

**METODE *ENSEMBLE* PADA ARSITEKTUR *VGG-16* DAN
VISION TRANSFORMER DALAM KLASIFIKASI PENYAKIT
*DIABETIC RETINOPATHY***

SKRIPSI

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

Oleh:

FITRI SALAMAH

NIM 08011182025003



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

2023

LEMBAR PENGESAHAN

**METODE *ENSEMBLE* PADA ARSITEKTUR *VGG-16* DAN *VISION*
TRANSFORMER DALAM KLASIFIKASI PENYAKIT
*DIABETIC RETINOPATHY***

SKRIPSI

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

Oleh

**FITRI SALAMAH
NIM 08011182025003**

Indralaya, Desember 2023

Pembimbing Kedua



Dr. Bambang Suprihatin, S.Si., M.Si.
NIP 197101261994121001

Pembimbing Utama



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

Mengetahui,

Ketua Jurusan Matematika



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

PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan dibawah ini:

Nama Mahasiswa : Fitri Salamah

NIM : 08011182025003

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 strata satu (S1) dari Universitas Sriwijaya maupun perguruan tinggi lain.

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

Demikianlah surat pernyataan ini saya buat dengan sebenarnya,

Indralaya, 21 Januari 2024

Penulis



Fitri Salamah

NIM 08011182025003

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

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

Nama Mahasiswa : Fitri Salamah

NIM : 08011182025003

Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam/Matematika

Jenis Karya : Skripsi

Demi pengembangan ilmu pengetahuan, saya menyetujui untuk memberikan kepada Universitas Sriwijaya “Metode Ensemble Pada Arsitektur VGG-16 dan Vision Transformer dalam Klasifikasi Penyakit Diabetic Retinopathy”. Dengan hak bebas royalti non-eksklusif ini Universitas Sriwijaya berhak menyimpan, mengalih, edit/memformat, 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, 21 Januari 2024

Penulis



Fitri Salamah

NIM 08011182025003

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk :

Yang MahaKuasa Allah Subhanahu Wa Ta'ala,

Orang tuaku yang sangat kucinta,

Kakak-kakakku tersayang,

Keluarga Besarku,

Semua Guru dan Dosenku,

Teman baik yang Kubanggakan,

Almamaterku

Motto

"If you never bleed, you're never gonna grow"

-Taylor Swift

KATA PENGANTAR

Puji syukur atas kehadiran Allah *Subhanahu Wa Ta'ala* yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi berjudul “Metode *Ensemble* Pada Arsitektur *VGG-16* dan *Vision Transformer* dalam Klasifikasi Penyakit Diabetic Retinopathy”. Skripsi ini ditulis sebagai salah satu syarat memperoleh gelar sarjana sains studi Matematika di Fakultas MIPA Universitas Sriwijaya.

Penulis menyadari bahwa skripsi ini tidak mungkin terselesaikan tanpa adanya semangat, dukungan, bantuan, bimbingan dan nasihat yang diberikan berbagai pihak selama proses penyusunan ini berlangsung. Penulis mengucapkan terima kasih yang sebesar-besarnya kepada orang tua tercinta, Ayahku **Zaidan** dan Bundaku **Leny Marlina** yang tidak pernah berhenti berjuang dan memberikan yang terbaik untukku sebagai putrinya, terkhusus Almarhumah Ibuku **Aminah** yang sudah melahirkan dan memberikan do'a serta pengajaran terbaik kepadaku selama masa hidupnya. Terima kasih karena tak pernah lelah mendidik, menasehati, membimbing, mendukung dan terus mendo'akan. Penulis juga ingin menyampaikan ucapan terima kasih kepada sebesar-besarnya dan penghargaan setinggi-tingginya kepada:

1. Bapak **Prof. Hermansyah, S.Si., M.Si., Ph.D** selaku Dekan Fakultas MIPA Universitas Sriwijaya.
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 Bapak **Dr. Bambang Suprihatin, S.Si., M.Si.** selaku Dosen Pembimbing yang telah bersedia meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan, arahan dan didikan yang berharga selama pembuatan skripsi, perlombaan dan proses perkuliahan.
4. Ibu **Dr. Ir. Herlina Hanum, M.Si.** dan Ibu **Dr. Yuli Andriani, S.Si., M.Si.** selaku Dosen Pembahas yang telah meluangkan waktunya dalam memberikan tanggapan, saran, masukan, dan kritik yang sangat bermanfaat untuk perbaikan dan penyelesaian draft skripsi ini. Ibu **Irmeilyana, M.Si** selaku ketua tim pelaksan tugas akhir penulis dan Bapak **Drs. Ali Amran, M.T.** selaku sekretaris tim pelaksana tugas akhir penulis.
5. **Seluruh Dosen di Jurusan Matematika Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Sriwijaya** 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-kakakku tersayang, **Rijau, Pipin,** dan **Muhammad Didi** yang senantiasa memberikan semangat dan doa terbaik untuk penulis
7. **Kakak-kakak tingkat angkatan 2018 dan 2019 bidang komputasi, Tim Komputasi 2020, Keluarga Matematika 2020, dan BPH Divisi Pendidikan GenBI 2023** yang telah membantu serta berbagi ilmu selama proses perkuliahan. Terima kasih untuk bantuan, semangat dan kerja samanya.

8. Semua pihak yang tidak dapat penulis sebutkan satu per satu, semoga semua kebaikan yang telah diberikan mendapatkan balasan dari Allah.

