

Klasifikasi Penyakit Tanaman Padi Berdasarkan Kondisi Daun Menggunakan *Compact Convolutional Transformers*

Hestin Nurdiana¹, Novi Lestari², Rusdiyanto³, Ahmad Sobri⁴

^{1,2,3,4} Program Studi Informatika, Universitas Bina Insan
E-mail : hestindiana36@gmail.com¹

Abstrak

Padi (*Oryza sativa*) adalah salah satu tanaman pangan utama di dunia karena berperan sebagai sumber makanan pokok bagi sebagian besar masyarakat di berbagai negara, termasuk Indonesia.. Produktivitas padi yang optimal dipengaruhi oleh kondisi kesehatan tanaman, terutama bagian daun yang rentan terhadap berbagai penyakit. Penyakit yang menyerang daun tanaman padi dapat menyebabkan penurunan hasil panen secara signifikan, sehingga deteksi dini dan pengelolaan penyakit menjadi hal yang sangat krusial bagi para petani. Metode berbasis *deep learning* seperti *Convolutional Neural Networks (CNNs)* telah menunjukkan performa yang sangat baik dalam pengenalan pola gambar, termasuk dalam klasifikasi penyakit tanaman berdasarkan citra daun. Salah satu pengembangan terbaru dalam hal ini adalah *Compact Convolutional Transformers (CCT)*, yang menggabungkan kelebihan CNN dalam menangkap fitur lokal dengan kemampuan *Transformers* dalam memahami hubungan global antar fitur gambar. Metode *Compact Convolutional Transformers (CCT)* akan diterapkan untuk klasifikasi penyakit tanaman padi berdasarkan citra daun. Penelitian ini mengklasifikasikan empat kategori, yaitu Normal, *Leaf smut*, *Brown spot*, dan *Bacterial leaf blight*. Dengan adanya teknologi ini, diharapkan mampu membantu petani dalam mendeteksi penyakit padi secara otomatis dan lebih cepat, Sehingga dapat meningkatkan hasil produksi serta mutu panen. Penelitian ini menghasilkan model yang handal terbukti akurasi yang didapat mencapai 94% dengan loss yang rendah.

Kata kunci : *Compact Convolutional Transformers (CCT)*, *Deep Learning*, Pengolahan Citra

Classification of Rice Plant Diseases Based on Leaf Conditions Using *Compact Convolutional Transformers*

Abstract

Rice (*Oryza sativa*) is one of the world's main food crops as it serves as a staple food source for the majority of people in various countries, including Indonesia. Optimal rice productivity is highly dependent on plant health, particularly the condition of the leaves, which are susceptible to various diseases. Diseases affecting rice leaves can significantly reduce yields, making early detection and disease management crucial for farmers. Deep learning methods, such as *Convolutional Neural Networks (CNNs)*, have demonstrated excellent performance in image pattern recognition, including plant disease classification based on leaf imagery. One of the latest advancements in this field is *Compact Convolutional Transformers (CCT)*, which combine the strengths of CNNs in capturing local features with the ability of *Transformers* to understand global relationships between image features. The *Compact Convolutional Transformers (CCT)* method will be applied to classify rice plant diseases based on leaf images. This study classifies four categories, namely Normal, *Leaf smut*, *Brown spot*, and *Bacterial leaf blight*. This technology is expected to assist farmers in detecting rice diseases automatically and more rapidly, ultimately enhancing productivity and harvest quality. The study has resulted in a reliable model, achieving an accuracy of 94% with a low loss.

