

**METODE *ENSEMBLE LEARNING* MENGGUNAKAN
TEKNIK *WEIGHTED VOTING* PADA HASIL
DENSENET, EFFICIENTNET DAN *VISION TRANSFORMER*
DALAM KLASIFIKASI PENYAKIT MATA**

SKRIPSI

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

Oleh:

KURNIA ROMADONA

NIM. 08011282126045



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

2025

LEMBAR PENGESAHAN

**METODE ENSEMBLE LEARNING MENGGUNAKAN
TEKNIK WEIGHTED VOTING PADA HASIL
DENSENET, EFFICIENTNET DAN VISION TRANSFORMER DALAM
KLASIFIKASI PENYAKIT MATA**

SKRIPSI

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

Oleh

KURNIA ROMADONA

NIM. 08011282126045

Indralaya, 18 Maret 2025

Pembimbing Kedua



Dr. Yuli Andriani, S.Si., M.Si
NIP. 197207021999032001

Pembimbing Utama



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

Mengetahui,

Ketua Jurusan Matematika



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

HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Kurnia Romadona
NIM : 08011282126045
Jurusan : Matematika
Fakultas : Matematika dan Ilmu Pengetahuan Alam

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 berasal dari penulis lain baik yang dipublikasikan atau 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, 18 Maret 2025

Penulis



Kurnia Romadona

NIM. 08011282126045

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk :

Yang MahaKuasa Allah Subhanahu Wa Ta'ala,

Orang tuaku yang sangat kucinta,

Adik-adikku tersayang,

Keluarga Besarku,

Semua Dosenku,

Semua Guruku,

Teman baik yang Kubanggakan,

Almamaterku

Motto

“Janganlah kamu bersikap lemah dan janganlah pula kamu bersedih hati, padahal kamulah orang-orang yang paling tinggi derajatnya jika kamu beriman”

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 Learning* Menggunakan Teknik *Weighted Voting* pada Hasil *Densenet*, *EfficientNet* dan *Vision Transformer* dalam Klasifikasi Penyakit Mata”. 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 **Yazil** dan ibuku **Munawwarah** yang tidak pernah berhenti berjuang dan memberikan yang terbaik untukku sebagai putrinya, terkhusus Ibuku **Munawwarah** yang sudah melahirkan dan memberikan do'a serta pengajaran terbaik kepadaku. 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. Ibu **Dr. Dian Cahyawati Sukanda, M.Si** selaku Ketua Jurusan Matematika 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.
2. Ibu **Sri Indra Maiyanti, S.Si., M.Si.** selaku dosen pembimbing akademik yang telah membimbing dan mengarahkan dalam urusan akademik selama menempuh perkuliahan di Jurusan Matematika FMIPA Universitas Sriwijaya. Ibu **Dr. Anita Desiani, S.Si., M.Kom** dan ibu **Dr. Yuli Andriani, 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. Ibu **Des Alwine Zayanti, S.Si., M.Si.** dan Ibu **Dr. Evi Yuliza, 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.
 3. **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.
 4. Adik-adikku tersayang, **Qonita Alamiah, Zam Harir,** dan **Hafidzah Arson** yang senantiasa memberikan semangat dan doa terbaik untuk penulis
 5. **Kakak tingkat dan Adik tingkat bidang komputasi, Tim Komputasi 2021, Keluarga Matematika 2021, Keluarga besar HIMASTIK, Lab Komputasi, Rekan-rekan dan Pengurus Bright Scholarship** serta **BPH UKM SBI**

UNSRI 2024 yang telah membantu, menemani proses perkuliahan serta berbagi ilmu selama proses perkuliahan. Terima kasih untuk bantuan, semangat dan kerja samanya.

6. 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, 18 Maret 2025

Penulis

**ENSEMBLE LEARNING METHOD USING
WEIGHTED VOTING TECHNIQUE ON RESULTS OF
DENSENET, EFFICIENTNET AND VISION TRANSFORMER IN
CLASSIFICATION OF EYE DISEASES**

Kurnia Romadona

08011282126045

ABSTRACT

Eye diseases are conditions that affect visual function and eye health. Eye diseases can be grouped into cataracts, Diabetic Retinopathy (DR) and glaucoma. Early detection can be done by utilizing Deep Learning. Deep Learning architectures that can be used include DenseNet, EfficientNet and ViT. DenseNet can connect information between layers with the dense block and transition layer process, where each layer receives input from all previous layers and sends output to all subsequent layers. The density of connection relationships in DenseNet leads to many iterations of information processing, thus increasing memory requirements. EfficientNet uses compound scaling, to proportionally optimize the depth, width and resolution of the model. Unlike DenseNet, EfficientNet relies on MBConv which consists of depthwise convolution and SE to reduce the number of unnecessary convolution operations and reduce memory usage. In general, CNN architectures have difficulty in understanding global relationships because they use convolution processes. The architecture that has the ability to capture global relationships is ViT because it uses a self-attention process, but ViT tends to have difficulty in classifying minority classes. The average evaluation result of each single architecture on accuracy is 96%, which means it can predict most eye diseases correctly. Sensitivity is 95%, which means the model is sensitive to the normal class. Specificity was 97%, which means the accuracy in predicting the eye disease class. F1-Score of 95% indicates a good balance of precision and sensitivity and Cohen's Kappa of 0.87 shows the consistency of predictions with the actual label, but the results of the accuracy and loss training graphs are still experiencing overfitting. The application of Ensemble Learning using weighted voting technique with FC learning produces accuracy and loss training graphs that are not overfitting. Ensemble Learning provides an improvement on a single classification with an accuracy value of 2%, sensitivity of 4%, specificity of 2%, F1-Score of 4%, and Cohen's Kappa of 11%. The evaluation results are very good for each class, but still quite low in the glaucoma class, which is still below 95%. Future research is expected to improve the classification of the glaucoma class.

