

**METODE *ENSEMBLE LEARNING* TEKNIK *WEIGHTED AVERAGE*
DENGAN PEMBELAJARAN *SQUEEZENET* PADA ARSITEKTUR
MOBILENETV2 DAN *EFFICIENTNET-B0* DALAM
KLASIFIKASI PENYAKIT MATA**

SKRIPSI

**Diajukan Sebagai Salah Satu Syarat untuk Memperoleh Gelar Sarjana
di Jurusan Matematika pada Fakultas MIPA**

Oleh:

LUCY CHANIA AGATHA

NIM 08011282126040



**JURUSAN MATEMATIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS SRIWIJAYA
2025**

LEMBAR PENGESAHAN

**METODE ENSEMBLE LEARNING TEKNIK WEIGHTED AVERAGE
DENGAN PEMBELAJARAN SQUEEZENET PADA ARSITEKTUR
MOBILENETV2 DAN EFFICIENTNET-B0 DALAM
KLASIFIKASI PENYAKIT MATA**

SKRIPSI

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

Oleh

**LUCY CHANIA AGATHA
NIM.08011282126040**

Pembimbing Kedua

**Indralaya, 22 Mei 2025
Pembimbing Utama**



**Drs. Ali Amran, M.T
NIP. 196612131994021001**



**Dr. Bambang Suprihatia, S.Si., M.Si
NIP. 1971011261994121001**

Mengetahui,

Ketua Jurusan Matematika



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

HALAMAN PERSEMBAHAN

Kupersembahkan skripsi ini untuk:

Yang Maha Kuasa Allah Subhanahu Wa Ta'ala,

Ayah dan Ibu yang sangat kucinta,

Adik-adikku tersayang,

Keluarga Besarku,

Semua Dosenku,

Teman baik yang Kubanggakan,

Almamaterku

Motto

“Jatah kebahagiaan dalam hidup sudah ditentukan, jatah kemalangan juga sudah ditentukan. Jika seseorang mengalami sebuah kesulitan, dia harus percaya ha-hal

baik akan segera datang”

~ Melo Movie

PERNYATAAN KEASLIAN KARYA ILMIAH

Yang bertanda tangan di bawah ini:

Nama Mahasiswa : Lucy Chania Agatha
NIM : 08011282126040
Fakultas/Jurusan : Matematika dan Ilmu Pengetahuan Alam /
Matematika

Menyatakan bahwa skripsi ini adalah hasil karya ilmiah 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 didalam skripsi ini yang berasal dari penulis lain baik yang dipublikasi atau tidak telah diberikan penghargaan dengan mengutip nama sumber penulis baik yang secara benar. Semua isi dari skripsi ini sepenuhnya menjadi tanggung jawab saya sebagai penulis.

Demikianlah surat pernyataan ini saya buat dengan sebenarnya.

Indralaya, 20 Mei 2025

Penulis



Lucy Chania Agatha

NIM. 08011282126040

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* Teknik *Weighted Average* dengan Pembelajaran *SqueezeNet* pada Arsitektur *MobileNetV2* dan *EfficientNet-B0* 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. Cinta pertama dan panutanku, Ayahku **Khairul Alris** yang tidak pernah berhenti berjuang dan memberikan yang terbaik untukku sebagai putrinya, sehingga penulis dapat menyelesaikan studinya hingga sarjana. Terkhusus pintu surgaku, Ibuku **Janna Mardalena** 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. Skripsi ini penulis persembahkan kepada ayah dan ibu penulis. 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 **Prof. Yulia Resti, S.Si, M.Si, Ph.D** selaku dosen pembimbing akademik, Bapak **Dr. Bambang Suprihatin, S.Si, M.Si** dan Bapak **Drs. Ali Amran, M.T** selaku dosen pembimbing, Ibu **Dr. Anita Desiani, S.Si, M.Kom** dan Ibu **Des Alwine Zayanti, S.Si, M.Si** selaku dosen pembahas yang telah bersedia meluangkan waktu, tenaga, dan pikiran untuk memberikan bimbingan yang berharga selama pembuatan skripsi dan proses perkuliahan.
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, **Reni Alfiah Chaniago** dan **Muhammad Atqan Chaniago** yang senantiasa memberikan semangat, mendukung dan terus mendo'akan untuk penulis. Tumbuhlah menjadi versi yang paling hebat.
5. **Keluarga Besar Himastik, Kakak-kakak dan adik-adik tingkat bidang komputasi, Tim Komputasi 2021, Keluarga Matematika 2021, BPH Himastik Kabinet Laskaria, BPH MAPALA SABAK** yang telah membantu serta berbagi ilmu selama proses perkuliahan. Terima kasih untuk bantuan, semangat dan kerjasamanya.

6. **Dulurku Angkatan SATRIA, Ka Peps, Pakam, Sahabatku Duta Angzayyy, Amin Asik Squad, Mitut, Gendatz, Elda, Lebu, Aul, Niken, Ruth, Lili** yang tidak pernah letih untuk menemani dan direpotkan oleh penulis. Terima kasih selalu memberikan doa dan dukungan kepada penulis.
7. Kepada pemilik **GMP.XXII.133.JBK**, terima kasih telah menjadi bagian dari perjalanan hidup penulis, berkontribusi baik tenaga dan waktu, menemani, mendukung, mendengarkan keluh kesah dan meyakinkan penulis untuk bisa menyelesaikan skripsi ini.
8. Kepada diri saya sendiri, **Lucy Chania Agatha, S.Si.** Terima kasih tetap memilih berusaha dan bertahan bahkan saat meragukan diri sendiri. Apapun kurang dan lebihmu mari rayakan diri sendiri.

