

Implementasi Metode Convolutional Neural Network (CNN) berbasis Internet Of Things untuk Klasifikasi Hama Tanaman pada Daun Anggur

Raraisa Prayunda Fakultas
Ilmu Komputer Universitas
Sriwijaya
Sumatera Selatan, Indonesia

Ahmad Zarkasi Fakultas
Ilmu Komputer
Universitas Sriwijaya
Sumatera Selatan, Indonesia

Abstract- Penelitian ini mengatasi tantangan utama dalam sektor pertanian, khususnya peningkatan permintaan pangan dan dampak perubahan iklim, dengan fokus pada deteksi dini hama tanaman untuk mencegah gagal panen. Penelitian ini bertujuan untuk mengklasifikasikan hama pada tanaman anggur menggunakan metode Convolutional Neural Network (CNN). Metodologi penelitian melibatkan penggunaan Grape Dataset yang berisi 9.207 citra daun anggur dari empat kategori: Black Rot, Esca, Leaf Blight, dan Healthy. Proses pra-pemrosesan data meliputi resize gambar menjadi 180x180 piksel, konversi RGB ke grayscale, filtering, cropping, thresholding, dan segmentation untuk memfokuskan analisis pada area daun yang relevan. Model CNN dirancang dengan tiga lapisan konvolusi (32, 64, 128 filter) dan memiliki total 13.201.732 parameter. Hasil penelitian menunjukkan bahwa model mencapai akurasi validasi sebesar 97,85% dengan loss yang stabil sekitar 0,14 pada epoch akhir. Precision, recall, dan F1-score untuk setiap kelas mencapai $\geq 0,98$, dengan 1,00 untuk kelas Esca dan Healthy. Ini membuktikan efektivitas CNN dalam mengklasifikasikan kondisi daun anggur dengan akurasi dan generalisasi yang sangat baik, tanpa overfitting yang signifikan.

Kata Kunci: Convolutional Neural Network (CNN), Klasifikasi Hama, Daun Anggur, Internet of Things (IoT), Pengendalian Hama.

I. Latar Belakang

Dalam beberapa tahun terakhir, sektor pertanian menghadapi sejumlah tantangan utama, seperti peningkatan permintaan pangan yang dipicu oleh pertumbuhan populasi dunia, perubahan iklim yang memengaruhi kondisi cuaca dan kesuburan tanah, serta keterbatasan akan sumber daya alam, seperti air dan lahan pertanian[1]. Pertanian merupakan sumber pendapatan utama bagi banyak negara. Penyakit pada tanaman menjadi penyebab utama penurunan jumlah dan kualitas hasil panen, maka mendeteksi penyakit tanaman sangatlah penting. Tanda-tanda penyakit dapat muncul di berbagai bagian tanaman, oleh karena itu daun tanaman biasanya digunakan sebagai bahan untuk mendiagnosis penyakit tersebut[2]. Untuk mengatasi masalah-masalah ini, dibutuhkan inovasi dalam teknologi pertanian. Salah

satu pendekatan yang dapat diambil adalah penerapan Internet of Things (IoT)[3]. IoT dipilih sebagai dasar penelitian ini karena kemampuannya dalam memberikan solusi otomatisasi yang dapat diandalkan, khususnya dalam menangani masalah serangan hama[4].

Hama merupakan hewan perusak tanaman yang dapat mengurangi hasil panen dan merugikan manusia sehingga kehadirannya perlu dikendalikan[5]. Pengendalian hama pada tanaman merupakan hal yang sangat penting demi meningkatkan produksi pangan dan menjaga kelangsungan hidup perekonomian[6]. dengan melakukan Pemantauan secara real-time serta peringatan dini terhadap hama yang menyerang tanaman daun anggur melalui Internet of Things (IoT) di bidang pertanian, membantu meningkatkan keakuratan informasi peringatan dini dan memudahkan dalam melakukan pengelolaan secara tepat waktu[7].

Berdasarkan dari masalah tersebut, penelitian ini berfokus pada klasifikasi hama pada tanaman untuk mengidentifikasi tanaman yang terkena hama[8]. Sebab antara metode tersebut, metode yang menggunakan Convolutional Neural Network (CNN) telah menunjukkan hasil yang baik dalam mendeteksi dan mengklasifikasi hama[9]. Maka dari itu penelitian ini bertujuan untuk mencegah gagal panen yang disebabkan oleh tanaman daun anggur yang sering terserang hama terutama pada daun anggur dengan memanfaatkan metode CNN maka menjadikan daun anggur tersebut menjadi data gambar yang akan diolah menjadi citra nantinya akan di proses dan dilakukan klasifikasi, dengan metode yang sama yakni Convolutional Neural Network (CNN)[10].

