

KLASIFIKASI PATOLOGI MAKULA RETINA MELALUI CITRA OCT MENGUNAKAN *CONVOLUTIONAL NEURAL NETWORK* DENGAN ARSITEKTUR *MOBILENET*

(*CLASSIFICATION OF PATHOLOGY OF MACULA RETINA THROUGH OCT IMAGE USING
CONVOLUTIONAL NEURAL NETWORK WITH MOBILENET ARCHITECTURE*)

Putri Nada Zakiya¹, Ledy Novamizanti², Syamsul Rizal³

^{1,2,3} Universitas Telkom, Bandung

¹putriinadaz@student.telkomuniversity.ac.id, ²ledyvaldn@telkomuniversity.ac.id,

³syamsul@telkomuniversity.ac.id

ABSTRAK

Makula adalah area utama untuk penginderaan dan terletak di tengah retina. Kerusakan makula pada retina dapat menyebabkan kehilangan penglihatan permanen. Pada saat ini, deteksi penyakit pada patologi makula retina masih dilakukan secara manual dan memerlukan waktu yang lama. Oleh karena itu diperlukan suatu teknik yang dapat mendeteksi dan mengklasifikasi suatu penyakit patologi makula retina dengan lebih cepat dan efisien waktu. Pada penelitian ini akan merancang sistem klasifikasi kondisi patologi makula retina menggunakan metode *Convolutional Neural Network (CNN)* dengan arsitektur *MobileNet*. Perancangan sistem dibagi menjadi beberapa tahapan yaitu menginput data citra retinal OCT, kemudian dilakukan *preprocessing* dengan menggunakan *CLAHE*, *gaussian filter*, dan *gabor filter*. Kemudian masuk ke tahap *training* akan menggunakan dua algoritma *optimizer* yaitu *Stochastic Gradient Descent (SGD)*, dan *Adaptive moment (Adam)*. Pada Tugas Akhir ini, sistem ini akan mengklasifikasi penyakit patologi makula retina yang dibagi menjadi empat kelas yaitu, *Choroidal Neovascularization (CNV)*, *Diabetic Macular Edema (DME)*, *Drusen*, dan Normal. Hasil akhir menunjukkan model terbaik untuk klasifikasi patologi makula pada retina berdasarkan citra retinal OCT yaitu *MobileNet* dengan *optimizer Adam* menggunakan citra *Gaussian filter* yang memiliki nilai akurasi *training* 95,679%, akurasi *validation* 92,045%, *loss training* 0,135 dan *loss validation* 0,299.

Kata Kunci : Makula, patologi retina, *Choroidal Neovascularization (CNV)*, *Diabetic Macular Edema (DME)*, *Drusen*, *Convolutional Neural Network (CNN)*, *MobileNet*, citra retina OCT

1. PENDAHULUAN

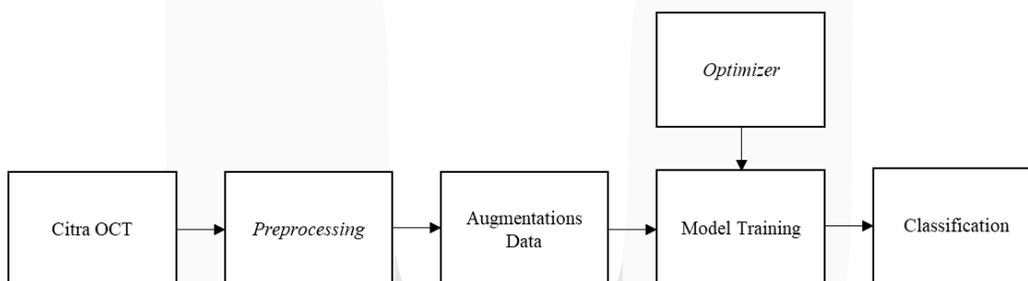
Retina mata manusia merupakan organ penting berupa sel tipis yang terletak di bagian belakang bola mata. Retina merupakan bagian dari mata yang dapat menerima cahaya yang difokuskan oleh lensa dan mengubahnya menjadi sinyal saraf [1]. Makula adalah area utama yang digunakan untuk penginderaan, yang terletak di tengah retina dan mengandung lapisan sel saraf fotoreseptor khusus, yang bertanggung jawab untuk mendeteksi warna, intensitas cahaya dan detail visual yang halus [2]. Banyak gangguan penglihatan yang mempengaruhi kesehatan makula retina menjadi masalah serius yang dapat mempengaruhi penglihatan normal. Neovaskularisasi koroid (CNV), *drusen* dan *Edema Makula Diabetic (DME)* adalah penyebab umum kehilangan penglihatan permanen di seluruh dunia. Oleh karena itu, pemeriksaan makula retina secara rutin sangat penting dilakukan untuk mendeteksi penyakit dan memberikan penanganan dini. Salah satu jenis pencitraan yang paling umum digunakan untuk diagnosis patologi yang terjadi di makula adalah *Optical coherence tomography (OCT)*. OCT merupakan teknik pencitraan paling menjanjikan yang baru-baru ini digunakan dalam oftalmologi [3]. Teknologi pencitraan ini bersifat non-invasif, tidak langsung menyentuh bola mata dan memiliki fungsi akuisisi gambar yang cepat [4]. Pada saat ini, pendeteksian penyakit pada patologi makula retina masih dilakukan secara manual oleh para dokter ahli, namun proses secara manual membutuhkan waktu yang lama yaitu dengan memeriksa dan mengevaluasi foto penyakit patologi makula pada retina manusia [4, 3]. Oleh karena itu, berbagai algoritma digunakan untuk mengklasifikasikan berbagai penyakit makula secara otomatis yang umum melalui citra OCT, salah satunya adalah *Convolutional Neural Network (CNN)*.