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, Mei 2025

Penulis

ENSEMBLE LEARNING METHOD WEIGHTED AVERAGE TECHNIQUE WITH SQUEEZENET LEARNING ON MOBILENETV2 AND EFFICIENTNET-B0 ARCHITECTURE IN EYE DISEASE CLASSIFICATION

By :

Lucy Chania Agatha

08011282126040

ABSTARCT

Eye diseases such as cataracts, diabetic retinopathy (DR), glaucoma are conditions that cause visual impairment to blindness. Automatic early detection can be done by classifying eye images, one of which uses Deep Learning methods. Effective deep learning approaches in eye image classification include Convolutional Neural Network (CNN). Various CNN architectures such as MobileNetV2 and EfficientNet-B0, have been developed to improve classification performance. MobileNetV2 is known as a lightweight architecture with high computational efficiency through Depthwise Separable Convolution, but has limitations in capturing the relationship between channels. EfficientNet-B0 uses Compound Scaling and Mobile Inverted Bottleneck Convolution (MBConv) to achieve computational efficiency, but the relatively small number of parameters makes EfficientNet-B0 less optimal in handling complex datasets. The performance of MobileNetV2 and EfficientNet-B0 can be improved by combining the classification results of both architectures using ensemble learning methods. This research applies ensemble learning weighted average technique through SqueezeNet learning. SqueezeNet was used for learning because it is a simple architecture that relies on fire modules, making the model faster to train and reducing the risk of overfitting in learning the weights. The average result of ensemble learning performance obtained 95% accuracy indicates the model is very good at predicting eye diseases correctly. Sensitivity of 95% indicates the model is sensitive to the normal class. Specificity of 98% indicates accuracy in predicting eye disease classes. F1-score 95% indicates the model is balanced in distinguishing each class. Cohen's Kappa 93% shows the consistency of the prediction with the actual class. These results provide an improvement over the single classification results with an accuracy of 14%, specificity of 16%, sensitivity of 5%, F1-score of 15%, and Cohen's Kappa of 20%. The performance evaluation results per class show very good performance, but it is still quite low in the DR class, which is still below 90%. The results prove that the proposed ensemble learning method is effective in the classification of eye diseases and is able to improve the performance results of a single classification.

Keywords: *MobileNetV2, EfficientNet-B0, SqueezeNet, Weighted Average*

**METODE *ENSEMBLE LEARNING* TEKNIK *WEIGHTED AVERAGE*
DENGAN PEMBELAJARAN *SQUEEZENET* PADA ARSITEKTUR
MOBILENETV2 DAN *EFFICIENTNET-B0* DALAM
KLASIFIKASI PENYAKIT MATA**

Oleh:

**Lucy Chania Agatha
08011282126040**

ABSTRAK

Penyakit mata seperti katarak, *diabetic retinopathy* (DR), glukoma merupakan kondisi yang menimbulkan gangguan penglihatan hingga kebutaan. Deteksi dini secara otomatis dapat dilakukan dengan mengklasifikasikan citra mata, salah satunya menggunakan metode *Deep Learning*. Pendekatan *deep learning* yang efektif dalam klasifikasi citra mata diantaranya *Convolutional Neural Network* (CNN). Berbagai Arsitektur CNN seperti *MobileNetV2* dan *EfficientNet-B0*, telah dikembangkan untuk meningkatkan kinerja klasifikasi. *MobileNetV2* dikenal sebagai arsitektur ringan dengan efisiensi komputasi tinggi melalui *Depthwise Separable Convolution*, namun memiliki keterbatasan dalam menangkap hubungan antar *channel*. *EfficientNet-B0* menggunakan *Compound Scaling* dan *Mobile Inverted Bottleneck Convolution* (MBConv) untuk mencapai efisiensi komputasi, namun jumlah parameter yang relatif sedikit, membuat *EfficientNet-B0* kurang optimal dalam menangani dataset kompleks. Kinerja *MobileNetV2* dan *EfficientNet-B0* dapat ditingkatkan dengan menggabungkan hasil klasifikasi kedua arsitektur tersebut menggunakan metode *ensemble learning*. Penelitian ini menerapkan *ensemble learning* teknik *weighted average* melalui pembelajaran *SqueezeNet*. *SqueezeNet* digunakan sebagai pembelajaran karena merupakan arsitektur sederhana yang mengandalkan *fire module*, sehingga membuat model lebih cepat saat dilatih dan mengurangi risiko *overfitting* dalam mempelajari bobot. Hasil rata-rata kinerja *ensemble learning* diperoleh akurasi 95% menunjukkan model sangat baik memprediksi penyakit mata dengan benar. Sensitivitas 95% menunjukkan model sensitif terhadap kelas normal. Spesifisitas 98% menunjukkan ketepatan dalam memprediksi kelas penyakit mata. *F1-score* 95% menunjukkan model seimbang dalam membedakan setiap kelas. *Cohen's Kappa* 93% menunjukkan konsistensi prediksi dengan kelas sebenarnya. Hasil tersebut memberi peningkatan dari hasil klasifikasi tunggal dengan akurasi sebesar 14%, spesifisitas 16%, sensitivitas 5%, *F1-score* 15%, dan *Cohen's Kappa* 20%. Hasil evaluasi kinerja per kelas menunjukkan performa sangat baik, namun masih cukup rendah pada kelas DR yaitu masih dibawah 90%. Pada penelitian selanjutnya diharapkan dapat dilakukan peningkatan klasifikasi pada kelas DR. Hasil

membuktikan metode *ensemble learning* yang diusulkan efektif dalam klasifikasi penyakit mata dan mampu meningkatkan hasil kinerja dari klasifikasi tunggal.

