

**IMPLEMENTASI KOMBINASI ARSITEKTUR VGG DAN *SQUEEZENET*
UNTUK KLASIFIKASI PENYAKIT PADA MATA**

SKRIPSI

**Diajukan sebagai salah satu syarat untuk memperoleh gelar sarjana di
Jurusan Matematika pada Fakultas MIPA**

Oleh:

M ALDI SAPUTRA

NIM. 08011382126096



JURUSAN MATEMATIKA

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

2025

LEMBAR PENGESAHAN
IMPLEMENTASI KOMBINASI ARSITEKTUR VGG DAN SQUEEZENET
UNTUK KLASIFIKASI PENYAKIT PADA MATA

SKRIPSI

Diajukan sebagai salah satu syarat untuk memperoleh gelar sarjana di
Jurusan Matematika pada Fakultas MIPA

Oleh

M ALDI SAPUTRA
08011382126096

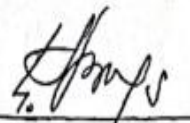
Indralaya, 16 Januari 2025

Pembimbing Kedua

Pembimbing Utama



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



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



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

HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH

Yang beranda tangan di bawah ini:

Nama Mahasiswa : M Aldi Saputra
NIM : 08011382126096
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, 30 Januari 2025
Penulis



M Aldi Saputra
NIM. 08011382126096

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,

Teman baik yang kubanggakan,

Almamaterku

Motto

“Apapun yang terjadi, dijalankan saja, jangan dilarikan”

-M Aldi Saputra

KATA PENGANTAR

Puji syukur atas kehadiran Allah *Subhanahu Wa Ta'ala* yang telah memberikan rahmat dan hidayah-Nya, sehingga penulis dapat menyelesaikan skripsi berjudul “Implementasi Arsitektur VGG dan *SqueezeNet* Untuk Klasifikasi Penyakit Pada Citra 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, Ibuku **Ailin** yang tidak pernah berhenti berjuang dan memberikan yang terbaik untukku sebagai putranya, Ayahku **Sufriadi** yang sudah memberikan doa serta pengajaran terbaik kepadaku. Terima kasih karena tak pernah lelah mendidik, menasehati, membimbing, mendukung dan terus mendoakan. 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 dan dosen pembimbing akademik serta Ibu **Des Alwine Zayanti, S.Si., M.Si.** selaku Sekretaris Jurusan Matematika sekaligus dosen pembahas kedua yang telah membimbing dan mengarahkan dalam urusan akademik selama menempuh perkuliahan di Jurusan Matematika FMIPA Universitas Sriwijaya

2. Ibu **Dr. Anita Desiani, S.Si, M.Kom**, selaku dosen Pembahas pertama sekaligus dosen bidang komputasi yang senantiasa bersedia memberikan ilmu, membimbing, dan membantu penulis selama perkuliahan
3. Bapak **Dr. Bambang Suprihatin, S.Si, M.Si.** dan Bapak **Drs. Ali Amran, M.T.** 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 **Prof. Dr. Yulia Resti S.Si, M.Si**, selaku dosen Pembimbing Akademik yang telah bersedia memberikan bimbingan kepada penulis selama perkuliahan.
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. Adik-adikku tersayang, **M Dani Ariski** dan **Deo Rayandra** yang senantiasa memberikan semangat dan doa terbaik untuk penulis
7. **Kakak-kakak tingkat bidang minat komputasi** dan **Teman-teman bidang minat komputasi angkatan 2021** yang telah berjuang bersama dan memberikan banyak bantuan serta semangat kepada penulis dalam menyelesaikan proses perkuliahan dan pembuatan skripsi ini.

8. **Teman-teman bidang minat komputasi angkatan 2021** yang telah berjuang bersama dan memberikan banyak bantuan serta semangat kepada penulis dalam menyelesaikan proses perkuliahan dan pembuatan skripsi ini.
9. **Teman-teman Matematika angkatan 2021** yang telah menemani masa perkuliahan penulis.
10. 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, Januari 2025

Penulis

IMPLEMENTASI KOMBINASI ARSITEKTUR VGG DAN *SQUEEZENET* UNTUK KLASIFIKASI PENYAKIT PADA MATA

By:

M Aldi Saputra

08011382126096

ABSTRACT

Cataract, diabetic retinopathy (DR), and glaucoma are eye diseases that are at risk of blindness. Early detection of these diseases can be done by utilising deep learning methods. This research proposes a combined model of Visual Geometry Group (VGG) and SqueezeNet architecture with the addition of batch normalisation for eye disease classification. The convolution and max pooling layers of the VGG architecture are added in the first block to capture important features in the image in detail. SqueezeNet is added in the middle of the model to reduce the number of parameters and prevent overfitting. In the last block, the model uses fully connected layers and softmax activation function to provide prediction results. Batch normalisation is added to each convolution layer, before the SqueezeNet architecture and before the fully connected layer to help the model converge. The proposed model obtained an average accuracy of 99.5%, sensitivity of 99.2%, specificity of 99.46%, F1-Score of 99.62%, and cohen's kappa of 78%. In this study, the proposed model works very well in recognising the DR class compared to cataract, glaucoma, and normal classes with a sensitivity value of 100%. Although the values obtained in cataract, glaucoma, and normal classes are still below DR, the results obtained are very good because the sensitivity values for cataract, glaucoma, and normal classes are above 90%. The cohen's kappa value is still below 80% due to the low cohen's kappa value in the cataract class, which is only 65%. For further research, architecture development can be carried out to overcome the cohen's kappa value which is still below 80%.

