

**KLASIFIKASI PENYAKIT *DIABETIC RETINOPATHY* MENGGUNAKAN
METODE *CONVOLUTIONAL NEURAL NETWORK* (CNN) MODEL *DEEP
RESIDUAL NETWORK* (RESNET)**

SKRIPSI



**UIN SUNAN AMPEL
S U R A B A Y A**

Disusun Oleh
ANISA NUR AZIZAH
H72217016

**PROGRAM STUDI MATEMATIKA
FAKULTAS SAINS DAN TEKNOLOGI
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL
SURABAYA**

2021

PERNYATAAN KEASLIAN

Saya yang bertanda tangan di bawah ini,

Nama : ANISA NUR AZIZAH

NIM : H72217016

Program Studi : Matematika

Angkatan : 2017

Menyatakan bahwa saya tidak melakukan plagiat dalam penulisan skripsi saya yang berjudul "KLASIFIKASI PENYAKIT *DIABETIC RETINOPATHY* MENGGUNAKAN METODE *CONVOLUTIONAL NEURAL NETWORK* (CNN) MODEL *DEEP RESIDUAL NETWORK* (RESNET)". Apabila suatu saat nanti terbukti saya melakukan tindakan plagiat, maka saya bersedia menerima sanksi yang telah ditetapkan.

Demikian pernyataan keaslian ini saya buat dengan sebenar-benarnya.

Surabaya, 25 Januari 2021

Yang menyatakan,

A 10,000 Rupiah Indonesian banknote is shown with a signature over it. The signature is in black ink and appears to be 'ANISA NUR AZIZAH'. The banknote features the Garuda Pancasila emblem and the text 'REPUBLIK INDONESIA', '10000', and 'METERAI KEASLIAN'. The serial number 'B007AJX061083157' is visible at the bottom of the note.

ANISA NUR AZIZAH
NIM. H72217016

LEMBAR PERSETUJUAN PEMBIMBING

Skripsi oleh

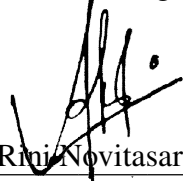
Nama : ANISA NUR AZIZAH

NIM : H72217016

Judul Skripsi : KLASIFIKASI PENYAKIT *DIABETIC RETINOPATHY*
MENGUNAKAN METODE *CONVOLUTIONAL*
NEURAL NETWORK (CNN) MODEL *DEEP RESIDUAL*
NETWORK (RESNET)

telah diperiksa dan disetujui untuk diujikan.

Pembimbing I



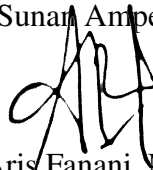
Dian C. Rini Novitasari, M. Kom
NIP. 198511242014032001

Pembimbing II



Lutfi Hakim, M.Ag
NIP. 197312252006041001

Mengetahui,
Ketua Program Studi Matematika
UIN Sunan Ampel Surabaya



Aris Fanani, M.Kom
NIP. 198701272014031002

PENGESAHAN TIM PENGUJI SKRIPSI

Skripsi oleh

Nama : ANISA NUR AZIZAH
NIM : H72217016
Judul Skripsi : *KLASIFIKASI PENYAKIT DIABETIC RETINOPATHY MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK (CNN) MODEL DEEP RESIDUAL NETWORK (RESNET)*

Telah dipertahankan di depan Tim Penguji
pada tanggal 28 Januari 2021

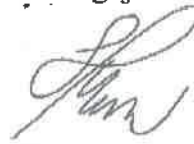
Mengesahkan,
Tim Penguji

Penguji I



Aris Fanani, M.Kom
NIP. 198701272014031002

Penguji II



Putroe Keumala Intan, M.Si
NIP. 198805282018012001

Penguji III



Dian C. Rini Navitasari, M. Kom
NIP. 198511242014032001

Penguji IV



Lutfi Hakim, M.Ag
NIP. 197312252006041001

Mengetahui,

Dekan Fakultas Sains dan Teknologi
Sunan Ampel Surabaya




Dr. Sumatar Rusydiyah, M.Ag
197312272005012003



KEMENTERIAN AGAMA
UNIVERSITAS ISLAM NEGERI SUNAN AMPEL SURABAYA
PERPUSTAKAAN

Jl. Jend. A. Yani 117 Surabaya 60237 Telp. 031-8431972 Fax.031-8413300
E-Mail: perpus@uinsby.ac.id

