

KLASIFIKASI PATOLOGI MAKULA PADA RETINA BERDASARKAN CITRA RETINAL OCT MENGGUNAKAN *CONVOLUTIONAL NEURAL NETWORK*

(*Classifying Retinal Pathology Using OCT Retinal Imaging With Convolutional Neural Network*)

Dewi Annisa Anam¹, Ledy Novamizanti², Syamsul Rizal³

^{1,2,3} Universitas Telkom

dewianss@student.telkomuniversity.ac.id¹, ledyaldn@telkomuniversity.ac.id²,

syamsul@telkomuniversity.ac.id³

Abstrak

Makula pada retina bertanggung jawab terhadap penglihatan pusat manusia. Kesehatan makula dapat dipengaruhi oleh sejumlah patologi umum seperti, *Age-related Macular Degeneration* (AMD), *Choroidal Neovascularization* (CNV), dan *Diabetic Macular Edema* (DME). *Optical Coherence Tomography* (OCT) adalah sebuah teknik pencitraan medis yang digunakan untuk mendeteksi patologi yang terjadi pada makula. Proses analisis manual, cenderung kurang efektif dan efisien baik dari segi waktu maupun keakuratan hasil diagnosa. Sehingga dibutuhkan sebuah sistem klasifikasi otomatis patologi umum makula retina berdasarkan citra Retinal OCT untuk mengatasi permasalahan tersebut. Pada penelitian ini, sistem dirancang menggunakan *Convolutional Neural Network* (CNN) dengan model *EfficientNet*. Model *EfficientNet* bekerja menggunakan metode *compound scaling* yaitu menyeimbangkan seluruh dimensi pada jaringan. Kinerja performansi sistem dibandingkan berdasarkan jenis *preprocessing*, yaitu *Gaussian Filter*, *Contrast Limited Adaptive Histogram Equalization* (CLAHE), dan *Gabor Filter*, fungsi optimasi, yaitu *Adaptive Moment* (Adam) dan *Stochastic Gradient Decent* (SGD), jumlah *epoch* serta nilai parameter *learning rate* dan *batch size* yang berbeda. Hasil penelitian menunjukkan konfigurasi terbaik untuk sistem klasifikasi patologi umum makula pada retina memperoleh nilai akurasi pengujian sebesar 90,60% dengan *loss* pengujian 0,27 menggunakan *preprocessing* CLAHE dan fungsi optimasi Adam.

Kata Kunci: *Patologi Makula Pada Retina, Retinal OCT, Convolutional Neural Network (CNN), EfficientNet*

Abstract

The macula on the retina is responsible for central vision in humans. Macular health can be affected by a number of common pathologies such as, *Age-related Macular Degeneration* (AMD), *Choroidal Neovascularization* (CNV), and *Diabetic Macular Edema* (DME). *Optical Coherence Tomography* (OCT) is a medical imaging technique used to detect pathology that occurs in the macula. Manual analysis process tends to be less effective and efficient both in terms of time and accuracy of diagnostic results. So, an automatic classification system for general macular retinal pathology is needed based on OCT retinal images to overcome these problems. In this research, the system is designed using *Convolutional Neural Network* (CNN) with *EfficientNet* model. The *EfficientNet* model works using a *compound scaling* method, which is to balance all dimensions of the network. The performance of the system is compared based on the type of *preprocessing*, namely *Gaussian Filter*, *Contrast Limited Adaptive Histogram Equalization* (CLAHE), and *Gabor Filter*, optimizer, namely *Adaptive Moment* (Adam) and *Stochastic Gradient Decent* (SGD), the number of epochs as well as the value of the learning rate and batch size parameters. different. The results showed that the best configuration for the general macular pathology classification system on the retina obtained a test accuracy value of 90.60% with a test loss of 0.27 using CLAHE preprocessing and Adam optimizer.