Keyword : DenseNet, EfficientNet, Fully Connected, Vision Transformer, Weighted Voting.

**METODE ENSEMBLE LEARNING MENGGUNAKAN
TEKNIK WEIGHTED VOTING PADA HASIL
DENSENET, EFFICIENTNET DAN VISION TRANSFORMER DALAM
KLASIFIKASI PENYAKIT MATA**

Kurnia Romadona

08011282126045

ABSTRAK

Penyakit mata merupakan kondisi yang mempengaruhi fungsi penglihatan dan kesehatan mata. Penyakit pada mata dapat dikelompokkan menjadi katarak, Diabetic Retinopathy (DR) dan glaukoma. Deteksi dini dapat dilakukan dengan memanfaatkan *Deep Learning*. Arsitektur *Deep Learning* yang dapat digunakan diantaranya adalah *DenseNet*, *EfficientNet* dan ViT. *DenseNet* dapat menghubungkan informasi antar layer dengan adanya proses *dense blok* dan *transition layer*, yaitu setiap layer menerima *input* dari semua layer sebelumnya dan mengirimkan *output* ke semua layer setelahnya. Kepadatan hubungan koneksi pada *DenseNet* menyebabkan banyaknya perulangan pemrosesan informasi, sehingga meningkatkan kebutuhan memori. *EfficientNet* menggunakan *compound scaling*, untuk mengoptimalkan kedalaman, lebar dan resolusi model secara proporsional. Berbeda dengan *DenseNet*, *EfficientNet* mengandalkan MBConv yang terdiri dari *depthwise convolution* dan SE untuk mengurangi jumlah operasi konvolusi yang tidak perlu dan mengurangi penggunaan memori. Secara umum arsitektur CNN kesulitan dalam memahami hubungan secara global karena menggunakan proses konvolusi. Arsitektur yang memiliki kemampuan menangkap hubungan secara global adalah ViT karena menggunakan proses *self attention*, namun ViT cenderung kesulitan dalam mengklasifikasikan kelas minoritas. Hasil rata-rata evaluasi masing-masing arsitektur tunggal pada akurasi sebesar 96% yang berarti dapat memprediksi sebagian besar penyakit mata dengan benar. Sensitivitas sebesar 95%, yang berarti model sensitif terhadap kelas normal. Spesifisitas sebesar 97%, yang berarti ketepatan dalam memprediksi kelas penyakit mata. F1-Score sebesar 95 % menandakan keseimbangan presisi dan sensitivitas yang baik dan *Cohen's Kappa* sebesar 0,87 menunjukkan konsistensi prediksi dengan label sebenarnya, namun hasil grafik *training* akurasi dan *loss* masih mengalami *overfitting*. Penerapana *Ensemble Learning* menggunakan teknik *weighted voting* dengan pembelajaran FC menghasilkan grafik *training* akurasi dan *loss* yang tidak *overfitting*. *Ensemble Learning* memberikan peningkatan pada klasifikasi tunggal dengan nilai akurasi sebesar 2%, sensitivitas sebesar 4%, spesifisitas sebesar 2%, F1-Score sebesar 4%, dan *Cohen's Kappa* sebesar 11%. Hasil evaluasi sangat baik untuk setiap kelas, namun masih cukup rendah pada kelas glaukoma yaitu masih dibawah 95%. Pada penelitian kedepannya diharapkan dilakukan peningkatan klasifikasi pada kelas glaukoma.

Kata Kunci: *DenseNet*, *EfficientNet*, *Fully Connected*, *Vision Transformer*, *Weighted Voting*.

DAFTAR ISI

LEMBAR PENGESAHAN	ii
HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH.....	ii
HALAMAN PERSEMBAHAN.....	iv
KATA PENGANTAR.....	v
ABSTRACT.....	viii
ABSTRAK	ix
DAFTAR ISI.....	x
DAFTAR TABEL.....	xii
DAFTAR GAMBAR.....	xiii
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang.....	1
1.2 Rumusan Masalah	7
1.3 Batasan Masalah.....	7
1.4 Tujuan.....	7
1.5 Manfaat.....	8
BAB II TINJAUAN PUSTAKA.....	9
2.1 Penyakit Mata.....	9
2.2 <i>Perbaikan Kualitas Citra</i>	10
2.3 Augmentasi Citra.....	11
2.4 Klasifikasi Citra.....	12
2.5 <i>DenseNet</i>	12
2.6 <i>EfficientNet</i>	23
2.7 <i>Vision Transformer (ViT)</i>	29
2.8 <i>Ensemble Learning</i>	37
2.10 Loss Function.....	40
2.11 <i>Optimization Function : Adaptive Moment Estimation (ADAM)</i>	40
2.12 <i>Confusion Matrix</i>	41
BAB III METODOLOGI PENELITIAN	44
3.1 Tempat.....	44
3.2 Waktu	44