Kata Kunci: *MobileNetV2, EfficientNet-B0, SqueezeNet, Weighted Average*

DAFTAR ISI

LEMBAR PENGESAHAN	ii
HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH.....	iii
HALAMAN PERSEMBAHAN.....	iv
KATA PENGANTAR.....	v
ABSTARCT	viii
ABSTRAK	ix
DAFTAR ISI.....	xi
DAFTAR TABEL.....	xiv
DAFTAR GAMBAR.....	xv
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	7
1.3 Batasan Masalah.....	7
1.4 Tujuan Penelitian.....	7
1.5 Manfaat Penelitian.....	8
BAB II TINJAUAN PUSTAKA.....	9
2.1 <i>Eyes Disease Classification</i>	9
2.2 Citra Digital.....	9
2.3 Citra Mata.....	10
2.4 Perbaikan Kualitas Citra.....	11
1. <i>Grayscale</i>	11
2. <i>Contrast Limited Adaptive Histogram Equalization (CLAHE)</i> ..	11

2.5 Augmentasi Citra.....	12
2.6 Klasifikasi Citra.....	13
2.7 <i>MobileNetV2</i>	14
2.8 <i>EfficientNet-B0</i>	25
2.9 <i>Ensemble Learning</i>	32
2.10 <i>SqueezeNet</i>	32
2.11 <i>Confusion Matrix</i>	37
BAB III METODOLOGI PENELITIAN	39
3.1 Tempat.....	39
3.2 Waktu.....	39
3.3 Alat.....	39
3.4 Tahapan Penelitian	40
3.4.1 Pengumpulan Data	40
3.4.2 <i>Preprocessing</i> : Perbaikan Citra	40
3.4.3 Augmentasi.....	40
3.4.4 Tahap Training	41
3.4.5 <i>Testing Data</i>	44
BAB IV HASIL DAN PEMBAHASAN.....	45
4.1 Deskripsi Data	45
4.2 <i>Preprocessing</i> Data	46
4.3 Operasi Manual Arsitektur	50
4.3.1 <i>MobileNetV2</i>	50
4.3.2 <i>EfficientNet-B0</i>	64

4.3.3 <i>Ensemble Learning</i>	78
4.4 Penerapan <i>MobileNetV2, EfficientNet-B0 dan Ensemble Learning</i>	89
4.4.1 <i>Training</i>	89
4.4.2 <i>Testing</i>	92
4.4.3 <i>Evaluasi</i>	97
4.4.4 Analisis dan hasil.....	100
BAB V PENUTUP	102
5.1 Kesimpulan.....	102
5.2 Saran.....	103
DAFTAR PUSTAKA	103

DAFTAR TABEL

Tabel 2. 1 Kinerja Arsitektur 38

Tabel 4. 1 Sampel Data Training dan Data Testing45

Tabel 4. 2 Hasil *Confusion Matrix* Data *Testing MobileNetV2* 93

Tabel 4. 3 Hasil *Confusion Matrix* Data *Testing EfficientNet-B0*..... 94

Tabel 4. 4 Hasil *Confusion Matrix* Data *Testing Ensemble* 95

Tabel 4. 5 Perbandingan hasil klasifikasi dari setiap model 99

Tabel 4. 4 Perbandingan Arsitektur dengan Penelitian Lain..... 101

DAFTAR GAMBAR

Gambar 2. 1 Citra Mata..... 10

Gambar 2. 2 Proses Augmentasi Citra 13

Gambar 2. 3 Arsitektur *MobileNetV2* 14

Gambar 2. 4 Ilustrasi *Padding Same* 15

Gambar 2. 5 Proses *Convolution Layer* 16

Gambar 2. 6 Ilustrasi *Global Average Pooling* 21

Gambar 2. 7 Arsitektur *EfficientNet-B0*..... 25

Gambar 2. 8 Arsitektur *SqueezeNet* 33

Gambar 2.9 Ilustrasi *Fire Module* 34

Gambar 2.10 Ilustrasi *Fully connected Layer* 35

Gambar 4. 1 Proses Augmentasi Citra49

Gambar 4. 3 Grafik (a) akurasi dan (b) *loss* proses *training MobileNetV2* 90

Gambar 4. 4 Grafik (a) akurasi dan (b) *loss* proses *training EfficientNet-B0*..... 91

Gambar 4.5 Grafik (a) akurasi dan (b) *loss* proses *training ensemble learning* ... 92

BAB I

PENDAHULUAN

1.1 Latar Belakang

Penyakit mata merupakan kondisi yang mempengaruhi fungsi dan kesehatan mata yang berpotensi menimbulkan ketidaknyamanan, gangguan penglihatan, dan bahkan kebutaan. Penyakit mata dapat dikelompokkan menjadi katarak, *diabetic rethinopathy* (DR) dan glukoma (Rachmawanto *et al.*, 2024). Deteksi dini untuk melakukan pencegahan dan diagnosis dapat dilakukan dengan klasifikasi citra mata, tetapi kelemahan manusia seperti kelelahan dan ketidaktepatan dalam analisis dapat menyebabkan diagnosis yang kurang akurat sehingga dapat menyebabkan kesalahan (Arif *et al.*, 2023). Klasifikasi citra mata secara otomatis yang membantu melakukan deteksi dini dapat dilakukan dengan menggunakan metode *deep learning* (Patil and Rane, 2021).

