



SISTEM DETEKSI PENYAKIT PADA DAUN TANAMAN KENTANG MENGUNAKAN METODE CNN ARSITEKTUR VGG-Net

Prasetyo Tri Utomo^{1*}, Budi Santoso², Slamet Kacung³

^{1,2,3}Teknik Informatika, Universitas Dr Soetomo

email: prasetyotriutomo.89@gmail.com^{1*}

Abstrak: Deteksi dini terhadap penyakit pada daun tanaman kentang memiliki peran krusial dalam mencegah penurunan produktivitas hasil panen. Penyakit seperti *early blight* dan *late blight* dapat dikenali melalui karakteristik visual pada permukaan daun, namun identifikasi secara manual cenderung bersifat subjektif dan memerlukan waktu yang cukup lama. Penelitian ini bertujuan untuk merancang sistem deteksi otomatis penyakit daun kentang dengan memanfaatkan metode *Convolutional Neural Network* (CNN) melalui pendekatan *transfer learning* menggunakan arsitektur VGG16. Dataset yang digunakan mencakup tiga kelas, yaitu daun sehat (*healthy*), *early blight*, dan *late blight*. Tahapan pra-pemrosesan meliputi preprocessing citra, augmentasi data, serta pelatihan model dengan memanfaatkan bobot awal dari VGG16. Parameter pelatihan yang diterapkan antara lain *batch size* sebesar 32, *learning rate* sebesar 0,0001, dimensi gambar 224×224 piksel, dan jumlah *epoch* sebanyak 10. Berdasarkan hasil pengujian, model mampu mencapai akurasi sebesar 95%, disertai nilai *precision*, *recall*, dan *F1-score* yang tinggi dan konsisten untuk setiap kelas. Evaluasi menggunakan *confusion matrix* menunjukkan performa klasifikasi yang baik dengan tingkat kesalahan prediksi yang rendah. Dengan demikian, sistem ini memiliki potensi untuk diterapkan sebagai alat bantu bagi petani dalam melakukan identifikasi penyakit daun secara cepat dan akurat di lapangan.

Kata Kunci : CNN, deteksi Penyakit, klasifikasi citra, kentang, pengolahan citra digital

PENDAHULUAN

Pengolahan citra digital kini berperan penting di berbagai sektor, termasuk pertanian, khususnya dalam deteksi penyakit tanaman[1]. Tanaman kentang (*Solanum tuberosum*) merupakan komoditas pangan utama yang rentan terhadap penyakit seperti *Phytophthora infestans* (*late blight*) dan *Alternaria solani* (*early blight*)[2]. Kedua penyakit ini dapat diidentifikasi melalui perbedaan warna dan tekstur daun[3]. Penyakit *Phytophthora infestans* (*late blight*) ditandai dengan pembentukan lesi berair pada daun, batang, dan buah, yang kemudian berubah menjadi coklat dan nekrotik[4]. Sedangkan ciri khas penyakit *Alternaria solani* (*early blight*) adalah kemunculan spot-spot kecil yang tidak teratur hingga membentuk lingkaran berwarna coklat gelap pada bagian bawah daun, dengan ukuran sekitar 0,5 mm. Bercak-bintik ini menyebabkan daun mengering dan mati[5]. Jika tidak ditangani, penyakit ini dapat merusak umbi dan menurunkan hasil panen.

Deteksi manual penyakit pada tanaman kentang memerlukan waktu, tenaga, dan hasilnya sering bergantung pada pengalaman petani, sehingga kurang konsisten. Keterlambatan identifikasi dapat menyebabkan kerusakan serius dan menurunkan hasil panen. Oleh karena itu, pemanfaatan teknologi seperti pengolahan citra digital menjadi solusi potensial untuk meningkatkan efektivitas deteksi penyakit.

Mengembangkan sistem deteksi penyakit daun kentang menggunakan teknologi pengolahan citra digital dan metode *Convolutional Neural Network* (CNN) untuk klasifikasi. CNN dipilih karena kemampuannya dalam ekstraksi fitur otomatis, akurasi tinggi dalam pemrosesan citra, serta mendukung transfer learning [6].