3.3	Alat	44
3.4	Tahapan Penelitian	44
3.4.1	Data	45
3.4.2	Perbaikan Citra	45
3.4.3	Augmentasi Citra	45
3.4.4	Tahap <i>Training</i>	46
i.	<i>DenseNet</i>	46
ii.	<i>EfficientNet</i>	47
iii.	Vision Transformer	48
iv.	Ensemble Learning	50
3.4.5	<i>Testing Data</i>	51
3.5	Analisis dan Interpretasi Hasil	51
BAB IV PEMBAHASAN.....		52
4.1	Deskripsi Data	52
4.2	<i>Preprocessing Data</i>	53
4.3	Operasi Manual <i>DenseNet</i>	55
4.4	Operasi Manual <i>EfficientNet</i>	71
4.5	Operasi Manual ViT	95
4.6	Operasi Manual <i>Ensemble Learning</i>	114
4.7	<i>Fully connected</i>	116
4.8	Hasil Penerapan <i>DenseNet</i> , <i>EfficientNet</i> , ViT dan <i>Ensemble Learning</i>	124
4.8.1	Proses <i>Training</i>	124
4.8.2	Proses <i>Testing</i>	133
4.8.3	Evaluasi	136
4.8.4	Pembahasan	143
BAB V PENUTUP.....		146
5.1	Kesimpulan	146
5.2	Saran	146
DAFTAR PUSTAKA		148

DAFTAR GAMBAR

Gambar 2. 1 Penyakit Mata (Sumber : Abdullah <i>et al</i> (2024)).....	9
Gambar 2. 2 Proses Augmentasi Citra	11
Gambar 2. 3 Ilustrasi Arsitektur <i>DenseNet</i>	13
Gambar 2. 4 Ilustrasi <i>Padding Same</i>	14
Gambar 2. 5 Ilustrasi Proses Konvolusi (Sumber : Ghosh <i>et al</i> (2020))	15
<i>Gambar 2. 6 Ilustrasi Concatenated Layer</i>	19
Gambar 2. 7 Ilustrasi <i>average pooling</i>	20
Gambar 2. 8 Ilustrasi <i>Global Average Pooling</i>	21
Gambar 2. 9 Ilustrasi Arsitektur <i>EfficientNet</i>	23
Gambar 2. 10 Ilustrasi Arsitektur <i>Vision Transformer</i>	29
<i>Gambar 2. 11 Ilustrasi Transformer Encoder</i>	32
Gambar 2. 12 Ilustrasi <i>Multi-Head Attention</i>	34
Gambar 2. 13 Ilustrasi <i>Self Attention</i> (Sumber : Cuenat and Couturier (2022))	35
Gambar 2. 14 Ilustrasi <i>Multilayer Perceptron</i>	36
Gambar 2. 15 Ilustrasi <i>Fully Connected</i>	39
Gambar 4. 1 Proses Augmentasi dan Perbaikan Citra	53
Gambar 4. 2 Tahapan membagi matriks <i>input</i> untuk <i>average pooling</i>	63
Gambar 4. 3 Ilustrasi <i>Compound Scalling</i>	111
Gambar 4. 4 Ilustrasi <i>Multi Layer Perceptron</i>	111
Gambar 4. 5 Grafik Nilai Akurasi pada Proses <i>Training Model Densenet</i>	125
Gambar 4. 6 Grafik Nilai Loss pada Proses Training Model Densenet.....	126
Gambar 4. 7 Grafik Nilai Akurasi pada Proses <i>Training Model EfficientNet</i>	127
Gambar 4. 8 Grafik Nilai <i>Loss</i> pada Proses <i>Training Model EfficientNet</i>	128
Gambar 4. 9 Grafik Akurasi pada Proses <i>Training Model ViT</i>	129
Gambar 4. 10 Grafik <i>Loss</i> pada Proses <i>Training Model ViT</i>	130
Gambar 4. 12 Ilustrasi <i>Ensemble Learning</i>	131
Gambar 4. 13 Grafik Akurasi pada Proses <i>Training Model Ensemble L</i>	132
Gambar 4. 14 Grafik <i>Loss</i> pada Proses <i>Training Model Ensemble Learning</i>	132