Keywords: *Macular Pathology of the Retina, Retinal OCT, Convolutional Neural Network (CNN), EfficientNet*

1. Pendahuluan

Kebutaan dan gangguan penglihatan mempengaruhi setidaknya 2.2 miliar orang diseluruh dunia. Berkurangnya penglihatan dapat disebabkan oleh sejumlah faktor, termasuk penyakit seperti *Age-related Macular*


Degeneration (AMD), *Choroidal Neovascularization* (CNV), dan *Diabetic Macular Edema* (DME). Makula adalah bagian tengah pada retina yang utamanya bertanggung jawab atas penglihatan pusat manusia. Kesehatan makula dapat dipengaruhi oleh sejumlah patologi umum, seperti Diagnosis klinis penyakit makula pada retina dapat dinilai melalui struktur makula dari kelainan atau perubahan ciri morfologi seperti drusen, bekas luka, cairan, kista, dan eksudat.

Salah satu alat yang digunakan untuk mendeteksi patologi yang terjadi pada makula adalah *Optical Coherence Tomography* (OCT). Dalam proses analisis manual, para dokter mata ahli oftalmologi memerlukan waktu yang cukup lama dan cenderung memberikan hasil subjektif. Sehingga, berbagai algoritma digunakan untuk mengklasifikasikan sejumlah patologi umum terhadap makula melalui citra OCT secara otomatis, salah satunya adalah *Convolutional Neural Network* (CNN). Penelitian ini menggunakan salah satu model dari CNN, yaitu *EfficientNet*. *EfficientNet* merupakan hasil dari peningkatan skala jaringan dasar *AutoML MNAS framework* untuk memperoleh sejumlah model. Berbeda dengan model CNN lain yang ditingkatkan dengan menskalakan salah satu dimensi saja seperti kedalaman, lebar atau resolusi gambar, *EfficientNet* ditingkatkan dengan menyeimbangkan seluruh dimensi pada jaringan. Metode ini disebut *compound scaling*.

2. Dasar Teori

2.1 Dataset

Pada penelitian ini menggunakan *dataset open source* dari <https://www.kaggle.com/paultimothymooney/kermany2018> yang berisi 4 folder kategori gambar, yaitu CNV, DME, Drusen, dan Normal berisi subfolder untuk tiap kategori gambar (NORMAL, CNV, DME, DRUSEN). Jumlah *Dataset* asli berisi 83.519 citra OCT latih (JPEG), namun pada penelitian ini hanya menggunakan 500 citra OCT latih untuk setiap kategori gambar. Berikut merupakan contoh *dataset* untuk setiap kelas ditunjukkan pada Gambar 1.

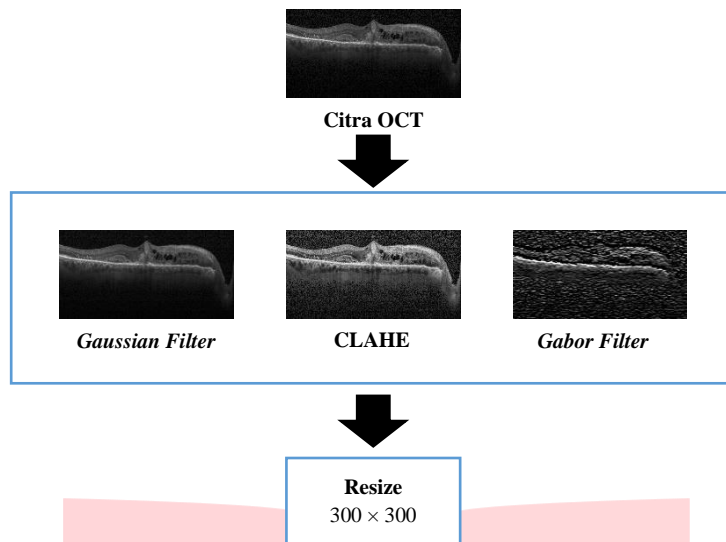


Gambar 1. Dataset Retinal OCT, (a) CNV, (b) DME, (c) Drusen, (d) Normal.

Citra OCT pada *dataset* ini dipilih dari kelompok retrospektif pasien dewasa 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.