Keyword : Cataract, Classification, Diabetic Retinopathy, Glaucoma, SqueezeNet, VGG

IMPLEMENTASI KOMBINASI ARSITEKTUR VGG DAN *SQUEEZENET* UNTUK KLASIFIKASI PENYAKIT PADA MATA

Oleh:

M Aldi Saputra

08011382126096

ABSTRAK

Katarak, diabetic retinopathy (DR), dan glaukoma merupakan penyakit mata yang beresiko mengakibatkan kebutaan. Deteksi dini penyakit-penyakit ini dapat dilakukan dengan memanfaatkan metode *deep learning*. Penelitian ini mengusulkan model kombinasi arsitektur *Visual Geometry Group* (VGG) dan *SqueezeNet* dengan penambahan *batch normalization* untuk klasifikasi penyakit mata. Lapisan konvolusi dan *max pooling* dari arsitektur VGG ditambahkan pada blok pertama untuk menangkap fitur penting pada citra secara detail. *SqueezeNet* ditambahkan pada bagian tengah model untuk mengurangi jumlah parameter dan mencegah *overfitting*. Pada blok terakhir model menggunakan lapisan *fully connected* dan fungsi aktivasi *softmax* untuk memberikan hasil prediksi. *Batch normalization* ditambahkan pada setiap lapisan konvolusi, sebelum arsitektur *SqueezeNet* dan sebelum lapisan *fully connected* untuk membantu konvergensi model. Model yang diusulkan memperoleh rata-rata akurasi sebesar 99,5%, sensitivitas 99,2%, spesifisitas 99,46%, *F1-Score* 99,62%, dan *cohen's kappa* 78%. Pada penelitian ini, model yang diusulkan bekerja dengan sangat baik dalam mengenali kelas DR dibandingkan kelas katarak, glaukoma, dan normal dengan nilai sensitivitas sebesar 100%. Meskipun nilai yang diperoleh pada kelas katarak, glaukoma, dan normal masih dibawah DR, hasil yang diperoleh sudah sangat baik karena nilai sensitivitas untuk kelas katarak, glaukoma dan normal telah diatas 90%. Nilai *cohen's kappa* masih dibawah 80% dikarenakan nilai *cohen's kappa* pada kelas katarak yang masih rendah, yaitu hanya sebesar 65%. Untuk penelitian selanjutnya dapat dilakukan pengembangan arsitektur untuk mengatasi nilai *cohen's kappa* yang masih dibawah 80%.

Kata kunci : *Diabetic Retinopathy*, Glaukoma, Katarak, Klasifikasi, *SqueezeNet*, VGG

DAFTAR ISI

LEMBAR PENGESAHAN	ii
HALAMAN PERNYATAAN KEASLIAN KARYA ILMIAH.....	iii
HALAMAN PERSEMBAHAN	iv
KATA PENGANTAR.....	v
ABSTRACT	viii
ABSTRAK	ix
DAFTAR ISI	x
DAFTAR TABEL.....	xiii
DAFTAR GAMBAR	xiv
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Perumusan Masalah.....	5
1.3 Batasan Masalah.....	5
1.4 Tujuan.....	5
1.5 Manfaat.....	6
BAB II TINJAUAN PUSTAKA	7
2.1 <i>Eyes Disease Classification</i>	7
2.2 Citra Mata.....	8
2.3 Perbaikan Kualitas Citra.....	10
2.3.1 <i>Grayscale</i>	10
2.3.2 Contrast and Brightness Adjustment.....	11
2.3.3 Blurring.....	11
2.4 Augmentasi Citra.....	12
2.5 Klasifikasi Citra.....	12
2.6 Convolutional Neural Network (CNN)	13
2.6.1 <i>Padding same</i>	13
2.6.2 Convolutional Layer	14
2.6.3 Batch Normalization	15
2.6.4 Fungsi Aktivasi ReLU	16

2.6.5 Max Pooling.....	16
2.6.6 Fire Module	17
2.6.7 Concatenated Layer	19
2.6.8 Fully Connected Layer.....	19
2.6.9 Fungsi Aktivasi Softmax	20
2.6.10 Loss Function.....	21
2.6.11 Optimization Function : Adaptive Moment Estimation (ADAM)	21
2.7 Visual Geometry Group	22
2.8 SqueezeNet.....	23
2.9 Confusion Matriks	24
BAB III METODOLOGI PENELITIAN.....	27
3.1 Tempat	27
3.2 Waktu.....	27
3.3 Alat	27
3.4 Tahapan Penelitian.....	27
3.4.1 Pengumpulan Data	28
3.4.2 Perbaikan Citra	28
3.4.3 Augmentasi Citra	28
3.4.4 Desain Arsitektur	29
3.4.5 Training dan Testing	29
3.4.6 Evaluasi.....	30
3.4.7 Analisis dan Interpretasi Hasil	31
BAB IV HASIL DAN PEMBAHASAN.....	32
4.1 Deskripsi Data	32
4.2 Preprocessing Data	33
4.3 Kombinasi Arsitektur VGG dan SqueezeNet.....	36
4.4 Perhitungan Manual	37
4.4.1 Padding same.....	37
4.4.2 Convolutional Layer	38
4.4.3 Batch Normalization.....	41
4.4.4 Fungsi Aktivasi ReLU	44
4.4.5 Max pooling	45