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

Indralaya, Desember 2023

Penulis

**ENSEMBLE METHOD WITH VGG-16 AND VISION TRANSFORMER
ARCHITECTURE FOR DIABETIC
RETINOPATHY CLASSIFICATION**

By :

**Fitri Salamah
08011182025003**

ABSTRACT

Diabetic retinopathy (DR) is a complication of the retina caused by diabetic disease. DR can be identified through images of the retina of the eye. One of the architectures that is often used to identify DR is VGG-16. VGG-16 is capable of handling large amounts of data and large attributes. However, the overfitting often occurs due to deep layers and multiple convolutions. Another method in deep learning that does not use convolution operations is the Vision Transformer (ViT). ViT has the advantage of not using convolution operations in the training process but using self attention. ViT tends to ignore minority classes so that the performance of the model in classifying the minority class is less optimal. The weaknesses of each architecture can be overcome by using ensemble learning. The study proposed an ensemble method that combines the results of VGG-16 and Vision Transformer using weighted voting techniques with ResNet. ResNet was used to help the model learn the weight patterns on each data and avoid over-training in the classification of DR disease. The accuracy, precision, recall, and F1-score results in this study were excellent, above 95%. The ensemble method training graphs in the study showed that the study was able to cope with overfitting. The results show the ensemble method in this study is excellent and strong for the classification of diabetic retinopathy disease based on the severity of retinal image behavior, implement in 5 classes: *Non-Proliferative Diabetic Retinopathy* (NDR), Mild, Moderate, Severe dan *Proliferative Diabetic Retinopathy* (PDR).

Keyword : *VGG-16, Vision Transformer MobileNet, ResNet, Weighted Voting.*

**METODE ENSEMBLE PADA ARSITEKTUR VGG-16 DAN VISION
TRANSFORMER DALAM KLASIFIKASI PENYAKIT
DIABETIC RETINOPATHY**

Oleh :

Fitri Salamah

08011182025003

ABSTRAK

Penyakit *Diabetic Retinopathy* (DR) merupakan suatu komplikasi pada retina yang disebabkan oleh penyakit diabetes. Penyakit DR dapat diidentifikasi melalui citra retina mata. Salah satu arsitektur yang sering digunakan dalam mengidentifikasi penyakit DR yaitu *VGG-16*. *VGG-16* yaitu dapat menangani data dalam jumlah yang banyak dan atribut yang besar. Namun, *VGG-16* sering terjadi *overfitting* diakibatkan lapisan yang mendalam dan banyaknya operasi konvolusi. Metode lain pada *deep learning* yang tidak menggunakan operasi konvolusi adalah *Vision Transformer (ViT)*. *ViT* memiliki kelebihan yaitu tidak menggunakan operasi konvolusi pada proses pelatihan tetapi menggunakan *self attention*. *ViT* cenderung mengabaikan kelas minoritas sehingga kinerja model dalam mengklasifikasikan kelas minoritas menjadi kurang optimal. Kelemahan yang dimiliki oleh masing-masing arsitektur dapat diatasi dengan menggunakan *ensemble learning*. Penelitian ini mengusulkan metode *ensemble* yang menggabungkan hasil *VGG-16* dan *Vision Transformer* menggunakan teknik *weighted voting* dengan pembelajaran *ResNet*. Pembelajaran *ResNet* digunakan untuk membantu model mempelajari pola bobot pada setiap data dan menghindari pelatihan yang berlebihan dalam klasifikasi penyakit DR. Hasil akurasi, presisi, recall, dan F1-score pada penelitian ini sangat baik, diatas 95 %. Grafik pelatihan metode *ensemble* pada penelitian ini membuktikan bahwa penelitian ini mampu mengatasi *overfitting*. Hasilnya menunjukkan metode *ensemble* pada penelitian ini sangat baik dan kuat untuk klasifikasi penyakit *diabetic retinopathy* berdasarkan tingkah keparahan citra retina, yang dilakukan dalam 5 kelas: *Non-Proliferative Diabetic Retinopathy* (NDR), Mild, Moderate, Severe dan *Proliferative Diabetic Retinopathy* (PDR).

Kata Kunci: *VGG-16, Vision Transformer MobileNet, ResNet, Weighted Voting.*

DAFTAR ISI

HALAMAN JUDUL	i
HALAMAN PENGESAHAN	ii
HALAMAN PERSEMBAHAN	iii
KATA PENGANTAR	iv
ABSTRACT	vii
ABSTRAK	viii
DAFTAR ISI	ix
DAFTAR TABEL	xi
DAFTAR GAMBAR	xii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah.....	6
1.3 Batasan Masalah.....	7
1.4 Tujuan	7
1.5 Manfaat	7
BAB II TINJAUAN PUSTAKA	8
2.1 Diabetic Retinopathy	8
2.2 Perbaikan Kualitas Citra	9
2.4 Klasifikasi Citra.....	12
2.5 <i>Ensemble Learning</i>	12
2.6 <i>Convolutional Neural Network (CNN)</i>	12
2.7 <i>VGG-16</i>	18
2.8 <i>ResNet</i>	19
2.9 <i>Vision Transformer</i>	20
2.10 <i>Weighted Voting</i>	27
2.11 <i>Confusion Matrix</i>	28
BAB III METODOLOGI PENELITIAN	31
3.1 Tempat	31
3.2 Waktu.....	31

3.3	Alat	31
3.4	Tahapan Penelitian	32
BAB IV PEMBAHASAN.....		37
4.1	Deskripsi Data	37
4.2	Contoh Operasi Manual	38
4.3	Penerapan <i>VGG-16</i> , <i>Vision Transformer</i> dan <i>Ensemble Learning</i>	66
BAB V PENUTUP.....		80
5.1	Kesimpulan.....	84
5.2	Saran.....	84
DAFTAR PUSTAKA.....		81

DAFTAR TABEL

Tabel 2.1 Kategori Kinerja	30
Tabel 4.1 Sampel Data Training dan Data Testing.....	38
Tabel 4.2 Hasil Perhitungan Rata-Rata.....	58
Tabel 4.3 Hasil Perhitungan Variansi	59
Tabel 4.4 Nilai Bobot <i>Hidden Layer</i> dan <i>Output</i>	66
Tabel 4.5 Hasil <i>Confusion Matrix</i> Data Testing	78
Tabel 4.6 Perbandingan Hasil Klasifikasi dari Setiap Model	81
Tabel 4.7 Perbandingan Arsitektur dengan Penelitian Lain.....	82