Dengan Tujuan akhir adalah untuk mengembangkan suatu sistem deteksi penyakit pada daun tanaman kentang yang mampu menghasilkan output deteksi secara cepat dan akurat dengan memanfaatkan teknologi pengolahan citra digital. Sistem yang dikembangkan dirancang agar memiliki tingkat kemudahan penggunaan yang tinggi serta dapat diakses dengan mudah oleh petani, sehingga mendukung proses deteksi dini terhadap penyakit pada tanaman kentang secara lebih efektif. Diharapkan, penerapan sistem ini dapat memberikan kontribusi dalam mengurangi waktu dan tenaga yang diperlukan dalam proses identifikasi penyakit secara manual, sehingga meningkatkan efisiensi kerja di bidang pertanian dan berdampak positif terhadap peningkatan hasil panen. Selain itu, sistem ini juga memberikan kemudahan bagi petani maupun ahli pertanian dalam menentukan tindakan penanganan yang tepat berdasarkan jenis penyakit yang terdeteksi, sehingga proses pengobatan dapat dilakukan secara lebih akurat dan terarah.

TINJAUAN PUSTAKA

Berdasarkan penelitian terdahulu, peneliti [7] Dengan menggunakan arsitektur CNN, penelitian ini menemukan penyakit daun kentang dengan akurasi 94%. Ini menunjukkan bahwa arsitektur ini baik untuk identifikasi jenis tanaman melalui citra. Model ini terdiri dari beberapa lapisan *convolutional*, *pooling*, dan sepenuhnya terhubung, dengan minimal 10 *epoch* dan ukuran *batch* 20. Kemampuan mengekstraksi fitur secara otomatis dan akurasi tinggi adalah keunggulan utamanya. Namun, ada beberapa keterbatasan. Ini termasuk bergantung pada dataset tertentu, tidak memiliki detail konfigurasi arsitektur, dan kemungkinan overfitting jika data tidak beragam atau regulasi tidak memadai.

Peneliti [8] juga melakukan identifikasi penyakit daun kentang menggunakan arsitektur VGG16, Resnet50, RNN, dan LTSM. Dalam dataset 600, ada lima kategori daun: daun sehat, daun bercak, daun berlubang, daun busuk, dan bukan daun. Setiap kategori mengandung 120 gambar citra berukuran 128 x 128 piksel. Dalam penelitian yang dilakukan dengan



berbagai model arsitektur, model ketiga, VGG16, yang dipasangkan dengan lapisan dense 75, mendapatkan nilai presisi 0.87, *recall* 0.86, akurasi 0.86, dan skor f1-0.86.

Penelitian [9] ini menghasilkan model CNN yang berhasil mengidentifikasi penyakit daun kentang berdasarkan gambar digital. Model mampu membedakan daun sehat dari yang terkena penyakit late blight dan early blight, dengan akurasi tertinggi 95,93% diberikan oleh arsitektur VGG16 dengan ukuran batch 32, diikuti oleh MobileNet-V2 dengan akurasi 94,15%. Meskipun keunggulannya terletak pada akurasi tinggi, ketergantungannya pada data dan komputasi besar membatasinya.


Berdasarkan literatur review penelitian ini akan tetap menggunakan metode CNN dan tetap menggunakan arsitektur VGG16 akan tetapi dengan menambahkan teknik learning rate dan menambahkan fine-tuning. CNN dipilih karena kemampuannya dalam mengekstraksi fitur visual dari citra, sedangkan VGG16 dipilih karena struktur bertingkatnya yang konsisten dan performa ekstraksi fitur yang baik, serta ketersediaan *pre-trained weights* dari ImageNet. Penelitian ini mengembangkan pendekatan sebelumnya dengan menerapkan *fine-tuning* pada beberapa layer akhir VGG16 agar model lebih adaptif terhadap ciri khusus daun kentang. Selain itu, pengaturan *learning rate* dilakukan secara eksplisit untuk memastikan pelatihan yang stabil dan optimal. Kombinasi teknik ini diharapkan menghasilkan model klasifikasi yang akurat dan mampu menggeneralisasi terhadap data baru.