Convolutional neural network (CNN) merupakan salah satu metode *deep learning* yang banyak digunakan untuk klasifikasi citra mata (Elkholy and Marzouk, 2023). CNN memiliki *convolution layer* yang membantu dalam proses klasifikasi untuk menangkap fitur-fitur penting seperti pola, tekstur, atau bentuk pada citra. Arsitektur CNN dengan *convolution layer* diantaranya yaitu *MobileNetV2* dan *EfficientNet-B0*. *MobileNetV2* merupakan arsitektur CNN yang memiliki efisiensi komputasi karena menggunakan *depthwise separable convolution*. *Depthwise separable convolution* adalah jenis konvolusi yang dirancang untuk mengurangi jumlah komputasi sehingga membuat model lebih

ringan dan lebih cepat (Sinha and El-Sharkawy, 2019). *Depthwise separable convolution* terdiri dari dua tahap, yaitu *depthwise convolution* dan *pointwise convolution*. Pada tahap *depthwise convolution*, berfungsi untuk melakukan ekstraksi spasial (pola dan bentuk citra) dengan filter diterapkan secara terpisah pada setiap *channel* input. Selanjutnya, *pointwise convolution* menggunakan filter berukuran 1×1 untuk menggabungkan informasi dari seluruh *channel* tersebut sehingga membentuk representasi akhir. Berbeda dengan konvolusi biasa yang menerapkan filter secara langsung pada seluruh *channel input* sekaligus, *depthwise separable convolution* lebih efisien karena memisahkan proses ekstraksi spasial dan penggabungan antar *channel* (Sun et al., 2020). *MobileNetV2* juga menggunakan *bottleneck layer*, yang merupakan lapisan untuk mengurangi dimensi data yang sedang diproses, terdiri dari *expansion layer*, *depthwise convolution*, dan *inverted residual connection*. *Expansion layer* adalah lapisan yang digunakan untuk memperluas dimensi fitur untuk menangkap informasi kompleks. *Depthwise convolution* adalah jenis konvolusi yang berfungsi untuk melakukan ekstraksi spasial (pola dan bentuk citra) secara efisien dengan beban komputasi yang lebih ringan dibandingkan konvolusi biasa. *Inverted residual connection* adalah suatu teknik yang menghubungkan fitur awal dan hasil akhir dari *bottleneck layer* untuk menjaga informasi penting dari fitur awal (Triwiyanto et al., 2023).

Saqib et al. (2024) menerapkan *MobileNetV2* dalam mendeteksi *Cataract* dan *Glaucoma*. Penelitian tersebut memperoleh nilai akurasi 97%. Namun hasil *Precision*, *Recall*, dan *F1-Score* masih dibawah 75%. Yassin (2023) menerapkan *MobileNetV2* dalam klasifikasi DR dengan hasil akurasi yaitu 88%. Namun

penelitian tersebut tidak mengukur nilai sensitivitas, spesifitas dan F1-Score. Jidan *et al.* (2023) menerapkan arsitektur *MobileNetV2* dalam klasifikasi katarak dan menghasilkan nilai akurasi, *Precision*, *Recall*, dan F1-Score diatas 95%. Namun, Penelitian tersebut hanya melakukan klasifikasi pada 2 kelas, yaitu katarak dan normal. Meskipun *MobileNetV2* dirancang untuk perangkat dengan sumber daya terbatas, *MobileNetV2* memiliki keterbatasan karena pemrosesan *channel* secara terpisah pada *depthwise convolution* mengakibatkan kurang optimal dalam menangkap hubungan antar *channel* dan sulit mengenali pola kompleks (Şener and Sümer, 2023).

Arsitektur CNN lain yang digunakan adalah *EfficientNet-B0*. *EfficientNet-B0* merupakan jenis model yang paling dasar (*base model*) pada arsitektur *EfficientNet*. *EfficientNet-B0* memiliki keunggulan dari jenis *EfficientNet-B1* hingga *EfficientNet-B7* karena merupakan jenis model yang paling ringan dan hanya membutuhkan lebih sedikit memori untuk menyimpan bobot model, yang sangat menguntungkan saat proses pelatihan dengan perangkat dengan kapasitas memori terbatas. *EfficientNet-B0* menggunakan modul *compound scaling* dan *Mobile Inverted Bottleneck Convolution* (MBConv). *Compound scaling* adalah suatu teknik yang mengoptimalkan 3 dimensi penting yaitu mengoptimalkan, lebar (*width*) jumlah *filter* per *layer*, kedalaman (*depth*) jumlah *layer*, dan resolusi (*resolution*) ukuran input gambar secara bersamaan sehingga model lebih efisien (Abdullah et al., 2024). MBConv adalah blok konvolusi yang meningkatkan efisiensi komputasi dengan parameter yang lebih sedikit. MBConv dilakukan dengan memperbesar jumlah *channel* untuk menangkap lebih banyak informasi,

sebelum kemudian mengecilkannya kembali untuk mengurangi kompleksitas dan meningkatkan efisiensi. Anand *et al.* (2024) menerapkan *EfficientNet-B0* klasifikasi DR dengan akurasi, *precision*, *recall*, dan *f1-score* diatas 90%. Namun penelitian tersebut hanya melakukan iterasi (epoch) sebanyak 15. Şener and Sümer (2023) menerapkan *EfficientNet-B0* pada klasifikasi *Diabetic Retinopathy*. Penelitian tersebut menghasilkan nilai akurasi, *Precision*, *Recall* diatas 95%. Namun, penelitian tersebut tidak mengukur nilai *f1-score*. Arif *et al.* (2023) menerapkan arsitektur *EfficientNet-B0* pada klasifikasi penyakit mata. Namun, penelitian tersebut menghasilkan akurasi, *precision*, *recall*, dan *f1-score* dibawah 85%. Meskipun *EfficientNet-B0* mampu meningkatkan efisiensi komputasi, jumlah parameter yang sedikit menyebabkan *EfficientNet-B0* kurang optimal dalam menangani dataset yang lebih kompleks (Abdullah *et al.*, 2024).