DAFTAR GAMBAR

Gambar 2.1 Tingkat Keparahan <i>Diabetic Retinopathy</i> (DR).....	8
Gambar 2.2 Representasi <i>Gamma Correction</i>	8
Gambar 2.3 Proses Augmentasi Citra.....	10
Gambar 2.4 Ilustrasi Proses <i>Convolution Layer</i>	11
Gambar 2.5 Ilustrasi <i>Max Pooling</i>	16
Gambar 2.6 Fungsi Aktivasi <i>ReLU</i>	17
Gambar 2.7 Fungsi Aktivasi <i>Softmax</i>	18
Gambar 2.8 Arsitektur <i>VGG-16</i>	19
Gambar 2.9 Arsitektur <i>ResNet-50</i>	20
Gambar 2.10 Arsitektur <i>Vision Transformer</i>	21
Gambar 2.11 Ilustrasi <i>Transformer Encoder</i>	24
Gambar 2.12 Ilustrasi <i>Self Attention</i>	24
Gambar 2.13 Ilustrasi <i>Multi-Head Attention</i>	26
Gambar 2.14 Ilustrasi <i>Multilayer Perceptron</i>	27
Gambar 4.1 Proses Partisi Sub Matriks	46
Gambar 4.2 Proses <i>Concatenate</i>	48
Gambar 4.3 Ilustrasi Pemotongan <i>Patch</i>	50
Gambar 4.4 Ilustrasi Perataan Gambar	51
Gambar 4.5 Ilustrasi Arsitektur <i>VGG-16</i>	70
Gambar 4.6 Grafik nilai akurasi pada proses <i>training</i> model <i>VGG-16</i>	71
Gambar 4.7 Grafik nilai <i>loss</i> pada proses <i>training</i> model <i>VGG-16</i>	72

Gambar 4.8 Ilustrasi Arsitektur <i>ViT</i>	72
Gambar 4.9 Grafik nilai akurasi pada proses <i>training</i> model <i>ViT</i>	74
Gambar 4.10 Grafik nilai <i>loss</i> pada proses <i>training</i> model <i>ViT</i>	75
Gambar 4.11 Ilustrasi Arsitektur <i>Ensemble Learning</i>	76
Gambar 4.12 Grafik nilai akurasi pada proses <i>training</i> model <i>Ensemble Learning</i>	77
Gambar 4.13 Grafik nilai <i>loss</i> pada proses <i>training</i> model <i>Ensemble Learning</i>	77

BAB I

PENDAHULUAN

1.1 Latar Belakang

Penyakit *Diabetic Retinopathy* (DR) merupakan suatu komplikasi pada retina yang disebabkan oleh penyakit diabetes. Penyakit DR mempengaruhi lapisan retina mata dan menyebabkan kebutaan (Sallam *et al.*, 2020). Penyakit DR dapat diklasifikasi melalui 5 tingkat keparahan, yaitu *Non-Proliferative Diabetic Retinopathy* (NDR), Mild, Moderate, Severe dan *Proliferative Diabetic Retinopathy* (PDR) (Gu *et al.*, 2023). Penyakit DR dapat diidentifikasi dengan melihat citra retina mata (Bhatia *et al.*, 2017). Metode *deep learning* telah diterapkan untuk mengklasifikasi citra dalam berbagai bidang. Salah satunya diterapkan untuk mengidentifikasi penyakit DR pada retina (Erdem *et al.*, 2020). Salah satu metode *deep learning* yang dapat mengidentifikasi melalui citra adalah *Convolutional Neural Network* (CNN).

Convolutional Neural Network (CNN) merupakan jaringan syaraf tiruan yang terdiri dari *convolutional layer* dan *pooling layer* yang saling terhubung untuk melakukan ekstraksi fitur dan pengenalan objek pada citra (Erdem *et al.*, 2020). Salah satu arsitekur yang sering digunakan yaitu VGG-16. VGG-16 merupakan arsitektur yang terdiri dari 13 lapisan *convolution layer* dan 3 lapisan *fully connected layer* (Mogan *et al.*, 2022). VGG-16 dapat menangani data dalam jumlah yang banyak dan atribut yang besar (Mascarenhas and Agarwal, 2021).

Lapisan konvolusi yang dalam dan parameter yang besar pada arsitektur *VGG-16* mampu mengekstraksi fitur-fitur penting untuk dipelajari (Chen *et al.*, 2020).

Klasifikasi DR menggunakan *VGG-16* telah diterapkan oleh beberapa peneliti. El Houbby *et al.* (2021) menerapkan *VGG-16* pada klasifikasi DR menggunakan 3 kelas, yaitu NDR, Mild+Moderate, dan Severe+PDR. Penelitian ini memperoleh nilai akurasi sebesar 80% dan nilai F1-Score masih di bawah 70%. Mutawa *et al.* (2023) menerapkan *VGG-16* pada klasifikasi DR menggunakan 2 kelas, yaitu NDR dan PDR. Penelitian ini menghasilkan nilai spesifisitas sebesar 95% dan nilai akurasi dan *recall* di bawah 80%. Mustapha *et al.* (2021) juga menerapkan *VGG-16* pada klasifikasi DR menggunakan 2 kelas, yaitu NDR dan PDR. Penelitian ini menghasilkan nilai akurasi dibawah 70% dan penelitian ini tidak mengukur kinerja sensitivitas, spesifisitas, dan F1-Score.