4.4.6 <i>Fire Module</i>	46
4.4.7 <i>Concatenated Layer</i>	49
4.4.8 <i>Fully Connected Layer</i>	50
4.4.9 Fungsi Aktivasi Softmax	51
4.4.10 <i>Categorical Cross Entropy</i>	52
4.4.11 <i>Adaptive Moment Estimation</i>	53
4.5 <i>Training</i>	57
4.6 <i>Testing</i>	59
4.7 Evaluasi	63
4.8 Analisis dan Interpretasi Hasil	70
BAB V KESIMPULAN DAN SARAN	72
5.1 Kesimpulan	72
5.2 Saran	72
DAFTAR PUSTAKA	74

DAFTAR TABEL

Tabel 2.1 Evaluasi Kinerja Model.....	26
Tabel 4.1 Sampel Data <i>Training</i> dan Data <i>Testing</i>	32
Tabel 4.2 Hasil Confusion Matriks Data <i>Testing</i>	59
Tabel 4.3 Evaluasi Kinerja model	69
Tabel 4.4 Perbandingan Hasil Evaluasi Kinerja dengan Penelitian Lain.....	70

DAFTAR GAMBAR

Gambar 2.1 Citra Mata Normal	8
Gambar 2.2 Citra Mata yang Terindikasi Katarak	9
Gambar 2.3 Citra Mata yang Terindikasi Diabetic Retinopathy (DR).....	9
Gambar 2.4 Citra Mata yang Terindikasi penyakit Glaukoma.....	10
Gambar 2.5 Proses Grayscale	10
Gambar 2.6 Proses augmentasi citra	12
Gambar 2.7 <i>Padding same</i>	13
Gambar 2.8 Ilustrasi proses <i>Convolution Layer</i>	14
Gambar 2.9 Fungsi Aktivasi ReLU	16
Gambar 2.10 Ilustrasi Max Pooling	17
Gambar 2.11 Ilustrasi <i>Fire Module</i>	17
Gambar 2.12 Ilustrasi <i>Concatenated Layer</i>	19
Gambar 2.13 Fungsi Aktivasi Softmax	20
Gambar 2.14 Ilustrasi Arsitektur <i>Visual Geometry Group</i>	23
Gambar 2.15 Arsitektur <i>SqueezeNet</i>	23
Gambar 4.1 Kombinasi Arsitektur VGG dan <i>SqueezeNet</i>	37
Gambar 4. 2 Ilustrasi <i>Max pooling</i>	45
Gambar 4.3 Grafik akurasi kombinasi arsitektur VGG dan <i>SqueezeNet</i>	58
Gambar 4. 4 Grafik loss kombinasi arsitektur VGG dan <i>SqueezeNet</i>	59

BAB I

PENDAHULUAN

1.1 Latar Belakang

Mata adalah organ penting yang berfungsi sebagai alat utama dalam menerima informasi visual dari lingkungan sekitar (Mustapha *et al.* 2021). Mata terdiri dari berbagai komponen seperti retina, lensa, kornea, dan saraf optik yang bekerja sama untuk memungkinkan proses penglihatan (Shirzadfar & Amirzadeh, 2019). Penyakit mata seperti katarak, *diabetic retinopathy* (DR), dan glaukoma dapat mengganggu fungsi penglihatan bahkan berpotensi mengakibatkan kebutaan (R.M. *et al.* 2024). Penyakit katarak, DR dan glaukoma dapat didiagnosis melalui klasifikasi. Klasifikasi manual pada penyakit mata membutuhkan keahlian khusus dari para ahli, namun keputusan yang bersifat subjektif dapat mengakibatkan klasifikasi rentan terhadap kesalahan dan membutuhkan waktu yang lama (Nandhakumar Raj S *et al.* 2023). Klasifikasi dapat dilakukan menggunakan bantuan komputer dengan memanfaatkan metode *deep learning* (Jiang *et al.* 2021).

Metode *deep learning* yang populer untuk tugas klasifikasi adalah *Convolutional Neural Networks* (CNN) (Guan *et al.* 2019). CNN merupakan jaringan syaraf tiruan yang dirancang untuk mengenali pola pada data seperti citra (Kandel & Castelli, 2020). Pemanfaatan CNN untuk tugas klasifikasi citra telah dikembangkan menjadi beberapa arsitektur, salah satunya adalah *Visual Geometry Group* (VGG). VGG merupakan arsitektur yang terdiri dari 13 *Layer* konvolusi dengan kernel tetap ukuran 3×3 , *pooling Layer*, dan 3 lapisan *fully connected* (Ritahani Ismail *et al.* 2024). Susunan lapisan yang mendalam pada VGG dengan

kernel tetap ukuran 3×3 memiliki kelebihan mampu mempelajari fitur penting citra pada *dataset* yang berukuran besar (Sánchez-Morales *et al.* 2024).

