [https://doi.org/10.1007/978-3-030-20893-6\\_13](https://doi.org/10.1007/978-3-030-20893-6_13)
- Chen, W., Yang, B., Li, J., & Wang, J. (2020). An approach to detecting diabetic retinopathy based on integrated shallow convolutional neural networks. *IEEE Access*, 8, 178552–178562. <https://doi.org/10.1109/ACCESS.2020.3027794>
- de la Torre, J., Puig, D., & Valls, A. (2018). Weighted kappa loss function for multi-class classification of ordinal data in deep learning. *Pattern Recognition Letters*, 105, 144–154. <https://doi.org/10.1016/j.patrec.2017.05.018>
- De Moura Lima, A. C., Maia, L. B., Pinheiro Pereira, R. M., Junior, G. B., Dallyson Sousa De Almeida, J., & De Paiva, A. C. (2018). Glaucoma Diagnosis over Eye Fundus Image through Deep Features. *International Conference on Systems, Signals, and Image Processing, 2018-June*, 1–5. <https://doi.org/10.1109/IWSSIP.2018.8439477>
- Deng, X., Liu, Q., Deng, Y., & Mahadevan, S. (2016). An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Information Sciences*, 340–341, 250–261. <https://doi.org/10.1016/j.ins.2016.01.033>
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). Fundamental concepts of convolutional neural network. In *Intelligent Systems Reference Library* (Vol. 172, Issue June). <https://doi.org/10.1007/978-3-030-32644->

9\_36

- Hosny, K. M., Kassem, M. A., & Foad, M. M. (2019). Classification of skin lesions using transfer learning and augmentation with Alex-net. *PLoS ONE*, *14*(5), 1–17. <https://doi.org/10.1371/journal.pone.0217293>
- Huang, G., Liu, Z., Maaten, L. van der, & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *American Journal of Veterinary Research*.
- Hurtik, P., Molek, V., & Hula, J. (2020). Data Preprocessing Technique for Neural Networks Based on Image Represented by a Fuzzy Function. *IEEE Transactions on Fuzzy Systems*, *28*(7), 1195–1204. <https://doi.org/10.1109/TFUZZ.2019.2911494>
- Ide, H., & Kurita, T. (2017). Improvement of learning for CNN with ReLU activation by sparse regularization. *Proceedings of the International Joint Conference on Neural Networks, 2017-May*, 2684–2691. <https://doi.org/10.1109/IJCNN.2017.7966185>
- Ioffe, S., & Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *Journal of Machine Learning Research*, *37*(6), 730–743. <https://doi.org/10.1080/17512786.2015.1058180>
- Jie, H. J., & Wanda, P. (2020). Runpool: A dynamic pooling layer for convolution neural network. *International Journal of Computational Intelligence Systems*, *13*(1), 66–76. <https://doi.org/10.2991/ijcis.d.200120.002>
- Kassani, S. H., Kassani, P. H., Wesolowski, M. J., Schneider, K. A., & Deters, R. (2020). Classification of histopathological biopsy images using ensemble of deep learning networks. *CASCON 2019 Proceedings - Conference of the Centre for Advanced Studies on Collaborative Research - Proceedings of the 29th Annual International Conference on Computer Science and Software Engineering*, 92–99.
- Khan, A., Sohail, A., Zahoora, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, *53*(8), 5455–5516. <https://doi.org/10.1007/s10462-020-09825-6>
- Kirar, B. S., & Agrawal, D. K. (2019). Computer aided diagnosis of glaucoma using discrete and empirical wavelet transform from fundus images. *IET Image Processing*, *13*(1), 73–82. <https://doi.org/10.1049/iet-ipr.2018.5297>
- Lau, M. M., & Lim, K. H. (2019). Review of adaptive activation function in deep neural network. *2018 IEEE EMBS Conference on Biomedical Engineering and Sciences, IECBES 2018 - Proceedings*, 686–690. <https://doi.org/10.1109/IECBES.2018.08626714>
- Le, D. N., Parvathy, V. S., Gupta, D., Khanna, A., Rodrigues, J. J. P. C., & Shankar, K. (2021). IoT enabled depthwise separable convolution neural network with deep support vector machine for COVID-19 diagnosis and classification.