Mengenai topik klasifikasi citra retina OCT, banyak penelitian telah dilakukan dan berbagai model telah diusulkan, seperti *Random Forest algorithm* yang berfokus pada klasifikasi penyakit mata menggunakan fitur klinis buatan tangan otomatis untuk pasien dengan AMD, DME dan retina normal dengan tingkat akurasi yang dihasilkan 96%. Namun, dalam model yang digunakan tersebut hanya dapat digunakan untuk deteksi dini penyakit patologi retina mata umum yang tidak memiliki gejala pada tahap awal yang *extreme* (parah) [5]. Penelitian lainnya oleh [6] menggunakan model CNN dengan sistem berbasis platform AI menghasilkan tingkat akurasi 90%. Namun, dalam model yang digunakan masih terdapat kesalahan dalam mendiagnosis dan memprediksi perubahan penyakit lainnya seperti diabetes edema makula. Penelitian lainnya oleh [7]. Penelitian ini menggunakan metode deteksi Anomali dengan keakuratan 81,40% pada tugas klasifikasi tiga kelas. Namun, pada model yang digunakan hasil penampilan normal berbeda dengan rentang yang diwakili dalam rangkaian pelatihan, karena tidak memiliki data pelatihan yang cukup.

Berdasarkan hasil penelitian-penelitian tersebut, maka penelitian ini merancang sistem untuk klasifikasi patologi makula pada retina berdasarkan citra retinal oct melalui tahap preprocessing terlebih dahulu kemudian diklasifikasi menggunakan metode CNN dengan arsitektur *Mobilenet*. Klasifikasi menggunakan 4 kelas yaitu: *Choroidal Neovascularization* (CNV), *Diabetic Macular Edema* (DME), *Drusen*, dan Normal.

2. BAHAN DAN METODE

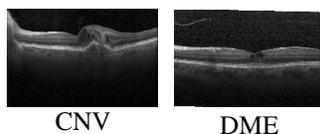
Penelitian ini dibagi menjadi 6 tahap, yaitu tahap pengambilan data, tahap *preprocessing* yaitu proses peningkatan kualitas pada citra. Tahap selanjutnya augmentasi data yaitu proses mendapatkan variasi data-data tambahan yang berguna untuk membuat model melakukan generalisasi dengan lebih baik. Tahap selanjutnya klasifikasi menggunakan CNN dengan arsitektur *mobilenet*. Kemudian tahap pengujian sistem menggunakan dua skenario pengujian. Gambar 1 merupakan blok diagram tahapan penelitian.



Gambar 1. Metode Penelitian

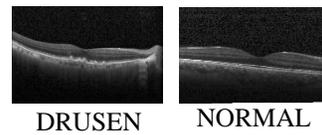
2.1 Dataset Retina OCT

Pada penelitian ini menggunakan *dataset* kermany et al 2018 yang diunduh dari website Kaggle paultimothymooney/kermany2018. Dataset diperoleh dari *Shiley Eye Institute of University of California San Diego* (UCSD), *California Retinal Research Foundation*, *Medical Center Ophthalmology Associates*, *The Shanghai First People’s Hospital*, dan *Beijing Tongren Eye Center* antara 1 Juli 2013 sampai 1 Maret 2017. *Dataset* dibagi menjadi 3 folder (data uji, dan data pelatihan) dan berisi subfolder untuk setiap 4 kategori gambar (NORMAL, CNV, DME, DRUSEN). Ada 84.495 citra OCT (JPEG) yang terdiri dari 83,527 citra data latih dan 968 data uji. Namun pada penelitian ini hanya menggunakan 2968 citra OCT (JPEG) yang terdiri dari 2000 citra data latih dan 968 data uji. Berikut Gambar 2 merupakan contoh citra dataset dari UCSD untuk setiap kategori gambar retinal OCT.



CNV

DME

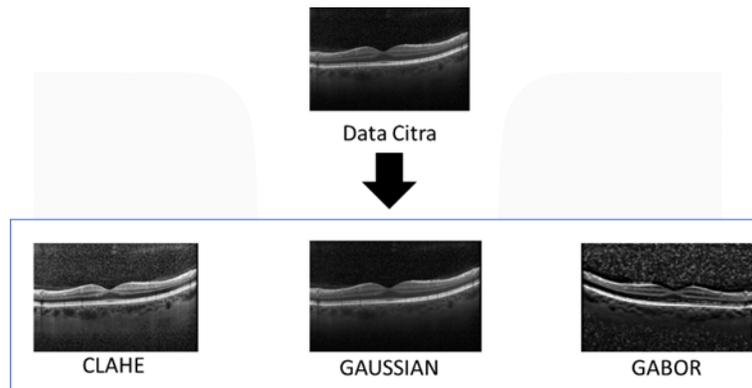


Gambar 2. Dataset Retinal OCT UCSD

Normal Retinal *Optical Coherence Images* adalah lapisan jaringan tipis yang melapisi bagian belakang dalam mata, di dekat saraf optic. *Choroidal Neovascularization* merupakan pembuluh darah baru yang tumbuh dari lapisan koroid dan memasuki ruang subretinal. *Drusen* adalah sejumlah kecil lemak atau lipoprotein yang terakumulasi di lapisan koroid, yang disebabkan oleh pengendapan metabolit epitel pigmen yang tidak normal. *Diabetic Macular Edema (DME)* adalah salah satu penyebab utama kehilangan penglihatan pada pasien diabetes, dan dapat terjadi pada setiap tahap retinopati diabetik (DR) [8].