Smaida & Serhii (2019) menerapkan VGG untuk klasifikasi 3 kelas pada citra retina, yaitu glaukoma, diabetic retinopathy, dan normal. Penelitian ini memperoleh nilai spesifisitas sebesar 92%, namun nilai akurasi dan *F1-Score* masih dibawah 80%. Gandhi & Gandhi (2024) menerapkan VGG untuk klasifikasi 2 kelas pada citra retina, yaitu glaukoma dan normal. Penelitian ini memperoleh nilai akurasi, spesifisitas, dan *sensitivitas* sebesar 90%, namun tidak mengukur nilai *fl score* dan *cohen's kappa*. Triyadi *et al.* (2022) menerapkan VGG untuk klasifikasi 2 kelas pada citra retina, yaitu katarak dan normal. Penelitian ini memperoleh nilai akurasi sebesar 91%, namun pada penelitian ini hanya mengukur nilai akurasi.

Susunan lapisan jaringan yang mendalam pada VGG dapat mengolah gambar secara keseluruhan untuk memperoleh fitur penting, namun parameter yang dibutuhkan jumlahnya besar (Martínez-Fernandez *et al.* 2023). Menurut Younis *et al.* (2022) dan Ramadhan & Baykara (2022) parameter pada VGG mencapai 148 juta parameter. Parameter yang besar mengakibatkan proses *training* menjadi lebih lama dan membutuhkan kapasitas memori dalam jumlah yang besar, sehingga sulit diimplementasikan pada perangkat dengan sumber daya terbatas (Jiang *et al.* 2021). Arsitektur CNN lain yang juga digunakan untuk tugas klasifikasi dengan parameter yang lebih sedikit adalah *SqueezeNet*. Menurut L. Xu *et al.* (2024) dan Kim *et al.*, (2020) *SqueezeNet* memiliki 3 juta parameter. *SqueezeNet* terdiri dari Lapisan konvolusi, *Fire Module*, dan *global average pooling*. Setiap lapisan *Fire module* terdiri dari 2 bagian yaitu lapisan *Squeeze* dan lapisan *expand*.

Lapisan *Squeeze* dan lapisan *expand* pada *Fire module* arsitektur *SqueezeNet* bekerja dengan cara mengurangi dimensi citra sehingga parameter yang dibutuhkan lebih sedikit. Lapisan *Squeeze* (penyempitan) menggunakan kernel 1×1 pada lapisan konvolusi untuk mengurangi dimensi citra yang masuk pada lapisan berikutnya (Rasool *et al.* 2023). Lapisan *expand* (pengembangan), menggunakan kernel 1×1 seperti lapisan *Squeeze*, namun diikuti kernel ukuran 3×3 untuk menangkap fitur penting dalam area yang lebih luas dengan tetap memperhatikan nilai di sekitar fitur (Rasool *et al.* 2023). Pengurangan dimensi pada citra mampu mengurangi parameter pada model (Rasool *et al.* 2023)

Khalifa *et al.* (2019) menerapkan arsitektur *SqueezeNet* untuk klasifikasi *diabetic retinopathy* pada citra retina. Hasil penelitian dengan ini memperoleh nilai akurasi sebesar 90%, namun nilai sensitivitas, spesifisitas, dan *F1-Score* masih dibawah 85%. Venkaiahppalaswamy *et al.* (2022) menerapkan arsitektur *SqueezeNet* untuk klasifikasi tingkat keparahan *diabetic retinopathy* dan memperoleh nilai akurasi, sensitivitas, dan spesivisitas sebesar 97%, namun pada penelitian ini tidak menghitung nilai *F1-Score* dan *cohen's kappa*. *SqueezeNet* juga telah digunakan pada beberapa penelitian citra medis lain seperti klasifikasi lesi kulit, klasifikasi penyakit parkinson, klasifikasi tumor otak, dan klasifikasi kanker kulit (Hameed *et al.* 2020, Rasool *et al.* 2023, Bernardo *et al.* 2022, Shinde *et al.* 2023)

Arsitektur *SqueezeNet* memiliki jumlah parameter yang lebih sedikit dan waktu *training* yang cepat, namun memiliki keterbatasan pada *dataset* yang berukuran besar. VGG dan *SqueezeNet* dapat dikombinasikan dengan tujuan memanfaatkan

layer konvolusi pada VGG untuk memproses gambar secara detail dan memanfaatkan *fire module* arsitektur *SqueezeNet* dengan tujuan mengurangi jumlah parameter yang terlalu besar. Kombinasi VGG dan *SqueezeNet* mengakibatkan lapisan jaringan menjadi semakin dalam. Lapisan jaringan yang semakin mendalam mengakibatkan bobot semakin besar dan proses *training* sulit mencapai konvergen (Trabelsi *et al.* 2019). Salah satu teknik yang dapat membantu menambah konvergensi pada model adalah *batch normalization*. *Batch normalization* merupakan teknik yang digunakan untuk menormalkan input ke setiap lapisan dalam jaringan syaraf tiruan dengan tujuan membuat model menjadi lebih stabil (Desiani *et al.* 2022). *Batch normalization* dapat membantu menjaga bobot tetap stabil karena range pada bobot tidak akan menjauh (Zhu *et al.* 2020).