Meskipun *VGG-16* memiliki kinerja yang baik pada klasifikasi DR, arsitektur ini sering mengalami *overfitting* akibat jumlah parameter yang besar (Khan *et al.*, 2021). Pengurangan jumlah lapisan konvolusi pada *VGG-16* dapat mengurangi jumlah parameter namun kinerja model dapat menurun dratis (Mogan *et al.*, 2022). Selain itu, *VGG-16* memiliki jumlah jaringan dan parameter yang besar sehingga memerlukan daya komputasi dan memori yang besar (Kumaresan *et al.*, 2023). *VGG-16* sulit mencapai konvergensi akibatnya proses pelatihan menjadi lebih lama (Rocha *et al.*, 2022). Semakin lama model melakukan pelatihan maka semakin besar resiko *overfitting* (Khan *et al.*, 2021). Permasalahan *overfitting* dan parameter yang terlalu besar merupakan kelemahan arsitektur CNN pada umumnya (Patil and Rane, 2021). Hal ini diakibatkan oleh CNN

memiliki lapisan yang mendalam dan banyaknya operasi konvolusi yang dilakukan pada setiap layer (Alzubaidi *et al.*, 2021). Operasi konvolusi merupakan proses operasi yang dilakukan berulang-ulang menggunakan submatriks (kernel) (Szegedy *et al.*, 2015). Proses operasi konvolusi dilakukan untuk mengekstraksi berbagai *feature map* melalui pergeseran kernel di seluruh wilayah *image* (Zafar *et al.*, 2022). Lapisan konvolusi yang terlalu besar dapat mengakibatkan *overfitting* dimana model tidak dapat mengenali pola data yang baru (Wang *et al.*, 2023). Selain itu, Proses operasi konvolusi yang berulang-ulang memerlukan sumber daya komputasi yang besar (Lawrence and Zhang, 2019).

Metode lain pada *deep learning* yang tidak menggunakan operasi konvolusi adalah *Vision Transformer (ViT)*. *ViT* merupakan metode *deep learning* yang sering digunakan dalam klasifikasi citra (Zhai *et al.*, 2021). *ViT* tidak menggunakan operasi konvolusi pada proses pelatihan tetapi menggunakan *self attention*. *Self attention* adalah operasi yang dilakukan dengan memotong citra menjadi beberapa *patch*, kemudian setiap *patch* disusun secara linier untuk dilakukan pembelajaran secara langsung dan bersamaan (Zhu *et al.*, 2022). Selain itu, *ViT* menggunakan memori yang sedikit untuk melakukan proses pembelajaran karena penggunaan *self attention* dalam arsitektur ViT (Dosovitskiy *et al.*, 2020). *Self-attention* membuat model fokus pada bagian-bagian penting dari citra, tanpa perlu melakukan operasi konvolusi berulang-ulang (Khan *et al.*, 2023).

Klasifikasi DR menggunakan *ViT* telah diterapkan oleh beberapa peneliti. Gu *et al.* (2023) menerapkan *ViT* pada klasifikasi DR dengan penambahan *Residual Attention*. Penelitian ini mengklasifikasi 5 kelas, yaitu NDR, Mild,

Moderate, Severe dan PDR. Penelitian ini menghasilkan nilai akurasi sebesar 82%. Sayangnya, nilai sensitivitas dan spesifitas di bawah 80%. Kamran *et al.* (2021) menerapkan *ViT* dengan penambahan *Generative Adversarial Network* (VT-GAN) pada klasifikasi DR dengan mengklasifikasi 2 kelas. Penelitian ini menghasilkan nilai spesifitas sebesar 90% dan sayangnya nilai akurasi dan sensitivitas masih di bawah 85%. Chen *et al.* (2021) menerapkan *ViT* dengan penambahan *Alex-Net* pada klasifikasi DR dengan mengklasifikasi 2 kelas, yaitu NDR dan PDR. Penelitian ini menghasilkan nilai akurasi sebesar 76%. Namun, nilai sensitivitas masih di bawah 80%. Meskipun *ViT* lebih ringan dibandingkan CNN tetapi *ViT* dapat mengalami penurunan kinerja pada dataset yang labelnya tidak seimbang (Heo *et al.*, 2021). *ViT* cenderung mengabaikan kelas minoritas sehingga kinerja model dalam mengklasifikasikan kelas minoritas menjadi kurang optimal (Chen *et al.*, 2022). Akibatnya, model cenderung memberikan klasifikasi yang kurang akurat atau kurang optimal untuk kelas minoritas.

Kelemahan yang dimiliki oleh masing-masing arsitektur dapat diatasi dengan menggunakan *ensemble learning*. *Ensemble learning* adalah metode yang menggabungkan hasil dari beberapa arsitektur untuk membuat satu keputusan akhir (Qummar *et al.*, 2019). Metode *ensemble* digunakan untuk menggabungkan kelemahan dari arsitektur klasifikasi tunggal dan mengambil kelebihan dari hasil arsitektur klasifikasi tunggal (Kesuma *et al.*, 2023). Salah satu metode *ensemble* yang sering digunakan adalah *weighted voting* (Dogan and Birant, 2019). *Weighted voting* bekerja dengan memilih suara terbanyak dengan pembobotan dari prediksi akhir yang dihasilkan oleh masing-masing metode (Deepa *et al.*,

2021). Pembobotan setiap arsitektur diterapkan untuk memberikan tingkat pengaruh yang berbeda pada prediksi masing-masing metode klasifikasi (Kesuma *et al.*, 2023). Metode dengan hasil yang dianggap akurat dapat memiliki pengaruh yang lebih besar dalam keputusan akhir *ensemble* (Deng and Perkowski, 2015).

Klasifikasi DR menggunakan *ensemble* telah diterapkan oleh beberapa peneliti. Qummar *et al.* (2019) menerapkan *ensemble learning* pada hasil arsitektur *ResNet50*, *Inceptionv3* dan *Xception* pada klasifikasi DR. Penelitian ini menghasilkan nilai akurasi sebesar 80%. Sayangnya, nilai sensitivitas dan spesifitas masih di bawah 60%. Jiang *et al.* (2019) menerapkan *ensemble learning* pada hasil arsitektur *InceptionV3*, *InceptionResNetV2*, dan *ResNet152* pada klasifikasi DR. Penelitian ini menghasilkan nilai akurasi sebesar 86%. Namun, nilai sensitivitas masih di bawah 70%. Hagos and Kant, (2019) menggunakan *ensemble learning* pada hasil *InceptionV3* dan *QIY model* menghasilkan nilai akurasi sebesar 90%. Namun, nilai sensitivitas 90% dan tidak menghitung kinerja lainnya. Penelitian-penelitian tersebut hanya melakukan metode *ensemble* pada proses *testing*. *Ensemble* yang dilakukan pada proses *testing* tidak menjamin apakah bobot yang diperoleh adalah bobot yang terbaik dan tidak mengalami *overfitting* (Kesuma *et al.*, 2023). Jika bobot yang dihasilkan mengalami *overfitting* artinya bobot yang digunakan tidak dapat mengenali pola data yang belum pernah dipelajari oleh model (Dogan and Birant, 2019). Untuk meyakinkan bahwa bobot *ensemble* merupakan bobot terbaik, perlunya model pembelajaran yang memastikan bahwa hasil bobot yang diperoleh merupakan bobot yang terbaik dan tidak akan mengalami *overfitting*. Salah satu arsitektur