Keywords : *Compact Convolutional Transformers (CCT)*, *Deep Learning*, Image Processing

1. Pendahuluan

Padi (*Oryza sativa*) merupakan salah satu tanaman pangan paling penting di dunia karena menjadi sumber utama makanan pokok bagi sebagian besar penduduk di berbagai negara, termasuk Indonesia [1]. Produktivitas padi yang optimal sangat dipengaruhi oleh kondisi kesehatan tanaman, terutama bagian daun yang rentan terhadap berbagai penyakit. Penyakit yang menyerang daun tanaman padi dapat menyebabkan penurunan hasil panen secara signifikan, sehingga deteksi dini dan pengelolaan penyakit menjadi hal yang sangat krusial bagi para petani [2]. Namun, mendeteksi penyakit pada tanaman padi secara manual merupakan tugas yang cukup sulit dan memerlukan keahlian khusus, hal ini karena beberapa jenis penyakit dapat memiliki gejala yang mirip satu sama lain [3]. Penyakit yang sering menyerang tanaman padi sehingga berpengaruh pada hasil panen dan dapat dilihat berdasarkan kondisi daunnya adalah *Leaf smut*, *Brown spot*, dan *Bacterial leaf blight* sehingga, teknologi berbasis kecerdasan buatan (*Artificial Intelligence, AI*) telah banyak digunakan dalam bidang pertanian untuk membantu mengidentifikasi dan mengklasifikasikan penyakit tanaman secara lebih akurat dan efisien [4], [5].

Metode berbasis *deep learning* seperti *Convolutional Neural Networks* (CNNs) telah menunjukkan performa yang sangat baik dalam pengenalan pola gambar, termasuk dalam klasifikasi penyakit tanaman berdasarkan citra daun seperti pada penelitian yang dilakukan oleh M. Pratama, et.al [6] untuk penyakit daun pisang dan penelitian dari S. Suhendar, et.al [2] untuk mengklasifikasi 2 penyakit pada daun padi. Namun, perkembangan lebih lanjut dalam arsitektur model pembelajaran mesin seperti *Transformers*, yang pada awalnya digunakan dalam bidang pemrosesan bahasa alami, telah membawa potensi baru dalam tugas pengenalan citra seperti pada penelitian K. N. Narahima Prasad, et.al [7] yang menggunakan teknik *transformer* dan *deep neural network* (DNN) untuk memprediksi penyakit tanaman padi berdasarkan daunnya.

Salah satu pengembangan terbaru dalam hal ini adalah *Compact Convolutional Transformers* (CCT), yang menggabungkan kelebihan CNN dalam menangkap fitur lokal dengan kemampuan *Transformers* dalam memahami hubungan global antar fitur gambar. Metode *Compact Convolutional Transformers* (CCT) akan diterapkan untuk klasifikasi penyakit tanaman padi berdasarkan citra daun. Penelitian ini akan mengklasifikasikan empat kategori utama yang umum dijumpai pada tanaman padi, yaitu Normal, *Leaf smut*, *Brown spot*, dan *Bacterial leaf blight*. Dengan adanya teknologi ini, diharapkan mampu membantu petani dalam mendeteksi penyakit padi secara otomatis dan lebih cepat, yang pada akhirnya dapat meningkatkan produktivitas dan kualitas panen. Model kecerdasan buatan yang penulis buat untuk mendeteksi penyakit dalam tanaman padi adalah dengan mengambil gambar citra daun dari tanaman padi untuk kemudian model akan melakukan klasifikasi secara otomatis kondisi daun tersebut.

Berdasarkan latar belakang dan permasalahan yang sudah penulis uraikan sebelumnya maka diperlukan sebuah solusi untuk mengatasi kesalahan dalam mengenali penyakit tanaman padi oleh karena itu dengan adanya klasifikasi otomatis menggunakan model *Compact Convolutional Transformers*, diharapkan deteksi penyakit padi dapat dilakukan secara lebih cepat dan akurat, sehingga membantu dalam pengelolaan penyakit di lapangan sehingga peneliti akan mengambil penelitian ini dengan judul “Klasifikasi Penyakit Tanaman Padi Berdasarkan Kondisi Daun Menggunakan *Compact Convolutional Transformers*”. Adapun tujuan penelitian ini adalah untuk mempermudah petani dalam mengidentifikasi penyakit tanaman padi berdasarkan citra daunnya dan memberikan kontribusi dalam bidang ilmu pengolahan citra untuk klasifikasi penyakit tanaman padi berdasarkan citra daun menggunakan *Compact Convolutional Transformers*.