Batool *et al.* (2023) menambahkan *batch normalization* pada arsitektur *EfficienNet* untuk klasifikasi penyakit *diabetic retinopathy*, penelitian ini memperoleh nilai akurasi, dan *F1-Score* diatas 87%. Sahlsten *et al.* (2019) menambahkan *batch normalization* pada arsitektur *Inception-V3* untuk melakukan klasifikasi *diabetic retinopathy*. Penelitian ini memperoleh akurasi dan *sensitivitas* sebesar 90%. Nderitu *et al.* (2021) menambahkan *batch normalization* pada arsitektur *EfficienNet* untuk melakukan klasifikasi *diabetic retinopathy* pada citra mata. Penelitian ini memperoleh nilai *sensitivitas* sebesar 97% dan *spesifisitas* sebesar 89%.

Penelitian ini mengusulkan model kombinasi arsitektur *VGG* dan *SqueezeNet*. Arsitektur modifikasi ini menggunakan lapisan konvolusi dan *max pooling* dari arsitektur VGG, *Fire module* dari arsitektur *SqueezeNet*, dan *fully connected Layer*

dari VGG. Lapisan konvolusi digunakan untuk membantu model belajar mengenali representasi fitur dengan lebih detail, sedangkan lapisan *Fire module* membantu menjaga parameter agar tidak semakin membesar dan mempercepat proses *training*. *Batch normalization* akan ditambahkan pada setiap lapisan konvolusi VGG, lapisan *Squeeze* dan *expand* pada *fire module* arsitektur *SqueezeNet*, dan sebelum lapisan *fully connected*. Penambahan *batch normalization* bertujuan untuk membantu konvergensi model. Penelitian ini menggunakan 4 kelas pada citra mata yaitu katarak, *diabetic retinopathy*, glaukoma, dan normal.

1.2 Perumusan Masalah

Bagaimana hasil kinerja kombinasi arsitektur VGG dan *SqueezeNet* dengan penambahan *batch normalization* pada klasifikasi penyakit mata berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-Score* dan *cohen's kappa*.

1.3 Batasan Masalah

Batasan masalah yang diterapkan pada penelitian ini adalah sebagai berikut.

- a. Penelitian ini melakukan klasifikasi penyakit mata yang terdiri dari 4 kelas yaitu normal, katarak, *diabetic retinopathy* (DR) dan glaukoma.
- b. Kriteria evaluasi yang digunakan dalam klasifikasi penyakit mata penelitian ini adalah nilai akurasi, presisi, *recall*, sensitivitas, spesifisitas, *F1-Score*, dan *Cohen's kappa*.

1.4 Tujuan

Tujuan penelitian ini adalah untuk mengevaluasi hasil kinerja dari kombinasi arsitektur *VGG-SqueezeNet* dengan penambahan *batch normalization* pada

klasifikasi penyakit mata berdasarkan nilai akurasi, sensitivitas, spesifisitas, *F1-Score*, dan *Cohen's kappa*.

1.5 Manfaat

Manfaat dari hasil penelitian ini sebagai berikut :

- a. Memperoleh kombinasi arsitektur *VGG* dan *SqueezeNet* yang mampu melakukan tugas klasifikasi pada *dataset* besar menggunakan perangkat dengan sumber daya yang terbatas.
- b. Dapat digunakan sebagai referensi penelitian pada klasifikasi penyakit mata dan pengembangan *deep learning*.

DAFTAR PUSTAKA

- Abdullah, A. A., Aldhahab, A., & Al Abboodi, H. M. (2024). Review of eye diseases detection and classification using deep learning techniques. *BIO Web of Conferences*, *97*, 1–19. <https://doi.org/10.1051/bioconf/20249700012>
- Abdullah, N. M., & AL-Allaf, A. F. (2021). Facial expression recognition (FER) of autism children using Deep Neural Networks. *4th International Iraqi Conference on Engineering Technology and Their Applications, IICETA 2021*, *12*, 111–116. <https://doi.org/10.1109/IICETA51758.2021.9717550>
- Al-Saggaf, U. M., Botalb, A., Faisal, M., Moinuddin, M., Alsaggaf, A. U., & Alfakeh, S. A. (2022). Constraints on hyper-parameters in deep learning Convolutional Neural Networks. *International Journal of Advanced Computer Science and Applications*, *13*(11), 439–449. <https://doi.org/10.14569/IJACSA.2022.0131150>
- AlRowaily, M. H., Arof, H., & Ibrahim, I. (2023). Luminosity and contrast adjustment of fundus images with reflectance. *Applied Sciences (Switzerland)*, *13*(5), 1–10. <https://doi.org/10.3390/app13053312>
- Batool, S., Gilani, S. O., Waris, A., Iqbal, K. F., Khan, N. B., Khan, M. I., Eldin, S. M., & Awwad, F. A. (2023). Deploying efficient net batch normalizations (BNs) for grading diabetic retinopathy severity levels from fundus images. *Scientific Reports*, *13*(1), 1–13. <https://doi.org/10.1038/s41598-023-41797-9>
- Bernardo, L. S., Damaševičius, R., Ling, S. H., de Albuquerque, V. H. C., & Tavares, J. M. R. S. (2022). Modified SqueezeNet architecture for parkinson's disease detection based on keypress data. *Biomedicines*, *10*(11), 1–15. <https://doi.org/10.3390/biomedicines10112746>
- 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*, 447–457. https://doi.org/10.1007/978-3-030-16660-1_44