LEMBAR PERNYATAAN PERSETUJUAN PUBLIKASI
KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Sebagai sivitas akademika UIN Sunan Ampel Surabaya, yang bertanda tangan di bawah ini, saya:

Nama : ANISA NUR AZIZAH
NIM : H72217016
Fakultas/Jurusan : SAINTEK / MATEMATIKA
E-mail address : anisaaazizah069@gmail.com

Demi pengembangan ilmu pengetahuan, menyetujui untuk memberikan kepada Perpustakaan UIN Sunan Ampel Surabaya, Hak Bebas Royalti Non-Eksklusif atas karya ilmiah :

Skripsi Tesis Desertasi Lain-lain (.....)
yang berjudul :

KLASIFIKASI PENYAKIT DIABETIC RETINOPATHY MENGGUNAKAN METODE
CONVOLUTIONAL NEURAL NETWORK (CNN) MODEL DEEP RESIDUAL
NETWORK (RESNET)

beserta perangkat yang diperlukan (bila ada). Dengan Hak Bebas Royalti Non-Eksklusif ini Perpustakaan UIN Sunan Ampel Surabaya berhak menyimpan, mengalih-media/format-kan, mengelolanya dalam bentuk pangkalan data (database), mendistribusikannya, dan menampilkan/mempublikasikannya di Internet atau media lain secara *fulltext* untuk kepentingan akademis tanpa perlu meminta ijin dari saya selama tetap mencantumkan nama saya sebagai penulis/pencipta dan atau penerbit yang bersangkutan.

Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak Perpustakaan UIN Sunan Ampel Surabaya, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini.

Demikian pernyataan ini yang saya buat dengan sebenarnya.

Surabaya, 22 Februari 2021

Penulis

(ANISA NUR AZIZAH)

3.1. Jenis Penelitian	37
3.2. Jenis dan Sumber Data	37
3.3. Kerangka Penelitian	37
IV HASIL DAN PEMBAHASAN	43
4.1. <i>Preprocessing</i>	43
4.2. Augmentasi Data	44
4.3. Klasifikasi DR Menggunakan Metode CNN Model ResNet	50
4.4. Analisis Hasil Klasifikasi DR	65
4.5. Aplikasi Identifikasi Tingkat Keparahan Penyakit DR	69
4.6. Integrasi Keilmuan Sains dan Teknologi Pada Al Qur'an dan Hadits	72
V PENUTUP	75
5.1. Kesimpulan	75
5.2. Saran	76
DAFTAR PUSTAKA	76

4.8	Perhitungan Convolution Layer dengan $stride = 2$	53
4.9	Visualisasi Keluaran <i>Convolution Layer</i>	55
4.10	visualisasi Keluaran <i>Batch Normalization</i>	57
4.11	Visualisasi Keluaran ReLU	59
4.12	Perhitungan <i>Pooling Layer</i> dengan $Stride = 2$	60
4.13	Perhitungan <i>Pooling Layer</i> dengan $Stride = 2$	60
4.14	Perhitungan <i>Pooling Layer</i> dengan $Stride = 2$	61
4.15	(a)Visualisasi Keluaran <i>Max Pooling</i> (b)Visualisasi Keluaran <i>Average Pooling</i>	62
4.16	Perhitungan Pada <i>Addition Layer</i>	62
4.17	Grafik <i>Training</i> Pada ResNet101	66
4.18	Hasil <i>Confusion Matrix</i> Pada ResNet101	67
4.19	Tampilan Pada Halaman Utama Aplikasi Pendeteksi DR	69
4.20	Tampilan Pada Aplikasi Pendeteksi DR	70
4.21	Tampilan Pada Aplikasi Pendeteksi DR	70
4.22	Tampilan Pada Aplikasi Pendeteksi DR	71
4.23	Tampilan Pada Aplikasi Pendeteksi DR	71
4.24	Tampilan Pada Aplikasi Pendeteksi DR	72