Klasifikasi dari masing-masing arsitektur *MobileNetV2* dan *EfficientNet-B0* termasuk kedalam klasifikasi tunggal. Hasil kinerja setiap arsitektur tunggal dapat ditingkatkan dengan menggunakan metode *ensemble learning* (Kesuma *et al.*, 2023). *Ensemble learning* adalah metode yang menggabungkan hasil klasifikasi dari arsitektur tunggal menjadi model baru dengan hasil yang lebih baik. *Ensemble learning* memiliki kelebihan dibandingkan dengan arsitektur tunggal karena berkerja dengan cara mengambil informasi dari beberapa arsitektur tunggal dan meminimalisir kesalahan (Mahajan *et al.*, 2023). Salah satu teknik pengambilan keputusan dalam metode *ensemble learning* adalah *weighted average* (Nazir *et al.*, 2024). *Weighted average* menetapkan bobot yang berbeda pada setiap *output* arsitektur tunggal, kemudian menghitung rata-rata bobot untuk menentukan

keputusan akhir. Pembobotan setiap arsitektur bertujuan untuk menunjukkan tingkat perbedaan hasil prediksi masing-masing arsitektur dalam metode kalsifikasi (Mohammed and Kora, 2023).

Nazir *et al.* (2024) menerapkan *Ensemble Learning* menggunakan teknik *Weighted Average* pada hasil arsitektur *InceptionV3*, CNN, dan *VGG16*. Penelitian tersebut meningkatkan nilai akurasi menjadi sebesar 95%, nilai presisi sebesar 88% dan *F1-Score* sebesar 86%. Namun nilai *recall* pada penelitian tersebut masih dibawah 85%. Alyami *et al.* (2024) menerapkan *ensemble learning* menggunakan teknik *Weighted Average* pada hasil arsitektur *VGG16*, *VGG16* dan *ResNet50*. Penelitian tersebut menghasilkan nilai akurasi, sensitifitas sebesar 99% dan nilai presisi, spesitifitas sebesar 100%. Namun nilai *recall* pada penelitian tersebut masih dibawah 65%. Vij and Arora (2024) juga menerapkan *Ensemble Learning* menggunakan teknik *Weighted Average* pada hasil arsitektur *ResNet34*, *InceptionV3* dan *VGG16*. Penelitian tersebut menghasilkan nilai akurasi, presisi sebesar 99% dan recall sebesar 100% namun hanya dilakukan klasifikasi DR. Penelitian-penelitian tersebut, hanya menerapkan metode *ensemble* pada tahap pengujian. Sehingga tidak menjamin bahwa bobot yang diperoleh adalah bobot terbaik dan tidak dilakukan pengecekan apakah bobot mengalami *overfitting*. *Overfitting* merupakan kondisi yang terjadi ketika model terlalu menyesuaikan diri dengan data pelatihan, sehingga kinerjanya buruk pada data baru atau pengujian (Desiani *et al.*, 2022).

Untuk memastikan bahwa bobot pada suatu model yang digunakan adalah yang terbaik dan tidak menyebabkan *overfitting*, diperlukan model pembelajaran

deep learning, salah satunya adalah *SqueezeNet*. *SqueezeNet* merupakan arsitektur CNN yang menggunakan *fire module*. *fire module* adalah blok terdiri dari dua lapisan *Squeeze layer* dan *Expand layer*. *Squeeze layer* menggunakan konvolusi 1×1 untuk mengurangi dimensi input, sementara *Expand layer* memperluas fitur kembali menggunakan konvolusi 1×1 dan 3×3 . Pendekatan ini mengurangi kompleksitas komputasi, menjadikan *SqueezeNet* arsitektur yang ringan dan lebih cepat saat dilatih. Selain itu, hal ini juga membantu mengurangi risiko *overfitting*. *SqueezeNet* sangat baik digunakan di tahap akhir klasifikasi untuk memetakan fitur pada kelas tertentu secara efektif (Khan *et al.*, 2020).

Penelitian ini mengusulkan metode *Ensemble Learning* yang menggabungkan hasil *MobileNetV2* dan *EfficientNet-B0* menggunakan teknik *weighted average* dengan pembelajaran *SqueezeNet* 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 average* berdasarkan hasil *MobileNetV2* dan *EfficientNet-B0* penelitian ini melakukan pembelajaran menggunakan pembelajaran *SqueezeNet* yang 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 kelas yaitu katarak, DR, glukoma, dan normal. Hasil kinerja arsitektur diukur berdasarkan akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *Cohens Kappa*.