2. Metodologi


Rancangan penelitian digunakan untuk menjelaskan serta menguraikan setiap tahapan permasalahan yang terdapat dalam penelitian. Rancangan penelitian dapat dilihat pada Gambar 1.

2.1 Metode Pengumpulan Data

Untuk memperoleh data yang akurat, relevan, dan valid, peneliti mengumpulkan data melalui metode berikut:

1. Metode Pengaman (Observasi)


Penulis melakukan pengamatan langsung pada tanaman padi untuk mengambil data yang akan menjadi data uji pada model yang akan dibuat.



Gambar 1. Rancangan Penelitian

2. Metode Dokumentasi

Penelitian ini menggunakan metode dokumentasi sebagai sarana untuk mengumpulkan berbagai data gambar daun padi dalam dataset yang akan digunakan sebagai data latih untuk model CCT dan data uji model CCT, dengan jumlah keseluruhan dataset adalah 4664 gambar. Dataset dalam penelitian ini diambil dari data citra daun padi pada website Kaggle (<https://www.kaggle.com/datasets/vbookshelf/rice-leaf-diseases>). Dataset ini terdiri dari 3 kelas yaitu *Leaf smut*, *Brown spot*, dan *Bacterial leaf blight*. Beberapa sampel citra dari dataset daun padi dapat dilihat pada Gambar 2.



Gambar 2. Dataset Citra Daun Padi

2.2 Deep Learning

Deep Learning (Pembelajaran Dalam) merupakan salah satu cabang dari *Machine Learning* (pembelajaran mesin) yang memanfaatkan algoritma untuk membentuk model abstraksi tingkat tinggi dari data melalui sejumlah fungsi transformasi non-linear yang tersusun secara berlapis dan mendalam [8]. *Deep Learning* beroperasi berdasarkan struktur jaringan serta prosedur optimal yang diterapkan dalam arsitektur tersebut [9]. Output dari setiap lapisan tersembunyi dapat diamati melalui grafik khusus yang dirancang untuk menampilkan hasil dari masing-masing neuron [10]. Proses Kombinasi dan rekombinasi antara neuron yang saling terhubung dalam setiap unit lapisan tersembunyi dilakukan dengan menggunakan

berbagai jenis fungsi aktivasi secara bersamaan [11]. Rangkaian prosedur tersebut disebut Transformasi Non-Linear, yang digunakan sebagai strategi optimal dalam menetapkan bobot terbaik pada setiap unit lapisan untuk mencapai nilai target yang diharapkan [12].

2.3 Compact Convolutional Transformers (CCT)

Penelitian ini menggunakan algoritma *Compact Convolutional Transformers* (CCT) untuk membuat model klasifikasi citra daun padi untuk mengidentifikasi penyakit tanaman padi. Algoritma CCT merupakan versi terbaru dari *Vision Transformer* (Vit), yang merupakan model ringkas untuk masalah pemrosesan gambar [13]. Transformator konvensional dianggap haus data untuk tugas-tugas pemrosesan gambar sehingga dibuatlah solusi dengan menggunakan algoritma CCT [13]. CCT adalah arsitektur yang menggabungkan elemen dari *Convolutional Neural Networks* (CNNs) dan *Transformers*, terutama untuk tugas visi komputer [14]. Secara umum, pendekatan matematikanya melibatkan operasi konvolusi diikuti oleh mekanisme perhatian (*attention*). Operasi konvolusi digunakan untuk mengolah data input gambar ke dalam representasi fitur yang lebih terkompresi. Secara matematis:

$$F = \text{Conv2D}(X, W) + b \quad (1)$$


Transformers menggunakan mekanisme perhatian untuk menangkap hubungan antar patch. Setiap kepala perhatian dihitung dengan [15]:

$$\text{Attention}(QKV) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (2)$$

3. Hasil Dan Pembahasan

3.1 Pra-pemrosesan

Pada tahap awal, dilakukan proses pra-pemrosesan citra dengan mengonversi citra daun padi ke dalam format *grayscale*. Citra grayscale memiliki intensitas piksel yang lebih sederhana dibandingkan citra berwarna, yang memungkinkan pengurangan dimensi data tanpa menghilangkan informasi penting untuk analisis lebih lanjut. Hasil *grayscale* dalam penelitian ini dapat dilihat pada Gambar 3.