BAB 1

PENDAHULUAN

1.1 Latar Belakang

Gangguan mata merupakan kondisi yang mempengaruhi fungsi penglihatan dan kesehatan mata secara keseluruhan. Gangguan pada kondisi mata dapat dikelompokkan menjadi katarak, *Diabetic Retinopathy* (DR), dan glaukoma (Hossain *et al.*, 2020 ; Kyari *et al.*, 2015). Sistem diagnosis otomatis yang tepat dibutuhkan untuk mengklasifikasikan citra penyakit mata menggunakan metode *Deep Learning*. Salah satu metode *Deep Learning* untuk klasifikasi otomatis gangguan citra mata telah banyak digunakan yaitu *Convolutional Neural Network* (CNN) (Erdem *et al.*, 2020). *Convolutional Neural Network* (CNN) merupakan jaringan syaraf tiruan yang terdiri dari *convolutional layer* dan *pooling layer* yang saling terhubung satu sama lain (Erdem *et al.*, 2020). *Convolutional layer* dan *pooling layer* yang saling terhubung mampu melakukan ekstraksi fitur dan pengenalan objek pada citra. Arsitektur CNN yang dapat digunakan seperti *Dense Convolutional Network* (*DenseNet*) dan *Efficient Convolutional Network* (*EfficientNet*).

DenseNet memiliki struktur utama yang terdiri dari beberapa *dense block* dan *transition layer* (Sitompul & Rosnelly, 2023). *Dense block* merupakan blok jaringan yang memungkinkan setiap *layer* menerima *input* dari semua *layer* sebelumnya dan mengirimkan *output* ke semua *layer* berikutnya (Cui *et al.*, 2020). *Transition layer* merupakan lapisan yang ditempatkan setelah *dense block* dan

berfungsi untuk mereduksi dimensi fitur agar ukuran *input* pada *dense block* tetap sama pada setiap lapisan (Huang *et al.*, 2020). Hubungan pada setiap layer yang ada pada *DenseNet* memungkinkan *DenseNet* mengatasi masalah *vanishing gradient* (Ryu *et al.*, 2021; Hadiyoso *et al.*, 2023).

Vanishing gradient merupakan proses dimana nilai *gradient* menjadi sangat kecil pada jaringan dengan jumlah lapisan yang sangat banyak, sehingga bobot yang dihasilkan sulit untuk dipelajari (Sitompul & Rosnelly, 2023). *Gradient* mengecil secara bertahap mendekati nol disebabkan oleh operasi konvolusi yang berulang. Penelitian yang telah menerapkan *Densenet* diantaranya adalah Jatmoko *et al.*, (2024) menerapkan arsitektur *DenseNet* pada klasifikasi penyakit retina mata dengan empat kelompok yaitu normal, katarak, DR, dan glaukoma. Namun, hasil akurasi, presisi, *recall* dan *F1-Score* masih dibawah 85%. Pravin *et al.*, (2023) menerapkan arsitektur *DenseNet* pada klasifikasi penyakit retina mata dengan dua kelompok yaitu, retina normal dan terinfeksi DR. Namun, penelitian ini menghasilkan akurasi, presisi, *recall*, *Cohen's Kappa* dan *F1-Score* masih dibawah 90%. *DenseNet* mampu mengatasi *vanishing gradient*. Namun, *dense block* dan *transition layer* menyebabkan tingginya jumlah koneksi langsung antar layer. koneksi langsung antar layer dapat menyebabkan *gradient redundancy*, yang mengakibatkan banyak informasi berulang diproses tanpa memberikan manfaat yang signifikan. *Gradient redundancy* secara tidak langsung dapat menyebabkan terjadinya *local optimal* pada model (Zhou *et al.*, 2022).

EfficientNet mengatasi permasalahan *gradient redundancy* dan *local optimal* yang terjadi pada *DenseNet* dengan pendekatan *compound scaling*, yang secara

optimal menyeimbangkan *depth* (kedalaman), *width* (lebar), dan *resolution* (resolusi gambar) dalam model. *Compound scaling*, memungkinkan *EfficientNet* dapat meningkatkan kapasitas model tanpa menambah parameter secara berlebihan, sehingga menghindari koneksi berlebih antar *layer* seperti pada *DenseNet* dan mengurangi informasi yang berulang tanpa manfaat signifikan.

EfficientNet tidak hanya menggunakan *compound scaling* tetapi juga menggunakan *Mobile Inverted Bottleneck Convolution (MBConv)*, yang lebih efisien dalam mengekstraksi fitur penting dengan *depthwise convolution*, sehingga mengurangi jumlah operasi yang tidak perlu dibandingkan dengan arsitektur konvolusi standar. *Squeeze-and-Excitation (SE) Block* juga diterapkan untuk memperkuat fitur yang relevan dan melemahkan fitur yang kurang berguna, sehingga informasi yang diproses lebih selektif dan tidak mengalami kelebihan informasi seperti pada *DenseNet* (Wang *et al.*, 2020). Penelitian yang telah menerapkan *EfficientNet* diantaranya Toptas and Hanbay (2022) menerapkan arsitektur *EfficientNet* pada klasifikasi penyakit retina mata dengan dua kelompok yaitu glaukoma dan *non* glaukoma. Hasil pada penelitian ini yaitu akurasi, presisi, *recall* dan *F1-Score* diatas 90%. Lin *et al.* (2021) menerapkan arsitektur *EfficientNet* pada klasifikasi penyakit mata dengan dua kelompok yaitu glaukoma dan tidak glaukoma. Hasil akurasi dan *F1-Score* dibawah 90%. *EfficientNet* memiliki keterbatasan dalam menangani gambar beresolusi tinggi. Hal ini karena *EfficientNet* menerapkan *Compound Scaling*, yang meningkatkan resolusi, kedalaman, dan lebar model secara bersamaan. Pada gambar yang telah beresolusi tinggi akan semakin diperbesar dan dapat mengakibatkan model berisiko