2.2 Preprocessing

Preprocessing secara umum dilakukan untuk meningkatkan kualitas citra, seperti mengoptimalkan akurasi sistem. Adapun tahapan dalam proses *preprocessing* ditunjukkan pada Gambar 2.



Gambar 2. Diagram Blok *Preprocessing*.

Pada penelitian ini, proses *preprocessing* dimulai dengan memasukkan citra OCT lalu citra akan diproses dengan tiga jenis *preprocessing* yaitu *Gaussian Filter*, *CLAHE*, dan *Gabor Filter*. Pertama – tama nilai *noise* didistribusikan agar intensitas *noise* tiap piksel tidak bergantung dengan piksel lainnya dalam proses *Gaussian Filter*. Pada *CLAHE* nilai batas atau *clip limit* diberikan pada histogram untuk melakukan peningkatan kontras terhadap citra. Sedangkan *Gabor Filter* dimodulasi oleh distribusi *Gaussian* untuk pengenalan tekstur pada citra.

2.3 Augmentasi Data

Augmentasi data merupakan suatu proses dalam pengolahan data citra dengan melakukan modifikasi citra berdasarkan parameter tertentu. Parameter augmentasi yang biasa digunakan adalah sebagai berikut.

1. *Rescale* citra dilakukan untuk melakukan normalisasi citra dengan cara mengalikan data dan nilai yang diberikan. Parameter ini dilakukan sebelum proses augmentasi yang lainnya.
2. *Rotation* dilakukan untuk memutar citra dalam rentang nilai sudut yang ditentukan.
3. *Shift* dilakukan untuk menggeser citra pada sumbu x dan y sesuai dengan rentang nilai penggeseran citra yang diberikan.
4. *Fill_mode* merupakan mode pengisian beberapa area citra yang hilang disebabkan oleh proses penggeseran, pemotongan atau pembesaran citra.
5. *Zoom* dilakukan untuk memperbesar citra dengan nilai perbesaran tertentu dari luas citra.
6. *Flip* dilakukan untuk membalikkan citra secara horizontal atau vertikal.

2.4 Optimizer

Optimizer memiliki tujuan utama untuk meminimalkan nilai *loss function* (ℓ) yaitu sekumpulan data yang dihitung secara keseluruhan oleh *neural network*.

2.4.1 Adaptive Moment (Adam)

Adam menyimpan rata – rata *gradient* proses sebelumnya, sehingga proses penurunan *gradient* relatif stabil.

$$\mathbf{a}_t = \beta_1 \mathbf{a}_{t-1} + (1 - \beta_1) \mathbf{d}_t \quad (1)$$

$$\mathbf{u}_t = \beta_2 \mathbf{u}_{t-1} + (1 - \beta_2) \mathbf{d}_t^2 \quad (2)$$

Nilai \mathbf{d}_t menyatakan *gradient* dari *objective function* berdasarkan parameter θ pada *time step* t dan β merupakan *decay rates* masing – masing persamaan. Kemudian persamaan \mathbf{a}_t dan \mathbf{u}_t dihitung dengan menambahkan koreksi bias melalui persamaan $\hat{\mathbf{a}}_t$ dan $\hat{\mathbf{u}}_t$ guna mengatasi keadaan saat nilai \mathbf{a}_t dan \mathbf{u}_t bias ke arah mendekati nol

$$\hat{\mathbf{a}}_t = \frac{\mathbf{a}_t}{1 - \beta_1^t} \quad (3)$$

$$\hat{\mathbf{u}}_t = \frac{\mathbf{u}_t}{1 - \beta_2^t} \quad (4)$$

Sehingga persamaan Adam dapat dinyatakan sebagai berikut

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\mathbf{u}_t + \epsilon}} \hat{\mathbf{a}}_t \quad (5)$$

Nilai η direpresentasikan sebagai *learning rate* dan ϵ adalah epsilon dengan angka yang sangat kecil untuk mencegah pembagian dengan nol saat implementasi.

