

IMPLEMENTASI SEBLOCK PADA KLASIFIKASI CITRA PENYAKIT MATA MANUSIA DENGAN ARSITEKTUR MOBILENETV3-SMALL

Raden Shalehuddin Albawani, Fetty Tri Anggraeny, Muhammad Muharrom Al Haromainy

Informatika, Universitas Pembangunan Nasional “Veteran” Jawa Timur
Jl. Rungkut Madya No.1, Gunung Anyar, Surabaya, Jawa Timur, 60294
fanimaho1999@gmail.com

ABSTRAK

Masyarakat Indonesia masih belum menyadari secara sepenuhnya tentang pentingnya kesehatan mata dimulai dengan adanya penyakit mata yang ringan seperti miopi, presbiopi, kelelahan mata, dan lain sebagainya dan juga penyakit mata yang berat seperti katarak, glaukoma, penyakit retina, dan lain sebagainya. Perkembangan teknologi saat ini memungkinkan manusia untuk dengan cepat dan tepat mengenali penyakit melalui gambar dengan memanfaatkan teknologi citra digital. Salah satu pendekatan yang digunakan adalah transfer learning dengan memakai arsitektur MobileNetV3-Small SEBlock yang dimana penggunaan metode tersebut dapat digunakan pada perangkat dengan spesifikasi yang rendah namun dapat menghasilkan hasil yang maksimal. Tingkat akurasi yang berhasil dicapai oleh MobileNetV3-Small SEBlock sangat memuaskan setelah melalui tahap pelatihan yang dimana pada fase tersebut dapat menunjukkan performa yang stabil serta hasil pengujian yang sangat baik dengan dapat membaca dan mengklasifikasi data sebanyak 3941 gambar dari 4000 gambar sehingga nilai akurasi yang didapatkan mencapai 90%.

Kata kunci : Penyakit Mata Manusia, Citra Digital, Transfer Learning, SEBlock, MobileNetV3-Small.

1. PENDAHULUAN

Seseorang yang mengalami masalah kesehatan pada mata menghadapi tantangan beragam, mulai dari gangguan yang ringan hingga kondisi yang serius, seperti kehilangan penglihatan. Di Indonesia, masih ada banyak masyarakat yang belum sepenuhnya menyadari akan pentingnya menjaga kesehatan mata. Terdapat berbagai jenis penyakit mata seperti miopi, hipermetropi, astigmatisme, presbiopi, kelelahan mata, keringat mata, dan gangguan penglihatan warna, mengingat jumlah penderita penyakit mata di Indonesia meningkat sebesar 1,2% setiap tahunnya [1]. Di antara masalah kesehatan mata yang memiliki tingkat keparahan yang signifikan termasuk penyakit katarak, glaukoma, dan penyakit retina [2].

Berkembangnya teknologi yang memudahkan manusia dalam mengakses berbagai informasi, telah muncul teknologi klasifikasi citra yang dapat mengidentifikasi jenis objek dalam gambar. Bidang ini menjadi dasar penting dalam pengembangan visi komputer dan memiliki peran yang cukup besar dalam berbagai aplikasi [3]. Salah satu aspek yang sedang menarik perhatian dalam bidang Machine Learning adalah Deep Learning, yang dikenal karena kemampuannya dalam mengolah data yang kompleks, seperti gambar dan suara. Banyak peneliti telah mengadakan penelitian terkait dengan isu-isu kesehatan mata, termasuk penelitian tentang identifikasi katarak menggunakan citra digital. Citra digital dapat diartikan sebagai representasi yang bersifat diskrit dari citra analog, yang mencakup koordinat dan nilai intensitas cahaya yang terdapat dalam citra tersebut [4].

Dalam domain visi komputer, kemampuan yang luar biasa dari deep learning terlihat dari kecakapannya dalam mengklasifikasikan objek dalam

citra [5]. Pendekatan ini bertujuan untuk mengoptimalkan struktur hierarkis dalam pemahaman lingkungan, karena metodenya memungkinkan eksplorasi informasi dalam data secara mendalam, menghilangkan kebutuhan untuk membagi data menjadi segmen-segmen yang lebih kecil [6].