mengalami saturasi fitur. saturasi fitur merupakan kondisi yang menjadikan model tidak dapat membedakan fitur penting dan tidak penting sehingga dapat mengganggu jalannya prediksi. Hal ini dapat menyebabkan peningkatan beban komputasi tanpa manfaat yang sepadan dalam performa model (Feng *et al.*, 2019).

Berbagai arsitektur CNN telah dikembangkan, namun kelemahan secara umum CNN adalah keterbatasannya dalam menangkap hubungan global sehingga menyebabkan kesulitan dalam memahami struktur keseluruhan data (Zhou *et al.*, 2022). Kelemahan tersebut disebabkan karena CNN menggunakan konvolusi yang hanya bekerja pada area terbatas. Arsitektur yang mampu menangkap hubungan global adalah *Vision Transformer (ViT)* (Zhai *et al.*, 2021).

ViT dirancang agar dapat menangkap hubungan global dalam citra dengan menggunakan *self attention* (Cuenat and Couturier, 2022). Mekanisme ViT diawali dengan membagi citra menjadi beberapa patch yang kemudian dijadikan vektor satu dimensi (*flattened*) dan dilanjutkan dengan *self attention*. *Self attention* merupakan proses yang memungkinkan model untuk mempelajari interaksi antar patch secara bersamaan. *Self attention* memungkinkan ViT mampu memperhatikan hubungan setiap *patch*, sehingga dapat menangkap pola dan struktur citra secara menyeluruh (Zhu *et al.*, 2022 ;Wang *et al.*, 2023). Penelitian yang telah menerapkan ViT diantaranya adalah Gu *et al.* (2023) menerapkan arsitektur ViT dengan hasil nilai akurasi, *recall* dan presisi dibawah 85%. Namun, penelitian ini hanya dilakukan pada klasifikasi DR. Kamran *et al.* (2021) menerapkan ViT dengan nilai spesifisitas sebesar 90%. Namun, nilai akurasi dan sensitivitas masih di bawah 85%. Walaupun ViT dapat menangkap hubungan global, ViT cenderung kesulitan dalam

mengklasifikasikan kelas minoritas, sehingga memberikan dampak pada penurunan kinerja model dalam mengklasifikasikan secara akurat kelas minoritas (Chen et al., 2022). Penurunan kinerja model terjadi karena mekanisme *self attention* cenderung memberikan bobot perhatian yang lebih tinggi pada pola-pola dominan yang sering muncul dalam data *training* (Dosovitskiy et al., 2021).

Kelebihan dari setiap arsitektur tunggal dapat dimaksimalkan dengan menggunakan *Ensemble Learning* (Kesuma et al., 2023; Qummar et al., 2019). *Ensemble Learning* merupakan metode yang bertujuan untuk menggabungkan hasil prediksi dari arsitektur tunggal menjadi model baru yang memiliki performa lebih akurat. Beberapa cara teknik *Ensemble Learning* diantaranya *stacking*, *bagging*, *averaging*, *boosting* dan *weighted voting* (Osamor and Okezie, 2021). *Weighted Voting* bekerja dengan memilih bobot terbaik dari prediksi yang dihasilkan oleh masing-masing arsitektur dan diberikan bobot tertentu. Pembobotan setiap arsitektur bertujuan untuk menunjukkan tingkat perbedaan hasil prediksi masing-masing pengaruh yang berbeda pada prediksi masing-masing metode klasifikasi (Deepa et al., 2021). Jiang et al. (2019) menerapkan *Ensemble Learning* menggunakan teknik *Weighted Voting* pada hasil arsitektur *InceptionV3*, *InceptionResNetV2*, dan *ResNet152* dalam klasifikasi DR. Penelitian ini menghasilkan nilai akurasi sebesar 86%, namun nilai sensitivitas masih di bawah 70%. Ho et al., (2022) He et al. (2021) menerapkan *Ensemble Learning* menggunakan teknik *Weighted Voting* pada hasil arsitektur *DenseNet 121*, *inception V3*, *efiicientNet B4* dan *EfficintNet B5* dengan nilai akurasi dan sensitivitas di atas 95%. Nilai *spesifisitas* pada penelitian ini masih di bawah 60%.