biaya yang cukup mahal, dan rawan terjadi kesalahan (Azzopardi et al., 2015). Langkah yang diambil untuk menyelesaikan permasalahan tersebut diperlukan suatu sistem deteksi cepat dan tepat sesuai dengan tingkat keparahan DR.

Beberapa penelitian sebelumnya telah dilakukan untuk mendapatkan sistem deteksi DR dari citra fundus retina dengan melihat pembuluh darah pada retina (Ahmed and Amin, 2015). Dari penelitian Selamat, dkk ciri-ciri penderita DR dapat dilihat melalui citra retina dengan mempertimbangkan adanya *microaneurysms*, tingkat pendarahan, eksudat, dan pembuluh darah (Selamat et al., 2019). Beberapa faktor tersebut sangat sulit diidentifikasi sehingga memerlukan suatu metode ekstraksi fitur untuk mengenali tanda-tanda DR. Ekstraksi fitur tersebut akan mengambil nilai-nilai karakteristik dari suatu citra sesuai dengan keadaan yang ada. Pada penelitian Erwin, dkk digunakan metode ekstraksi fitur *Gray-Level Co-occurrence Matrix (GLCM)* dan *green channel* dalam mendeteksi *microaneurysms* dan menghapus *optic disk* untuk mendeteksi eksudat (Erwin et al., 2019). Selanjutnya Shailesh Kumar, dkk mengusulkan operasi morfologi matematika dan metode *watershed transform* untuk mendeteksi adanya pembuluh darah dan segmentasi pembuluh darah pada retina (Kumar et al., 2020)), dimana morfologi matematika tersebut merupakan kumpulan operasi non linear yang digunakan untuk pengolahan citra berdasarkan bentuk segmennya seperti dilasi, erosi, *opening*, *closing*, *top-hat transformation*, dan lainnya (Priandini et al., 2018). Beberapa penelitian tersebut menandakan bahwa untuk mendapatkan ciri fitur dari suatu citra fundus retina memerlukan suatu metode ekstraksi fitur yang baik, sehingga didapatkan informasi yang akurat.

Sebuah sistem untuk mengklasifikasikan penyakit DR yang baik, selain dilihat dari pemilihan metode ekstraksi fitur yang bagus juga memerlukan metode

pengklasifikasian yang bagus pula. Para peneliti banyak mengusulkan metode-metode seperti, metode *backpropagation neural network* oleh Suwanto Sanjaya, dkk dengan melakukan klasifikasi tingkat keparahan DR yaitu normal, *Non-Proliferative Diabetic Retinopathy* (NPDR), *Proliferative Diabetic Retinopathy* (PDR), dan *Makular Edema* (ME) menghasilkan akurasi tertinggi 56,25% (Sanjaya et al., 2018). Selanjutnya Suci Aulia, dkk membandingkan metode *K-Nearest Neighbor* (KNN) dan *Support Vector Machine* (SVM) dengan hasil akurasi sebesar 65% dan 62% pada 4 kelas klasifikasi DR yaitu normal, *mild*, *moderate*, dan *severe* (Aulia et al., 2015). Cara untuk meningkatkan akurasi pengenalan tingkat keparahan DR, Toni Arifin dan Asti Herliana menggunakan metode SVM dan *naive bayes* di mana kedua metode tersebut ditambah dengan optimasi pemilihan fitur menggunakan *Particle Swarm Optimization* (PSO) dengan nilai akurasi tertinggi adalah 76,11% dan AUC 0.827 (Arifin and Herliana, 2018). Pada beberapa penelitian tersebut hasil dari masing-masing klasifikasi masih dirasa kurang memuaskan dengan rata-rata akurasi masih dibawah 80% sehingga diperlukan suatu metode yang baik dalam mengklasifikasikan penyakit DR.