- International Journal of Machine Learning and Cybernetics*, 12(11), 3235–3248. <https://doi.org/10.1007/s13042-020-01248-7>
- Li, Q., Ning, J., Yuan, J., & Xiao, L. (2021). A depthwise separable dense convolutional network with convolution block attention module for COVID-19 diagnosis on CT scans. *Computers in Biology and Medicine*, 137(September), 104837. <https://doi.org/10.1016/j.compbimed.2021.104837>
- Li, X., Fan, P., Li, Z., Chen, G., Qiu, H., & Hou, G. (2021). Soil Classification Based on Deep Learning Algorithm and Visible Near-Infrared Spectroscopy. *Journal of Spectroscopy*, 2021. <https://doi.org/10.1155/2021/1508267>
- Li, Z., Guo, C., Lin, D., Nie, D., Zhu, Y., Chen, C., Zhao, L., Wang, J., Zhang, X., Dongye, M., Wang, D., Xu, F., Jin, C., Zhang, P., Han, Y., Yan, P., Han, Y., & Lin, H. (2020). Deep learning for automated glaucomatous optic neuropathy detection from ultra-widefield fundus images. *British Journal of Ophthalmology*, 105(11), 1548–1554. <https://doi.org/10.1136/bjophthalmol-2020-317327>
- 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*. 9803(850), 1–14. <https://doi.org/10.1117/12.2217959>
- Nath, S. S., Mishra, G., Kar, J., Chakraborty, S., & Dey, N. (2014). A survey of image classification methods and techniques. *2014 International Conference on Control, Instrumentation, Communication and Computational Technologies, ICCICCT 2014*, 554–557. <https://doi.org/10.1109/ICCICCT.2014.6993023>
- Oltu, B., Karaca, B. K., Erdem, H., & Özgür, A. (2021). *A systematic review of transfer learning based approaches for diabetic retinopathy detection*. <http://arxiv.org/abs/2105.13793>
- Ovrei, S., Cristescu, I., Balta, F., & Ovrei, E. (2020). An Exploratory Study for Glaucoma Detection using Densely Connected Neural Networks. *2020 8th E-Health and Bioengineering Conference, EHB 2020*, 4–7. <https://doi.org/10.1109/EHB50910.2020.9280173>
- Powers, D. M. W. (2015). *Evaluation Evaluation a Monte Carlo study*. 1–5. <http://arxiv.org/abs/1504.00854>
- Rathi, S., Andrews, C. A., Greenfield, D. S., & Stein, J. D. (2020). Trends in Glaucoma Surgeries Performed by Glaucoma Subspecialists versus Nonspecialists on Medicare Beneficiaries from 2008 through 2016. *Ophthalmology*, 128(1), 30–38. <https://doi.org/10.1016/j.ophtha.2020.06.051>
- Santra, A. K., & Christy, C. J. (2012). Genetic Algorithm and Confusion Matrix for Document Clustering. *International Journal of Computer Science Issues*,

9(1), 322–328.