Citra Digital

Citra Digital biasanya merujuk pada pengolahan gambar dua dimensi menggunakan komputer digital. Secara umum, hal ini mencakup pengolahan digital dari data dua dimensi mana pun. Sebuah gambar digital merupakan susunan angka nyata atau kompleks yang diwakili oleh sejumlah bit yang terbatas[10]. Terdapat tiga jenis gambar digital yakni berwarna, grayscale, dan biner. Gambar berwarna memiliki informasi intensitas untuk tiga saluran warna (biasanya RGB), sedangkan gambar grayscale hanya memiliki satu saluran dengan variasi intensitas dari hitam hingga putih. Sementara itu, gambar biner terdiri dari hanya dua kemungkinan nilai piksel, biasanya hitam dan putih, yang umum digunakan dalam proses segmentasi atau deteksi objek sederhana[11].

Convolutional Neural Network (Cnn)


Convolutional Neural Network (CNN) merupakan pengembangan dari *Artificial Neural Network (ANN)* yang dirancang khusus untuk memproses data visual seperti gambar dan video[12]. CNN banyak digunakan dalam berbagai aplikasi visi komputer karena kemampuannya dalam mengenali pola spasial dan hierarki fitur dari data citra. Keunggulan utama CNN terletak pada kemampuannya dalam mengurangi jumlah parameter jaringan secara signifikan melalui penggunaan operasi konvolusi yang bersifat lokal dan berbagi bobot[13]. Dengan demikian, CNN menjadi lebih efisien dibandingkan ANN standar, terutama dalam menangani data berukuran besar. Arsitektur CNN secara umum terdiri dari dua tahap utama, yaitu tahap ekstraksi fitur dan tahap klasifikasi. Tahap ekstraksi fitur mencakup operasi konvolusi untuk mengambil pola penting dari gambar, fungsi aktivasi seperti *ReLU* (Rectified Linear Unit) untuk meningkatkan non-linearitas, serta operasi *pooling* untuk mereduksi dimensi dan kompleksitas data. Setelah fitur diekstraksi, data akan diproses pada lapisan *fully connected* yang bertugas melakukan klasifikasi berdasarkan fitur yang telah diidentifikasi sebelumnya.[14].



Gambar 1. Arsitektur CNN

Convolutional Layer

Convolutional Layer merupakan lapisan utama dalam CNN yang berfungsi mengekstraksi fitur dari gambar masukan. Lapisan ini menggunakan filter berukuran tetap yang digeser melintasi citra untuk menerapkan fungsi-fungsi kompleks [15].




Gambar 2. Ilustrasi Operasi konvolusi pada citra RGB

METODE

Pada tahap pelatihan model, digunakan arsitektur *Convolutional Neural Network* (CNN) berbasis VGG16 yang telah dilatih sebelumnya (*pre-trained*), kemudian dilakukan proses *fine-tuning* untuk menyesuaikan dengan data klasifikasi penyakit daun kentang. Beberapa hyperparameter utama ditentukan secara eksplisit untuk mengoptimalkan proses pelatihan. *Batch size* ditetapkan sebesar 32 karena nilai ini umum digunakan dan memberikan keseimbangan antara efisiensi pemrosesan dan kestabilan pembelajaran. *Learning rate* yang digunakan adalah 0,0001 agar proses pelatihan berjalan secara bertahap dan tidak merusak bobot awal dari model VGG16 yang sudah dilatih pada dataset ImageNet. Ukuran gambar ditetapkan 224×224 piksel, menyesuaikan dengan ukuran input standar dari arsitektur VGG16 sehingga tidak perlu dilakukan perubahan struktur jaringan. Sementara itu, jumlah *epoch* ditetapkan sebanyak 10 karena model berbasis *transfer learning* umumnya memerlukan jumlah iterasi yang lebih sedikit dibanding model dari awal, dan untuk menghindari *overfitting*. Tahapan ini dilakukan dengan pemantauan terhadap akurasi dan *loss* pada data validasi, serta dievaluasi menggunakan confusion matrix dan classification report, untuk menilai seberapa baik model dalam mengklasifikasikan jenis penyakit berdasarkan citra daun kentang.