Dalam menentukan metode terbaik untuk mengekstraksi fitur suatu citra sekaligus sistem klasifikasi yang cukup bagus, *Convolutional Neural Network* (CNN) merupakan solusi yang baik (Gayathri et al., 2020; Varshni et al., 2019). Pada tahun 2020, Gayathri, dkk mengusulkan metode CNN untuk mengklasifikasikan penyakit DR (Gayathri et al., 2020). Pada tahun 2018, Burewar, dkk mengusulkan metode CNN dalam pengklasifikasian tingkat keparahan DR melalui citra fundus menjadi 5 tingkat keparahan dengan hasil akurasi 93.33% (Burewar et al., 2018). Metode CNN memanfaatkan operasi *convolution* yang diproses dengan filter-filter tertentu, sehingga menghasilkan

1. BAB I PENDAHULUAN Berisi tentang latar belakang masalah mengenai penyakit *Diabetic Retinopathy* (DR) dan cara mendeteksi penyakit tersebut, perumusan masalah, batasan masalah, tujuan dari penelitian, manfaat penelitian, dan sistematika penulisan.
2. BAB II TINJAUAN PUSTAKA Berisi landasan teori mengenai *Diabetic Retinopathy* (DR), citra fundus retina, proses augmentasi data, penjelasan mengenai metode *Convolutional Neural Network* (CNN), penjelasan mengenai metode *Deep Residual Network* (ResNet), serta metode evaluasi *confusion matrix*.
3. BAB III METODE PENELITIAN Berisi tentang jenis penelitian, sumber data yang digunakan, dan alur penelitian yang dimulai dengan pengumpulan data, tahap pengolahan, analisis pengoptimalan model, dan kesimpulan.
4. BAB IV HASIL DAN PEMBAHASAN Berisi tentang hasil dan pembahasan dari rumusan masalah yang dibuat, penjabaran proses yang dilakukan oleh peneliti, analisis dan penarikan kesimpulan dari penelitian.
5. BAB V PENUTUP Berisi tentang kesimpulan penelitian serta saran dari peneliti kepada peneliti-peneliti selanjutnya.

menunjukkan posisi diskret serta H adalah skala keabuan. Proses diskritisasi terjadi akibat pengaruh alat pengambilan suatu citra seperti kamera atau sebagainya. Besar nilai H biasanya adalah bilangan bulat pangkat dua seperti 2, 4, 8, 16, 32, dan seterusnya (Dougherty, 2020).

Pada representasi citra dibagi menjadi 3 yaitu citra biner, citra *gray scale*, dan citra RGB. Di mana citra biner merupakan citra yang terdiri dari dua nilai yaitu 0 (warna hitam) dan 1 (warna putih). Sedangkan citra *gray scale* adalah citra yang memiliki nilai dengan rentang antara 0 sampai 255. Selanjutnya citra RGB merupakan citra yang memiliki tiga komponen warna keabuan yaitu merah, hijau, dan biru dengan masing-masing komponen memiliki nilai dengan rentang antara 0 sampai 255 (Bilen, 2017).

2.3. Citra Fundus Retina

Citra fundus merupakan hasil dari pemotretan bagian belakang mata menggunakan alat *ophthalmoscope* atau *fundus photography* yang dapat dilihat pada Gambar 2.2. alat tersebut pertama kali dikenalkan oleh Hermann Von Helmholtz pada tahun 1851 dan terus dikembangkan sampai sekarang (Kaur et al., 2020). *Fundus photography* akan mengambil citra retina mata yang digunakan untuk mendiagnosis suatu penyakit.

augmentasi yaitu dengan merotasi sebesar 30° , 45° , 60° , dan 90° , serta dilakukan refleksi terhadap sumbu x dan sumbu y . Data citra kemudian dibagi secara acak sehingga 80% sebagai data *training* dan 20% sebagai data *testing*.