II. Metodologi penelitian

A. Sumber Data

Dataset yang akan digunakan pada penelitian ini adalah Grape Dataset. Dataset ini dapat diakses dan dapat di download pada website <https://www.kaggle.com/datasets/khalil18/grape-dataset> dengan format file CSV. Dataset ini terdiri dari 9.207 citra daun anggur yang terbagi merata ke dalam empat kategori penyakit atau kondisi: Black Rot, Esca, Leaf Blight, dan Healthy. Setiap kategori selanjutnya dibagi menjadi tiga subset data train, validasi, dan testing untuk mendukung proses pembelajaran, penyetelan, dan evaluasi model.

B. Convolutional Neural Network (CNN)

CNN adalah jaringan saraf tiruan khusus untuk pengolahan citra dan visi komputer yang memanfaatkan lapisan konvolusi untuk mengekstrak fitur penting secara otomatis dari gambar, sehingga terbukti sangat efektif untuk klasifikasi gambar, pengelompokan, dan deteksi objek[11].

CNN terdiri dari tiga komponen utama, yaitu convolutional layer, pooling layer, dan fully connected layer [12]. Dalam paradigma arsitektur ini, convolutional layers memiliki peran untuk mengekstrak fitur spasial yang kompleks dari data asli[13]. Berikutnya, pooling layer berfungsi untuk mengurangi jumlah parameter serta tingkat kompleksitas komputasi dengan menurunkan dimensi dari data yang diproses[14]. Dan fully connected layer berhasil menyatukan fitur yang telah diekstraksi untuk melakukan tugas tertentu, seperti klasifikasi atau regresi[15].

C. Perancangan

Sistem yang digunakan pada penelitian ini menggunakan algoritma Convolution Neural Network untuk mendeteksi serangan hama pada daun anggur. Bahasa program yang digunakan adalah python. Untuk mengeksekusi kode python tersebut dengan menggunakan jupyter notebook. Berikut adalah flowchart proses perancangan sistem pada




Figure 1 Arsiktur Perancangan

1. Input Data

Proses penginputan data gambar, data yang digunakan dalam melakukan penelitian adalah dataset yang berisi 9.023 gambar daun anggur yang dibagi menjadi tiga bagian: Test (182 gambar), Train (7.218 gambar), dan Validation (1.623 gambar). Pada subset Test, setiap kelas memiliki 48 gambar untuk Black Rot dan Esca, serta 43 gambar untuk Healthy dan Leaf Blight. sSubset Train memiliki distribusi gambar yang hampir seimbang, yaitu 1.887 gambar Black Rot, 1.919 gambar Esca (Black Measles), 1.691 gambar Healthy,

dan 1.721 gambar Leaf Blight. Subset Validation terdiri dari 424 gambar Black Rot, 432 gambar Esca, 380 gambar Healthy, dan 387 gambar Leaf Blight. Dengan distribusi yang cukup merata di setiap kelas dan bagian, model CNN dapat dilatih dan diuji secara adil untuk mengukur kemampuannya dalam memprediksi data yang belum pernah dilihat sebelumnya.

2. Resize

Tahap resize bertujuan untuk mengatur ukuran semua gambar menjadi bentuk yang sama, sehingga proses komputasi, seperti ekstraksi fitur dan inferensi pada CNN, dapat berjalan lebih cepat dan lebih konsisten. Dalam penelitian ini, setiap gambar diubah ukurannya menjadi 180×180 piksel. Dengan langkah ini, dimensi tensor input menjadi (180, 180, 3). Konversi dari RGB ke grayscale memungkinkan proses pengolahan batch yang lebih efisien dan mengurangi beban memori tanpa mengorbankan detail tekstur penting pada daun anggur[16].




Figure 2 Resize

3. RGB to Grayscale

Tahapan yang dilakukan yaitu proses RGB (Red, Green dan Blue) menjadi grayscale. Citra RGB terdiri dari tiga saluran utama yang membentuk warna pada gambar digital: merah, hijau, dan biru. Ketika gambar berwarna diubah menjadi gambar keabuan (grayscale), hanya informasi kecerahan (lightness) yang dipertahankan, sedangkan informasi warna (hue) dan kejenuhan (chroma) hilang[17].