Penelitian tersebut menerapkan metode *Ensemble* pada tahapan pengujian. Penerapan *Ensemble* pada tahapan pengujian tidak dapat menjamin bahwa bobot yang dihasilkan adalah yang terbaik dan tidak dapat dilakukan pengecekan apakah metode *Ensemble* tidak mengalami *overfitting* terutama pada citra yang mirip (Abayomi et al., 2022; Yohannese et al., 2018). Untuk memastikan bahwa bobot *Ensemble* yang digunakan adalah yang terbaik dan tidak menyebabkan *overfitting*, diperlukan model pembelajaran yang efisien dan mendapatkan bobot terbaik seperti *Fully Connected* untuk memastikan kualitas bobot tersebut. *Fully Connected* merupakan komponen dalam jaringan syaraf tiruan yang menghubungkan semua fitur-fitur yang telah dipelajari sebelumnya dengan fitur-fitur yang akan dipelajari berikutnya. *Fully Connected* dapat digunakan pada tahapan akhir klasifikasi dengan memetakan fitur pada kelas tertentu (Khan et al., 2020). Smaida and Yaroshchak, (2020) menggunakan metode *Ensemble Learning* yang menggabungkan hasil CNN, Vgg16 and InceptionV3 dengan pembelajaran *Fully Connected* pada citra penyakit mata dengan empat kelas, namun hasil akurasi pada penelitian ini masih di bawah 88%.

Penelitian ini mengusulkan metode *Ensemble Learning* yang menggabungkan hasil *DenseNet*, *EfficienNet* dan *Vision Transformer* menggunakan teknik *Weighted Voting* dengan menggunakan pembelajaran *Fully Connected* (FC) dan melibatkan fungsi aktivasi pada klasifikasi penyakit mata. Penerapan metode *Ensemble Learning* pada penelitian ini diharapkan dapat memberikan hasil yang tidak mengalami *overfitting* dan menunjukkan kinerja yang baik. Setelah melakukan teknik *weighted voting* berdasarkan hasil *DenseNet*, *EfficienNet* dan *Vision*

Transformer, penelitian ini melakukan pembelajaran menggunakan pembelajaran FC. Pembelajaran *FC* digunakan untuk membantu model mempelajari pola pembobotan pada setiap data, sekaligus mencegah *overfitting* dalam proses klasifikasi penyakit mata. Penelitian ini mengklasifikasi tingkat keparahan penyakit mata dengan 4 kelompok yaitu normal, katarak, DR, dan glaukoma. Hasil kategori kinerja arsitektur dapat diukur berdasarkan akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *Cohen's Kappa*.

1.2 Rumusan Masalah

Bagaimana hasil kinerja metode *Ensemble Learning* menggunakan teknik *Weighted Voting* pada arsitektur *DensesNet*, *EfficienNet* dan *Vision Transformer* pada proses *training* dengan pembelajaran *Fully Connected* dibandingkan hasil kinerja dari arsitektur tunggal berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-Score* dan *Cohen's Kappa* dalam klasifikasi penyakit mata *single classsifier DensesNet*, *EfficienNet* dan *Vision Transformer*.

1.3 Batasan Masalah

Batasan masalah yang diterapkan pada penelitian ini adalah ukuran hasil kinerja yang digunakan dalam klasifikasi penyakit mata berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-Score* dan *Cohens Kappa*.

1.4 Tujuan

Tujuan penelitian ini adalah untuk memperoleh hasil kinerja dari metode *Ensemble Learning* menggunakan teknik *Weighted Voting* pada arsitektur *DensesNet*, *EfficienNet* dan *Vision Transformer* pada proses *training* dengan

pembelajaran *Fully Connected* dibandingkan hasil kinerja dari arsitektur tunggal berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-Score* dan *Cohens Kappa* dalam klasifikasi penyakit mata *single classsifier DensesNet, EfficienNet* dan *Vision Transformer*.

1.5 Manfaat

Manfaat dari hasil penelitian ini sebagai berikut :

- a. Dapat digunakan sebagai model aplikasi yang berbasis AI yang dapat mengklasifikasi penyakit mata pada citra 2D untuk deteksi dini penyakit mata.
- b. Dapat digunakan sebagai referensi model yang digunakan untuk penelitian lainnya, khususnya dalam klasifikasi penyakit mata pada 2D dan pengembangan *Deep Learning*.