3. Pelatihan menggunakan Model CNN ResNet

Dalam tahap pelatihan digunakan model CNN ResNet dengan berbagai arsitektur, diantaranya ResNet18, ResNet50, dan ResNet101. Berikut ini adalah keterangan tiap arsitektur yang digunakan:

- (a) ResNet18: terdiri dari 72 *layers* yaitu 1 *layer* data, 1 *preprocessing layer*, 1 *maxpooling layer*, 20 *convolution layer*, 20 *batch normalization layer*, 17 *activation layer* ReLU, 8 *addition layer*, 1 *average pooling layer*, 1 *fully connected layer*, 1 *softmax layer*, 1 *classification layer*. Arsitektur ini dapat dilihat pada Gambar 3.3 serta penjelasan antar *layer* dapat dilihat pada Tabel 2.2.
- (b) ResNet50: terdiri dari 177 *layers* yaitu 1 *layer* data, 1 *maxpooling layer*, 53 *convolution layer*, 53 *batch normalization layer*, 49 *activation layer* ReLU, 16 *addition layer*, 1 *average pooling layer*, 1 *fully connected layer*, 1 *softmax layer*, 1 *classification layer*. Arsitektur ini dapat dilihat pada Gambar 3.4 serta penjelasan antar *layer* dapat dilihat pada Tabel 2.2.
- (c) ResNet101: terdiri dari 347 *layers* yaitu 1 *layer* data, 1 *maxpooling layer*, 104 *convolution layer*, 104 *batch normalization layer*, 100 *activation layer* ReLU, 33 *addition layer*, 1 *average pooling layer*, 1 *fully connected layer*, 1 *softmax layer*, 1 *classification layer*. Arsitektur

pooling di mana hasil *feature map* sudah berupa *array*. Selanjutnya adalah proses pengklasifikasian, hasil dari *feature map* \mathbf{x} akan dikalikan dengan bobot \mathbf{W} dan dijumlah dengan bias \mathbf{b} menggunakan Persamaan 2.10.

$$\mathbf{x} = \begin{bmatrix} 0.045 & 0.741 & 0.016 & 0.049 & 0.027 & 0 & 0.523 & \dots & 1.149 \end{bmatrix}$$

$$\mathbf{b} = \begin{bmatrix} 0.00144 & -0.00137 & -0.00042 & -0.00151 \end{bmatrix}$$

$$\mathbf{W} = \begin{bmatrix} 0.0512 & -0.0101 & -0.0106 & -0.0295 & -0.0173 & \dots & -0.0368 \\ -0.0236 & -0.0375 & 0.0397 & 0.0168 & 0.0073 & \dots & -0.0423 \\ 0.0123 & 0.0449 & 0.0573 & -0.0215 & 0.0209 & \dots & 0.0105 \\ 0.0242 & 0.0636 & 0.0549 & 0.0675 & -0.0194 & \dots & 0.06 \end{bmatrix}$$

$$f_{c_1} = 0.00144 + \sum_{i=1}^{2048} x_i W_{i,1}$$

$$= 0.00144 + ((0.045 \times 0.0512) + (0.741 \times 0.0101) + (0.016 \times -0.0106) + (0.049 \times -0.029) + (0.027 \times -0.0173) + \dots + (1.1486 \times -0.037))$$

$$= -3.6725$$

$$f_{c_2} = -0.00137 + ((0.045 \times -0.0236) + (0.741 \times -0.0375) + (0.016 \times 0.0397) + (0.049 \times 0.0168) + (0.027 \times 0.0074) + \dots + (1.1486 \times -0.0423))$$

$$= 5.1424$$

$$f_{c_3} = -0.00042 + ((0.045 \times 0.0123) + (0.741 \times 0.0449) + (0.016 \times 0.0573) + (0.049 \times -0.0215) + (0.027 \times 0.021) + \dots + (1.1486 \times 0.0106))$$