Figure 3 RGB to Grayscale

4. Filtering

Pada tahap filtering menggunakan Gaussian blur, variasi kecerahan diurangi dan noise di latar belakang dihaluskan, tetapi struktur utama daun dan bercak tetap

terjaga. Dengan mengurangi gangguan kecil pada piksel, proses penyaringan membantu menyoroti fitur penting, yaitu pola bercak dan bentuk daun, sebagai persiapan yang baik untuk langkah berikutnya seperti thresholding dan segmentasi.



5. Copping


Tahap ini dilakukan mendeteksi kontur terbesar (daun) pada mask hasil segmentasi, kemudian membuat bounding box di sekitar kontur tersebut dengan sedikit ruang tambahan agar seluruh tepi daun termasuk dalam area tersebut. Dengan cara ini, bagian latar belakang yang tidak penting dihilangkan, sehingga model hanya menerima area yang berisi daun, yang membuat proses komputasi lebih cepat dan meningkatkan akurasi ekstraksi fitur berikutnya.



Figure 5 Copping

6. Thresholding

Thresholding adalah proses yang digunakan untuk membuat citra biner dari citra grayscale atau warna. Proses ini bekerja dengan menetapkan nilai piksel menjadi 0 atau 1 berdasarkan nilai ambang batas yang ditentukan. Dalam matriks thresholding, kolom yang memiliki nilai 1 akan ditampilkan sebagai warna putih, sedangkan kolom dengan nilai 0 akan ditampilkan sebagai warna hitam. Hasil dari proses thresholding ini digunakan sebagai masukan untuk tahap berikutnya. Citra biner yang dihasilkan didasarkan pada nilai ambang batas yang dipilih, yang juga menentukan bagaimana nilai piksel dalam citra tersebut diubah[18].



7. Segmentasi

Pada tahap ini, hasil segmentasi menunjukkan seluruh area daun beserta bercak penyakit tetap terlihat, sedangkan latar belakang diubah menjadi hitam. Dengan demikian, hanya piksel daun yang memiliki detail bercak yang tampil, sedangkan piksel latar belakang disetel menjadi nol, sehingga memudahkan model CNN untuk berfokus pada area yang terkena penyakit tanpa terganggu oleh latar belakang.



Figure 7 Segmentasi

III. Hasil dan Pembahasan

A. Data Gambar 1. Black Rot

Jenis penyakit black rot adalah penyakit jamur yang ditandai dengan bercak coklat kehitaman yang berbentuk bulat dan oval pada daun anggur, dengan disertai pinggiran yang lebih gelap dan bagian tengah daun terkadang cekung dan ditutupi spora keabu-abuan hingga oranye.



Figure 8 Dataset Black Rot

2. Esca (Black Measles)

Jenis penyakit Esca atau dikenal juga black measles adalah penyakit yang ditandai dengan bercak kecil hingga sedang berwarna coklat tua hingga hitam pada permukaan atas daun. Bercak ini dapat menyatu membentuk area nekrotik lebih luas, membuat daun tampak berbintik lalu mengering dan menggugur.



Figure 9 Dataset Esca (Black Measles)

3. Healthy

Healthy pada daun anggur menunjukkan permukaan yang hijau merata tanpa bercak, nekrosis dan perubahan warna yang mencolok, pada tepi daun permukaan yang utuh tanpa lubang atau kerutan.



Figure 10 Dataset Healthy

4. Leaf Blight

Jenis penyakit leaf blight ini merupakan penyakit yang timbul dengan tanda-tanda pada daun dengan warna coklat dan nekrosis jaringan daun yang dimulai dari tengah



Figure 11 Dataset Leaf Blight

B. Proses Model CNN

Model CNN dirancang untuk mengklasifikasikan gambar dengan ukuran 180x180 piksel dan 3 saluran warna (RGB). Model ini memiliki tiga lapisan Conv2D secara berurutan, dengan jumlah filter masing-masing sebanyak 32, 64, dan 128. Setiap lapisan Conv2D diikuti oleh lapisan MaxPooling2D untuk mengurangi ukuran dimensi spasial.