1.2 Rumusan Masalah

Bagaimana hasil kinerja metode *Ensemble Learning* menggunakan teknik *Weighted Average* pada arsitektur *MobileNetV2* dan *EfficientNet-B0* pada proses *training* dengan pembelajaran *SqueezeNet* dibandingkan hasil kinerja dari arsitektur tunggal berdasarkan nilai akurasi, sensitifitas, spesitifitas, *F1-Score* dan *Cohens Kappa* dalam klasifikasi penyakit mata

1.3 Batasan Masalah

Beberapa pembatasan masalah dalam penelitian adalah sebagai berikut:

1. Penelitian mengklasifikasikan penyakit mata menggunakan 4 kelas yaitu katarak, DR, glukoma, dan normal.
2. Ukuran hasil kinerja pada model klasifikasi penyakit mata penelitian adalah nilai akurasi, sensitivitas, spesitifitas, *f1-score*, dan *cohen's kappa*.

1.4 Tujuan Penelitian

Tujuan dari penelitian adalah untuk memperoleh hasil kinerja metode *Ensemble Learning* menggunakan teknik *Weighted Average* pada arsitektur *MobileNetV2* dan *EfficientNet-B0* pada proses *training* dengan pembelajaran *SqueezeNet* dibandingkan hasil kinerja dari arsitektur tunggal berdasarkan nilai akurasi, sensitifitas, spesitifitas, *F1-Score* dan *Cohens Kappa* dalam klasifikasi penyakit mata

1.5 Manfaat Penelitian

Manfaat dari hasil penelitian sebagai berikut:

1. Memperoleh model yang dapat diterapkan untuk perkembangan teknologi dan membantu para ahli dalam melakukan klasifikasi penyakit mata.
2. Dapat digunakan sebagai referensi penelitian terkait klasifikasi penyakit mata dengan metode *ensemble learning* menggunakan teknik *weighted average*.

DAFTAR PUSTAKA

- 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. <https://doi.org/10.22266/ijies2024.1231.75>
- Alyami, M. F. M., Garg, M., Anand, V., Gupta, S., Reshan, M. S. Al, Almansour, S. H. S., Alyami, S. S. H., & Shaikh, A. (2024). An Intelligent Ensembling of Fine-Tuned Transfer Learning-Based Model for Cataract Diagnosis from Fundus Images. *International Journal of Engineering Trends and Technology*, 72(5), 120–130. <https://doi.org/10.14445/22315381/IJETT-V72I5P113>
- Anand, V., Koundal, D., Alghamdi, W. Y., & Alsharbi, B. M. (2024). Smart grading of diabetic retinopathy: an intelligent recommendation-based fine-tuned EfficientNetB0 framework. *Frontiers in Artificial Intelligence*, 7. <https://doi.org/10.3389/frai.2024.1396160>
- Arif, Z., Nur Fu'adah, R. Y., Rizal, S., & Ilhamdi, D. (2023). Classification of eye diseases in fundus images using Convolutional Neural Network (CNN) method with EfficientNet architecture. *JRTI (Jurnal Riset Tindakan Indonesia)*, 8(1), 125. <https://doi.org/10.29210/30032835000>
- Babaqi, T., Jaradat, M., Yildirim, A. E., Al-nimer, S. H., & Won, D. (2023). Eye Disease Classification Using Deep Learning Techniques. *IISE Annual Conference and Expo 2023, July*. https://doi.org/10.21872/2023IISE_1944
- Bird, J. J., & Lotfi, A. (2024). CIFAKE: Image Classification and Explainable Identification of AI-Generated Synthetic Images. *IEEE Access*, 12(February), 15642–15650. <https://doi.org/10.1109/ACCESS.2024.3356122>
- Biswas, S., Khan, M. I. A., Hossain, M. T., Biswas, A., Nakai, T., & Rohdin, J. (2022). Which Color Channel Is Better for Diagnosing Retinal Diseases Automatically in Color Fundus Photographs? *Life*, 12(7), 1–38. <https://doi.org/10.3390/life12070973>
- 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. <https://doi.org/10.1109/ACCESS.2021.3084050>
- Desiani, A., Adrezo, M., Kresnawati, E. S., Ermatita, Akbar, M., & Hasibuan, M. S. (2023). Back Translation-EDA and Transformer for Hate Speech Classification in Indonesian. *2023 International Conference on Informatics, Multimedia, Cyber and Information Systems, ICIMCIS 2023, November*, 611–616. <https://doi.org/10.1109/ICIMCIS60089.2023.10348979>