DAFTAR PUSTAKA

- Abayomi Alli, O. O., Damaševičius, R., Maskeliūnas, R., & Misra, S. (2022). An ensemble learning model for COVID-19 detection from blood test samples. *Sensors*, 22(6).
- Abbas, Q. (2017). Glaucoma-deep: detection of glaucoma eye disease on retinal fundus images using deep learning. *International Journal of Advanced Computer Science and Applications*, 8(6), 41–45.
- Abdullah, A. A., Aldhahab, A., & Abboodi, H. M. Al. (2024). Deep-Ensemble Learning Models for the Detection and Classification of Eye Diseases Based on Engineering Feature Extraction with Efficientb6 and Densnet169. *International Journal of Intelligent Engineering and Systems*, 17(6), 1001–1022.
- Ahmed J. Afifi, Olaf, L. Z., Soomro, S., Gao, & Junbin. (2019). Deep Learning Models for Retinal Blood Vessels Segmentation: A Review. *IEEE Access*, 7.
- Albawi, S., Mohammed, T. A. M., & Alzawi, S. (2017). Layers of a Convolutional Neural Network. *Icet2017*, 1–6.
- 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).
- Bagchi, S., & Bathula, D. R. (2022). EEG-conv transformer for single-trial EEG-based visual stimulus classification. *Pattern Recognition*, 129, 108757.
- Bashmal, L., Bazi, Y., & Al Rahhal, M. (2021). Deep vision transformers for remote sensing scene classification. *International Geoscience and Remote Sensing Symposium (IGARSS), 2021-July*, 2815–2818.
- 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. In *Advances in Intelligent Systems and Computing* (Vol. 941). Springer International Publishing.
- Bird, J. J., & Lotfi, A. (2024). CIFAKE: image classification and explainable identification of AI-generated synthetic images. *IEEE Access*, 12(February), 15642–15650.
- 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.
- 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, 78368–78381.
- Cuenat, S., & Couturier, R. (2022). Convolutional neural network (CNN) vs vision transformer (ViT) for digital holography. *2022 2nd International Conference on Computer, Control and Robotics, ICCCR 2022, March*, 235–240.
- Cui, B., Chen, X., & Lu, Y. (2020). Semantic Segmentation of Remote Sensing Images Using Transfer Learning and Deep Convolutional Neural Network with Dense Connection. *IEEE Access*, 8, 116744–116755.

- 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 (IJETR)*, 9(12).
- 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*, 1–11.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., 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: transformers for image recognition at scale. *ICLR 2021 - 9th International Conference on Learning Representations*.
- 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, 84631–84641.
- 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*, 6804–6815.
- Farhad Hossain, M., Chandra Nandi, D., Nazmul Ahsan, M., & Author, C. (2020). Knowledge, attitude and practices regarding common eye disease in bangladesh: a study of cumilla zone. *IOSR Journal Of Humanities And Social Science (IOSR-JHSS)*, 25(7), 50–55.
- Feng, X., Yao, H., & Zhang, S. (2019). An efficient way to refine DenseNet. *Signal, Image and Video Processing*, 13(5), 959–965.
- Foroozesh, J., Khosravani, A., Mohsenzadeh, A., & Haghghat mesbahi, A. (2013). Application of artificial intelligence (AI) modeling in kinetics of methane hydrate growth. *American Journal of Analytical Chemistry*, 04, 616–622.
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). *Fundamental Concepts of Convolutional Neural Network BT - Recent Trends and Advances in Artificial Intelligence and Internet of Things* (V. E. Balas, R. Kumar, & R. Srivastava (eds.); pp. 519–567). Springer International Publishing.
- 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*, 2023, 1305583.
- He, J., Li, C., Ye, J., Qiao, Y., & Gu, L. (2021). Multi-label ocular disease classification with a dense correlation deep neural network. *Biomedical Signal Processing and Control*, 63(June 2020), 102167.
- Hendrycks, D., & Gimpel, K. (2016). *Gaussian error linear units (GELUs)*. 1–10.
- Ho, E., Wang, E., Youn, S., Sivajohan, A., Lane, K., Chun, J., & Hutnik, C. M. L. (2022). Deep Ensemble Learning for Retinal Image Classification. *Translational Vision Science and Technology*, 11(10), 1–11.
- Huang, W., Feng, J., Wang, H., & Sun, L. (2020). A new architecture of densely

- connected convolutional networks for pan-sharpening. *ISPRS International Journal of Geo-Information*, 9(4).
- Jadon, S. (2020). A survey of loss functions for semantic segmentation. *2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology, CIBCB 2020*.
- Jatmoko, C., Lestiawan, H., Agustina, F., & Erawan, L. (2024). Comparative study of classification of eye disease types using densenet and EfficientNetb3. *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, 4(3).
- 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, EMBS*, 2045–2048.
- 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, 2021-October*, 3228–3238.
- Kandel, I., & Castelli, M. (2020). Transfer learning with convolutional neural networks for diabetic retinopathy image classification. a review. *Applied Sciences*, 10(6), 1–24.
- 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.
- 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*.
- 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.
- Khudhair, Z. N., Khdiar, A. N., El Abbadi, N. K., Mohamed, F., Saba, T., Alamri, F. S., & Rehman, A. (2023). Color to grayscale image conversion based on singular value decomposition. *IEEE Access*, 11(6), 54629–54638.
- Kyari, F., Entekume, G., Rabi, M., Spry, P., Wormald, R., Nolan, W., Murthy, G. V. S., & Gilbert, C. E. (2015). A population-based survey of the prevalence and types of glaucoma in nigeria: results from the nigeria national blindness and visual impairment survey. *BMC Ophthalmology*, 15(1), 1–15.
- Li, Q., 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*, 2018, 1–8.
- Lin, H., Li, R., Liu, Z., Chen, Y., & Guo, M. (2021). EfficientNet b3-based deep learning model for glaucoma detection with attention mechanism. *Computers in Biology and Medicine*, 134, 104482.
- Luque, A., Carrasco, A., Martín, A., & de las Heras, A. (2019). The impact of class