Gambar 3. Hasil Grayscale Citra Daun Padi

3.2 Hasil Framework Model Compact Convolutional Transformers (CCT).

Model yang digunakan dalam penelitian ini adalah *Compact Convolutional Transformers* (CCT). Rincian arsitektur model yang digunakan dapat dilihat pada Gambar 4.

Layer (type)	Output Shape	Param #	Connected to
input_layer (InputLayer)	(None, 224, 224, 3)	0	-
conv2d (Conv2D)	(None, 112, 112, 64)	1,792	input_layer[0][0]
conv2d_1 (Conv2D)	(None, 56, 56, 128)	73,856	conv2d[0][0]
max_pooling2d (MaxPooling2D)	(None, 28, 28, 128)	0	conv2d_1[0][0]
conv2d_2 (Conv2D)	(None, 14, 14, 256)	295,168	max_pooling2d[0]...
max_pooling2d_1 (MaxPooling2D)	(None, 7, 7, 256)	0	conv2d_2[0][0]
global_average_poo... (GlobalAveragePool...)	(None, 256)	0	max_pooling2d_1[...
reshape (Reshape)	(None, 1, 256)	0	global_average_p...
multi_head_attenti... (MultiHeadAttentio...)	(None, 1, 256)	263,168	reshape[0][0], reshape[0][0]
layer_normalization (LayerNormalizatio...)	(None, 1, 256)	512	multi_head_atten...
flatten (Flatten)	(None, 256)	0	layer_normalizat...
dropout_1 (Dropout)	(None, 256)	0	flatten[0][0]
dense (Dense)	(None, 512)	131,584	dropout_1[0][0]
dropout_2 (Dropout)	(None, 512)	0	dense[0][0]
dense_1 (Dense)	(None, 3)	1,539	dropout_2[0][0]

Total params: 767,619 (2.93 MB)
Trainable params: 767,619 (2.93 MB)
Non-trainable params: 0 (0.00 B)

Gambar 4. Arsitektur *Compact Convolutional Transformers* (CCT).

Gambar 4. merupakan arsitektur CCT yang menggabungkan keunggulan *Convolutional Neural networks* (CNN) dan transformer untuk pemrosesan data citra. Model ini dirancang untuk menangani tugas klasifikasi citra dengan efisiensi dan akurasi yang tinggi. Operasi yang digunakan pada arsitektu CCT adalah sebagai berikut:

1. *Input Layer*
Output Shape: (None, 224, 224, 3)
Fungsi: Menerima input citra berukuran 224x224 piksel dengan 3 channel (RGB).
2. *Convolutional Layers* (Conv2D)
Fungsi: Mengekstraksi fitur lokal dari citra melalui penerapan filter. Penjelasan detail:
 - Layer pertama menghasilkan 64 fitur map dengan ukuran 112x112.
 - Layer kedua menghasilkan 128 fitur map dengan ukuran 56x56.
 - Layer ketiga menghasilkan 256 fitur map dengan ukuran 14x14.
3. *Max Pooling Layers*
Fungsi: Mengurangi dimensi data untuk mempercepat komputasi dan mengurangi risiko *overfitting*.
Detail: Diterapkan setelah lapisan Conv2D pertama dan kedua untuk mengurangi ukuran fitur map menjadi separuhnya.
4. *Global Average Pooling*
Fungsi: Mengubah fitur map menjadi vektor 1 dimensi dengan mengambil rata-rata dari semua nilai piksel.
Output Shape: (None, 256).
5. *Reshape Layer*