- Santurkar, S., Tsipras, D., Ilyas, A., & Madry, A. (2018). How does batch normalization help optimization? *Advances in Neural Information Processing Systems, 2018-Decem*(NeurIPS), 2483–2493.
- Serener, A., & Serte, S. (2019). Transfer learning for early and advanced glaucoma detection with convolutional neural networks. *TIPTEKNO 2019 - Tip Teknologileri Kongresi*, 1–4. <https://doi.org/10.1109/TIPTEKNO.2019.8894965>
- Song, J. M., Kim, W., & Park, K. R. (2019). Finger-Vein Recognition Based on Deep DenseNet Using Composite Image. *IEEE Access*, 7, 66845–66863. <https://doi.org/10.1109/ACCESS.2019.2918503>
- 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, 71696–71717. <https://doi.org/10.1109/ACCESS.2019.2920616>
- Wang, Q., & Yuan, Y. (2014). Learning to resize image. *Computer Vision and Pattern Recognition*, 131, 357–367. <https://doi.org/10.1016/j.neucom.2013.10.007>
- Warrens, M. J. (2015). Five Ways to Look at Cohen's  $\kappa$ . *Journal of Psychology & Psychotherapy*, 05(04), 8–11. <https://doi.org/10.4172/2161-0487.1000197>
- Wu, H., & Zhao, J. (2018). Deep convolutional neural network model based chemical process fault diagnosis. *Computers and Chemical Engineering*, 115, 185–197. <https://doi.org/10.1016/j.compchemeng.2018.04.009>
- Xia, D. H., Song, S., Tao, L., Qin, Z., Wu, Z., Gao, Z., Wang, J., Hu, W., Behnamian, Y., & Luo, J. L. (2020). Review-material degradation assessed by digital image processing: Fundamentals, progresses, and challenges. *Journal of Materials Science and Technology*, 53, 146–162. <https://doi.org/10.1016/j.jmst.2020.04.033>
- Zhao, Y., & Wang, L. (2019). The Application of Convolution Neural Networks in Sign Language Recognition. *9th International Conference on Intelligent Control and Information Processing, ICICIP 2018*, 8(3), 269–272. <https://doi.org/10.1109/ICICIP.2018.8606707>
- Zhen, Y., Wang, L., Liu, H., Zhang, J., & Pu, J. (2018). Performance assessment of the deep learning technologies in grading glaucoma severity. *Computer Vision and Pattern Recognition*.
- Badriyah, T., Santoso, D. B., Syarif, I., & Syarif, D. R. (2019). Improving stroke diagnosis accuracy using hyperparameter optimized deep learning. *International Journal of Advances in Intelligent Informatics*, 5(3), 256–272. <https://doi.org/10.26555/ijain.v5i3.427>

- Bubb, L., Mathews, D., Oehring, D., & Harper, R. A. (2021). *Ophthalmic nurse practitioner assessment of glaucoma: evaluating agreement within an initiative to enhance capacity in glaucoma clinics*. 3258–3265. <https://doi.org/10.1038/s41433-021-01394-4>
- Burana-anusorn, C., Kongprawechnon, W., Kondo, T., & Sintuwong, S. (2013). Image Processing Techniques for Glaucoma Detection Using the Cup-to-Disc Ratio. *Science & Technology Asia*, 18(1), 22–34.
- Chen, C., Chuah, J. H., Ali, R., & Wang, Y. (2021). Retinal vessel segmentation using deep learning: A review. *IEEE Access*, 9, 111985–112004. <https://doi.org/10.1109/ACCESS.2021.3102176>
- Chen, W. C., Chang, C. C., & Lee, C. R. (2019). Knowledge Distillation with Feature Maps for Image Classification. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics): Vol. 11363 LNCS*. Springer International Publishing. [https://doi.org/10.1007/978-3-030-20893-6\\_13](https://doi.org/10.1007/978-3-030-20893-6_13)
- Chen, W., Yang, B., Li, J., & Wang, J. (2020). An approach to detecting diabetic retinopathy based on integrated shallow convolutional neural networks. *IEEE Access*, 8, 178552–178562. <https://doi.org/10.1109/ACCESS.2020.3027794>
- de la Torre, J., Puig, D., & Valls, A. (2018). Weighted kappa loss function for multi-class classification of ordinal data in deep learning. *Pattern Recognition Letters*, 105, 144–154. <https://doi.org/10.1016/j.patrec.2017.05.018>
- De Moura Lima, A. C., Maia, L. B., Pinheiro Pereira, R. M., Junior, G. B., Dallyson Sousa De Almeida, J., & De Paiva, A. C. (2018). Glaucoma Diagnosis over Eye Fundus Image through Deep Features. *International Conference on Systems, Signals, and Image Processing, 2018-June*, 1–5. <https://doi.org/10.1109/IWSSIP.2018.8439477>
- Deng, X., Liu, Q., Deng, Y., & Mahadevan, S. (2016). An improved method to construct basic probability assignment based on the confusion matrix for classification problem. *Information Sciences*, 340–341, 250–261. <https://doi.org/10.1016/j.ins.2016.01.033>
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). Fundamental concepts of convolutional neural network. In *Intelligent Systems Reference Library* (Vol. 172, Issue June). [https://doi.org/10.1007/978-3-030-32644-9\\_36](https://doi.org/10.1007/978-3-030-32644-9_36)
- Hosny, K. M., Kassem, M. A., & Foad, M. M. (2019). Classification of skin lesions using transfer learning and augmentation with Alex-net. *PLoS ONE*, 14(5), 1–17. <https://doi.org/10.1371/journal.pone.0217293>
- Huang, G., Liu, Z., Maaten, L. van der, & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *American Journal of Veterinary Research*.