2.4.2 Stochastic Gradient Descent (SGD)

SGD melakukan pembaruan parameter setiap data pada proses pelatihan, sehingga biaya kalkulasi penyimpanan yang dibutuhkan juga cukup besar. Persamaan SGD dapat dinyatakan sebagai

$$\theta_{t+1} = \theta_t - \eta \mathbf{d}_t \quad (6)$$

Nilai \mathbf{d}_t direpresentasikan sebagai *gradient* dari *objective function* berdasarkan parameter θ pada *time step t* dan η direpresentasikan sebagai *learning rate*.

2.5 Confusion Matrix

Confusion Matrix adalah matriks yang berisi informasi tentang nilai prediksi dan nilai aktual yang dihasilkan oleh sistem klasifikasi. *Confusion Matrix* juga merupakan salah satu metode yang digunakan untuk mengevaluasi kinerja sistem klasifikasi berdasarkan perhitungan data dalam matriks ini. Berikut gambaran dari *Confusion Matrix* ditunjukkan pada Tabel 1.

Tabel 1. *Confusion Matrix*.

		Prediksi		
		Kelas 1	...	Kelas n
Aktual	Kelas 1	X_{11}	...	X_{1n}
	⋮	⋮		⋮
	Kelas n	X_{n1}	...	X_{nn}

2.6 Metrik Kinerja Klasifikasi

Metrik kinerja dapat berguna untuk membandingkan kualitas dari prediksi keseluruhan sistem. Berikut merupakan metrik kinerja yang dapat dievaluasi pada penelitian ini berdasarkan 4 metrik kinerja yaitu *True Positive (TP)*, *True Negative (TN)*, *False Positive (FP)*, dan *False Negative (FN)*.

1. Accuracy

Accuracy atau akurasi didefinisikan sebagai tingkat kedekatan antara nilai prediksi dengan nilai aktual. Hasil perhitungan akurasi dapat diperoleh melalui persamaan berikut

$$Accuracy = \frac{(TP + TN)}{(TP + FP + FN + TN)} \quad (7)$$

2. Recall

Recall atau sensitivitas adalah tingkat keberhasilan sistem dalam menemukan kembali sebuah informasi. Hasil perhitungan sensitivitas dapat diperoleh melalui persamaan berikut

$$Recall = \frac{(TP)}{(TP + FN)} \quad (8)$$

3. Precision

Precision atau presisi adalah tingkat ketepatan antara informasi yang diminta oleh pengguna dengan jawaban yang diberikan sistem. Hasil perhitungan presisi dapat diperoleh melalui persamaan berikut

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

4. F-1 Score

F1-Score adalah perbandingan rata-rata *precision* dan *recall* yang dibobotkan. Hasil perhitungan *F1-Score* dapat diperoleh melalui persamaan berikut

$$F1-Score = \frac{2(Recall \times Precision)}{(Recall + Precision)} \quad (10)$$

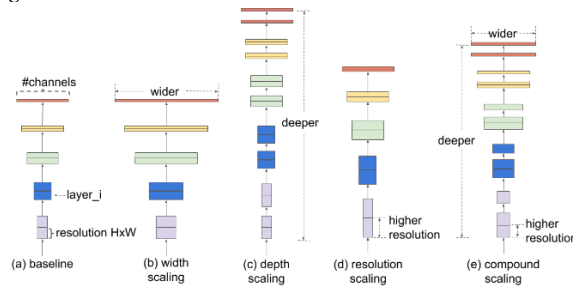
3. Perancangan Sistem

3.1 Convolutional Neural Network (CNN)

CNN merupakan bentuk umum dari *Deep Neural Network*. CNN memiliki jangkauan aplikasi yang luas dan bervariasi, namun sebagian besar aplikasi CNN berfokus pada data gambar. CNN terdiri dari 3 lapisan utama yaitu *input layer*, *hidden layer (convolution layer, pooling layer)*, dan *fully-connected (FC) layer*.

3.2 EfficientNet

EfficientNet bekerja dengan metode *compound scaling* atau menyeimbangkan seluruh dimensi pada jaringan (*width, depth, resolution*). Gambar 3 (a) adalah contoh jaringan dasar; (b) – (d) merupakan *conventional scaling*; dan (e) metode *compound scaling*.