6. Fungsi: Mengubah dimensi vektor untuk mempersiapkan data masuk ke transformer.
Output Shape: (None, 1, 256).
Multi-Head Attention (Transformer Encoder)
 Fungsi: Memahami hubungan global antar fitur yang diekstraksi dari citra. Komponen ini adalah inti dari transformer.
 Parameter: 263,168.
Output Shape: (None, 1, 256).
7. *Layer Normalization*
 Fungsi: Menormalkan output transformer untuk stabilitas pelatihan dan peningkatan performa.
8. *Flatten Layer*
 Fungsi: Mengubah data ke bentuk vektor satu dimensi untuk masuk ke *fully connected layer*.
Output Shape: (None, 256).
9. *Dropout Layers*
 Fungsi: Mengurangi *overfitting* dengan secara acak menonaktifkan sejumlah neuron selama pelatihan.
 Dropout digunakan dua kali dengan berbagai posisi pada *fully connected layers*.
10. *Dense Layers (Fully Connected Layers)*
 Fungsi: Mengintegrasikan informasi fitur dan menghasilkan output akhir. Penjelasan detail dari layer ini adalah sebagai berikut:
 - Dense pertama: 512 neuron dengan fungsi aktivasi ReLU.
 - Dense kedua: 1 neuron dengan fungsi aktivasi sigmoid (untuk klasifikasi biner).

3.3 Hasil Pelatihan Model


Model dilatih selama 30 *epoch* menggunakan dataset citra daun padi. Hasil pelatihan model menunjukkan perkembangan akurasi dan penurunan nilai loss seiring bertambahnya jumlah *epoch*. Akurasi tertinggi pada data pelatihan dicapai pada *epoch* ke-30, dengan nilai loss yang terus menurun hingga mendekati stabil. Gambar 5 berikut menunjukkan proses pelatihan model deteksi penyakit tanaman padi berdasarkan citra daun.

```
Epoch 20: val_accuracy improved from 0.86228 to 0.86292, saving model to modelCCT_rice.keras
147/147 — 105% 695ms/step - accuracy: 0.8356 - loss: 0.4391 - val_accuracy: 0.8629 - val_loss: 0.328
Epoch 21/30
147/147 — 0% 584ms/step - accuracy: 0.8329 - loss: 0.4088
Epoch 21: val_accuracy improved from 0.86292 to 0.87746, saving model to modelCCT_rice.keras
147/147 — 102% 671ms/step - accuracy: 0.8330 - loss: 0.4080 - val_accuracy: 0.8775 - val_loss: 0.299
Epoch 22/30
147/147 — 0% 562ms/step - accuracy: 0.8426 - loss: 0.4066
Epoch 22: val_accuracy did not improve from 0.87746
147/147 — 98% 648ms/step - accuracy: 0.8426 - loss: 0.4066 - val_accuracy: 0.8764 - val_loss: 0.3015
Epoch 23/30
147/147 — 0% 570ms/step - accuracy: 0.8449 - loss: 0.3971
Epoch 23: val_accuracy improved from 0.87746 to 0.88473, saving model to modelCCT_rice.keras
147/147 — 99% 656ms/step - accuracy: 0.8449 - loss: 0.3970 - val_accuracy: 0.8847 - val_loss: 0.2890
Epoch 24/30
147/147 — 0% 588ms/step - accuracy: 0.8615 - loss: 0.3653
Epoch 24: val_accuracy improved from 0.88473 to 0.88559, saving model to modelCCT_rice.keras
147/147 — 101% 675ms/step - accuracy: 0.8615 - loss: 0.3653 - val_accuracy: 0.8856 - val_loss: 0.289
Epoch 25/30
147/147 — 0% 578ms/step - accuracy: 0.8570 - loss: 0.3588
Epoch 25: val_accuracy improved from 0.88559 to 0.88901, saving model to modelCCT_rice.keras
147/147 — 99% 657ms/step - accuracy: 0.8570 - loss: 0.3588 - val_accuracy: 0.8890 - val_loss: 0.2691
Epoch 26/30
147/147 — 0% 567ms/step - accuracy: 0.8664 - loss: 0.3532
Epoch 26: val_accuracy improved from 0.88901 to 0.89778, saving model to modelCCT_rice.keras
147/147 — 99% 654ms/step - accuracy: 0.8664 - loss: 0.3532 - val_accuracy: 0.8978 - val_loss: 0.2748
Epoch 27/30
147/147 — 0% 568ms/step - accuracy: 0.8673 - loss: 0.3538
Epoch 27: val_accuracy improved from 0.89778 to 0.89991, saving model to modelCCT_rice.keras
147/147 — 99% 657ms/step - accuracy: 0.8673 - loss: 0.3538 - val_accuracy: 0.8999 - val_loss: 0.2503
Epoch 28/30
147/147 — 0% 574ms/step - accuracy: 0.8725 - loss: 0.3238
Epoch 28: val_accuracy improved from 0.89991 to 0.90633, saving model to modelCCT_rice.keras
147/147 — 99% 660ms/step - accuracy: 0.8725 - loss: 0.3238 - val_accuracy: 0.9063 - val_loss: 0.2376
Epoch 29/30
147/147 — 0% 569ms/step - accuracy: 0.8769 - loss: 0.3169
Epoch 29: val_accuracy did not improve from 0.90633
147/147 — 99% 655ms/step - accuracy: 0.8769 - loss: 0.3169 - val_accuracy: 0.9068 - val_loss: 0.2388
Epoch 30/30
147/147 — 0% 567ms/step - accuracy: 0.8708 - loss: 0.3151
Epoch 30: val_accuracy improved from 0.90633 to 0.90676, saving model to modelCCT_rice.keras
147/147 — 99% 655ms/step - accuracy: 0.8708 - loss: 0.3150 - val_accuracy: 0.9068 - val_loss: 0.2357
Restoring model weights from the end of the best epoch: 30.
```