Transfer Learning adalah salah satu teknik yang digunakan untuk melakukan klasifikasi citra. Selain memiliki kemampuan merancang, metode ini mampu mengklasifikasikan berbagai jenis citra [7]. Transfer Learning juga terkait erat dengan kecerdasan buatan atau AI, suatu pendekatan yang bertujuan memberikan kemampuan kecerdasan pada mesin, terutama dalam program komputer yang sangat canggih [8]. Fokus utama di bidang kecerdasan buatan adalah memberikan kemampuan pada mesin untuk meniru logika dan kecerdasan yang dimiliki oleh manusia [9].

Kemudian untuk penyelesaian di dalam transfer learning ini menggunakan sebuah arsitektur yaitu MobileNetV3-Small dengan teknik SEBlock. MobileNet terdiri dari 2 jenis untuk implementasinya yaitu MobileNetV3-Large dan MobileNetV3-Small yang dimana perbedaannya terletak pada layer, untuk MobileNetV3-Large terdiri dari 15 layer dan MobileNetV3-Small terdiri dari 11 layer [10].

Penggunaan SEBlock pada penelitian ini bertujuan untuk meningkatkan kapabilitas model dalam menangkap fitur-fitur penting dari input. Awalnya, mekanisme ini diperkenalkan khususnya dalam kerangka Convolutional Neural Networks (CNNs) dan telah terbukti berhasil meningkatkan kinerja model dalam beragam tugas pengolahan gambar [11]. Diharapkan dengan penggunaan MobileNetV3-Small dengan SEBlock pada penelitian ini dapat menghasilkan akurasi yang maksimal, yang dimana sudah ada pembuktian jurnal yang telah

melakukan penelitian terkait penggunaan Mobilenet dengan SEBlock.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Untuk penelitian terdahulu penulis mendapatkan acuan dari artikel dengan judul “Peningkatan Performa MobilenetV3 dengan Squeeze-and-Excitation (Studi Kasus Klasifikasi Kesegaran Ikan Berdasarkan Mata Ikan)” yang ditulis oleh Galih Ashari Rakhmat dan Muhammad Fikri Haekal pada tahun 2023 [11]. Penelitian tersebut akan dilakukan pengelompokan kesegaran ikan berdasarkan mata ikan dengan metode klasifikasi. Pada penelitian tersebut menghasilkan model dengan kinerja terbaik diperoleh pada hyperparameter learning rate 0.00001, batch size train 10 val 10, optimizer ADAM, epochs 100 dengan model arsitektur MobileNetV3-Small. berdasarkan hasil evaluasi performa model didapatkan 68% accuracy, 69% precision, 67% recall dan 68% f1-score pada pengujian 876 data uji dengan 24 kelas yaitu terdiri dari tingkat kesegaran dan jenis ikan yang berbeda.

2.2. MobileNetV3-Small

MobileNetV3 adalah suatu struktur jaringan saraf tiruan yang didesain khusus untuk aplikasi dengan kebutuhan pemrosesan yang ringan pada perangkat mobile atau perangkat tepi. Arsitektur ini merupakan kelanjutan dari rangkaian MobileNet yang telah terkenal dalam pengolahan gambar bergerak (visi komputer mobile) karena kemampuannya menghasilkan model yang ringan dan efisien tanpa mengurangi kinerja. Terdapat dua varian MobileNetV3, yakni MobileNetV3-Large dan MobileNetV3-Small, yang difokuskan pada pengurangan ukuran model dan peningkatan kecepatan proses inferensi [12].

2.3. Squeeze-and-Excitation

Squeeze-and-Excitation (SE) adalah sebuah mekanisme atau blok yang diimplementasikan dalam jaringan saraf tiruan (neural network) dengan tujuan meningkatkan kemampuan model dalam menangkap fitur-fitur penting dari input. Mekanisme ini awalnya diperkenalkan dalam kerangka Convolutional Neural Networks (CNNs) dan telah terbukti berhasil meningkatkan kinerja model dalam berbagai tugas pengolahan gambar [13].