Model: "sequential"

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 178, 178, 32)	896
max_pooling2d (MaxPooling2D)	(None, 89, 89, 32)	0
conv2d_1 (Conv2D)	(None, 87, 87, 64)	18496
max_pooling2d_1 (MaxPooling2D)	(None, 43, 43, 64)	0
conv2d_2 (Conv2D)	(None, 41, 41, 128)	73856
max_pooling2d_2 (MaxPooling2D)	(None, 20, 20, 128)	0
flatten (Flatten)	(None, 51200)	0
dense (Dense)	(None, 256)	13107456
dense_1 (Dense)	(None, 4)	1028

Total params: 13,201,732
 Trainable params: 13,201,732
 Non-trainable params: 0

Figure 12 Model CNN

Figure 12. menunjukkan susunan model CNN bertipe Sequential yang terdiri dari tiga lapisan Conv2D dengan masing-masing 32, 64, dan 128 filter. Selanjutnya, vektor tersebut diproses oleh lapisan Dense yang memiliki 256 neuron, lalu diarahkan ke lapisan output Dense dengan 4 neuron sesuai jumlah kelas yang ada, menggunakan fungsi aktivasi softmax. Model ini memiliki total parameter sebanyak 13. 201.732, menunjukkan bahwa model ini cukup rumit dan mampu melakukan klasifikasi citra dengan beberapa kelas secara efektif.

C. Hasil Training dan Validasi

Table 1 Hasil Epoch

Epoch	Train Loss	Train Accuracy	Val Loss	Val Accuracy
1	56.1622	66.26%	0.1775	94.77%
2	0.2037	93.45%	0.1852	93.23%

3	0.0607	98.31%	0.1130	96.31%
4	0.0428	98.38%	0.3713	86.77%
5	0.2363	92.84%	0.2089	92.31%
46	5.4909e-06	100.00%	0.1380	97.54%
47	5.0810e-06	100.00%	0.1389	97.85%
48	4.8972e-06	100.00%	0.1399	97.54%
49	4.8477e-06	100.00%	0.1396	97.85%

Tabel 1 menunjukkan hasil training dan validasi model CNN pada beberapa epoch penting. Pada awal pelatihan, yaitu pada epoch 1 sampai 5, model dengan cepat meningkatkan akurasi dari 66,26% menjadi lebih dari 98%, meskipun terjadi sedikit naik turun pada loss validasi dan akurasi (misalnya di epoch 4). Hal ini menunjukkan bahwa model sedang menyesuaikan diri dengan data. Pada epoch 46 sampai 50, model mencapai akurasi 100% pada data pelatihan dan stabil pada rentang 97,5% hingga 97,85% pada data validasi, dengan loss yang sangat rendah. Hal ini menunjukkan bahwa model sudah belajar dengan baik dan mampu menggeneralisasi ke data validasi secara konsisten, tanpa adanya overfitting yang signifikan.

D. Nilai Loss dan Accuracy





Figure 13 Loss

Figure 13. terlihat penurunan tajam pada loss training di awal epoch, dari nilai yang sangat tinggi menjadi mendekati nol dalam beberapa iterasi pertama,

yang menunjukkan bahwa model dengan cepat menyesuaikan bobotnya untuk mengurangi kesalahan prediksi pada data latih. Setelah itu, loss training dan loss validasi tetap stabil di sekitar nol hingga epoch ke 50, dengan *validasi loss* sedikit lebih tinggi dari *training loss*, menunjukkan model memiliki kemampuan generalisasi yang baik tanpa tanda-tanda overfitting yang jelas. Kejelasan dan konsistensi kedua kurva loss pada epoch berikutnya menegaskan bahwa model telah mencapai konvergensi yang baik dan tetap mempertahankan performa yang stabil pada data yang belum pernah dilihat selama proses validasi.



mengalami peningkatan cepat: akurasi pelatihan naik dari 0.66 ke hampir 1.0, sementara akurasi validasi turun ke 0.87 lalu segera naik lagi. Mulai dari epoch ke 5, kedua kurva stabil di atas 0.95, dengan akurasi pelatihan hampir mencapai 1.00 dan akurasi validasi berfluktuasi sedikit antara 0.96 hingga 0.98 hingga epoch ke 50. Pola ini menunjukkan bahwa model belajar dengan cepat dan mampu mempertahankan kemampuan generalisasi yang baik. Tingginya akurasi pelatihan tanpa penurunan signifikan pada akurasi validasi menunjukkan bahwa model tidak mengalami overfitting berlebihan, serta kinerja klasifikasi tetap konsisten pada data baru yang belum pernah dilihat sebelumnya.