- Carneiro, M. B., Moreira, M. W. L., Pereira, S. S. L., Gallindo, E. L., & Rodrigues, J. J. P. C. (2021). Recommender system for postpartum depression monitoring based on sentiment analysis. *2020 IEEE International Conference on E-Health Networking, Application and Services, HEALTHCOM 2020*, 6(20), 3–5. <https://doi.org/10.1109/HEALTHCOM49281.2021.9398922>
- 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(7), 78368–78381. <https://doi.org/10.1109/ACCESS.2021.3084050>
- 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(9), 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. *Mathematical Problems in Engineering*, 21(15), 11. <https://doi.org/10.1155/2021/9494368>
- Gandhi, V. C., & Gandhi, P. P. (2024). Glaucoma eye's disease identification: using Vgg16 model with Deep Neural Network. *International Journal of Computing and Digital System*, 16(1), 1–10. <http://dx.doi.org/10.12785/ijcds>
- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2019). Fundamental concepts of Convolutional Neural Network. *Intelligent Systems Reference Library*, 172(1), 519–567. https://doi.org/10.1007/978-3-030-32644-9_36

- Golla, S. B., & Abburu, S. (2017). Ontology driven framework to resolve information interoperability in multidisciplinary applications and semantic information retrieval. *International Journal of Advanced Engineering Research and Technology (IJAERT)*, 5(10), 723–731. <http://www.ijaert.org/>
- Guan, Q., Wang, Y., Ping, B., Li, D., Du, J., Qin, Y., Lu, H., Wan, X., & Xiang, J. (2019). Deep convolutional neural network VGG-16 model for differential diagnosing of papillary thyroid carcinomas in cytological images: A pilot study. *Journal of Cancer*, 10(20), 4876–4882. <https://doi.org/10.7150/jca.28769>
- Hameed, N., Shabut, A., Hameed, F., Cirstea, S., Harriet, S., & Hossain, A. (2020). Mobile-based skin lesions classification using convolution neural network. *Annals of Emerging Technologies in Computing*, 4(2), 26–37. <https://doi.org/10.33166/AETiC.2020.02.003>
- Hattiya, T., Dittakan, K., & Musikasuwana, S. (2021). Diabetic retinopathy detection using Convolutional Neural Network: a comparative study on different architectures. *Engineering Access*, 7(1), 50–60. <https://doi.org/10.14456/mijet.2021.8>
- 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(6), 102167. <https://doi.org/10.1016/j.bspc.2020.102167>
- Islam, M. M., Poly, T. N., Walther, B. A., Yang, H. C., & Li, Y. C. (2020). Artificial intelligence in ophthalmology: a meta-analysis of deep learning models for retinal vessels segmentation. *Journal of Clinical Medicine*, 9(4), 2–19. <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, CIBCB 2020*, 4(9), 3–5. <https://doi.org/10.1109/CIBCB48159.2020.9277638>

- Jatmoko, C., & Lestiawan, H. (2024). Prediksi Penyakit Mata Menggunakan Convolutional Neural Network. *Semnas Ristek (Seminar Nasional Riset Dan Inovasi Teknologi)*, 8(01), 34–38. <https://doi.org/10.30998/semnasristek.v8i01.7129>
- Jiang, Z. P., Liu, Y. Y., Shao, Z. E., & Huang, K. W. (2021). An improved VGG16 model for pneumonia image classification. *Applied Sciences (Switzerland)*, 11(23), 3–19. <https://doi.org/10.3390/app112311185>
- Junayed, M. S., Islam, M. B., Sadeghzadeh, A., & Rahman, S. (2021). CataractNet: an automated cataract detection system using deep learning for fundus images. *IEEE Access*, 9(8), 128799–128808. <https://doi.org/10.1109/ACCESS.2021.3112938>
- Kandel, I., & Castelli, M. (2020). Transfer Learning with Convolutional Neural Networks for Diabetic Retinopathy Image Classification. A Review. *Applied Sciences*, 10(6), 1–11. <https://doi.org/10.3390/app10062021>
- Khalifa, N. E. M., Loey, M., Taha, M. H. N., & Mohamed, H. N. E. T. (2019). Deep transfer learning models for medical diabetic retinopathy detection. *Acta Informatica Medica*, 27(5), 327–332. <https://doi.org/10.5455/aim.2019.27.327-332>
- Khan, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2020a). 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, A., Sohail, A., Zahoor, U., & Qureshi, A. S. (2020b). 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(6), 54629–54638. <https://doi.org/10.1109/ACCESS.2023.3279734>