$$= -4.1343$$

$$f_{c_4} = -0.00151 + ((0.045 \times 0.0242) + (0.741 \times 0.0636) + (0.016 \times 0.0549) + (0.049 \times 0.0675) + (0.027 \times -0.0194) + \dots + (1.1486 \times 0.06))$$

$$= -2.6692$$

ResNet101. Hal tersebut dipengaruhi oleh seberapa dalam jaringan yang dipakai sehingga sistem tersebut semakin detail dalam memahami pola citra fundus retina. Rata-rata hasil dari seluruh percobaan *batchsize* pada ResNet101 didapatkan nilai akurasi sebesar 90.18%, sensitifitas sebesar 87.69%, dan spesitifitas adalah 96.37. Di mana hasil tersebut merupakan nilai yang cukup baik untuk digunakan sebagai suatu sistem pembantu keputusan para tenaga medis dalam mendiagnosa tingkat keparahan DR.

5.2. Saran

Pada penelitian mengenai klasifikasi tingkat keparahan penyakit *diabetic retinopathy* melalui citra fundus retina menggunakan metode CNN model ResNet ini masih banyak terdapat kekurangan, sehingga perbaikan dan inovasi sangat diperlukan untuk menjadikan sistem klasifikasi ini menjadi semakin baik. Beberapa hal yang disarankan penelitian mendatang yaitu:

1. Data citra fundus adalah data yang cukup sulit untuk diidentifikasi ciri-ciri DR. Perlu dilakukan tahap pengolahan citra seperti CLAHE, atau lain sebagainya. Sehingga data yang digunakan memiliki kualitas citra yang bagus dan mempermudah tahap *feature learning*.
2. Melakukan beberapa modifikasi terhadap metode klasifikasi di arsitektur CNN, karena metode ResNet termasuk metode yang cukup baik dalam hal *feature learning* namun memerlukan waktu komputasi yang lama. Sehingga diharapkan mampu menggabungkan atau memodifikasi arsitektur CNN pada *feature learning* ResNet dengan metode klasifikasi lain yang cukup bagus seperti SVM atau sebagainya.

- Azzopardi, G., Strisciuglio, N., Vento, M., and Petkov, N. (2015). Trainable COSFIRE filters for vessel delineation with application to retinal images. *Med. Image Anal.*, 19(1):46–57.
- Baldominos, A., Saez, Y., and Isasi, P. (2018). Evolutionary convolutional neural networks: An application to handwriting recognition. *Neurocomputing*, 283:38–52.
- Bilen, H. (2017). *Image Processing*.
- Burewar, S., Gonde, A. B., and Vipparthi, S. K. (2018). Diabetic Retinopathy Detection by Retinal segmentation with Region merging using CNN. In *2018 IEEE 13th Int. Conf. Ind. Inf. Syst.*, pages 136–142. IEEE.
- Darmawan, C. (2018). Musibah Di Era Modern Dalam Perspektif Pemikiran Quraish Shihab. *Yonet. J. Manaj. Dakwah*, 1(1):77–102.
- Ding, X., Lin, Z., He, F., Wang, Y., and Huang, Y. (2018). A deeply-recursive convolutional network for crowd counting. In *2018 IEEE Int. Conf. Acoust. Speech Signal Process.*, pages 1942–1946. IEEE.
- Dougherty, E. R. (2020). *Digital image processing methods*. CRC Press.
- Duh, E. J., Sun, J. K., and Stitt, A. W. (2017). Diabetic retinopathy: current understanding, mechanisms, and treatment strategies. *JCI insight*, 2(14).
- Dumoulin, V. and Visin, F. (2016). A guide to convolution arithmetic for deep learning. *arXiv Prepr. arXiv1603.07285*.
- Erwin, Nurjanah, L. A., Yurika, Y., and Noviyanti, D. S. (2019). Klasifikasi Penyakit Diabetik Retinopathy dengan Metode Naive Bayes pada Citra Retina. In *Annu. Res. Semin.*, volume 4, pages 126–131.