E. Classification Report & Confusion Matrix

Tabel 2 menampilkan ringkasan lengkap dari metrik evaluasi model klasifikasi CNN. Terdapat precision, recall, dan f1-score untuk setiap kelas, serta jumlah data (support) pada masing-masing kelas. Precision mengukur seberapa tepat prediksi model dalam mengklasifikasikan data ke kelas yang benar. Recall mengukur seberapa baik model dapat menemukan semua data yang sebenarnya termasuk dalam kelas tersebut. F1-score adalah rata-rata harmonis dari precision dan recall.

Dengan menambahkan `target_names=classes`, hasil laporan menjadi lebih jelas dan informatif karena menampilkan nama kelas secara langsung, bukan hanya angka indeks saja.

Table 2 Hasil Klasifikasi

Class	Precision	Recall	F1-Score	Support
Black Rot	0.99	0.98	0.98	89
Esca (Black Measles)	1.00	1.00	1.00	95
Healthy	1.00	1.00	1.00	61
Leaf Blight	0.98	0.99	0.98	80

Secara umum, hasil laporan menunjukkan bahwa model CNN memiliki performa yang sangat baik dalam mengklasifikasikan keempat jenis penyakit daun anggur. Semua kelas memiliki nilai precision, recall, dan f1-score yang sangat tinggi, yaitu di atas 0.98, bahkan mencapai 1.00 pada kelas Esca (Black Measles) dan Healthy, yang artinya model mampu memprediksi dengan benar dan konsisten tanpa kesalahan pada kedua kelas tersebut. Nilai support menunjukkan jumlah sampel yang digunakan untuk setiap kelas, dan secara keseluruhan hasil ini menunjukkan bahwa model memiliki tingkat akurasi dan kemampuan generalisasi yang sangat baik terhadap data uji.

Figure 15. menunjukkan confusion matrix model CNN terhadap empat kelas, yaitu Black Rot, Esca (Black Measles), Healthy, dan Leaf Blight. Hasilnya terlihat sangat baik, karena nilai pada diagonal tergolong tinggi, seperti 87 dari 89 untuk kelas Black Rot, 95 dari 95 untuk Esca, dan 61 dari 61 untuk Healthy. Terdapat sedikit kesalahan, misalnya Black Rot terkadang diprediksi sebagai Leaf Blight sebanyak dua kali, dan Leaf Blight sekali diklasifikasikan sebagai Black Rot. Secara umum, confusion matrix ini menunjukkan bahwa model mampu mengklasifikasikan data dengan akurasi dan presisi yang sangat baik.

IV. Kesimpulan dan Saran


Berdasarkan hasil analisis penelitian ini, disimpulkan bahwa metode Convolutional Neural Network (CNN) dengan proses pra-pemrosesan berupa resize ukuran 180×180 , konversi ke skala abu-abu, filtering, pembatasan area daun (ROI), thresholding, dan segmentasi berhasil mengklasifikasikan empat kondisi daun anggur yaitu Black Rot, Esca (Black Measles), Leaf Blight, dan Healthy secara sangat baik.

Model yang menggunakan tiga blok konvolusi dengan jumlah filter 32–64–128, diakhiri lapisan Flatten dan Dense, menunjukkan akurasi validasi sebesar 97,85% dan loss tetap stabil sekitar 0,14 pada epoch akhir. Selain itu, nilai precision, recall, dan F1 score masing-masing mencapai $\geq 0,98$ untuk setiap kelas. Hal ini menunjukkan bahwa meskipun hanya menggunakan satu kanal skala abu-abu, model mampu menangkap pola bercak penyakit secara konsisten dan menghasilkan performa klasifikasi yang dapat diandalkan.

Selanjutnya, penelitian ini disarankan untuk dikembangkan dengan menerapkan teknik augmentasi gambar yang lebih beragam, seperti rotasi, flip, perubahan kontras, serta menjelajahi pendekatan transfer learning seperti MobileNetV2 atau EfficientNet agar model dapat lebih tahan terhadap perubahan kondisi di lapangan.