CNN yang digunakan dalam mempelajari bobot adalah ResNet. ResNet merupakan arsitektur CNN yang memiliki *skip connection* (Elsawah *et al.*, 2020). *Skip connection* mampu mempercepat konvergensi bobot sehingga menghasilkan bobot terbaik pada data multi kelas tanpa mengalami penurunan performa dan memberikan hasil akhir yang akurat dan konsisten (Sallam *et al.*, 2020). Selain itu, ResNet mampu mengatasi masalah *vanishing gradient* yang sering terjadi pada jaringan yang sangat dalam (Zhang *et al.*, 2018).

Penelitian ini mengusulkan metode *ensemble* yang menggabungkan hasil *VGG-16* dan *Vision Transformer* menggunakan teknik *weighted voting* dengan pembelajaran ResNet. Metode *ensemble* akan diterapkan pada tahap pelatihan, untuk memastikan bahwa bobot yang dihasilkan tidak mengalami *overfitting*. Penelitian ini tidak langsung melakukan teknik *weighted voting* berdasarkan hasil *VGG-16* dan *ViT*, tapi dilakukan dengan menggunakan pembelajaran ResNet. Pembelajaran ResNet digunakan untuk membantu model mempelajari pola bobot pada setiap data dan menghindari pelatihan yang berlebihan dalam klasifikasi penyakit DR. Penelitian ini mengklasifikasi tingkat keparahan penyakit DR dengan 5 kelas. Hasil evaluasi kinerja arsitektur dapat diukur berdasarkan akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *Cohens Kappa*.

1.2 Rumusan Masalah

Bagaimana hasil penerapan metode *ensemble learning* pada arsitektur *VGG-16* dan *Vision Transformer* menggunakan teknik *weighted voting* dengan pembelajaran ResNet dalam klasifikasi penyakit DR?

1.3 Batasan Masalah

Batasan masalah yang diterapkan pada penelitian ini adalah sebagai berikut.

- a. Penelitian ini melakukan klasifikasi DR terdiri dari 5 kelas yaitu NDR, Mild, Moderate, Severe dan PDR.
- b. Kriteria evaluasi yang digunakan dalam klasifikasi DR penelitian ini adalah nilai akurasi, sensitifitas, spesifitas, *F1-Score*, dan *Cohens Kappa*.

1.4 Tujuan

Tujuan penelitian ini adalah untuk meningkatkan hasil evaluasi kinerja dari metode *ensemble learning* pada arsitektur *VGG-16* dan *Vision Transformer* menggunakan teknik *weighted voting* dengan pembelajaran ResNet dalam klasifikasi penyakit DR berdasarkan nilai akurasi, sensitifitas, spesifitas, *F1-Score*, dan *Cohens Kappa*.

1.5 Manfaat

Manfaat dari hasil penelitian ini sebagai berikut :

- a. Memperoleh model *ensemble learning* (*VGG-16* dan *Vision Transformer*) yang mampu mengklasifikasi penyakit DR.
- b. Dapat digunakan sebagai referensi penelitian pada klasifikasi penyakit DR dan pengembangan *deep learning*.

DAFTAR PUSTAKA

- Abburu, S., & Babu Golla, S. (2015). Satellite image classification methods and techniques: a review. *International Journal of Computer Applications*, 119(8), 20–25. <https://doi.org/10.5120/21088-3779>
- Albawi, S., Mohammed, T. A. M., & Alzawi, S. (2017). Layers of a convolutional neural network. *International Conference on Education and Technology*, 5(2), 1–6. <https://doi.org/9781538619490>
- Ali, A. M., Benjdira, B., Koubaa, A., El-Shafai, W., Khan, Z., & Boulila, W. (2023). Vision transformers in image restoration: a survey. *Sensors*, 23(5). <https://doi.org/10.3390/s23052385>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Dujaili, A. Al, Duan, Y., Shamma, O. Al, Santamaría, J., Fadhel, M. A., Amidie, M. Al, & 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>
- Antal, B., & Hajdu, A. (2014). An ensemble-based system for automatic screening of diabetic retinopathy. *Knowledge-Based Systems*, 60(1), 20–27. <https://doi.org/10.1016/j.knosys.2013.12.023>
- Bagchi, S., & Bathula, D. R. (2022). EEG-ConvTransformer for single-trial EEG-based visual stimulus classification. *Pattern Recognition*, 129(2), 11-17. <https://doi.org/https://doi.org/10.1016/j.patcog.2022.108757>
- Bashmal, L., Bazi, Y., & Al Rahhal, M. (2021). Deep vision transformers for remote sensing scene classification. *International Geoscience and Remote Sensing Symposium*. 516(13), 2-19. <https://doi.org/10.1109/IGARSS47720.2021.9553684>
- Bharati, S., Podder, P., Mondal, R., Mahmood, A., & Raihan-Al-Masud, M. (2020). Comparative performance analysis of different classification algorithm for the purpose of prediction of lung cancer. *Advances in Intelligent Systems and Computing*, 941(1), 1-18. Springer International Publishing. https://doi.org/10.1007/978-3-030-16660-1_44
- Bhatia, K., Arora, S., & Tomar, R. (2017). Diagnosis of diabetic retinopathy using machine learning classification algorithm. *International Conference on Next Generation Computing Technologies*, 516(13), 2-19. <https://doi.org/10.1109/IGARSS47720.2021.9553684>
- Chen, J., He, Y., Frey, E. C., Li, Y., & Du, Y. (2021). ViT-V-Net: vision transformer for unsupervised volumetric medical image registration. 7(2), 1–9. <http://arxiv.org/abs/2104.06468>