- Gayathri, S., Gopi, V. P., and Palanisamy, P. (2020). A lightweight CNN for Diabetic Retinopathy classification from fundus images. *Biomed. Signal Process. Control*, 62:102115.
- Guillemot, M., Heusele, C., Korichi, R., Schnebert, S., and Chen, L. (2020). Breaking Batch Normalization for better explainability of Deep Neural Networks through Layer-wise Relevance Propagation. *arXiv Prepr. arXiv2002.11018*.
- Hakim, D. M. and Rainarli, E. (2019). Convolutional Neural Network untuk Pengenalan Citra Notasi Musik. *Techno. Com*, 18(3):214–226.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016a). Deep residual learning for image recognition. In *Proc. IEEE Conf. Comput. Vis. pattern Recognit.*, pages 770–778.
- He, K., Zhang, X., Ren, S., and Sun, J. (2016b). Identity mappings in deep residual networks. In *Eur. Conf. Comput. Vis.*, pages 630–645. Springer.
- Hussain, Z., Gimenez, F., Yi, D., and Rubin, D. (2017). Differential data augmentation techniques for medical imaging classification tasks. In *AMIA Annu. Symp. Proc.*, volume 2017, page 979. American Medical Informatics Association.
- Hwang, H. B., Jee, D., and Kwon, J.-w. (2019). Characteristics of diabetic macular edema patients with serous retinal detachment. *Medicine (Baltimore)*, 98(51):e18333.
- Ide, H. and Kurita, T. (2017). Improvement of learning for CNN with ReLU activation by sparse regularization. In *2017 Int. Jt. Conf. Neural Networks*, pages 2684–2691. IEEE.

- Indrayuni, E. and Wahyudi, M. (2015). Penerapan character N-gram untuk sentiment analysis review hotel menggunakan algoritma naive bayes. *Konf. Nas. Ilmu Pengetah. dan Teknol.*, 1(1):83–88.
- Ioffe, S. and Szegedy, C. (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv Prepr. arXiv1502.03167*.
- Kaur, R., Singh, H., Samria, S., Kumar, N., Parachuri, N., Sharma, R., Francesco, B., Loewenstein, A., Bilong, Y., and Faridi, M. H. (2020). MII RetCam assisted smartphone-based fundus imaging (MSFI) A boon for paediatric retinal imaging. *Eye*, pages 1–3.
- Khojasteh, P., Aliahmad, B., and Kumar, D. K. (2018). Fundus images analysis using deep features for detection of exudates, hemorrhages and microaneurysms. *BMC Ophthalmol.*, 18(1):1–13.
- Kumar, S., Adarsh, A., Kumar, B., and Singh, A. K. (2020). An automated early diabetic retinopathy detection through improved blood vessel and optic disc segmentation. *Opt. Laser Technol.*, 121:105815.
- Lever, J., Krzywinski, M., and Altman, N. (2016). Points of significance: model selection and overfitting.
- Lucentis (2020). What are diabetic retinopathy (DR) and diabetic macular edema (DME)?
- Manliguez, C. (2016). Generalized confusion matrix for multiple classes.
- Mapayi, T., Viriri, S., and Tapamo, J.-R. (2015). Adaptive thresholding technique for retinal vessel segmentation based on GLCM-energy information. *Comput. Math. Methods Med.*, 2015.