2.2 Preprocessing

Pada penelitian ini, system klasifikasi patologi makula pada retina melalui tahap *preprocessing* terlebih dahulu, agar akurasi dapat lebih optimal. *Preprocessing* bertujuan untuk untuk mengolah citra agar dapat diambil karakteristiknya [9], [10]. *Preprocessing* dilakukan menginputkan data citra lalu citra akan diproses dengan tiga jenis *preprocessing* yaitu CLAHE, *gaussian filter*, dan *gabor filter*. Gambar 3 menjelaskan alur kerja pada tahap *preprocessing*.

Gambar 3. Alur kerja tahap *preprocessing*

Contrast limited Adaptive Histogram Equalization (CLAHE) merupakan penyempurnaan dari metode *Adaptive Histogram Equalization* dan *Histogram Equalization*. Metode ini menggunakan teori probabilitas skala abu-abu untuk meningkatkan dan membatasi masalah kontras gambar digital dengan memberikan nilai yang diketahui untuk ambang batas atau *clip limit* [11]. Nilai batas atau *clip limit* merupakan batas maksimum suatu histogram, dapat dihitung dengan persamaan (1).

$$\beta = \frac{M}{N} \left(1 + \frac{\sigma}{100} (S_{max} - 1) \right) \quad (1)$$

dengan variabel M menyatakan luas region size, N menyatakan nilai *grayscale* dan α merupakan *clip factor* menyatakan penambahan batas *limit* histogram yang bernilai antara 0 sampai 100. Histogram diatas nilai clip limit dianggap kelebihan (*excess*) piksel yang akan didistribusikan kepada area sekitar dibawah *clip limit* sehingga histogram merata.

Gaussian filter adalah filter yang respon impulsnya merupakan fungsi Gaussian. Filter gaussian memiliki sifat tidak memiliki *overshoot* pada input fungsi langkah sambil meminimalkan waktu naik dan turun [12]. Filter Gaussian sangat bagus untuk menghaluskan *noise* yang terdistribusi secara normal, dapat dihitung dengan persamaan (2).

$$G(X, Y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (2)$$

dengan σ adalah nilai deviasi standar distribusi normal yang digunakan. Makin besar nilai σ , maka makin banyak titik tetangga yang diikuti dalam perhitungan, x dan y adalah posisi koordinat mask dimana koordinat $(0,0)$ adalah posisi titik tengah dari mask yang mempunyai nilai paling besar/paling tinggi, π adalah konstanta dengan nilai 3,14, e adalah konstanta bilangan natural dengan nilai 2,718281828.

Gabor filter didefinisikan sebagai fungsi harmonik yang dimodulasi oleh distribusi Gaussian. Gabor filter adalah filter yang dapat mensimulasikan karakteristik sistem visual manusia saat memisahkan frekuensi dan arah tertentu dari suatu citra. Gabor filter bertindak sebagai filter bandpass dengan distribusi frekuensi spasial lokal untuk mencapai resolusi optimal dalam domain spasial dan frekuensi, dapat dihitung dengan persamaan (3), (4), dan (5).

$$G(x, y, \theta, \sigma, \lambda) = \exp\left\{-\frac{1}{2}\left[\frac{x_\theta^2}{\sigma_x^2} - \frac{y_\theta^2}{\sigma_y^2}\right]\right\} \cos\left(2\pi \frac{x_\theta}{\lambda}\right) \quad (3)$$

$$x_\theta = x \cos(\theta) + y \sin(\theta) \quad (4)$$

$$y_\theta = -x \sin(\theta) + y \cos(\theta) \quad (5)$$

dengan θ adalah orientasi gabor filter, λ adalah panjang gelombang dari faktor sinusoidal, σ_x dan σ_y adalah standar deviasi sifat gaussian sepanjang sumbu x dan y , x_θ dan y_θ mendefinisikan sumbu dan dari koordinat filter.

2.3 Augmentasi Data

Augmentasi data adalah proses mengubah atau memodifikasi suatu citra sehingga komputer mendeteksi bahwa citra yang dimodifikasi adalah citra berbeda, tetapi manusia dapat mengetahui bahwa citra yang dimodifikasi adalah citra yang sama [13].