3. METODE PENELITIAN

3.1. Jenis dan Sumber Data

Pada tahap ini, terdapat berbagai metode yang dapat digunakan untuk mengumpulkan data. Jenis data yang diperoleh memiliki keragaman yang tinggi, dan dalam penelitian ini, digunakan jenis data sekunder. Data sekunder adalah informasi yang diperoleh tidak langsung dari sumber aslinya, melalui pendapat narasumber, wawancara individu atau kelompok, atau

hasil observasi suatu objek, peristiwa, atau eksperimen.


Data yang digunakan dalam penelitian ini diambil dari Kaggle, dimana Guna Venkat Doddi merupakan pemilik data tersebut. Dataset ini mencakup empat kelas yang berbeda, yaitu normal, katarak, retinopati diabetik, dan glaukoma, dengan setiap kelas memiliki 1000 gambar. Oleh karena itu, total dataset terdiri dari 4000 gambar. Untuk melihat contoh data yang digunakan, dapat dilihat pada gambar 1 berikut:



Gambar 1. Sampel Dataset yang digunakan.

3.2. Tahapan Penelitian

Penelitian ini membutuhkan langkah – langkah untuk menjalankan proses pengerjaan dengan baik, sehingga pada penelitian ini dapat menemukan serta menjawab tujuan dari rumusan masalah yang telah dijelaskan. Langkah – langkah penelitian tersebut dapat dijelaskan melalui gambar 2.



Gambar 2. Flowchart (A) Pelatihan, (B) Pengujian

Dalam gambar flowchart tersebut dijelaskan bahwa proses untuk menyelesaikan penelitian dibagi menjadi dua tahap, yakni pelatihan dan pengujian. Tahap pelatihan adalah langkah awal dalam menyelesaikan penelitian yang dimulai dengan pengumpulan data yang dibutuhkan, diikuti dengan memasukkan data pelatihan, melakukan preprocessing dengan menambahkan label pada setiap data dan mengubah ukuran citra, merancang Transfer Learning, dan mengoptimalkan bobot. Sementara itu, tahap berikutnya adalah tahap pengujian, yang melibatkan


proses memasukkan data uji, melakukan preprocessing, menguji Transfer Learning, dan menampilkan hasil klasifikasi menggunakan Transfer Learning dengan menggunakan bobot optimal yang dihasilkan dari tahap pelatihan sebelumnya.

3.3. Pre-Processing

Tahap pre-processing merupakan langkah awal yang dilakukan sebelum memulai proses klasifikasi. Pada tahap ini, tindakan melibatkan pelabelan data dan menyesuaikan ukuran citra untuk menjadikannya simetris. Semakin besar ukuran citra, semakin meningkatkan kompleksitas dalam proses klasifikasi, tetapi pada saat yang sama, ukuran gambar yang lebih besar memiliki dampak signifikan pada tingkat akurasi yang dicapai. Dalam konteks penelitian ini, digunakan ukuran gambar yang lebih kecil, yaitu 128 x 128 piksel, untuk mengevaluasi kemampuan gambar tersebut dalam dikenali atau tidak.

3.4. Pelatihan dan Pengujian Model

Pelatihan model dimulai setelah tahap pre-processing selesai dilakukan dan metode Transfer Learning telah dirancang dengan baik. Untuk flowchart yang akan digunakan akan disajikan dalam Gambar 3.




Gambar 3. Flowchart Pelatihan Model

Dalam gambar flowchart tersebut, dijelaskan bahwa setelah tahap pre-processing, langkah selanjutnya adalah memasukkan data ke dalam model. Proses ini dimulai dengan inisialisasi variabel "train" dan "accuracy". Variabel "train" digunakan untuk menginisialisasi data pelatihan, sedangkan variabel "accuracy" digunakan untuk menginisialisasi data akurasi. Penggunaan modul "tqdm" adalah untuk menampilkan tabel proses dengan perulangan yang sederhana dalam bahasa pemrograman Python. Perulangan ini akan terus berlanjut hingga nilai "e" lebih besar dari nilai epoch atau iterasi yang telah ditentukan. Dalam penelitian ini, akan dilakukan validasi dengan parameter yang akan disesuaikan adalah nilai epoch dan learning rate, serta penggunaan optimasi pada penelitian ini adalah ADAM. Kedua parameter ini akan mempengaruhi persentase akurasi yang diperoleh dalam penelitian ini dengan menggunakan ADAM sebagai optimasi.