Gambar 3. Model Scaling.

Arsitektur *EfficientNet – B0* menggunakan *mobile inverted bottleneck convolution* (MBConv) dengan meningkatkan jaringan dasar dari *AutoML MNAS framework* untuk memperoleh beberapa versi model.



Gambar 4. AutoML MNAS Framework.

4. Hasil dan Analisis

Perancangan sistem klasifikasi patologi umum pada retina menggunakan perangkat keras berupa *notebook* dengan spesifikasi perangkat lunak diantaranya menggunakan sistem operasi *Windows 10 Home 64-Bit* dan *software Python 3.7*.

4.1 Hasil Pengujian Terhadap Preprocessing

Skenario 1 merupakan pengujian terhadap pengaruh *preprocessing* pada citra Retinal OCT. Terdapat tiga jenis *preprocessing* yang digunakan dalam penelitian ini yaitu *Gaussian Filter*, *CLAHE*, dan *Gabor Filter*. Pengujian ini menggunakan skenario terbaik berdasarkan hasil pengujian fungsi optimasi yaitu optimasi Adam. Berikut merupakan hasil pengujian *preprocessing* terhadap akurasi sistem ditunjukkan pada Tabel 2.

Tabel 2. Hasil Pengujian Terhadap Preprocessing

Citra	Accuracy		Loss	
	Train (%)	Test (%)	Train	Test
Asli	96.90	89.40	0.1	0.32
Gaussian Filter	98.45	87.40	0.06	0.37
CLAHE	97.60	90.60	0.08	0.27
Gabor Filter	92.65	70.30	0.25	1

Berdasarkan Tabel 2 hasil terbaik terdapat pada CLAHE dengan akurasi pelatihan mencapai 97,6%, akurasi pengujian mencapai 90,6%, *loss* pelatihan 0,08, dan *loss* pengujian 0,27. Dari hasil pengujian menunjukkan bahwa *preprocessing* pada citra yang dilakukan sebelum proses klasifikasi dapat meningkatkan nilai akurasi sistem serta meminimalkan *loss* yang terjadi. Dari hasil pengujian juga menunjukkan bahwa CLAHE dianggap sebagai *preprocessing* terbaik untuk meningkatkan kualitas citra Retinal OCT. Hal ini dikarenakan CLAHE memberikan nilai batas atau *clip limit* pada histogram sehingga mencegah terjadinya peningkatan kontras secara berlebihan.

4.2 Hasil Pengujian Terhadap Fungsi Optimasi

Skenario 2 merupakan pengujian terhadap fungsi optimasi. Terdapat dua jenis optimasi yang digunakan dalam penelitian ini yaitu Adam dan SGD. Kinerja setiap optimasi diuji menggunakan *learning rate* yang sama yaitu 0,01. Berikut merupakan hasil pengujian optimasi terhadap akurasi sistem ditunjukkan pada Tabel 3.

Tabel 3. Hasil Pengujian Terhadap Fungsi Optimasi.

Optimizer	Accuracy		Loss	
	Train (%)	Test (%)	Train	Test
Adam	97.60	90.60	0.08	0.27
SGD	88.90	80.00	0.42	0.57

Berdasarkan Tabel 3 optimasi Adam dianggap lebih optimal terhadap akurasi sistem dengan akurasi pelatihan mencapai 97,6% dan akurasi pengujian mencapai 90,6%. Optimasi Adam juga menghasilkan nilai *loss* yang lebih rendah daripada optimasi SGD dengan *loss* pelatihan 0,08 dan *loss* pengujian 0,27. Dari hasil pengujian ini, optimasi Adam dianggap optimasi terbaik untuk klasifikasi terhadap citra Retinal OCT menggunakan model CNN dan arsitektur *EfficientNet*. Hal ini disebabkan optimasi Adam menyimpan rata – rata *gradient* proses sebelumnya, sehingga proses penurunan *gradient* relatif stabil.