- Hurtik, P., Molek, V., & Hula, J. (2020). Data Preprocessing Technique for Neural Networks Based on Image Represented by a Fuzzy Function. *IEEE Transactions on Fuzzy Systems*, 28(7), 1195–1204. <https://doi.org/10.1109/TFUZZ.2019.2911494>
- Ide, H., & Kurita, T. (2017). Improvement of learning for CNN with ReLU activation by sparse regularization. *Proceedings of the International Joint Conference on Neural Networks*, 2017-May, 2684–2691. <https://doi.org/10.1109/IJCNN.2017.7966185>
- Ioffe, S., & Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift. *Journal of Machine Learning Research*, 15, 730–743. <https://doi.org/10.1080/17512786.2015.1058180>
- Jie, H. J., & Wanda, P. (2020). Runpool: A dynamic pooling layer for convolution neural network. *International Journal of Computational Intelligence Systems*, 13(1), 66–76. <https://doi.org/10.2991/ijcis.d.200120.002>
- Kassani, S. H., Kassani, P. H., Wesolowski, M. J., Schneider, K. A., & Deters, R. (2020). Classification of histopathological biopsy images using ensemble of deep learning networks. *CASCON 2019 Proceedings - Conference of the Centre for Advanced Studies on Collaborative Research - Proceedings of the 29th Annual International Conference on Computer Science and Software Engineering*, 92–99.
- Khan, A., Sohail, A., Zahoora, U., & Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial Intelligence Review*, 53(8), 5455–5516. <https://doi.org/10.1007/s10462-020-09825-6>
- Kirar, B. S., & Agrawal, D. K. (2019). Computer aided diagnosis of glaucoma using discrete and empirical wavelet transform from fundus images. *IET Image Processing*, 13(1), 73–82. <https://doi.org/10.1049/iet-ipr.2018.5297>
- Lau, M. M., & Lim, K. H. (2019). Review of adaptive activation function in deep neural network. *2018 IEEE EMBS Conference on Biomedical Engineering and Sciences, IECBES 2018 - Proceedings*, 686–690. <https://doi.org/10.1109/IECBES.2018.08626714>
- Le, D. N., Parvathy, V. S., Gupta, D., Khanna, A., Rodrigues, J. J. P. C., & Shankar, K. (2021). IoT enabled depthwise separable convolution neural network with deep support vector machine for COVID-19 diagnosis and classification. *International Journal of Machine Learning and Cybernetics*, 12(11), 3235–3248. <https://doi.org/10.1007/s13042-020-01248-7>
- Li, Q., Ning, J., Yuan, J., & Xiao, L. (2021). A depthwise separable dense convolutional network with convolution block attention module for COVID-19 diagnosis on CT scans. *Computers in Biology and Medicine*, 137(September), 104837. <https://doi.org/10.1016/j.compbiomed.2021.104837>