- 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>
- Chen, Y., Gu, X., Liu, Z., & Liang, J. (2022). A fast inference vision transformer for automatic pavement image classification and its visual interpretation method. *Remote Sensing*, 14(8), 1–20. <https://doi.org/10.3390/rs14081877>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021). The matthews correlation coefficient (mcc) is more informative than cohen's kappa and brier score in binary classification assessment. *IEEE Access*, 9(2), 78368–78381. <https://doi.org/10.1109/ACCESS.2021.3084050>
- da Costa, R. F., Hayashi Yelisetty, S. M., Marques, J. C., & Tasinaffo, P. M. (2019). A brief didactic theoretical review on convolutional neural networks, deep belief networks and stacked auto-encoders. *International Journal of Engineering and Technical Research*, 9(12), 1-12. <https://doi.org/10.31873/ijetr.9.12.35>
- Deepa, V., Kumar, C. S., & Cherian, T. (2021). Ensemble of multi-stage deep convolutional neural networks for automated grading of diabetic retinopathy using image patches. *Journal of King Saud University-Computer and Information Sciences*, 5(9), 1–11. <https://doi.org/10.1016/j.jksuci.2021.05.009>
- Deng, C., & Perkowski, M. (2015). A novel weighted hierarchical adaptive voting ensemble machine learning method for breast cancer detection. *Proceedings of The International Symposium on Multiple-Valued Logic*, 27(2), 115–120. <https://doi.org/10.1109/ISMVL.2015.27>
- Desiani, A, Adrezo, M., Marselina, N. C., Arhami, M., Salsabila, A., & Al-Filambany, M. G. (2022). A Combination of Image Enhancement and U-Net Architecture for Segmentation in Identifying Brain Tumors on CT-SCAN Images. *2022 International Conference on Informatics, Multimedia, Cyber and Information System (ICIMCIS)*, 423–428. <https://doi.org/10.1109/ICIMCIS56303.2022.10017519>
- Desiani, Anita, Erwin, Safmi, A., Suprihatin, B., & Fathoni. (2022). The augmentation data of retina image for blood vessel segmentation using u-net convolutional neural network method. *International Journal of Computational Intelligence and Applications*, 21(01), 2250004. <https://doi.org/10.1142/S1469026822500043>
- Dogan, A., & Birant, D. (2019). A weighted majority voting ensemble approach for classification. *International Conference on Computer Science and Engineering*, 366–371. <https://doi.org/10.1109/UBMK.2019.8907028>
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S.,

- Uszkoreit, J., & Hounsby, N. (2020). An image is worth 16x16 words: transformers for image recognition at scale. *12*(1), 115-120. <http://arxiv.org/abs/2010.11929>
- El Houbby, E. M. F. (2021). Using transfer learning for diabetic retinopathy stage classification. *Applied Computing and Informatics*, *7*(2), 1-11. <https://doi.org/10.1108/ACI-07-2021-0191>
- Elswah, D. K., Elnakib, A. A., & El-Din Moustafa, H. (2020). Automated diabetic retinopathy grading using resnet. *National Radio Science Conference*, *9*(2), 248–254. <https://doi.org/10.1109/NRSC49500.2020.9235098>
- Erdem, D., Beke, A., & Kumbasar, T. (2020). A deep learning-based pipeline for teaching control theory: Transforming feedback control systems on whiteboard into MATLAB. *IEEE Access*, *8*(2), 84631–84641. <https://doi.org/10.1109/ACCESS.2020.2992614>
- Ergul, E., & Eminoglu, I. (2020). Power-law fitness scaling on multi-objective evolutionary algorithms: interpretations of experimental results. *Soft Computing*, *24*(1), 248-254. <https://doi.org/10.1007/s00500-019-04242-6>
- Erwin, Putra, H. K., Suprihatin, B., & Ramadhini, F. (2022). A hybrid clahe-gamma adjustment and densely connected u-net for retinal blood vessel segmentation using augmentation data. *Engineering Letters*, *30*(2), 485–493.
- Fan, H., Xiong, B., Mangalam, K., Li, Y., Yan, Z., Malik, J., & Feichtenhofer, C. (2021). Multiscale vision transformers. *Proceedings of the IEEE International Conference on Computer Vision*, *7*(6), 6804–6815. <https://doi.org/10.1109/ICCV48922.2021.00675>
- Foroozesh, J., Khosravani, A., Mohsenzadeh, A., & Haghghat mesbahi, A. (2013). Application of artificial intelligence modeling in kinetics of methane hydrate growth. *American Journal of Analytical Chemistry*, *4*(2), 616–622. <https://doi.org/10.4236/ajac.2013.411073>
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). Fundamental concepts of convolutional neural network. *Springer International Publishing*, *97*(3), 519–567. https://doi.org/10.1007/978-3-030-32644-9_36
- Gu, Z., Li, Y., Wang, Z., Kan, J., Shu, J., & Wang, Q. (2023). Classification of diabetic retinopathy severity in fundus images using the vision transformer and residual attention. *Computational Intelligence and Neuroscience*, *8*(2), 1305583. <https://doi.org/10.1155/2023/1305583>
- Hagos, M. T., & Kant, S. (2019). Transfer learning based detection of diabetic retinopathy from small dataset. *4*(1), 1-9. <https://doi.org/10.48550/arXiv.1905.07203>
- Hattiya, T., Dittakan, K., & Musikasawan, S. (2021). Diabetic retinopathy detection using convolutional neural network: a comparative study on