4.3 Hasil Pengujian Terhadap Pengaruh Jumlah Epoch

Skenario 3 merupakan pengujian terhadap pengaruh jumlah *epoch*. Dalam penelitian ini menggunakan dua nilai maksimum *epoch* yaitu 10 dan 20. Berikut merupakan hasil pengujian pengaruh jumlah *epoch* terhadap akurasi sistem ditunjukkan pada Tabel 4.

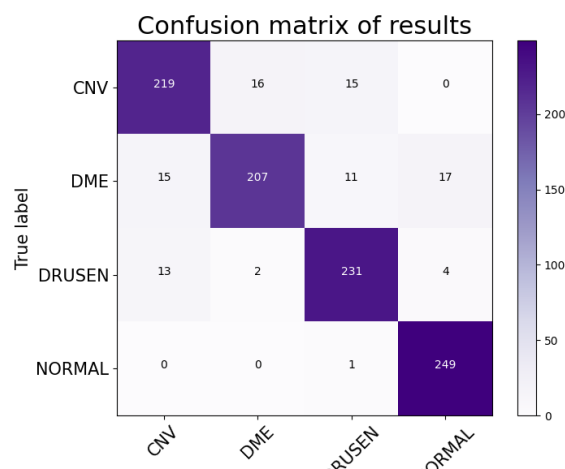
Tabel 4. Hasil Pengujian Terhadap Pengaruh Jumlah Epoch.

Epoch	Accuracy		Loss	
	Train (%)	Test (%)	Train	Test
10	97.60	90.60	0.08	0.27
20	98.30	89.10	0.05	0.34

Berdasarkan Tabel 4 dapat dilihat bahwa jumlah *epoch* tidak berbanding lurus terhadap kenaikan akurasi sistem serta penurunan *loss*. Pengujian menggunakan 10 *epoch* menghasilkan akurasi pelatihan sebesar 97,6% dan akurasi pengujian sebesar 90,6%, dengan menggunakan 20 *epoch* mengalami peningkatan akurasi pelatihan menjadi 98,3% namun terjadi penurunan akurasi pengujian sebesar 1,5% menjadi 89,1%. Berdasarkan Tabel 4 dapat dilihat juga bahwa pengujian menggunakan 10 *epoch* memiliki *loss* pelatihan senilai 0,08 dan *loss* pengujian senilai 0,27, dengan menggunakan 20 *epoch* mengalami penurunan nilai *loss* pelatihan menjadi 0,05 namun terjadi peningkatan nilai *loss* pengujian sebesar 0,07 menjadi 0,34.

4.4 Hasil Pengujian Performa Sistem

Skenario 4 merupakan pengujian performa sistem. Dalam penelitian terdapat empat parameter performansi yang akan dibandingkan yaitu akurasi, presisi, *recall*, dan *F1 – Score*. Berikut merupakan *confusion matrix* hasil pengujian ditunjukkan pada Gambar 9.

**Gambar 5.** Confusion Matrix.

Berdasarkan Gambar 5 dapat dilihat perbandingan hasil deteksi citra oleh sistem (*prediction*) dengan hasil sebenarnya (*actual*). Pada penelitian ini melakukan pengujian terhadap 4 kategori citra OCT dengan masing –

masing jumlah data uji sebanyak 250 citra. Pada Gambar 9 juga dapat diketahui bahwa sistem yang diusulkan bekerja secara optimal dalam mengklasifikasikan citra OCT kelas Normal. Berdasarkan nilai – nilai dari *confusion matrix* dapat dilakukan perhitungan parameter performansi akurasi, presisi, *recall*, dan *F – 1 Score*. Tabel 5 merupakan hasil perhitungan parameter performansi untuk tiap kelas.

Tabel 5. Performa Sistem Patologi Makula Pada Retina.

	Akurasi	Presisi	Recall	F-1 Score
CNV	87,6%	89%	88%	88%
DME	82,8%	92%	83%	87%
DRUSEN	92,4%	90%	92%	91%
NORMAL	99,6%	92%	100%	96%

Berdasarkan hasil performa pada Tabel 5 arsitektur *EfficientNet* memiliki rerata akurasi sebesar 90,6%, *presisi* dan *recall* sebesar 90,75%, serta *F1 – Score* sebesar 90,5%, hal ini menunjukkan arsitektur *EfficientNet* pada penelitian ini memiliki kinerja yang optimal dalam mengklasifikasikan setiap kategori citra.