Gambar 5. Proses Pelatihan model dengan 30 *epoch*

3.4 Hasil Validasi Model

Pada Grafik *Training and Validation Loss* menunjukkan tren penurunan loss pada data pelatihan dan validasi, sedangkan grafik *Training and Validation Accuracy* menunjukkan peningkatan akurasi. Model mencapai akurasi validasi mendekati 94% pada epoch terakhir, hal ini menunjukkan bahwa model mampu mengenali pola pada data baru dengan baik. Grafik *Training and Validation Loss* dapat dilihat pada Gambar 6.



Gambar 6. Hasil Proses Training pada Dataset Citra Daun Padi a) Grafik Loss dan b) Grafik Akurasi

Pada Gambar 6a) dapat dilihat bahwa nilai loss untuk training dan validasi menurun secara bertahap seiring bertambahnya jumlah epoch, hal ini menunjukkan bahwa model semakin baik dalam meminimalkan kesalahan prediksi. Namun, pada epoch terakhir, terdapat sedikit kenaikan pada loss validasi yang dapat mengindikasikan potensi overfitting. Grafik Akurasi pada Gambar 6b) meningkat secara konsisten hingga mencapai titik yang cukup tinggi. Akurasi validasi bahkan melebihi akurasi training di akhir proses, yang dapat menunjukkan bahwa model memiliki generalisasi yang baik terhadap data validasi. Secara keseluruhan, grafik ini mencerminkan bahwa model berhasil dilatih dengan baik, meskipun perlu pengamatan lebih lanjut terhadap fenomena overfitting di akhir pelatihan.

4. Kesimpulan

Hasil ini menunjukkan bahwa Proses pra-pemrosesan dengan konversi citra daun padi ke format grayscale berhasil menyederhanakan data tanpa menghilangkan informasi penting. Model *Compact Convolutional Transformers* (CCT) berhasil menggabungkan keunggulan *convolutional layers* untuk ekstraksi fitur lokal dan *transformer encoder* untuk memahami hubungan global dalam citra. Model menunjukkan performa yang baik dengan akurasi validasi mendekati 94% dan tren penurunan loss yang konsisten selama pelatihan. Hasil validasi menunjukkan bahwa model mampu mengenali pola pada data baru dengan tingkat generalisasi yang baik. Model dapat mengenali jenis penyakit berdasarkan citra daun padi dengan akurasi yang memadai, menunjukkan bahwa framework yang digunakan efektif untuk tugas klasifikasi pada domain ini.