- different architectures. *Maharakham International Journal Of Engineering Technology*, 70(1), 7-13. https://doi.org/10.1007/978-981-15-5309-7_13
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 770–778. <https://doi.org/10.1002/chin.200650130>
- Hendrycks, D., & Gimpel, K. (2016). *Gaussian error linear units (GELUS)*. 16(6), 1–10. <http://arxiv.org/abs/1606.08415>
- Heo, B., Yun, S., Han, D., Chun, S., Choe, J., & Joon, S. (2021). Rethinking spatial dimensions of vision transformers. 163(2), 11936–11945. <https://arxiv.org/abs/2103.16302>
- Islam, M. M., Poly, T. N., Walther, B. A., Yang, H. C., & Li, Y.-C. (Jack). (2020). Artificial Intelligence in ophthalmology: a meta-analysis of deep learning models for retinal vessels segmentation. *Journal of Clinical Medicine*, 9(4), 1018. <https://doi.org/10.3390/jcm9041018>
- Jadon, S. (2020). A survey of loss functions for semantic segmentation. (2020) *IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology*, 8(4), 1-5. <https://doi.org/10.1109/CIBCB48159.2020.9277638>
- Jiang, H., Yang, K., Gao, M., Zhang, D., Ma, H., & Qian, W. (2019). An interpretable ensemble deep learning model for diabetic retinopathy disease classification. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2045–2048. <https://doi.org/10.1109/EMBC.2019.8857160>
- Kamran, S. A., Hossain, K. F., Tavakkoli, A., Zuckerbrod, S. L., & Baker, S. A. (2021). VTGAN: semi-supervised retinal image synthesis and disease prediction using vision transformers. *Proceedings of the IEEE International Conference on Computer Vision*, 3228–3238. <https://doi.org/10.1109/ICCVW54120.2021.00362>
- Kandel, I., & Castelli, M. (2020). Transfer learning with convolutional neural networks for diabetic retinopathy image classification. *Applied Sciences*, 10(6), 1–24. <https://doi.org/10.3390/app1006202>
- Kassani, S. H., Kassani, P. H., Khazaeinezhad, R., Wesolowski, M. J., Schneider, K. A., & Deters, R. (2019). Diabetic retinopathy classification using a modified Xception architecture. *IEEE International Symposium on Signal Processing and Information Technology*, 1–5. <https://doi.org/10.1109/ISSPIT47144.2019.9001846>
- Kesuma, L. I., Ermatita, & Erwin. (2023). ELREI: ensemble learning of resnet, efficientnet, and inception-v3 for lung disease classification based on chest x-ray image. *International Journal of Intelligent Engineering and Systems*, 16(5), 149–161. <https://doi.org/10.22266/ijies2023.1031.14>

- Khan, A., Rauf, Z., Sohail, A., Rehman, A., Asif, H., Asif, A., & Farooq, U. (2023). A survey of the vision transformers and its cnn-transformer based variants. <http://arxiv.org/abs/2305.09880>
- Khan, A., Sohail, A., Zahoor, 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>
- Khan, Z., Khan, F., Khan, A., Ur Rehman, Z., Shah, S., Qummar, S., Ali, F., & Pack, S. (2021). Diabetic retinopathy detection using vgg a deep learning architecture. *IEEE Access*, 1-10. <https://doi.org/10.1109/ACCESS.2021.3074422>
- Kumar, S., & Kumar, B. (2018). Diabetic retinopathy detection by extracting area and number of microaneurysm from colour fundus image. *International Conference on Signal Processing and Integrated Networks*, 359–364. <https://doi.org/10.1109/SPIN.2018.8474264>
- Kumaresan, S., Aultrin, K. S. J., Kumar, S. S., & Anand, M. D. (2023). Deep learning-based weld defect classification using vgg16 transfer learning adaptive fine-tuning. *International Journal on Interactive Design and Manufacturing*, 7(2), 2-12. <https://doi.org/10.1007/s12008-023-01327-3>
- Lawrence, T., & Zhang, L. (2019). IoTNet: an efficient and accurate convolutional neural network for iot devices. *Sensors*, 19(24). <https://doi.org/10.3390/s19245541>
- Li, Qiaoliang, Xu, Y., Chen, Z., Liu, D., Feng, S. T., Law, M., Ye, Y., & Huang, B. (2018). Tumor segmentation in contrast-enhanced magnetic resonance imaging for nasopharyngeal carcinoma: deep learning with Convolutional Neural Network. *BioMed Research International*, 1–8. <https://doi.org/10.1155/2018/9128527>
- Li, Qing, Cai, W., Wang, X., Zhou, Y., Feng, D. D., & Chen, M. (2014). Medical image classification with convolutional neural network. *International Conference on Control Automation Robotics and Vision*, 844–848. <https://doi.org/10.1109/ICARCV.2014.7064414>
- Mapayi, T., Viriri, S., & Tapamo, J. R. (2015). Comparative study of retinal vessel segmentation based on global thresholding techniques. *Computational and Mathematical Methods in Medicine*, 1-8. <https://doi.org/10.1155/2015/895267>
- Mascarenhas, S., & Agarwal, M. (2021). A comparison between vgg16, vgg19 and resnet50 architecture frameworks for image classification. *International Conference on Disruptive Technologies for Multi-Disciplinary Research and Applications 1(2)*, 96–99. <https://doi.org/10.1109 /CENTCON52345.2021.9687944>
- Mogan, J. N., Lee, C. P., Lim, K. M., & Muthu, K. S. (2022). VGG16-MLP: gait