Untuk pengujian model tahapan awal adalah menginisialisasi data uji. Langkah selanjutnya adalah menginisialisasi fungsi "predict" yang berguna untuk

menentukan apakah data uji memenuhi kriteria klasifikasi yang sesuai. Kriteria ini awalnya diatur dengan nilai awal yaitu 0, 1, 2 dan 3. Nilai 0 merepresentasikan penyakit katarak, nilai 1 untuk penyakit retinopati diabetik, nilai 2 untuk penyakit glaukoma, dan nilai 3 untuk mata yang normal. Selanjutnya, nilai-nilai ini akan dihubungkan dengan gambar yang sesuai. Hasil dari pengujian tersebut akan ditampilkan pada akhir program. Untuk mengetahui alur dari pengujian model dapat dijelaskan melalui flowchart pada gambar 4.



Gambar 4. Flowchart Pengujian Model

3.5. Skenario Uji Coba

Skenario Uji Coba dilakukan agar mendapatkan hasil yang sesuai dengan target yang akan dicapai, Rincian pengujian yang dilakukan pada penelitian ini adalah :

- Melakukan pengujian menggunakan dataset yang terdiri dari citra penyakit mata seperti katarak, glaukoma, retinopati diabetik, dan mata normal. Jumlah gambar yang digunakan dalam pengujian mencakup 2890 gambar untuk data latih, 510 gambar untuk data validasi, dan 600 gambar untuk data uji.
- Menerapkan model Transfer Learning dengan menambahkan SEBlock ke dalam arsitektur MobileNetV3-Small, dengan parameter uji yang mencakup 20 epoch, batch size 16, learning rate dan weight decay sebesar 0.0001. Pembagian data latih dan validasi dilakukan dengan proporsi 85%, sedangkan data uji sebesar 15%. Optimalisasi dilakukan menggunakan algoritma ADAM, dan fungsi aktivasi yang digunakan adalah Softmax.
- Memberikan arsitektur dan melakukan perhitungan tingkat akurasi pada data latih dan data validasi, lalu menampilkan hasil akhir pada data uji.

4. HASIL DAN PEMBAHASAN

4.1. Implementasi Arsitektur

Pada penelitian ini, digunakan model arsitektur MobileNetV3-Small dengan penerapan teknik squeeze-and-excitation untuk membandingkan akurasi dalam klasifikasi citra mata manusia. Proses pembelajaran model mencakup tahap training dan testing dengan melibatkan 4000 data gambar hasil augmentasi. Pembagian data dilakukan dengan menggunakan 85% dari total data sebagai data train dan validation, sedangkan 15% sisanya sebagai data test. Evaluasi model dilakukan dengan

mempertimbangkan akurasi hasil klasifikasi untuk setiap kelas, seperti mata normal, mata dengan penyakit katarak, mata dengan penyakit retinopati

diabetik, dan mata dengan penyakit glaukoma. Hasil penelitian ini mencakup analisis akurasi dari masing-masing model untuk menilai tingkat keberhasilannya.