Daftar Pustaka

- [1] U. H. Mubarak, M. Nasiruddin, and D. A. S. H. 3, "Uji Efektivitas Bahan Jebakan Papan Terhadap Keanekaragaman Serangga Pada Tanaman Padi (*Oryza sativa* L.)," *J. Pendidik. Sos. dan Hum.*, vol. 3, no. 3, pp. 2438–2449, 2024.
- [2] S. Suhendar, A. Purnama, and E. Fauzi, "Deteksi Penyakit Pada Daun Tanaman Ubi Jalar Menggunakan Metode Convolutional Neural Network," *J. Ilm. Inform. Glob.*, vol. 14, no. 3, pp. 62–67, 2023.

- [3] G. Y. Christiawan, R. A. Putra, A. Sulaiman, E. Poerbaningtyas, S. Widyayuningtias, and K. Kunci, "Penerapan Metode Convolutional Neural Network (CNN) Dalam Mengklasifikasikan Penyakit Daun Tanaman Padi," *J-INTECH(Journal ofInformation Technol.*, no. 204, pp. 294–306, 2023.
- [4] A. C. Milano, A. Yasid, and R. T. Wahyuningrum, "Klasifikasi Penyakit Daun Padi Menggunakan Model Deep Learning Efficientnet-B6," *JITET (Jurnal Inform. dan Tek. Elektro Ter.*, vol. 12, no. 1, pp. 551–559, 2024.
- [5] A. A. Huda, B. Setiaji, and F. R. Hidayat, "Implementasi Gray Level CO-Occurrence Matrix (GLCM) untuk Klasifikasi Penyakit Daun Padi," *J. Pseudocode*, vol. 9, no. 1, pp. 33–38, 2022.
- [6] K. Penyakit and D. Pisang, "Klasifikasi Penyakit Daun Pisang Menggunakan Convolutional Neural Network (CNN)," *J. Teknol. Terpadu Vol.*, vol. 10, no. 1, pp. 1–6, 2024.
- [7] N. Krishnamoorthy, L. V. N. Prasad, C. S. P. Kumar, B. Subedi, H. Baraki, and V. E. Sathishkumar, "Rice leaf diseases prediction using deep neural networks with transfer learning," *Environ. Res.*, vol. 198, p. 111275, 2021, doi: 10.1016/j.envres.2021.111275.
- [8] H. A. Pratiwi, M. Cahyanti, and M. Lamsani, "Implementasi Deep Learning Flower Scanner Menggunakan Metode Convolutional Neural Network," vol. 25, no. 1, pp. 124–130, 2021, doi: 10.46984/sebatik.v25i1.1297.
- [9] A. Raup, W. Ridwan, Y. Khoeriyah, and Q. Y. Zaqiah, "Deep Learning dan Penerapannya dalam Pembelajaran," *JIIP (Jurnal Ilm. Ilmu Pendidikan)*, vol. 5, no. 9, pp. 3258–3267, 2022.
- [10] A. K. Syarif, "Sistem Klasifikasi Penyakit Tanaman Cabai Menggunakan Metode Deep Learning dengan Library Tensorflow Lite," Univesitas Hasanudin, 2021.
- [11] N. Musfirah, "Identifikasi Jenis Serangan Hama pada Buah Kakao menggunakan Image processing," Univesitas Hasanudin, 2023.
- [12] Rizky Alfiansyah, "Deteksi Manipulasi Citra dengan Error Level Anlysis dan Convolutional Neural Network," Univesitas Hasanudin, 2023.
- [13] A. I. Jajja *et al.*, "Compact Convolutional Transformer (CCT)-Based Approach for Whitefly Attack Detection in Cotton Crops," *Agric. Artic.*, vol. 12, pp. 1–17, 2022.
- [14] A. Hassani *et al.*, "Escaping the Big Data Paradigm with Compact Transformers," *arXiv*, 2021.
- [15] R. Farkh, G. Oudinet, and Y. Foued, "Image Captioning Using Multimodal Deep Learning Approach," *Comput. Mater. Contin.*, vol. 81, no. 3, pp. 3951–3968, 2024, doi: 10.32604/cmc.2024.053245.