2.4 Fungsi Optimizer

Fungsi *Optimizer* berfungsi untuk menemukan bobot optimal, meminimalkan kesalahan dan memaksimalkan akurasi. Pada proses pelatihan, parameter (bobot) dapat diubah untuk mencoba dan meminimalkan fungsi kerugian, agar mampu memprediksi seakurat mungkin. Penelitian ini menggunakan dua jenis optimasi yaitu *adaptive moment optimization* (Adam), dan *Stochastic Gradient Descent* (SGD). *Adaptive moment optimization* (Adam) adalah algoritma pengoptimalan berbasis gradien orde pertama dimana efisien secara komputasi membutuhkan memori yang rendah. *Adaptive moment optimization* (Adam) merupakan salah satu adaptif *learning rate* optimasi yang mengkombinasikan rmsprop dan momentum [14]. Rumus perhitungan optimasi Adam ditunjukkan pada persamaan (6).

$$\theta_{t+1} = \theta_t - \alpha \frac{\eta}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \quad (6)$$

dengan θ merupakan parameter yang akan diperbaiki (pada kasus ini adalah bobot), α adalah *step size* atau *learning rate*, \hat{m}_t merupakan estimasi momentum dengan bias yang dikoreksi pada saat itu t , \hat{v}_t adalah estimasi *subgradien* adaptif dengan bias yang dikoreksi pada saat itu t .

Stochastic Gradient Descent (SGD) merupakan algoritma *optimizer* yang terpopuler dalam melakukan optimasi pada *artificial neural network* dan *optimizer* paling sederhana namun memakan waktu yang cukup lama untuk mendekati *konvergen*. Algoritma ini digunakan untuk mengupdate sebuah parameter dalam hal ini ialah bobot (*weight*) dan bias. Keunggulan menggunakan SDG adalah terminimalisirnya memori yang dibutuhkan pada saat mencari *weight* baru [15]. Proses pembaruan parameter pada SGD dapat didefinisikan pada persamaan (7).

$$\theta = \theta - \alpha \times \nabla_{\theta} J(\theta; x^{(i)}; y^{(i)}) \quad (7)$$

dengan θ adalah bobot atau bias, $\nabla_{\theta} J(\theta; x^{(i)}; y^{(i)})$ merupakan *gradient* terhadap bobot atau bias, x dan y , x adalah input, y adalah label.

2.5 Parameter Uji

Untuk mendapatkan model sistem terbaik diperlukan parameter uji sebagai nilai pembandingan untuk setiap model. Parameter performa yang digunakan dalam penelitian ini yaitu akurasi, presisi, *recall*, *F1-score*, dan *confusion matrix* [16], [17].

1. Akurasi

Akurasi menjelaskan keakuratan model yang dapat diklasifikasikan dengan benar. Oleh karena itu, akurasi merupakan rasio prediksi benar (*positif* dan *negatif*) terhadap keseluruhan data. Dengan kata lain, akurasi adalah seberapa dekat nilai prediksi dengan nilai aktual (sebenarnya). Akurasi dapat dihitung dengan persamaan (8).

$$\text{Akurasi} = \frac{(TP+TN)}{(TP+FP+FN+TN)} \quad (8)$$

dengan TP (*True Positive*) adalah kasus dimana diprediksi (*Positive*), hasil *positive*, TN (*True Negative*) adalah kasus dimana diprediksi (*Negative*), hasil *positive*, FP (*False Positive*) adalah kasus dimana yang diprediksi *positive*, ternyata tidak. Hasil salah (*Negative*), FN (*False Negative*) adalah kasus dimana yang diprediksi *positive*, ternyata tidak. Hasilnya salah (*negative*)

2. Presisi

Presisi menggambarkan tingkat akurasi antara data yang diminta dan hasil prediksi yang diberikan oleh model. Secara matematis perhitungan presisi dapat dituliskan dengan persamaan (9).

$$\text{Presisi} = \frac{(TP)}{(TP+FP)} \quad (9)$$

dengan TP (*True Positive*) adalah kasus dimana diprediksi (*Positive*), hasil *positive*, FP (*False Positive*) adalah kasus dimana yang diprediksi *positive*, ternyata tidak. Hasil salah (*Negative*).

3. Recall

Recall menggambarkan keberhasilan model dalam memulihkan informasi. Oleh karena itu, *recall* adalah rasio prediksi positif benar terhadap keseluruhan data positif benar. Recall dapat dihitung dengan persamaan (10).

$$\text{Recall} = \frac{(TP)}{(TP+FN)} \quad (10)$$

dengan TP (*True Positive*) adalah kasus dimana diprediksi (*Positive*), hasil *positive*. FN (*False Negative*) adalah kasus dimana yang diprediksi *positive*, ternyata tidak. Hasilnya salah (*negative*).

4. F1 Score

F-1 score merupakan kalkulasi evaluasi dalam pencarian informasi yang menggabungkan *recall* dan presisi. Dalam situasi tertentu, nilai *recall* dan presisi dapat memiliki bobot yang berbeda. Secara sistematis perhitungan F1 Score dapat dituliskan dengan persamaan (11).