Gambar berikut menunjukkan flowchart sistem deteksi penyakit daun kentang yang dikembangkan menggunakan teknik pengolahan citra digital dan metode *deep learning*. Algoritma *Convolutional Neural Network* (CNN) dengan arsitektur VGG16 digunakan secara khusus.



Gambar 3. Alur Sistem

Memasukkan atau mengimpor gambar daun kentang yang diperoleh dari platform Kaggle merupakan tahap awal dalam proses pembangunan sistem deteksi penyakit pada daun tanaman kentang. Dataset ini bernama “*Potato Disease Leaf Dataset*” yang diunggah oleh Rizwan Saeed yang dikumpulkan dari wilayah Punjab, Pakistan dan *update* terakhir dari dataset empat tahun lalu. Dataset ini terdiri dari 4062 gambar yang telah dikategorikan berdasarkan jenis penyakit atau kondisi daun, seperti daun sehat, daun yang terkena *early blight*, dan daun yang terkena *late blight*.



Gambar 4. Sample Data Daun Kentang

Tahapan kedua dilakukan persiapan gambar sebagai input model, yang meliputi proses *preprocessing* seperti perubahan ukuran gambar agar sesuai dengan input standar model, normalisasi nilai piksel ke dalam rentang tertentu, serta augmentasi gambar melalui teknik seperti rotasi dan *flip* untuk meningkatkan variasi data dan mencegah overfitting.

```
train_datagen = ImageDataGenerator(  
    rescale=1./255,  
    rotation_range=20,  
    zoom_range=0.2,  
    width_shift_range=0.2,  
    height_shift_range=0.2,  
    shear_range=0.2,  
    horizontal_flip=True,  
    fill_mode='nearest'  
)
```

Gambar 5. Augmentasi Data

Tahapan ketiga Model CNN dengan arsitektur VGG16 dilatih melalui mekanisme propagasi maju dan balik, dengan perhitungan kesalahan melalui *loss categorical crossentropy* dan optimisasi bobot melalui algoritma Adam. Proses ini ditingkatkan dengan data *augmentation*, *fine-tuning*, dan pengaturan *hyperparameter* seperti *learning rate*, *epochs*, dan *batch size* untuk mencapai akurasi optimal dalam klasifikasi penyakit daun kentang.

Tahapan keempat, setelah pelatihan selesai kinerja model dievaluasi dengan data validasi untuk mengetahui seberapa umum model itu dan untuk menghindari overfitting. Hasil evaluasi dilakukan menggunakan metrik akurasi, matriks kecacauan, dan laporan klasifikasi yang mencakup akurasi, recall, dan skor F1 per kelas. Hasil ini menunjukkan seberapa baik model berfungsi untuk mendeteksi penyakit daun kentang baik secara keseluruhan maupun per kategori. Ini menunjukkan seberapa baik aplikasinya di dunia nyata.

HASIL DAN PEMBAHASAN

Sebelum melakukan evaluasi terhadap performa model, terlebih dahulu ditentukan beberapa *hyperparameter* penting yang digunakan selama proses pelatihan.


Tabel 1. Hyperparameter Arsitektur CNN

Hyperparameter	Nilai yang digunakan
Batch_size	32
Learning_rate	0,0001
Image_size	224
Epoch	10

Pemilihan *hyperparameter* pada model didasarkan pada pertimbangan efisiensi dan kesesuaian dengan arsitektur VGG16. Ukuran *batch* sebesar 32 dipilih karena memberikan keseimbangan antara kecepatan pelatihan dan penggunaan memori. *Learning rate* sebesar 0,0001 digunakan agar proses *fine-tuning* berjalan stabil tanpa merusak bobot awal dari model *pre-trained*. Ukuran gambar 224×224 disesuaikan dengan standar input VGG16, sehingga tidak memerlukan modifikasi arsitektur. Jumlah *epoch* sebanyak 10 dianggap cukup untuk mencapai konvergensi awal, mengingat model sudah memanfaatkan *transfer learning*.