References

- [1] A. Maulana and N. Latifah Dwi Mutiara Sari, "Literatur Review Implementasi Artificial Intelligence dalam Pertanian," *Seminar Nasional Informatika-FTI UPGRIS*, vol. 2, 2024.
- [2] S. M. Javidan, A. Banakar, K. A. Vakilian, and Y. Ampatzidis, "Diagnosis of grape leaf diseases using automatic K-means clustering and machine learning," *Smart Agricultural Technology*, vol. 3, Feb. 2023, doi: 10.1016/j.atech.2022.100081.
- [3] J. Tika, "KLASIFIKASI PENYAKIT PADA SAWI PAKCOY DENGAN MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK



- (CNN),” *Jurnal TIKFA Fakultas Ilmu Komputer Universitas Almuslim*, vol. 9, no. 2, [Online]. Available: <http://www.journal.umuslim.ac.id/index.php/tikfa/index>
- [4] P. Rajak, A. Ganguly, S. Adhikary, and S. Bhattacharya, “Internet of Things and smart sensors in agriculture: Scopes and challenges,” *J Agric Food Res*, vol. 14, Dec. 2023, doi: 10.1016/j.jafr.2023.100776.
- [5] W. Astuti and C. Rini Widyastuti, “PESTISIDA ORGANIK RAMAH LINGKUNGAN PEMBASMI HAMA TANAMAN SAYUR.”
- [6] L. Zachmann, L. Christen, and R. Finger, “Location matters: A geospatial analysis of fungus-resistant grapes in Switzerland,” *Agric Syst*, vol. 229, Oct. 2025, doi: 10.1016/j.agsy.2025.104422.
- [7] B. Cao, P. Zhou, W. Chen, H. Wang, and S. Liu, “Real-time Monitoring and Early Warning of Cotton Diseases and Pests Based on Agricultural Internet of Things,” in *Procedia Computer Science*, Elsevier B.V., 2024, pp. 253–260. doi: 10.1016/j.procs.2024.09.032.
- [8] R. M. Wahid, G. Santoso, S. Hani, A. Hamzah, S. Raharjo, and E. Setyaningsih, “SISTEM PENGENDALI HAMA PADA TANAMAN PADI BERBASIS IoT MENGGUNAKAN TENAGA SURYA PADA MASYARAKAT DESA WUKIRSARI,” 2023.
- [9] D. Jin, H. Yin, and Y. H. Gu, “Shuffle-PG: Lightweight feature extraction model for retrieving images of plant diseases and pests with deep metric learning,” *Alexandria Engineering Journal*, vol. 113, pp. 138–149, Feb. 2025, doi: 10.1016/j.aej.2024.11.052.
- [10] A. D. Nurcahyati, R. Makhfuddin Akbar, and S. Zahara, “Terbit online pada laman web jurnal: <http://ejurnal.unim.ac.id/index.php/submit> SUBMIT (Jurnal Ilmiah Teknologi Informasi dan Sains) KLASIFIKASI CITRA PENYAKIT PADA DAUN JAGUNG MENGGUNAKAN DEEP LEARNING DENGAN METODE CONVOLUTION NEURAL NETWORK (CNN),” vol. 2, no. 2, pp. 43–51, 2022, [Online]. Available: <http://ejurnal.unim.ac.id/index.php/submit>
- [11] L. Nanni, A. Lumini, L. Barcellona, and S. Ghidoni, “Convolutional neural networks and vision transformers for Plankton Classification,” *Ecol Inform*, vol. 90, p. 103272, Dec. 2025, doi: 10.1016/j.ecoinf.2025.103272.
- [12] L. Alzubaidi *et al.*, “Review of deep learning: concepts, CNN architectures, challenges, applications, future directions,” *J Big Data*, vol. 8, no. 1, Dec. 2021, doi: 10.1186/s40537-021-00444-8.
- [13] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks.” [Online]. Available: <http://code.google.com/p/cuda-convnet/>
- [14] H. Gholamalinezhad and H. Khosravi, “Pooling Methods in Deep Neural Networks, a Review.”
- [15] P. Ramachandran, B. Zoph, and Q. V. Le, “Searching for Activation Functions,” Oct. 2017, [Online]. Available: <http://arxiv.org/abs/1710.05941>
- [16] RAHMA SHINTA, “KLASIFIKASI CITRA PENYAKIT DAUN TANAMAN PADI MENGGUNAKAN CNN DENGAN ARSITEKTUR VGG-19”.
- [17] S. Akram, H. Alrubaie, and A. H. Hameed, “Dynamic Weights Equations for Converting Grayscale Image to RGB Image.”
- [18] A. Hibatullah and I. Maliki, “PENERAPAN METODE CONVOLUTIONAL NEURAL NETWORK PADA PENGENALAN POLA CITRA SANDI RUMPUT.”