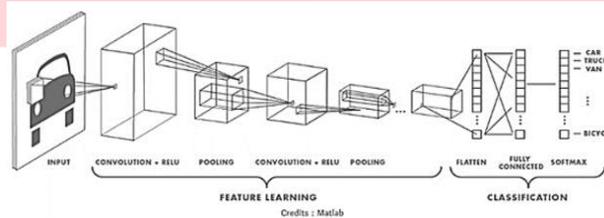
$$\text{F1 Score} = 2 \times \frac{(\text{Recall} \times \text{Presisi})}{(\text{Recall} + \text{Presisi})} \times 100 \quad (11)$$

5. Confusion Matrix

Confusion Matrix merupakan metode yang biasa digunakan untuk mengukur suatu classifier dalam melakukan prediksi pada kategori yang berbeda. Ada empat istilah yang merupakan representasi hasil proses klasifikasi pada *confusion matrix* yaitu *True Positif* (TP), *True Negatif* (TN), *False Positif* (FP), dan *False Negatif* (FN) [18].

3 DESAIN ARSITEKTUR CNN

Penelitian ini menggunakan salah satu algoritma deep learning yaitu Convolutional Neural Network (CNN) dengan arsitektur Mobilenet. *Convolutional Neural Networks* (CNN) merupakan Jaringan Saraf Buatan. Dimana model algoritma ini digunakan untuk melakukan tugas klasifikasi langsung melalui gambar, video, teks, ataupun suara. CNN juga merupakan salah satu algoritma paling populer dalam teknik *Deep Learning*. CNN dapat digunakan untuk mendiagnosis penyakit medis, terutama data berbasis citra seperti citra X-ray dan citra OCT [19]. CNN terdiri dari dua tahapan utama yaitu *feature learning* dan *classification*. Pada tahapan *feature learning* terdiri dari *convolution layer*, ReLU (fungsi aktivasi) dan *pooling layer* sedangkan pada tahap *classification* terdiri dari *flatten*, *fully-connected layer*, dan *softmax*.



Gambar 4. Convolutional Neural Network

3.1 Convolution Layer

Convolution Layer merupakan lapisan utama yang paling penting di metode CNN. Hasil dari convolution layer adalah citra baru yang menunjukkan fitur dari citra masukan. Setiap citra yang menjadi masukan, menggunakan filter *convolution* layer dalam proses tersebut. Convolutional layer terdiri dari neuron yang tersusun sedemikian rupa sehingga membentuk sebuah filter dengan panjang dan tinggi (*pixel*) [20].

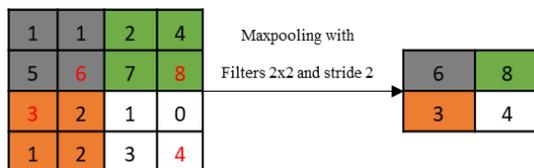
3.2 ReLU

Rectified Linear Unit merupakan sebuah *activation function* yang terdapat pada *hidden layer*. ReLU memungkinkan pelatihan data yang lebih cepat dan efisien dengan memetakan nilai negatif ke nol dan mempertahankan nilai positif [21]. Perhitungan ReLU dapat menggunakan rumus pada persamaan (12).

$$f(x) = \max(0, x) \quad (12)$$

3.3 Pooling layer

Pooling layer merupakan lapisan yang berfungsi untuk mengurangi ukuran spasial dari fitur konvolusi sehingga dapat mengurangi sumber daya komputasi yang dibutuhkan untuk memproses data melalui pengurangan dimensi dari feature map (*downsampling*) sehingga mempercepat komputasi karena parameter yang diperbarui semakin sedikit. Selain itu, berguna untuk mengekstraksi fitur dominan sehingga proses pelatihan model lebih efektif. Ada dua jenis *pooling layer*, yaitu *max pooling* dan *average pooling* [22]. Konsep *max pooling* yaitu membuat matriks baru berukuran lebih kecil dengan cara mengambil fitur terbesar pada sebuah matriks. Dalam implementasinya, *max pooling* mengambil piksel terbesar yang akan disusun menjadi *matriks* baru [23]. Konsep *max pooling* diilustrasikan pada Gambar 5.



Gambar 5. Konsep Max pooling

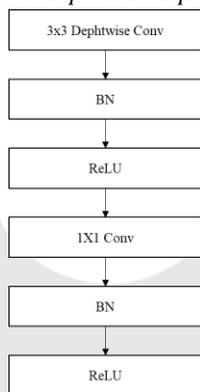
Gambar 5 menunjukkan operasi *max pooling* pada citra berukuran 4x4, menggunakan filter 2x2, dan nilai stride 2 yang menandakan pergeseran baris dan kolom sebanyak 2

3.4 Fully Connected Layer

Lapisan *Fully-connected* adalah lapisan di mana semua *neuron* aktif di lapisan sebelumnya terhubung ke neuron di lapisan berikutnya, seperti yang dapat dilakukan oleh jaringan saraf tiruan. Setiap aktivitas dari lapisan sebelumnya harus diubah menjadi data satu dimensi sebelum dapat ditautkan ke semua *neuron* di lapisan *Fully-Connected* [16].