- Desiani, A., 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(1), 1–17. <https://doi.org/10.1142/S1469026822500043>
- Desiani, A., Erwin, Suprihatin, B., Efriliyanti, F., Arhami, M., & Setyaningsih, E. (2022). VG-DropDNet a Robust Architecture for Blood Vessels Segmentation on Retinal Image. *IEEE Access*, 10(September), 92067–92083. <https://doi.org/10.1109/ACCESS.2022.3202890>
- Eapen, N. G., Samanta, D., Kaur, M., Al-amri, J. F., & Masud, M. (2021). *Elementary Methods for Generating Three-Dimensional Coordinate Estimation and Image Reconstruction from Series of Two-Dimensional Images*. 2021. <https://doi.org/10.1155/2021/9494368>
- Elkholy, M., & Marzouk, M. A. (2023). Deep learning-based classification of eye diseases using Convolutional Neural Network for OCT images. *Frontiers in Computer Science*, 5. <https://doi.org/10.3389/fcomp.2023.1252295>
- Garbin, C., Zhu, X., & Marques, O. (2020). Dropout vs. batch normalization: an empirical study of their impact to deep learning. *Multimedia Tools and Applications*, 79(19–20), 12777–12815. <https://doi.org/10.1007/s11042-019-08453-9>
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2019). Fundamental concepts of convolutional neural network. In *Intelligent Systems Reference Library* (Vol. 172, Issue June). https://doi.org/10.1007/978-3-030-32644-9_36
- Hayati, M., Muchtar, K., Roslidar, Maulina, N., Syamsuddin, I., Elwirehardja, G. N., & Pardamean, B. (2022). Impact of CLAHE-based image enhancement for diabetic retinopathy classification through deep learning. *Procedia Computer Science*, 216(2022), 57–66. <https://doi.org/10.1016/j.procs.2022.12.111>
- 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). <https://doi.org/10.3390/ijgi9040242>
- Iandola, F., Shaw, A., Krishna, R., & Keutzer, K. (2020). *SqueezeBERT: What can computer vision teach NLP about efficient neural networks?* 124–135. <https://doi.org/10.18653/v1/2020.sustainlp-1.17>
- Jadon, S. (2020). A survey of loss functions for semantic segmentation. *2020 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology, CIBCB 2020*. <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, EMBS*, 2045–2048. <https://doi.org/10.1109/EMBC.2019.8857160>
- Jidan, O. J., Paul, S., Roy, A., Khushbu, S. A., Islam, M., & Badhon, S. M. S. I. (2023). A Comprehensive Study of DCNN Algorithms-based Transfer Learning for Human Eye Cataract Detection. *International Journal of Advanced Computer Science and Applications*, 14(6), 980–989. <https://doi.org/10.14569/IJACSA.2023.01406105>
- Kandel, I., & Castelli, M. (2020). applied sciences Transfer Learning with Convolutional Neural Networks for Diabetic Retinopathy Image. *Applied Sciences*, 10(6), 2021. <https://www.mdpi.com/2076-3417/10/6/2021>
- 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., 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>
- 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(May), 54629–54638. <https://doi.org/10.1109/ACCESS.2023.3279734>
- Mahajan, P., Uddin, S., Hajati, F., & Moni, M. A. (2023). Ensemble Learning for Disease Prediction: A Review. *Healthcare (Switzerland)*, 11(12). <https://doi.org/10.3390/healthcare11121808>
- Mishra, S., Vanli, O. A., Huffer, F. W., & Jung, S. (2016). Regularized discriminant analysis for multi-sensor decision fusion and damage detection with Lamb waves. *Sensors and Smart Structures Technologies for Civil, Mechanical, and Aerospace Systems 2016*, 9803(March), 98032H. <https://doi.org/10.1117/12.2217959>
- Mohammed, A., & Kora, R. (2023). A comprehensive review on ensemble deep learning: Opportunities and challenges. *Journal of King Saud University - Computer and Information Sciences*, 35(2), 757–774. <https://doi.org/10.1016/j.jksuci.2023.01.014>
- Nazir, K., Kim, J., & Byun, Y. C. (2024). Enhancing Early-Stage Diabetic Retinopathy Detection Using a Weighted Ensemble of Deep Neural Networks. *IEEE Access*, 12(July), 113565–113579. <https://doi.org/10.1109/ACCESS.2024.3432867>

- Oliveira, A., Pereira, S., & Silva, C. A. (2018). Retinal vessel segmentation based on Fully Convolutional Neural Networks. *Expert Systems with Applications*, 112, 229–242. <https://doi.org/10.1016/j.eswa.2018.06.034>
- 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>
- Oza, P., Sharma, P., & Patel, S. (2022). a Transfer Representation Learning Approach for Breast Cancer Diagnosis From Mammograms Using Efficientnet Models. *Scalable Computing*, 23(2), 51–58. <https://doi.org/10.12694/scpe.v23i2.1975>
- 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
- Philip, A. (2024). Optimizing Food101 Classification with Transfer Learning: A Fine-Tuning Approach Using EfficientNetB0. *International Journal of Intelligent Information Systems*, 13(4), 59–77. <https://doi.org/10.11648/j.ijiis.20241304.11>
- Praneeth, D., Kumar, N. S., & Nagaraju, V. (2024). Enhanced Detection and Segmentation of Retinal Exudates in Diabetic Retinopathy using a Feature Pyramid Network with EfficientNet-B0 Encoder. *Indian Journal Of Science And Technology*, 17(32), 3377–3387. <https://doi.org/10.17485/ijst/v17i32.1997>
- Prasad, K., Sajith, P. S., Neema, M., Madhu, L., & Priya, P. N. (2019). Multiple eye disease detection using Deep Neural Network. *IEEE Region 10 Annual International Conference, Proceedings/TENCON, 2019-Octob*, 2148–2153. <https://doi.org/10.1109/TENCON.2019.8929666>
- Rachmawanto, E. H., Sari, C. A., Krismawan, A. D., Erawan, L., Sari, S., Award, D., Laksana, W., Adi, S., & Yaacob, N. M. (2024). *Eye disease classification using deep learning convolutional neural networks*. 332–341.
- Ram, S., Vinoth, S., Gopalakrishnan, R. N., Balakumar, A. A., Kalinathan, L., & Velankanni, T. A. J. (2024). Leveraging Diverse CNN Architectures for Medical Image Captioning: DenseNet-121, MobileNetV2, and ResNet-50 in ImageCLEF 2024. *CEUR Workshop Proceedings*, 3740, 1720–1728.
- Salma, A., Bustamam, A., & Sarwinda, D. (2021). *Diabetic Retinopathy Detection Using GoogleNet Architecture of Convolutional Neural Network Through Fundus Images. 2021*, 1–6. <https://doi.org/10.11594/nstp.2021.0701>
- Sandeep, M. S., Tiprak, K., Kaewunruen, S., Pheinsusom, P., & Pansuk, W. (2023). Shear strength prediction of reinforced concrete beams using machine learning. *Structures*, 47(November 2022), 1196–1211. <https://doi.org/10.1016/j.istruc.2022.11.140>