- Kim, J.-E., Nam, N.-E., Shim, J.-S., Jung, Y.-H., Cho, B.-H., & Hwang, J. J. (2020). Transfer learning via Deep Neural Networks for implant fixture system classification using periapical radiographs. *Journal of Clinical Medicine*, *9*(4), 1117. <https://doi.org/10.3390/jcm9041117>
- Lee, H. J., Ullah, I., Wan, W., Gao, Y., & Fang, Z. (2019). Real-time vehicle make and model recognition with the Residual Squeezenet Architecture. *Sensors (Switzerland)*, *19*(5), 2–14. <https://doi.org/10.3390/s19050982>
- 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*, *18*(20), 7. <https://doi.org/10.1155/2018/9128527>
- Manassakorn, A., Auethavekiat, S., Sa-Ing, V., Chansangpetch, S., Ratanawongphaibul, K., Uramphorn, N., & Tantisevi, V. (2022). GlauNet: glaucoma diagnosis for OCTA imaging using a new CNN architecture. *IEEE Access*, *10*(8), 95613–95622. <https://doi.org/10.1109/ACCESS.2022.3204029>
- Martínez-Fernandez, E., Rojas-Valenzuela, I., Valenzuela, O., & Rojas, I. (2023). Computer aided classifier of colorectal cancer on histopathological whole slide images analyzing Deep Learning architecture parameters. *Applied Sciences (Switzerland)*, *13*(7), 6–10. <https://doi.org/10.3390/app13074594>
- Maurya, L., Lohchab, V., Kumar Mahapatra, P., & Abonyi, J. (2022). Contrast and brightness balance in image enhancement using Cuckoo Search-optimized image fusion. *Journal of King Saud University - Computer and Information Sciences*, *34*(9), 7247–7258. <https://doi.org/10.1016/j.jksuci.2021.07.008>
- 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), 2737–8543. www.ijceds.com

- 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. <https://doi.org/10.1049/iet-spr.2017.0272>
- Nandhakumar Raj S, Pradhiksha S, & Sivakumar M. (2023). Deep Learning-based ocular disease recognition. *International Journal of Engineering Technology and Management Sciences*, *7*(2), 772–781. <https://doi.org/10.46647/ijetms.2023.v07i02.083>
- Nderitu, P., do Rio, J. M. N., Rasheed, R., Raman, R., Rajalakshmi, R., Bergeles, C., Sivaprasad, S., Bhende, P., Raman, R., Rajalakshmi, R., Mohan, V., Ramasamy, K., Das, T., Rani, P. K., Roy, R., Das, S., Mohan, D., Narendran, V., Manayath, G., ... Surya, J. (2021). Deep learning for gradability classification of handheld, non-mydratic retinal images. *Scientific Reports*, *11*(1), 1–9. <https://doi.org/10.1038/s41598-021-89027-4>
- Nsonwu, M., Ozims, S., & Nnodim, J. (2024). Perspective of cataract and oxidative stress. *Series of Clinical and Biomedical Research*, *1*(1), 1–10. <https://doi.org/10.54178/2997-2701.v1i1a1994>
- 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*(6), 102223. <https://doi.org/https://doi.org/10.1016/j.bspc.2020.102223>
- Putra, M. R. P., & Utami, E. (2024). Comparative analysis of hybrid model performance using stacking and Blending techniques for student drop-out prediction in MOOC. *J. RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, *8*(3), 346–354. <http://jurnal.iaii.or.id>
- R.M., B., Vardhan, K. B., Nidhish, M., Kiran C., S., Nahid Shameem, D., & Sai Charan, V. (2024). Eye disease detection using deep learning models with Transfer Learning Techniques. *ICST Transactions on Scalable Information Systems*, *11*, 1–13. <https://doi.org/10.4108/eetsis.5971>

- Rahman Khan, M. M., Bakr Siddique, M. A., Sakib, S., Aziz, A., Tanzeem, A. K., & Hossain, Z. (2020). Electrocardiogram heartbeat classification using Convolutional Neural Networks for the detection of cardiac arrhythmia. *Proceedings of the 4th International Conference on IoT in Social, Mobile, Analytics and Cloud, ISMAC 2020*, 20(15), 915–920. <https://doi.org/10.1109/I-SMAC49090.2020.9243474>
- Ramadhan, A. A., & Baykara, M. (2022). A novel approach to detect COVID-19: enhanced deep learning models with Convolutional Neural Networks. *Applied Sciences (Switzerland)*, 12(18), 3–15. <https://doi.org/10.3390/app12189325>
- Ramesh, G., Logeshwaran, J., Gowri, J., & Mathew, A. (2022). The management and reduction of digital noise in video image processing by using transmission based noise elimination scheme. *Ictact Journal on Image and Video Processing*, 9102(13), 1. <https://doi.org/10.21917/ijivp.2022.0398>
- Rasool, M., Ismail, N. A., Al-Dhaqm, A., Yafooz, W. M. S., & Alsaeedi, A. (2023). A novel approach for classifying brain tumours Combining a SqueezeNet Model with SVM and Fine-Tuning. *Electronics (Switzerland)*, 12(1). <https://doi.org/10.3390/electronics12010149>
- Ritahani Ismail, A., Syed Qamrun Nisa, Shaharuddin, S. A., Masni, S. I., & Suharudin Amin, S. A. (2024). Utilising VGG-16 of Convolutional Neural Network for medical image classification. *International Journal on Perceptive and Cognitive Computing*, 10(1), 113–118. <https://doi.org/10.31436/ijpcc.v10i1.460>
- Sahlsten, J., Jaskari, J., Kivinen, J., Turunen, L., Jaanio, E., Hietala, K., & Kaski, K. (2019). Deep learning fundus image analysis for diabetic retinopathy and macular edema grading. *Scientific Reports*, 9(1), 1–11. <https://doi.org/10.1038/s41598-019-47181-w>
- Sánchez-Morales, M. E., Guillen-Bonilla, J. T., Guillen-Bonilla, H., Guillen-Bonilla, A., Aguilar-Santiago, J., & Jiménez-Rodríguez, M. (2024). Vectorial image representation for image classification. *Journal of Imaging*, 10(2), 1–