3.5 MobileNet

MobileNet atau *MobileNetV1* merupakan model yang memiliki ukuran kecil baik dari jumlah parameter maupun ukuran model yang dihasilkan. Seperti namanya, *Mobile*, para peneliti dari *Google* membuat arsitektur CNN yang dapat digunakan untuk kebutuhan *mobile*. *MobileNetV1* adalah sebuah arsitektur model yang dikembangkan untuk pengembangan aplikasi pada perangkat mobile ataupun perangkat lain yang memiliki keterbatasan sumber daya perangkat keras dengan mengurangi ukuran dan kompleksitas model menggunakan *depthwise separable convolutions* [20]. Perbedaan mendasar antara arsitektur *MobileNet* dan arsitektur CNN pada umumnya adalah penggunaan lapisan atau *layer* konvolusi dengan ketebalan *filter* yang sesuai dengan ketebalan input image. Gambar 6 menunjukkan gambar *depthwise separable convolutions*, yakni *blok layer* yang tersusun dari *depthwise convolution* dan *pointwise convolution*, masing-masing layer tersebut diikuti oleh *batch normalization* dan *ReLU nonlinearity* berikut adalah gambar arsitektur *depthwise separable convolutions*.



Gambar 6. *depthwise separable convolutions*

Blok layer tersebut kemudian disusun secara berulang membentuk arsitektur *MobileNet*. Berdasarkan pustaka keras, *MobileNet* memiliki jumlah *layer* sebanyak 28 *convolution layer* dan 1 *fully connected layer* yang diikuti oleh lapisan *softmax*. [21]

4 HASIL DAN PEMBAHASAN

Spesifikasi perangkat yang digunakan pada pengujian sistem ini, yaitu bahasa pemrograman Python 3.8, *software pycharm community*, dan *hardware*, dengan spesifikasi :Intel(R)Core(TM) i5-8250U CPU @ 1.60GHz 1.80 GHz , dan memori 8.00gb RAM.

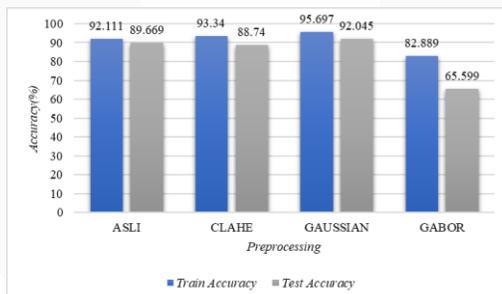
4.1 Pengujian Preprocessing

Bagian ini merupakan pengujian terhadap pengaruh *preprocessing* pada sebuah citra sebelum proses klasifikasi. *Preprocessing* yang digunakan yaitu CLAHE, *gaussian filter*, dan *gabor filter*. Pengujian ini membandingkan hasil citra original dengan citra hasil *preprocessing*. *Optimizer* yang digunakan adalah Adam dengan *learning rate* 0.01, *batch size* 16, dan *epoch* 50. Tabel 1 merupakan hasil pengujian *preprocessing* terhadap performa akurasi dan *loss*.

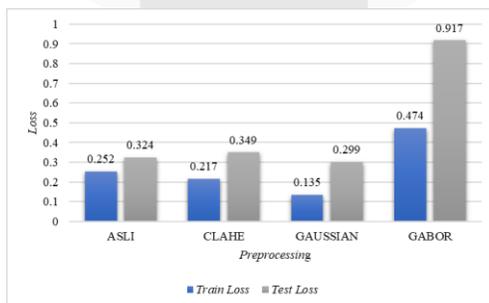
Tabel 1. Pengaruh Preprocessing terhadap Performa

Citra	Accuracy		Loss	
	Training (%)	validation (%)	Training	validation
Original	92.111	89.669	0.252	0.324
Clahe	93.34	88.74	0.217	0.349
Gaussian	95.697	92.045	0.135	0.299
Gabor	82.889	65.599	0.474	0.917

Berdasarkan Tabel 1, hasil terbaik untuk pengujian *preprocessing* adalah *Gaussian* yang memiliki akurasi training 95,679%, akurasi validation 92,045%, *loss training* 0,135 dan *loss validation* 0,299. Sedangkan untuk citra asli menghasilkan akurasi *training* 92,111%, akurasi *validation* 89,669%, *loss training* 0,252, dan *loss validation* 0,324. Adanya *preprocessing* pada citra sebelum proses klasifikasi dapat jauh lebih mengoptimalkan hasil akurasi dan meminimalkan *loss*. Berdasarkan hasil pengujian *preprocessing gaussian filter* dianggap sebagai *preprocessing* yang paling baik untuk menghilangkan *noise* pada citra Retinal OCT. Hasil pengujian *gaussian filter* terhadap performa akurasi dan *loss* dapat dilihat pada Gambar 7 dan Gambar 8.



Gambar 7. Performa Gaussian Filter terhadap akurasi



Gambar 8. Performa Gaussian Filter terhadap Loss

4.2 Pengujian Optimizer

Bagian ini merupakan pengujian terhadap pengaruh fungsi *optimizer*. *Optimizer* yang digunakan yaitu SGD, dan Adam. Semua *optimizer* menggunakan *learning rate* 0,01, *batch size* 16, dan *epoch* 50 untuk mengetahui kinerja setiap optimasi pada *learning rate* yang sama. Dalam pengujian ini digunakan citra *Gaussian Filter* yang memiliki hasil terbaik pada skenario sebelumnya. Tabel 2 merupakan hasil pengujian fungsi *optimizer*.