- Pangestu, G. (2016). Deteksi kelainan pada jantung menggunakan citra ekg (elektrokardiogram) dengan metode learning vector quantization.
- Prabhu (2018). Understanding of Convolutional Neural Network (CNN)-Deep Learning.
- Priandini, D. A., Nangi, J., Muchtar, M., and Sari, J. Y. (2018). Deteksi area plat mobil menggunakan operasi morfologi citra. In *Semin. Nas. Teknol. Terap. Berbas. Kearifan Lokal*, volume 1.
- Prijono, B. (2018). Student Notes: Convolutional Neural Networks (CNN) Introduction.
- Putra, I. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101.
- Quinn, J., McEachen, J., Fullan, M., Gardner, M., and Drummy, M. (2019). *Dive into deep learning: Tools for engagement*. Corwin Press.
- Roglic, G. (2016). WHO Global report on diabetes: A summary. *Int. J. Noncommunicable Dis.*, 1(1):3.
- Salamat, N., Missen, M. M. S., and Rashid, A. (2019). Diabetic retinopathy techniques in retinal images: A review. *Artif. Intell. Med.*, 97:168–188.
- Sanjaya, S., Priyatno, A. M., Yanto, F., and Afrianty, I. (2018). Klasifikasi Diabetik Retinopati Menggunakan Wavelet Haar dan Backpropagation Neural Network. In *Semin. Nas. Teknol. Inf. Komun. dan Ind.*, pages 77–84.
- Sapada, A. O. and Arsyam, M. (2020). Ilmu Pengetahuan dan Teknologi Menurut Pandangan Islam.

- Shahdoosti, H. R. and Mirzapour, F. (2017). Spectral-spatial feature extraction using orthogonal linear discriminant analysis for classification of hyperspectral data. *Eur. J. Remote Sens.*, 50(1):111–124.
- Shorten, C. and Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *J. Big Data*, 6(1):60.
- Solomon, S. D., Chew, E., Duh, E. J., Sobrin, L., Sun, J. K., VanderBeek, B. L., Wykoff, C. C., and Gardner, T. W. (2017). Diabetic retinopathy: a position statement by the American Diabetes Association. *Diabetes Care*, 40(3):412–418.
- Suardana, I. W., Mustika, I. W., and Utami, D. A. S. (2019). Hubungan Perilaku Pencegahan dengan Kejadian Komplikasi Akut pada Pasien Diabetes Melitus. *J. Persat. Perawat Nas. Indones.*, 4(1):50–58.
- Sumitro, I. L., Ningrum, I. P., and Ramadhan, R. (2016). Aplikasi Diagnosis Penyakit Diabetes Melitus Menggunakan Metode Fuzzy Multi Criteria Decision Making. *semanTIK*, 2(1).
- Umbaugh, S. E. (2017). *Digital Image Processing and Analysis: Applications with MATLAB and CVIPtools*. CRC Press.
- Varshni, D., Thakral, K., Agarwal, L., Nijhawan, R., and Mittal, A. (2019). Pneumonia detection using CNN based feature extraction. In *2019 IEEE Int. Conf. Electr. Comput. Commun. Technol.*, pages 1–7. IEEE.
- Wang, W. and Lo, A. C. Y. (2018). Diabetic retinopathy: pathophysiology and treatments. *Int. J. Mol. Sci.*, 19(6):1816.
- Wicaksana, A. and Iswari, N. M. S. (2019). Decision Support System for Choosing

an Elective Course Using Naive Bayes Classifier. In *Int. Conf. Softw. Eng. Artif. Intell. Netw. Parallel/Distributed Comput.*, pages 97–110. Springer.

Yuen, L., Saeedi, P., Riaz, M., Karuranga, S., Divakar, H., Levitt, N., Yang, X., and Simmons, D. (2019). IDF Diabetes Atlas: Projections of the prevalence of hyperglycaemia in pregnancy in 2019 and beyond: results from the International Diabetes Federation Diabetes Atlas. *Diabetes Res. Clin. Pract.*, page 107841.

Zhang, X., Zhou, X., Lin, M., and Sun, J. (2018). Shufflenet: An extremely efficient convolutional neural network for mobile devices. In *Proc. IEEE Conf. Comput. Vis. pattern Recognit.*, pages 6848–6856.

Zhou, Y., Wang, X., Zhang, M., Zhu, J., Zheng, R., and Wu, Q. (2019). MPCE: a maximum probability based cross entropy loss function for neural network classification. *IEEE Access*, 7:146331–146341.