Tabel 1. Arsitektur MobileNetV3-Small dengan SEBlock

Layer		Kernel Size	Stride	Padding	Dilation	Activation
Input	Channel (In/Out)					
Conv2dNormActivation	3/16	3x3	(2,2)	(1,1)	-	Hardwish
InvertedResidual	16/16	3x3	(2,2)	(1,1)	-	ReLU
SqueezeExcitation	16/16	1x1	(1,1)	0	-	ReLU
Conv2dNormActivation	16/16	1x1	(1,1)	0	-	ReLU
InvertedResidual	16/72	1x1	(1,1)	0	-	ReLU
Conv2dNormActivation	72/72	3x3	(2,2)	(1,1)	-	ReLU
Conv2dNormActivation	72/24	1x1	(1,1)	0	-	-
InvertedResidual	24/88	1x1	(1,1)	(1,1)	-	ReLU
Conv2dNormActivation	88/88	1x1	(1,1)	(1,1)	-	ReLU
Conv2dNormActivation	88/24	1x1	(1,1)	0	-	-
InvertedResidual	24/96	1x1	(1,1)	0	-	Hardwish
Conv2dNormActivation	96/96	5x5	(2,2)	(2,2)	-	Hardwish
SqueezeExcitation	96/96	1x1	(1,1)	0	-	ReLU
Conv2dNormActivation	96/40	1x1	(1,1)	0	-	-
InvertedResidual	40/240	1x1	(1,1)	(1,1)	-	Hardwish
Conv2dNormActivation	240/240	5x5	(1,1)	(2,2)	-	Hardwish
SqueezeExcitation	240/240	1x1	(1,1)	0	-	ReLU
Conv2dNormActivation	240/40	1x1	(1,1)	0	-	-
InvertedResidual	40/240	1x1	(1,1)	(1,1)	-	Hardwish
Conv2dNormActivation	240/240	5x5	(1,1)	(2,2)	-	Hardwish
SqueezeExcitation	240/240	1x1	(1,1)	0	-	ReLU
Conv2dNormActivation	240/40	1x1	(1,1)	0	-	-
InvertedResidual	40/120	1x1	(1,1)	(1,1)	-	Hardwish
Conv2dNormActivation	120/120	5x5	(1,1)	(2,2)	-	Hardwish
SqueezeExcitation	120/120	1x1	(1,1)	0	-	ReLU
Conv2dNormActivation	120/48	1x1	(1,1)	0	-	-
InvertedResidual	48/144	1x1	(1,1)	(1,1)	-	Hardwish
Conv2dNormActivation	144/144	5x5	(1,1)	(2,2)	-	Hardwish
SqueezeExcitation	144/144	1x1	(1,1)	0	-	ReLU
Conv2dNormActivation	144/48	1x1	(1,1)	0	-	-
InvertedResidual	48/288	1x1	(1,1)	(1,1)	-	Hardwish
Conv2dNormActivation	288/288	5x5	(2,2)	(2,2)	-	Hardwish
SqueezeExcitation	288/288	1x1	(1,1)	0	-	ReLU
Conv2dNormActivation	288/96	1x1	(1,1)	0	-	-
InvertedResidual	96/576	1x1	(1,1)	(1,1)	-	Hardwish
Conv2dNormActivation	576/576	5x5	(1,1)	(2,2)	-	Hardwish
SqueezeExcitation	576/576	1x1	(1,1)	0	-	ReLU
Conv2dNormActivation	576/96	1x1	(1,1)	0	-	-
InvertedResidual	96/576	1x1	(1,1)	(1,1)	-	Hardwish
Conv2dNormActivation	576/576	5x5	(1,1)	(2,2)	-	Hardwish
SqueezeExcitation	576/576	1x1	(1,1)	0	-	ReLU
Conv2dNormActivation	576/96	1x1	(1,1)	0	-	-
Conv2dNormActivation	96/576	1x1	(1,1)	0	-	Hardwish
SEBlock	576/64	1x1	(1,1)	0	-	ReLU
Linear	576/1024	-	-	-	-	Hardwish
Dropout	1024/1024	-	-	-	-	-
Linear	1024/4	-	-	-	-	-

4.2. Pelatihan dan Pengujian Model

Pada tahap ini, model melakukan eksperimen dengan berbagai pengaturan, termasuk jumlah iterasi (epoch) sebanyak 20. Selain itu, komponen-komponen lain dalam training melibatkan pemanfaatan learning rate sebesar 0.0001, weight decay sebesar 0.0001,


batch size sebesar 16, penggunaan fungsi aktivasi softmax, dan optimasi menggunakan ADAM.

```
[ ] time_str = float(sum(times))
print('total waktu {:.3f} s'.format(time_str))
# print(time_str)

total waktu 2702.373 s
```

Gambar 5. Waktu Tempuh Epoch

Dengan merujuk pada gambar 5, dapat dilihat bahwa arsitektur MobileNetV3-Small dalam penelitian ini membutuhkan waktu rata-rata sekitar 45 menit.