- imbalance in classification performance metrics based on the binary confusion matrix. *Pattern Recognition*, 91, 216–231.
- 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*, 2015.
- 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, 136668–136673.
- Muhammad Nur Ihsan Muhlashin, & Stefanie, A. (2023). Klasifikasi penyakit mata berdasarkan citra fundus menggunakan yolo v8. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(2), 1363–1368.
- Nandal, A., Bhaskar, V., & Dhaka, A. (2018). Contrast-based image enhancement algorithm using grey-scale and colour space. *IET Signal Processing*, 12(4), 514–521.
- 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.
- 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.
- Osamor, V. C., & Okezie, A. F. (2021). Enhancing the weighted voting ensemble algorithm for tuberculosis predictive diagnosis. *Scientific Reports*, 11(1), 1–12.
- Perez, L., & Wang, J. (2017). *The effectiveness of data augmentation in image classification using deep learning*.
- Pravin, S. C., Sabapathy, S. P. K., Selvakumar, S., Jayaraman, S., & Subramani, S. V. (2023). An efficient densenet for diabetic retinopathy screening. *International Journal of Engineering and Technology Innovation*, 13(2), 125–136.
- 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.
- 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.
- 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.
- Rodrawangpai, B., & Daungjaiboon, W. (2022). Improving text classification with transformers and layer normalization. *Machine Learning with Applications*, 10, 1–9.

- Rong, Z., Yuan, L., & Yang, L. (2024). Enhanced knowledge graph recommendation algorithm based on multi-level contrastive learning. *Scientific Reports*, *14*(1), 1–14.
- Ryu, S., Joe, I., & Kim, W. T. (2021). Intelligent forwarding strategy for congestion control using Q-learning and LSTM in named data networking. *Mobile Information Systems*.
- Sitompul, P., & Rosnelly, R. (2023). *Segmentation of Skin Cancer Images Using Fully Convolutional DenseNet - Tiramisu (One Hundred Layers)*. August, 130–138.
- Smaida, M., & Yaroshchak, S. (2020). Bagging of convolutional neural networks for diagnostic of eye diseases. *CEUR Workshop Proceedings*, *2604*, 715–729.
- Tan, M., & Le, Q. V. (2019a). EfficientNet: Rethinking model scaling for convolutional neural networks. *ArXiv Preprint ArXiv*, *97*, 10691–10700.
- Tan, M., & Le, Q. V. (2019b). EfficientNet: Rethinking model scaling for convolutional neural networks. *International Conference on Machine Learning, ICML 2019*, 10691–10700.
- Toptas, B., & Hanbay, D. (2022). The Separation of glaucoma and non-glaucoma fundus images using EfficientNet-B0. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, *11*(4), 1084–1092.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). Attention is all you need. In I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, & R. Garnett (Eds.), *Advances in Neural Information Processing Systems* (Vol. 30). Curran Associates, Inc.
- Verdy, & Ery Hartati. (2024). Klasifikasi penyakit mata menggunakan convolutional neural network model resnet-50. *Jurnal Rekayasa Sistem Informasi Dan Teknologi*, *1*(3), 199–206.
- Wang, G., Chen, H., Chen, L., Zhuang, Y., Zhang, S., Zhang, T., Dong, H., & Gao, P. (2023). P2FEViT: plug-and-play cnn feature embedded hybrid vision transformer for remote sensing image classification. *Remote Sensing*, *15*(7), 1–26.
- Wang, J., Yang, L., Huo, Z., He, W., & Luo, J. (2020). Multi-label classification of fundus images with EfficientNet. *IEEE Access*, *8*, 212499–212508.
- Wang, Q., Ma, Y., Zhao, K., & Tian, Y. (2020). A comprehensive survey of loss functions in machine. *Annals of Data Science*, *5*.
- Yaghoubi, E., Yaghoubi, E., Khamees, A., & Vakili, A. H. (2024). A systematic review and meta-analysis of artificial neural network, machine learning, deep learning, and ensemble learning approaches in field of geotechnical engineering. In *Neural Computing and Applications* (Vol. 36, Issue 21). Springer London.
- Ye, J. C. (2022). Artificial neural networks and backpropagation. *Mathematics in Industry*, *37*(August), 91–112.
- Yohannese, C. W., Li, T., & Bashir, K. (2018). A three-stage based ensemble

- learning for improved software fault prediction: an empirical comparative study. *International Journal of Computational Intelligence Systems*, 11(1), 1229–1247.
- 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, H., & He, Z. (2019). Automatic cataract grading methods based on deep learning. *Computer Methods and Programs in Biomedicine*, 182, 104978.
- Zhang, Z., Liang, X., Dong, X., Xie, Y., & Cao, G. (2018). A sparse-view ct reconstruction method based on combination of densenet and deconvolution. *IEEE Transactions on Medical Imaging*, 37(6), 1407–1417.
- Zhou, T., Ye, X., Lu, H., Zheng, X., Qiu, S., & Liu, Y. (2022). Dense Convolutional Network and Its application in medical image analysis. *BioMed Research International*, 2022, 22.
- 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(May), 105737.
- Zubair, M., Kim, J., & Yoon, C. (2016). An automated ECG beat classification system using convolutional neural networks. *6th International Conference on IT Convergence and Security, ICITCS 2016*.