17. <https://doi.org/10.3390/jimaging10020048>
- Sav, U., & Magar, G. (2021). Insider threat detection based on anomalous behavior of user for cybersecurity. *Lecture Notes in Networks and Systems*, 132, 17–28. https://doi.org/10.1007/978-981-15-5309-7_3
- Shamsan, A., Senan, E. M., & Shatnawi, H. S. A. (2023). Automatic classification of colour fundus images for prediction eye disease types based on hybrid features. *Diagnostics*, 13(10), 1706. <https://doi.org/10.3390/diagnostics13101706>
- Sharmili, N., Yonbawi, S., Alahmari, S., Laxmi Lydia, E., Ishak, M. K., Alkahtani, H. K., Aljarbouh, 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>
- Shaw, A., Hunter, D., Landola, F., & Sidhu, S. (2019). SqueezeNAS: Fast Neural Architecture Search for Faster Semantic Segmentation. *2019 IEEE/CVF International Conference on Computer Vision Workshop (ICCVW)*, 1(20), 2014–2024. <https://doi.org/10.1109/ICCVW.2019.00251>
- Shinde, R. K., Alam, M. S., Hossain, M. B., Md Imtiaz, S., Kim, J. H., Padwal, A. A., & Kim, N. (2023). Squeeze-MNet: precise skin cancer detection model for low computing IoT devices using Transfer Learning. *Cancers*, 15(1), 2–13. <https://doi.org/10.3390/cancers15010012>
- Shirzadfar, H., & Amirzadeh, P. (2019). A comprehensive study on eye issues and modern developments in visual rehabilitation for people with Impaired Vision. *International Journal of Biosensors & Bioelectronics*, 5(2), 48–54. <https://doi.org/10.15406/ijbsbe.2019.05.00153>
- Smaida, M., & Serhii, Y. (2019). Comparative study of image classification algorithms for eyes diseases diagnostic. *International Journal of Innovative Science and Research Technology*, 4(12), 2456–2165. www.ijisrt.com40

- Topaloglu, I. (2023). Deep learning-based Convolutional Neural Network structured new image classification approach for eye disease identification. *Scientia Iranica*, 30(5), 1731–1742. <https://doi.org/10.24200/sci.2022.58049.5537>
- Trabelsi, A., Chaabane, M., & Ben-Hur, A. (2019). Comprehensive evaluation of deep learning architectures for prediction of DNA/RNA sequence binding specificities. *Bioinformatics*, 35(14), 1269–1277. <https://doi.org/10.1093/bioinformatics/btz339>
- Triyadi, A. B., Bustamam, A., & Anki, P. (2022). Deep learning in image classification using VGG-19 and Residual Networks for cataract detection. *Proceedings - 2022 2nd International Conference on Information Technology and Education, ICITE and E 2022*, 20(14), 293–297. <https://doi.org/10.1109/ICITE54466.2022.9759886>
- Venkaiappalaswamy, B., Reddy, P. V. G. D. P., & Batha, S. (2022). An effective diagnosis of diabetic retinopathy based on 3d Hybrid Squeezenet architecture. *International Journal of Engineering Trends and Technology*, 70(12), 147–159. <https://doi.org/10.14445/22315381/IJETT-V70I12P216>
- Xiong, R., Yang, Y., He, D., Zheng, K., Zheng, S., Xing, C., Zhang, H., Lan, Y., Wang, L., & Liu, T. Y. (2020). On layer normalization in the Transformer architecture. *37th International Conference on Machine Learning, ICML 2020*, 16(8), 10455–10464.
- Xu, L., Chen, X., & Yang, X. (2024). Tourism image classification based on Convolutional Neural Network SqueezeNet -taking slender west lake as an example. *PLoS ONE*, 19(1), 1–16. <https://doi.org/10.1371/journal.pone.0295439>
- 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>

- Younis, A., Qiang, L., Nyatega, C. O., Adamu, M. J., & Kawuwa, H. B. (2022). Brain tumor analysis using Deep Learning and VGG-16 ensembling learning approaches. *Applied Sciences (Switzerland)*, *12*(14). <https://doi.org/10.3390/app12147282>
- Zhang, R., Zhou, B., Lu, C., & Ma, M. (2022). The performance research of the data augmentation method for image classification. *Mathematical Problems in Engineering*, *22*(20), 5–6. <https://doi.org/10.1155/2022/2964829>
- Zhu, Q., He, Z., Zhang, T., & Cui, W. (2020). Improving classification performance of softmax loss function based on scalable batch-normalization. *Applied Sciences (Switzerland)*, *10*(8), 1–8. <https://doi.org/10.3390/APP10082950>