5. Kesimpulan

Penelitian ini telah mengusulkan sistem klasifikasi patologi umum makula pada retina berdasarkan citra Retinal OCT menggunakan model *Convolutional Neural Network* dengan arsitektur *EfficientNet*. Berdasarkan hasil pengujian sistem dapat disimpulkan bahwa arsitektur *EfficientNet* pada penelitian ini memiliki kinerja yang optimal dalam mengklasifikasikan setiap kategori citra dengan akurasi pelatihan sebesar 97,6%, akurasi pengujian 90,6%, *loss* pelatihan 0,08, dan *loss* pengujian 0,27. Sistem klasifikasi patologi umum makula pada retina yang diusulkan juga memiliki performa yang cukup baik dengan perolehan rerata presisi dan *recall* sebesar 90,75%, serta *F – 1 Score* sebesar 90,5%. Hasil ini didapatkan dengan menambahkan *preprocessing* CLAHE, melakukan augmentasi data, pemilihan *optimizer* Adam dengan *learning rate* 0,01, dan pemilihan jumlah *epoch* yaitu 10 *epoch*.

REFERENSI

- [1] M. Tan, B. Chen, V. Vasudevan, M. Sandler, A. Howard and Q. V. Le, "MnasNet: Platform-Aware Neural Architecture Search for Mobile," *IEEE*, pp. 2815-2823, 2019.
- [2] J. Sanjaya and M. Ayub, "Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan RandomCrop, Rotate, dan Mixup," *Jurnal Teknik Informatika dan Sistem Informasi*, vol. 6, pp. 318-319, 2020.
- [3] K. H. Mahmud, A. and S. A. Faraby, "Klasifikasi Citra Multi-Kelas Menggunakan Convolutional Neural Network," *e-Proceeding of Engineering*, vol. 6, p. 2131, 2019.
- [4] S. Bera and V. K. Shrivastava, "Analysis of various optimizers on deep convolutional neural network model in the application of hyperspectral remote sensing image classification," *International Journal of Remote Sensing*, vol. 41, no. 7, pp. 2664-2683, 2019.
- [5] D. Choi, C. J. Shallue, Z. Nado, J. Lee, C. J. Maddison and G. E. Dahl, "On Empirical Comparisons of Optimizers for Deep Learning," 2020.
- [6] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," *International Conference for Learning Representations*, 2015.
- [7] H. Robbins and S. Monro, "A Stochastic Approximation Method," *The Annals of Mathematical Statistics*, pp. 400-407, 1951.
- [8] P. N. Andono, T. Sutojo and M. , *Pengolahan Citra Digital*, Yogyakarta: Penerbit ANDI (Anggota IKAPI), 2017.
- [9] Z. C. Lipton, C. Elkan and B. Naryanaswamy, "Thresholding Classifiers to Maximize F1 Score," pp. 1-16, 2014.
- [10] N. Seliya, T. M. Khoshgoftaar and J. V. Hulse, "A Study on the Relationships of Classifier Performance Metrics," *IEEE International Conference on Tools with Artificial Intelligence*, pp. 59-66, 2009.
- [11] C. C. Aggarwal, *Neural Networks and Deep Learning*, New York: Springer, 2018.
- [12] V. Sze, Y. H. Chen, T. J. Yang and J. S. Emer, "Efficient Processing of Deep Neural Networks: A Tutorial and Survey," *IEEE*, vol. 105, no. 12, pp. 2295-2329, 2017.
- [13] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," in *Proceedings of the 36th International Conference on Machine Learning*, Long Beach, California, 2019.

- [14] M. Tan and Q. V. Le, "Google AI Blog," Google, 29 May 2019. [Online]. Available: <https://ai.googleblog.com/2019/05/efficientnet-improving-accuracy-and.html>. [Accessed 28 November 2020].