- recognition with fine-tuned vgg-16 and multilayer perceptron. *Applied Sciences*, 12(15), 2-12. <https://doi.org/10.3390/app12157639>
- Momeni Pour, A., Seyedarabi, H., Abbasi Jahromi, S. H., & Javadzadeh, A. (2020). Automatic detection and monitoring of diabetic retinopathy using efficient convolutional neural networks and contrast limited adaptive histogram equalization. *IEEE Access*, 8(2), 136668–136673. <https://doi.org/10.1109/ACCESS.2020.3005044>
- Mustapha, A., Mohamed, L., Hamid, H., & Ali, K. (2021). Diabetic retinopathy classification using resnet50 and vgg-16 pretrained networks. *International Journal of Computer Engineering and Data Science*, 1(1), 1–7. <https://www.ijceds.com/ijceds/article/view/15>
- Mutawa, A. M., Alnajdi, S., & Sruthi, S. (2023). Transfer learning for diabetic retinopathy detection: a study of dataset combination and model performance. *Applied Sciences*, 13(9). <https://doi.org/10.3390/app13095685>
- Nath, S. S., Mishra, G., Kar, J., Chakraborty, S., & Dey, N. (2014). A survey of image classification methods and techniques. *International Conference on Control, Instrumentation, Communication and Computational Technologies*, 554–557. <https://doi.org/10.1109/ICCICCT.2014.6993023>
- Oltu, B., Akşahin, M. F., & Kibaroglu, S. (2021). A novel electroencephalography based approach for Alzheimer's disease and mild cognitive impairment detection. *Biomedical Signal Processing and Control*, 63, 102223. <https://doi.org/https://doi.org/10.1016/j.bspc.2020.102223>
- Osamor, V. C., & Okezie, A. F. (2021). Enhancing the weighted voting ensemble algorithm for tuberculosis predictive diagnosis. *Scientific Reports*, 11(1), 1–12. <https://doi.org/10.1038/s41598-021-94347-6>
- Patil, A., & Rane, M. (2021). Convolutional Neural Networks: an overview and its applications in pattern recognition. *Smart Innovation, Systems and Technologies*, 195, 21–30. https://doi.org/10.1007/978-981-15-7078-0_3
- Perez, L., & Wang, J. (2017). *The effectiveness of data augmentation in image classification using deep learning*. <http://arxiv.org/abs/1712.04621>
- Putra, R. E., Tjandrasa, H., & Suciati, N. (2020). Severity classification of non-proliferative diabetic retinopathy using convolutional support vector machine. *International Journal of Intelligent Engineering and Systems*, 13(4), 156–170. <https://doi.org/10.22266/IJIES2020.0831.14>
- Putra, T. A., Rufaida, S. I., & Leu, J. S. (2020). Enhanced skin condition prediction through machine learning using dynamic training and testing augmentation. *IEEE Access*, 8, 40536–40546. <https://doi.org/10.1109/ACCESS.2020.2976045>
- Qomariah, D. U. N., Tjandrasa, H., & Fatichah, C. (2019). Classification of

- diabetic retinopathy and normal retinal images using cnn and svm. *Proceedings of 2019 International Conference on Information and Communication Technology and Systems*, 152–157. <https://doi.org/10.1109/ICTS.2019.8850940>
- Qummar, S., Khan, F. G., Shah, S., Khan, A., Shamshirband, S., Rehman, Z. U., Khan, I. A., & Jadoon, W. (2019). A deep learning ensemble approach for diabetic retinopathy detection. *IEEE Access*, 7, 150530–150539. <https://doi.org/10.1109/ACCESS.2019.2947484>
- Rocha, D., Ferreira, F., & Peixoto, Z. (2022). Diabetic retinopathy classification using vgg16 neural network. *Research on Biomedical Engineering*, 38, 1–12. <https://doi.org/10.1007/s42600-022-00200-8>
- Sallam, M. S., Asnawi, A. L., & Olanrewaju, R. F. (2020). Diabetic retinopathy grading using resnet convolutional neural network. *2020 IEEE Conference on Big Data and Analytics*, 73–78. <https://doi.org/10.1109/ICBDA50157.2020.9289822>
- 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. *IEEE Access*, 7, 71696–71717. <https://doi.org/10.1109/ACCESS.2019.2920616>
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *IEEE Conference on Computer Vision and Pattern Recognition*, 1–9.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, 30. https://proceedings.neurips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf
- Wang, N., Li, K., Zhang, G., Zhu, Z., & Wang, P. (2023). Improvement of retinal vessel segmentation method based on u-net. *Electronics (Switzerland)*, 12(2).
- Wang, S., Yin, Y., Cao, G., Wei, B., Zheng, Y., & Yang, G. (2015). Hierarchical retinal blood vessel segmentation based on feature and ensemble learning. *Neurocomputing*, 149, 708–717. <https://doi.org/10.1016/j.neucom.2014.07.059>
- Ye, J. C. (2022). Artificial neural networks and backpropagation. *Mathematics in Industry*, 37(8), 91–112. https://doi.org/10.1007/978-981-16-6046-7_6
- Yin, R., Luo, Z., Zhuang, P., Lin, Z., & Kwoh, C. K. (2021). VirPreNet: A weighted ensemble convolutional neural network for the virulence prediction of influenza a virus using all eight segments. *Bioinformatics*, 37(6), 737–743. <https://doi.org/10.1093/bioinformatics/btaa901>
- Zafar, A., Aamir, M., Nawi, N. M., Arshad, A., Riaz, S., Alruban, A., Dutta, A.

- K., & Almotairi, S. (2022). A comparison of pooling methods for convolutional neural networks. *Applied Sciences*, 1–21.
- Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2021). An image is worth 16 x 16 words. *International Conference on Learning Representations*.
- Zhang, D., Bu, W., & Wu, X. (2018). Diabetic retinopathy classification using deeply supervised ResNet. *IEEE*, 2(1), 1-6. <https://doi.org/10.1109/UIC-ATC.2017.8397469>
- Zhang, Y. J. (2015). Image and graphics. *Proceedings in Artificial Intelligence and Lecture Notes in Bioinformatics*, 9218, 11–17. <https://doi.org/10.1007/978-3-319-21963-9>
- Zhu, J., Tan, Y., Lin, R., Miao, J., Fan, X., Zhu, Y., Liang, P., Gong, J., & He, H. (2022). Efficient self-attention mechanism and structural distilling model for Alzheimer's disease diagnosis. *Computers in Biology and Medicine*, 147(5), 105737. <https://doi.org/10.1016/j.combiomed.2022.105737>
- Zubair, M., Kim, J., & Yoon, C. (2016). An automated ecg beat classification system using convolutional neural networks. *International Conference on IT Convergence and Security, 2016*. <https://doi.org/10.1109/ICITCS.2016.7740310>