Dengan konfigurasi *hyperparameter* ini, model kemudian dilatih dan dievaluasi untuk mengukur kemampuannya dalam mengklasifikasikan citra daun kentang ke dalam tiga kategori, yaitu *healthy*, *early blight*, dan *late blight*. Hasil pelatihan ini disajikan melalui grafik akurasi dan *loss* serta metrik evaluasi lainnya untuk menilai efektivitas model secara menyeluruh.




Gambar 6. Grafik Accuracy Dan Loss

Grafik yang ditampilkan merupakan visualisasi dari proses pelatihan model pembelajaran mesin selama 10 epoch, dengan dua metrik utama yang diamati yakni akurasi dan *loss*. Grafik sebelah kiri menunjukkan perbandingan antara akurasi data pelatihan dan data validasi dari waktu ke waktu, sedangkan grafik sebelah kanan menampilkan perkembangan nilai *loss* pada data pelatihan dan validasi. Evaluasi terhadap kedua grafik ini memberikan gambaran penting mengenai kemampuan model dalam belajar dari data dan menggeneralisasi terhadap data baru yang belum pernah dilihat sebelumnya.

Pada grafik akurasi (kiri), terlihat bahwa akurasi pelatihan meningkat secara konsisten dari sekitar 0,73 pada epoch pertama hingga melampaui angka 0,96 pada epoch ke-9. Kenaikan yang stabil ini menandakan bahwa model berhasil mempelajari pola-pola dalam data pelatihan dengan baik seiring bertambahnya jumlah epoch. Akurasi validasi juga menunjukkan peningkatan yang cukup signifikan pada awal pelatihan, terutama hingga sekitar epoch ke-3 dan ke-5. Namun, setelahnya, akurasi validasi cenderung fluktuatif meskipun tetap berada pada tingkat yang tinggi, yaitu di atas 0,91. Fluktuasi ini dapat diinterpretasikan sebagai sinyal adanya sedikit ketidakonsistenan dalam performa model terhadap data validasi, yang bisa mengindikasikan potensi awal dari gejala *overfitting*, meskipun belum terlalu signifikan.

Sementara itu, pada grafik *loss* (kanan), terlihat bahwa nilai *loss* pada data pelatihan mengalami penurunan yang cukup drastis dari awal pelatihan hingga sekitar epoch ke-5. Setelah itu, nilai *loss* cenderung stabil dan tetap rendah di bawah angka 0,15, yang merupakan indikasi bahwa model mampu meminimalkan kesalahan prediksi pada data pelatihan. Di sisi lain, nilai *loss* pada data validasi juga menunjukkan tren penurunan secara umum, tetapi tidak sehalus data pelatihan. Terdapat beberapa titik fluktuasi, terutama pada epoch ke-7 dan ke-8, di mana terjadi kenaikan nilai *loss*. Hal ini menunjukkan bahwa model mengalami tantangan dalam mempertahankan kemampuan generalisasi terhadap data validasi pada titik-titik tertentu.

Untuk mengevaluasi performa model dalam mendeteksi dan mengklasifikasikan penyakit daun kentang, digunakan *confusion matrix* sebagai salah satu metode analisis. *Confusion matrix* memberikan gambaran rinci mengenai jumlah prediksi yang benar dan salah untuk masing-masing kelas, sehingga dapat digunakan untuk mengukur efektivitas model dalam membedakan antara kategori *early blight*, *late blight*, dan *healthy*.



Gambar 7. Hasil Evaluasi Model

Evaluasi kinerja model dilakukan dengan menggunakan metrik confusion matrix, akurasi, recall, dan skor F1. Berdasarkan confusion matrix yang dihasilkan, model menunjukkan kemampuan klasifikasi yang sangat baik untuk ketiga kelas, yaitu *Early Blight*, *Healthy*, dan *Late Blight*. Dari total 416 data uji, model berhasil mengklasifikasikan sebagian




besar data dengan benar. Kesalahan prediksi terjadi dalam jumlah yang sangat kecil, terutama pada kelas *Late_Blight* yang kadang diklasifikasikan sebagai *Early Blight*, menunjukkan kemungkinan kemiripan karakteristik visual antar kelas tersebut.