Tabel 2. Hasil Pengujian Fungsi *Optimizer*

Optimizer	Accuracy		Loss	
	Training (%)	validation (%)	Training	validation
Adam	95.697	92.045	0.135	0.299
SGD	93.443	89.153	0.163	0.302

Berdasarkan Tabel 2, hasil terbaik untuk pengujian *optimizer* adalah Adam yang memiliki akurasi *training* 95,679%, akurasi *validation* 92,045%, *loss training* 0,135 dan *loss validation* 0,299. Sedangkan untuk SGD akurasi *training* 93,443%, akurasi *validation* 89,153%, *loss training* 0,163 dan *loss validation* 0,302. Berdasarkan hasil pengujian *optimizer* Adam dianggap paling baik untuk klasifikasi patologi makula pada retina berdasarkan citra retinal OCT menggunakan model CNN dengan arsitektur *Mobilenet*. *Optimizer* Adam adalah hasil penurunan metode SGD yang didasarkan pada estimasi *adaptif momen orde* pertama dan kedua dan *optimizer* adam juga melakukan penyimpanan rata-rata *gradient* proses sebelumnya secara eksponensial yang membuat pada pengujian dengan menggunakan *optimizer* adam lebih dapat menghasilkan hasil yang optimal.

4.3 Pengujian Perbandingan Performa Sistem

Bagian ini merupakan pengujian terhadap performa sistem Parameter performasi yang dibandingkan antara lain akurasi, *recall*, presisi, dan *F-1 score*. Pengujian ini menggunakan hasil terbaik dari model CNN dengan *Mobilenet* berdasarkan dari pengujian sebelumnya. Proses pengujian menggunakan 3000 citra dengan 4 kelas.



Gambar 9. Confusion matrix

Pada gambar 9, memperlihatkan informasi perbandingan hasil deteksi yang dilakukan oleh sistem (*prediction*) dengan hasil sebenarnya (*actual*). Berdasarkan hasil *confusion matrix* tersebut dapat dilakukan perhitungan parameter performansi akurasi, *recall*, presisi, dan *F-1 score*. Tabel 3 merupakan hasil performa *system*.

Tabel 3. performa *system*

	Akurasi	Presisi	Recall	F-1 Score
CNV	86%	93%	86%	90%
DME	90%	90%	90%	90%
DRUSEN	92%	92%	92%	92%
NORMAL	100%	92%	100%	96%

Berdasarkan Tabel 3, hasil performa *system* secara keseluruhan hasil terbaik yang didapatkan menggunakan model CNN dengan arsitektur *MobileNet* menggunakan 3000 citra dengan 4 kelas memiliki akurasi 86%-100%, presisi 90%-93%, *recall* 86%-100%, dan *f1-score* 90%-96%.

5 KESIMPULAN

Penelitian ini mengusulkan sistem klasifikasi patologi makula pada retina menggunakan metode CNN dengan arsitektur *MobileNet*. Sistem dapat mengidentifikasi 4 kelas dengan akurasi *training* 95,679%, akurasi *validation* 92,045%, *loss training* 0,135 dan *loss validation* 0,299. Berdasarkan dari nilai *confusion matrix* didapatkan hasil akurasi sebesar sebesar 92,04% untuk *recall*, 91,75% untuk presisi dan 92,25% untuk *F1-score*. Hasil ini didapatkan dengan menggunakan *preprocessing* Gaussian filter, *learning rate* 0,01, *batch size* 16, *epoch* 50 dan *optimizer* Adama. Augmentasi data juga dilakukan pada penelitian ini guna meningkatkan akurasi sistem yang dilatih. Augmentasi yang dilakukan adalah memutar citra secara acak antara 0 dan 20 derajat, melakukan penggeseran pada gambar sepanjang sumbu X sebesar 20% dan sumbu Y sebesar 20%, dan membalikan gambar secara *horizontal*. Dari hasil pengujian, bahwa *preprocessing Gaussian filter* pada citra, dilakukannya proses augmentasi, dan penggunaan fungsi *Optimaizer* Adam dapat meningkatkan performa sistem klasifikasi patologi makula pada retina. Hasil dari klasifikasi patologi makula pada retina menggunakan metode CNN dengan arsitektur *MobileNet*. dapat dinilai bekerja dengan baik.