Gambar 6. Grafik Akurasi (atas) dan Grafik Loss (bawah)

Pada Gambar 6 menjelaskan bahwa grafik training model menggunakan arsitektur MobileNetV3-Small dengan penambahan modul SEBlock menunjukkan performa yang baik dan stabil selama proses pelatihan. Untuk pengujian model nilai akurasi dapat dicapai dengan cara nilai data yang benar dibagi dengan nilai total data uji lalu dikali 100%, sehingga nilai akurasi dapat ditampilkan dari sebuah model yang dilakukan dalam tahap pengujian.

4.3. Evaluasi Hasil

Pada penelitian ini, penerapan arsitektur MobileNetV3-Small dengan SEBlock menghasilkan kemampuan dalam mengklasifikasikan objek. Keluaran klasifikasi ini berupa citra berukuran 128 x 128 piksel yang telah dilabeli. Citra yang diklasifikasikan dengan benar ditandai dengan label berwarna hijau, sementara citra yang diklasifikasikan secara salah ditandai dengan label berwarna merah, seperti yang tampak pada Gambar 7.



Gambar 7. Hasil Klasifikasi

Pada model arsitektur MobileNetV3-Small dengan SEBlock, untuk hasil pengujian seperti yang ditunjukkan pada Gambar 8, arsitektur dapat membaca 3941 gambar yang terklasifikasi dengan benar dari total 4000 gambar yang diuji. Hanya 59 gambar yang tidak terklasifikasi dengan benar melalui tabel confusion matrix.

	cataract	diabetic_retinopathy	glaucoma	normal
cataract	1.4e+02	0	6	4
diabetic_retinopathy	1	1.5e+02	2	0
glaucoma	6	0	1.2e+02	23
normal	5	0	12	1.3e+02

Gambar 8. Tabel Confusion Matrix

Kemudian dari hasil tabel confusion matrix tersebut, menghasilkan performance metrics yang terdiri dari presisi, akurasi, dan f1-score yang sesuai pada gambar 9, sehingga menghasilkan tingkat akurasi sebesar 90%.

	precision	recall	f1-score
0	0.92	0.93	0.93
1	1.00	0.98	0.99
2	0.86	0.81	0.83
3	0.83	0.89	0.86
accuracy			0.90
macro avg	0.90	0.90	0.90
weighted avg	0.90	0.90	0.90

Gambar 9. Hasil Performance Metrics

F1-Score pada penelitian ini adalah akurasi dari setiap kelas yang dimana pada pelabelan nama kelas terdiri dari 0 yaitu katarak, 1 yaitu retinopati diabetik, 2 yaitu glaukoma, dan 3 adalah mata normal. Untuk nilai akurasi adalah jumlah total dari f1-score yang kemudian dibuat menjadi rata-rata yang kemudian menghasilkan akurasi sebesar 90% pada penelitian ini.

5. KESIMPULAN DAN SARAN

Kesimpulan pada penelitian ini berdasarkan dalam tahap penelitian yang melibatkan 4000 dataset gambar penyakit mata dengan 4 kelas, dapat disimpulkan bahwa arsitektur MobileNetV3-Small dengan SEBlock, menggunakan parameter uji coba seperti 20 epoch, batch size 16, learning rate dan weight decay setinggi 0.0001, serta optimasi dengan ADAM dan fungsi aktivasi Softmax, berhasil mencapai tingkat akurasi sebesar 90% yang didapat melalui pelatihan komputasi dengan waktu 45 menit dengan hasil grafik akurasi dan loss yang stabil sehingga tidak terjadi overfitting ataupun underfitting. Kemudian hasil evaluasi dari pelatihan dan pengujian yang terdiri atas tabel confusion matrix yang membaca dan mencocokkan dataset dengan hasil 3941 data dapat terklasifikasi dan 59 tidak dapat terklasifikasi, kemudian jumlah akurasi sebesar 90% didapat dari perhitungan total f1-score yang kemudian dibuat menjadi rata-rata. Serta saran untuk penelitian ini adalah dengan menambahkan arsitektur lain yang kemudian ditambahkan dengan teknik SEBlock.