Berdasarkan nilai metrik klasifikasi, model memperoleh akurasi keseluruhan sebesar 95 persen. Untuk kelas *Early Blight*, *recall* mencapai 0.98, yang menunjukkan bahwa hampir seluruh data *Early Blight* dikenali dengan benar oleh model, dengan *precision* 0.94 dan *F1-score* 0.95. Kelas *Healthy* menunjukkan keseimbangan yang sangat baik antara *precision* dan *recall*, masing-masing 0.95, dengan *F1-score* 0.95. Sementara itu, kelas *Late Blight* memiliki *precision* tertinggi (0.97) namun *recall* sedikit lebih rendah (0.93), dengan *F1-score* tetap tinggi di angka 0.95.

Nilai *macro average* dan *weighted average* untuk *precision*, *recall*, dan *F1-score* semuanya berada pada angka 0.95 atau 95%, yang mengindikasikan bahwa model memberikan performa yang seimbang terhadap semua kelas, tanpa terlalu memihak pada kelas mayoritas. Hasil ini menunjukkan bahwa model memiliki generalisasi yang baik dan layak untuk digunakan dalam aplikasi nyata seperti sistem deteksi penyakit daun kentang berbasis citra.

Implementasi




Berdasarkan hasil pengujian terhadap model dengan arsitektur VGG16, model tersebut akan digunakan sebagai dasar dalam implementasi sistem yang akan dikembangkan ke dalam bentuk web sederhana dengan tujuan untuk melakukan percobaan.






Gambar 8. Tampilan web sederhana

Untuk mengetahui seberapa baik model bekerja dalam skenario aplikasi sebenarnya, dilakukan serangkaian percobaan pada sistem yang telah dibangun.

Tabel 2. Hasil Pengujian Klasifikasi Model

No	Gambar	Jenis	Hasil	Status
1		Early Blight		Berhasil
2		Early Blight		Berhasil
3		Healthy		Berhasil



4		Healthy		Berhasil
5		Late Blight		Berhasil
6		Late Blight		Berhasil

KESIMPULAN DAN SARAN

Berdasarkan hasil evaluasi model klasifikasi daun tanaman kentang, dapat disimpulkan bahwa model memiliki performa yang sangat baik. Bukti ini dapat diamati dalam akurasi tinggi 95%, disertai dengan *precision*, *recall* dan *F1-Score* masih konsisten di tiga kelas (*Early Blight*, *Healty* dan *Late Blight*). Confusion matrix menunjukkan bahwa model mampu mengenali masing-masing kelas dengan baik, meskipun masih terdapat sedikit kesalahan klasifikasi, khususnya antara kelas *Late Blight* dan *Early Blight*, yang kemungkinan disebabkan oleh kemiripan karakteristik visual.

Secara keseluruhan, grafik akurasi dan loss menunjukkan bahwa model memiliki kinerja yang baik dan mampu belajar dengan efektif dari data pelatihan, serta cukup mampu menggeneralisasi ke data validasi. Meskipun terdapat sedikit fluktuasi pada nilai akurasi dan loss validasi, performa model secara keseluruhan masih tergolong stabil dan menjanjikan. Untuk mengatasi potensi overfitting di masa mendatang, dapat dipertimbangkan penggunaan teknik seperti regularisasi, dropout, atau validasi silang.