- Saqib, S. M., Iqbal, M., Zubair Asghar, M., Mazhar, T., Almogren, A., Ur Rehman, A., & Hamam, H. (2024). Cataract and glaucoma detection based on Transfer Learning using MobileNet. *Heliyon*, 10(17), e36759. <https://doi.org/10.1016/j.heliyon.2024.e36759>
- Şener, B., & Sümer, E. (2023). Classification of Eye Disease from Retinal Images Using Deep Learning. *14th International Conference on Electrical and Electronics Engineering, ELECO 2023 - Proceedings, December*. <https://doi.org/10.1109/ELECO60389.2023.10416049>
- Sharmili, N., Yonbawi, S., Alahmari, S., Laxmi Lydia, E., Ishak, M. K., Alkahtani, H. K., Aljarbough, A., & Mostafa, S. M. (2023). Earthworm optimization with improved SqueezeNet enabled facial expression recognition model. *Computer Systems Science and Engineering*, 46(2), 2247–2262. <https://doi.org/10.32604/csse.2023.036377>
- Simanjuntak, R. B. J., Fu'adah, Y., Magdalena, R., Saidah, S., Wiratama, A. B., & Ubaidah, I. D. S. (2023). Eye Disease Classification Based on Fundus Images Using Convolutional Neural Network. *IES 2023 - International Electronics Symposium: Unlocking the Potential of Immersive Technology to Live a Better Life, Proceeding*, 6(March), 563–568. <https://doi.org/10.1109/IES59143.2023.10242558>
- Sinha, D., & El-Sharkawy, M. (2019). Thin MobileNet: An Enhanced MobileNet Architecture. *2019 IEEE 10th Annual Ubiquitous Computing, Electronics and Mobile Communication Conference, UEMCON 2019*, 0280–0285. <https://doi.org/10.1109/UEMCON47517.2019.8993089>
- Soomro, T. A., Afifi, A. J., Zheng, L., Soomro, S., Gao, J., Hellwich, O., & Paul, M. (2019). Deep Learning Models for Retinal Blood Vessels Segmentation: A Review. *IEEE Access*, 7, 71696–71717. <https://doi.org/10.1109/ACCESS.2019.2920616>
- Subin, P. G., & Muthukannan, P. (2022). Optimized convolution neural network based multiple eye disease detection. *Computers in Biology and Medicine*, 146(January), 105648. <https://doi.org/10.1016/j.combiomed.2022.105648>
- Sun, W., Zhang, X., & He, X. (2020). Lightweight image classifier using dilated and depthwise separable convolutions. *Journal of Cloud Computing*, 9(1). <https://doi.org/10.1186/s13677-020-00203-9>
- Tayal, A., Gupta, J., Solanki, A., Bisht, K., Nayyar, A., & Masud, M. (2022). DL-CNN-based approach with image processing techniques for diagnosis of retinal diseases. *Multimedia Systems*, 28(4), 1417–1438. <https://doi.org/10.1007/s00530-021-00769-7>
- Tragoudaras, A., Stoikos, P., Fanaras, K., Tziouvaras, A., Floros, G., Dimitriou, G., Kolomvatsos, K., & Stamoulis, G. (2022). Design Space Exploration of a Sparse MobileNetV2 Using High-Level Synthesis and Sparse Matrix Techniques on FPGAs. *Sensors*, 22(12), 1–16. <https://doi.org/10.3390/s22124318>

- Triwiyanto, T., Rizal, A., & Caesarendra, W. (2023). Proceeding of the 3rd International Conference on Electronics, Biomedical Engineering, and Health Informatics. In *Biomedical Engineering, and Health Informatics ICEBEHI* (Vol. 1008). <https://link.springer.com/10.1007/978-981-99-0248-4>
- Vij, R., & Arora, S. (2024). A hybrid evolutionary weighted ensemble of deep transfer learning models for retinal vessel segmentation and diabetic retinopathy detection. *Computers and Electrical Engineering*, 115(November 2022), 109107. <https://doi.org/10.1016/j.compeleceng.2024.109107>
- 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. <https://doi.org/10.1007/s00521-024-09893-7>
- Yassin, N. I. R. (2023). Fundus Images Classification of Diabetic Retinopathy using MobileNetV2. *International Journal of Computer Science and Mobile Computing*, 12(5), 54–63. <https://doi.org/10.47760/ijcsmc.2023.v12i05.006>
- Yi, D., Ahn, J., & Ji, S. (2020). An effective optimization method for machine learning based on ADAM. *Applied Sciences (Switzerland)*, 10(3).
- Yoo, W. S., Kang, K., Kim, J. G., & Yoo, Y. (2022). Extraction of Color Information and Visualization of Color Differences between Digital Images through Pixel-by-Pixel Color-Difference Mapping. *Heritage*, 5(4), 3923–3945. <https://doi.org/10.3390/heritage5040202>
- Zhou, J., Lu, Q., Xu, R., Gui, L., & Wang, H. (2020). EL_LSTM: Prediction of DNA-Binding Residue from Protein Sequence by Combining Long Short-Term Memory and Ensemble Learning. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 17(1), 124–135. <https://doi.org/10.1109/TCBB.2018.2858806>
- Zubair, M., Kim, J., & Yoon, C. (2016). An automated ECG beat classification system using convolutional neural networks. *2016 6th International Conference on IT Convergence and Security, ICITCS 2016*. <https://doi.org/10.1109/ICITCS.2016.7740310>