- Li, X., Fan, P., Li, Z., Chen, G., Qiu, H., & Hou, G. (2021). Soil Classification Based on Deep Learning Algorithm and Visible Near-Infrared Spectroscopy. *Journal of Spectroscopy*, 2021. <https://doi.org/10.1155/2021/1508267>
- Li, Z., Guo, C., Lin, D., Nie, D., Zhu, Y., Chen, C., Zhao, L., Wang, J., Zhang, X., Dongye, M., Wang, D., Xu, F., Jin, C., Zhang, P., Han, Y., Yan, P., Han, Y., & Lin, H. (2020). Deep learning for automated glaucomatous optic neuropathy detection from ultra-widefield fundus images. *British Journal of Ophthalmology*, 105(11), 1548–1554. <https://doi.org/10.1136/bjophthalmol-2020-317327>
- 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*. 9803(850), 1–14. <https://doi.org/10.1117/12.2217959>
- Nath, S. S., Mishra, G., Kar, J., Chakraborty, S., & Dey, N. (2014). A survey of image classification methods and techniques. *2014 International Conference on Control, Instrumentation, Communication and Computational Technologies, ICCICCT 2014*, 554–557. <https://doi.org/10.1109/ICCICCT.2014.6993023>
- Oltu, B., Karaca, B. K., Erdem, H., & Özgür, A. (2021). *A systematic review of transfer learning based approaches for diabetic retinopathy detection*. <http://arxiv.org/abs/2105.13793>
- Ovrei, S., Cristescu, I., Balta, F., & Ovrei, E. (2020). An Exploratory Study for Glaucoma Detection using Densely Connected Neural Networks. *2020 8th E-Health and Bioengineering Conference, EHB 2020*, 4–7. <https://doi.org/10.1109/EHB50910.2020.9280173>
- Powers, D. M. W. (2015). *Evaluation Evaluation a Monte Carlo study*. 1–5. <http://arxiv.org/abs/1504.00854>
- Rathi, S., Andrews, C. A., Greenfield, D. S., & Stein, J. D. (2020). Trends in Glaucoma Surgeries Performed by Glaucoma Subspecialists versus Nonspecialists on Medicare Beneficiaries from 2008 through 2016. *Ophthalmology*, 128(1), 30–38. <https://doi.org/10.1016/j.ophtha.2020.06.051>
- Santra, A. K., & Christy, C. J. (2012). Genetic Algorithm and Confusion Matrix for Document Clustering. *International Journal of Computer Science Issues*, 9(1), 322–328.
- Santurkar, S., Tsipras, D., Ilyas, A., & Madry, A. (2018). How does batch normalization help optimization? *Advances in Neural Information Processing Systems, 2018-Decem(NeurIPS)*, 2483–2493.
- Serener, A., & Serte, S. (2019). Transfer learning for early and advanced glaucoma detection with convolutional neural networks. *TIPTEKNO 2019 - Tip Teknolojileri Kongresi*, 1–4.

<https://doi.org/10.1109/TIPTEKNO.2019.8894965>

- Song, J. M., Kim, W., & Park, K. R. (2019). Finger-Vein Recognition Based on Deep DenseNet Using Composite Image. *IEEE Access*, 7, 66845–66863. <https://doi.org/10.1109/ACCESS.2019.2918503>
- 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, 71696–71717. <https://doi.org/10.1109/ACCESS.2019.2920616>
- Wang, Q., & Yuan, Y. (2014). Learning to resize image. *Computer Vision and Pattern Recognition*, 131, 357–367. <https://doi.org/10.1016/j.neucom.2013.10.007>
- Warrens, M. J. (2015). Five Ways to Look at Cohen's  $\kappa$ . *Journal of Psychology & Psychotherapy*, 05(04), 8–11. <https://doi.org/10.4172/2161-0487.1000197>
- Wu, H., & Zhao, J. (2018). Deep convolutional neural network model based chemical process fault diagnosis. *Computers and Chemical Engineering*, 115, 185–197. <https://doi.org/10.1016/j.compchemeng.2018.04.009>
- Xia, D. H., Song, S., Tao, L., Qin, Z., Wu, Z., Gao, Z., Wang, J., Hu, W., Behnamian, Y., & Luo, J. L. (2020). Review-material degradation assessed by digital image processing: Fundamentals, progresses, and challenges. *Journal of Materials Science and Technology*, 53, 146–162. <https://doi.org/10.1016/j.jmst.2020.04.033>
- Zhao, Y., & Wang, L. (2019). The Application of Convolution Neural Networks in Sign Language Recognition. *9th International Conference on Intelligent Control and Information Processing, ICICIP 2018*, 8(3), 269–272. <https://doi.org/10.1109/ICICIP.2018.8606707>
- Zhen, Y., Wang, L., Liu, H., Zhang, J., & Pu, J. (2018). Performance assessment of the deep learning technologies in grading glaucoma severity. *Computer Vision and Pattern Recognition*.