DAFTAR PUSTAKA

- [1] M. Javaid, A. Haleem, I. H. Khan, and R. Suman, "Understanding the potential applications of Artificial Intelligence in Agriculture Sector," *Adv. Agrochem*, vol. 2, no. 1, pp. 1–16, 2023, doi: 10.1016/j.aac.2022.10.001.
- [2] M. Islam, A. Dinh, W. Khan, and P. Bhowmik, "Detection of Potato Diseases Using Image Segmentation and Multiclass Support Vector Machine," *2017 IEEE 30th Can. Conf. Electr. Comput. Eng.*, pp. 1–4, 2017.
- [3] W. F. Hidayat, T. Asra, and A. Setiadi, "Klasifikasi Penyakit Daun Kentang Menggunakan Model Logistic Regression," *Indones. J. Softw. Eng.*, vol. 8, no. 2, pp. 173–179, 2022, [Online]. Available: <http://ejournal.bsi.ac.id/ejurnal/index.php/ijse>
- [4] M. N. and E. U. K. Marcin Nowicki, Majid R. Foolad, "Potato and Tomato Late Blight Caused by *Phytophora infestans*: An Overview of Pathology and Resistance Breeding," *Plant Dis.*, vol. 96, no. 1, pp. 1–14, 2012.
- [5] S. A. Ganie, M. Y. Ghani, Q. Nissar, N. Jabeen, and Q. Anjum, "Status and symptomatology of early blight (*Alternaria solani*) of potato (*Solanum tuberosum* L.) in Kashmir valley," *African J. Agric. Res.*, vol. 8, no. 41, pp. 5104–5115, 2013, doi: 10.5897/AJAR2013.7338.
- [6] M. A. Leonardi and A. Y. Chandra, "Analisis Perbandingan CNN dan Vision Transformer untuk Klasifikasi Biji Kopi Hasil Sangrai," *J. Media Inform. Budidarma*, vol. 8, no. 3, p. 1398, 2024, doi: 10.30865/mib.v8i3.7732.
- [7] K. I. Nauval and S. Lestari, "Implementasi Deteksi Objek Penyakit Daun Kentang dengan Metode Convolutional Neural Network," *J. Apl. Teknol. Inf. dan Manaj.*, vol. 3, no. 2, pp. 136–149, 2022, doi: 10.31102/jatim.v3i2.1576.
- [8] J. R. Aisya and A. Prasetyadi, "Klasifikasi Penyakit Daun Kentang dengan Metode CNN dan RNN," *J. Tekno Insentif*, vol. 17, no. 1, pp. 1–10, 2023, doi: 10.36787/jti.v17i1.888.
- [9] A. D. Septian and A. Suhendar, "IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEURAL NETWORK UNTUK DETEKSI PENYAKIT DAUN KENTANG MENGGUNAKAN CITRA DIGITAL," pp. 1017–1025, 2024.
- [10] A. K. JAIN, *Fundamentals of Digital Image Processing*. 1989.
- [11] M. Z. Andrekha and Y. Huda, "Deteksi Warna Manggis Menggunakan Pengolahan Citra dengan OpenCV Python," *Voteteknika*



(*Vocational Tek. Elektron. dan Inform.*, vol. 9, no. 4, pp. 1–7, 2021, doi: 10.24036/voteteknika.v9i4.114251.

- [12] V. H. and R. B. M. Sonka, *Image processing, analysis, and machine vision*. Cengage Learning. 2014.
- [13] R. Cipta, Khoerunisa, N. M. S. Saraswati, Rizki Noor Prasetyono, and M. Zidan Alfariki, “Deteksi Penyakit Bercak Coklat, Coklat Sempit Dan Hawar Melalui Spektrum Warna Citra Digital Daun Padi Menggunakan Metode Convolutional Neural Network,” *Zo. J. Sist. Inf.*, vol. 5, no. 2, pp. 334–346, 2023, doi: 10.31849/zn.v5i2.13245.
- [14] S. Albawi, T. A. Mohammed, and S. Al-Zawi, “Understanding of a convolutional neural network,” *Proc. 2017 Int. Conf. Eng. Technol. ICET 2017*, vol. 2018–Janua, pp. 1–6, 2017, doi: 10.1109/ICEngTechnol.2017.8308186.
- [15] A. C. Ian Goodfellow, Yoshua Bengio, “Deep learning,” *EEG Signal Process. Featur. Extr.*, pp. 1–800, 2019, doi: 10.1007/978-981-13-9113-2_16.