6 REFERENSI

- [1] A. . M. Alqudah, MSc, "AOCT-NET: A Convolutional Network Automated Classification Of Multiclass Retinal Diseases Using Spectral-Domain Optical Coherence Tomography Images," in *International Federation for Medical and Biological Engineering 2019*, Yarmouk University, Irbid, Jordan, November 2019.
- [2] Y. Wang, Y. Zhang, . Z. Yao, R. Zhao and . F. Zhou, "Machine Learning Based Detection Of Age Related Macular Degeneration (AMD) And Diabetic Macular Edema (DME) From Optical Coherence Tomography (OCT) Images," *Biomedical Optics Express*, vol. 7, no. 12, p. 4928–4940, November 2016.
- [3] H. D. Novita and M. , "Optical Coherence Tomography (OCT)," *Jurnal Oftalmologi Indonesia*, vol. 6, no. 3, pp. 169-177, Desember 2008.
- [4] F. Li, H. Chen, . Z. Liu, . X. Zhang and . Z. Wu , "Fully Automated Detection Of Retinal Disorders By Image-Based Deep Learning," *Graefes Arch Clin Exp Ophthalmol*, vol. 257, no. 3, p. 495–505, 2019.
- [5] M. A. Hussain, A. Bhuiyan, C. D. Luu, R. T. Smith, R. H. Guymer, H. Ishikawa, J. S Schuman and K. Ramamohanarao, "Classification Of Healthy And Diseased Retina Using SD-OCT Imaging And Random Forest Algorithm," *PLOS ONE*, vol. 13, no. 6, 2018.
- [6] D. K. Hwang, C.-C. Hsu, K. J. Chang, D. Chao, C. H. Sun, Y. C. Jheng, A. A.Yarmishyn, J. C. Wu, C. Y. Tsai, M. L. Wang, C. H. Peng, K. H. Chien, C. L. Kao, T. C. Lin, L. C. Woung, S. J. Chen and S. H. Chiou, "Artificial Intelligence-Based Decision-Making For Age-Related Macular Degeneration," *Theranostics*, vol. 9, no. 1, pp. 232-245, 2019.
- [7] P. Seebock, S. . M. Waldstein, S. Klmscha, H. Bogunovic, T. Schlegl, B. S. Gerendas, R. Donner, U. Schmidt-Erfurth and G. Langs, "Unsupervised Identification Of Disease Marker Candidates In Retinal OCT Imaging Data," *Ieee Transactions On Medical Imaging* , vol. 38, no. 4, pp. 1037-1047, 2018.
- [8] D. Kermany, K. Zhang and M. Goldbaum, "Large Dataset Of Labeled Optical Coherence Tomography (OCT) And Chest X-Ray Images," *Mendeley Data*, vol. 3, 2018.
- [9] C.P. Riesmala, A. Rizal, L. Novamizanti, Pengenalan Motif Batik Dengan Analisis Struktur Dan Warna Pada Citra Digital, Skripsi Sarjana pada IT Telkom Bandung, 2012
- [10] L Novamizanti, J Raharjo, II Tirtosmoro, Identifikasi Pola Iris Mata Menggunakan Dekomposisi Transformasi Wavelet dan Levenshtein Distance, IT Telkom, Bandung, 2009.

- [11] J. Wang and L. Perez, "The Effectiveness of Data Augmentation in Image Classification using Deep," *arXiv e-prints*, Dec 2017.
- [12] D. P. Kingma and J. L. Ba, "ADAM: A Method For Stochastic Optimization," *CoRR*, 2015.
- [13] S. Ruder, "An Overview Of Gradient Descent Optimization," *ArXiv*, 2017.
- [14] N. D. Miranda, L. Novamizanti, and S. Rizal, "Convolutional Neural Network Pada Klasifikasi Sidik Jari Menggunakan Resnet-50," *J. Tek. Inform.*, vol. 1, no. 2, pp. 61–68, 2020, doi: 10.20884/1.jutif.2020.1.2.18.
- [15] C. D. R. Wulandari, S. A. Wibowo and L. Novamizanti, "Classification of diabetic retinopathy using statistical region merging and convolutional neural network", *Proceedings - 2019 IEEE Asia Pacific Conference on Wireless and Mobile APWiMob2019*, pp. 94-98, 2019.
- [16] A. Jamhari, F. M. Wibowo and W. A. Saputra, "Perancangan Sistem Pengenalan Wajah Secara Real-Time pada CCTV Dengan Metode Eigenface," *Journal of Informatics, Information System, Software Engineering and Applications*, vol. 2, no. 2, pp. 020-032, 2020.
- [17] F. Li, H. Chen, Z. Liu, X. d. Zhang, M. s. Jiang, Z. z. Wu and K. q. Zhou, "Deep learning-Based Automated Detection Of Retinal Diseases Using Optical Coherence Tomography Images," *Biomedical Optics Express*, vol. 10, no. 12, pp. 6204-6226, 2019.
- [18] A. Peryanto, A. Yudhana and R. Uma, "Rancang Bangun Klasifikasi Citra Dengan Teknologi Deep Learning Berbasis Metode Convolutional Neural Network," *Jurnal Format*, vol. 8, no. 2, 2019.
- [19] A. Yusuf, R. . C. Wihandika and C. Dewi, "Klasifikasi Emosi Berdasarkan Ciri Wajah Menggunakan Convolutional," *Pengembangan Teknologi Informasi dan Ilmu Komputer*, vol. 3, no. 11, pp. 10595-10604, 2020.
- [20] M. . R. Alwanda, R. P. K. Ramadhan and D. Alamsyah, "Implementasi Metode Convolutional Neural Network Menggunakan Arsitektur LeNet-5 untuk Pengenalan Doodle," *Algoritme*, vol. 1, no. 1, pp. 45 - 56, Oktober 2020.
- [21] S. ALBAWI, T. A. MOHAMMED and S. AL-ZAWI , "Understanding of a Convolutional Neural Network," *International Conference on Engineering*, pp. 1-6, 2017.
- [22] A. G. Howard, M. Zhu, B. Chen, D. Kalenichenko, W. Wang, T. Weyand, M. Andreetto and H. Adam, "MobileNets: Efficient Convolutional Neural Networks For Mobile Vision," *Computer Science*, 2017.
- [23] B. Khasoggi and E. Samsuryadi, "Efficient MobileNet Architecture as Image Recognition on Mobile and Embedded Devices," *Journal of Electrical Engineering and Computer Science*, vol. 16, no. 1, p. 389~394, October 2019.