DAFTAR PUSTAKA

- [1] M. Oktaviansyah, R. Tamara, dan I. Fitri, "Sistem Pakar Untuk Mendiagnosa Penyakit Mata Menerapkan Metode Certainty Factor dan Forward Chaining," *J. Media Inform. Budidarma*, vol. 6, no. 1, hal. 645, 2022, doi: 10.30865/mib.v6i1.3542.
- [2] F. N. Cahya, N. Hardi, D. Riana, dan S. Hadiyanti, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)," *Sistemasi*, vol. 10, no. 3, hal. 618, 2021, doi: 10.32520/stmsi.v10i3.1248.
- [3] N. F. Adilah dan S. H. Hidayat, "Keparahan penyakit daun keriting kuning dan pertumbuhan populasi kutukebul pada beberapa genotipe cabai," *J. Fitopatol. Indones.*, 2014.
- [4] Gonzalez, R. C. and Woods, dan R. E, "Digital image processing, prentice hall," *Up. Saddle River, NJ*, 2008.
- [5] L. Marifatul Azizah, S. Fadillah Umayah, dan F. Fajar, "Deteksi Kecacatan Permukaan Buah Manggis Menggunakan Metode Deep Learning dengan Konvolusi Multilayer," *Semesta Tek.*, vol. 21, no. 2, hal. 230–236, 2018, doi: 10.18196/st.212229.
- [6] A. N. Sihananto, M. Muharrom, A. Haromainy, A. P. Sari, A. H. Mubarroq, dan D. Ramadhan, "Pemilahan Jenis Sampah Menggunakan Algoritma Cnn," *SCAN J. Teknol. Inf. dan Komun.*, vol. 17, no. 3, 2022.
- [7] F. A. Danendra, F. T. Anggraeny, dan H. Maulana, "Klasifikasi Citra Penyakit Daun Cabai Rawit Dengan Menggunakan CNN Arsitektur AlexNet dan SqueezeNet," vol. 12, no. 01, hal. 50–61, 2023.
- [8] J. McCarthy, "What Is Artificial Intelligence?," *Am. Sci.*, vol. 73, no. 3, hal. 258, 2007.
- [9] S. Berhil, H. Benlahmar, dan N. Labani, "A review paper on artificial intelligence at the service of human resources management," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 18, no. 1, hal. 32–40, 2019, doi: 10.11591/ijeecs.v18.i1.pp32-40.
- [10] K. Zhang, Y. Yamamoto, dan Schuller Björn, "Artificial Intelligence Internet of Things for the Elderly," hal. 78–88, 2021.
- [11] G. Ashari Rakhmat dan M. Fikri Haekal, "Peningkatan Performa MobilenetV3 dengan Squeeze-and-Excitation (Studi Kasus Klasifikasi Kesegaran Ikan Berdasarkan Mata Ikan)," *J. MIND J. | ISSN*, vol. 8, no. 1, hal. 27–41, 2023, [Daring]. Tersedia pada: <https://doi.org/10.26760/mindjournal.v8i1.27-41>
- [12] A. Howard, W. Wang, G. Chu, L. Chen, B. Chen, dan M. Tan, "Searching for MobileNetV3 Accuracy vs MADDs vs model size," *Int. Conf. Comput. Vis.*, hal. 1314–1324, 2019.
- [13] J. Hu, L. Shen, S. Albanie, G. Sun, dan E. Wu, "Squeeze-and-Excitation Networks," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 42, no. 8, hal. 2011–2023, 2020, doi: 10.1109/TPAMI.2019.2913372.