

Sistem Deteksi Penyakit Tanaman Padi berdasarkan Citra menggunakan Algoritma CNN berbasis Web

Rice Plant Disease Detection System based on Leaf Image using Web-based CNN Algorithm

¹Lisa Menden, ²Kristofel Santa*, ³Sondy Kumajas

^{1,2,3}Teknik Informatika, Teknik, Universitas Negeri Manado

^{1,2,3}Jl. Kampus Unima, Tonsaru, Kec, Tondano Selatan, Kab. Minahasa, Sulawesi Utara, 95618

*e-mail: kristofelsanta@gmail.com

(received: 12 January 2026, revised: 17 February 2026, accepted: 18 February 2026)

Abstrak

Padi (*Oryza sativa*) memegang peranan krusial sebagai komoditas pangan utama. Namun, penyakit seperti *Bacterial Blight*, *Brown Spot*, dan *Leaf Blast* dapat menyebabkan gagal panen yang signifikan. Metode identifikasi manual saat ini memiliki kelemahan pada subjektivitas tinggi dan waktu diagnosis yang lama. Penelitian ini mengusulkan sistem deteksi otomatis menggunakan *Convolutional Neural Network* (CNN) berbasis web. Dataset bersumber dari Kaggle dengan total 2.800 citra yang terdistribusi merata (700 citra per kelas). Data dibagi dengan rasio 80:20 untuk data latih dan validasi, serta melalui tahap pra-pemrosesan berupa *resizing* menjadi 224x224 piksel dan augmentasi data. Arsitektur CNN dirancang dengan empat blok konvolusi dan dioptimasi menggunakan *Adam optimizer*. Hasil pelatihan selama 50 *epoch* menunjukkan akurasi 77,50%, Presisi 82,98%, *Recall* 77,50%, dan *F1-score* 72,84%. Berdasarkan analisis *Confusion Matrix*, model mampu mendeteksi *Bacterial Blight* dan *Brown Spot* dengan sangat baik, namun masih mengalami kesulitan dalam mengidentifikasi kelas *Leaf Blast*. Berdasarkan hasil tersebut, sistem yang dikembangkan berpotensi menjadi alat bantu keputusan bagi petani, dengan catatan perlunya peningkatan performa lebih lanjut pada deteksi varian penyakit tertentu.

Kata kunci: *convolutional neural network* (CNN), *deep learning*, pengolahan citra digital, pertanian presisi, deteksi penyakit padi

Abstract

Rice (*Oryza sativa*) plays a crucial role as a major staple food commodity. However, diseases such as *Bacterial Blight*, *Brown Spot*, and *Leaf Blast* can cause significant crop losses. Current manual identification methods have limitations due to high subjectivity and long diagnosis time. This study proposes a web-based automatic detection system using a *Convolutional Neural Network* (CNN). The dataset was obtained from Kaggle and consisted of 2,800 images evenly distributed across four classes (700 images per class). The data were split using an 80:20 ratio for training and validation sets, followed by preprocessing steps including resizing to 224×224 pixels and data augmentation. The CNN architecture was designed with four convolutional blocks and optimized using the *Adam optimizer*. Training for 50 epochs achieved an accuracy of 77.50%, precision of 82.98%, recall of 77.50%, and an *F1-score* of 72.84%. Based on the confusion matrix analysis, the model performed very well in detecting *Bacterial Blight* and *Brown Spot* but still faced difficulties in identifying the *Leaf Blast* class. Overall, the developed system has the potential to serve as a decision-support tool for farmers, although further performance improvements are required, particularly for detecting specific disease variants.

Keywords: *convolutional neural network* (CNN), *deep learning*, digital image processing, precision agriculture, rice disease detection

1 Pendahuluan

Sektor pertanian merupakan pilar fundamental bagi stabilitas ekonomi nasional dan ketahanan pangan di Indonesia, di mana tanaman padi (*Oryza sativa*) menempati posisi paling strategis sebagai

<http://sistemasi.ftik.unisi.ac.id>

sumber makanan pokok bagi mayoritas penduduk. Namun, produktivitas padi nasional sering kali menghadapi tantangan berat akibat faktor eksternal yang sulit diprediksi. Data terbaru dari Badan Pusat Statistik (BPS) mengindikasikan bahwa fluktuasi hasil panen padi sangat dipengaruhi oleh anomali perubahan iklim dan intensitas serangan hama serta penyakit yang memerlukan strategi pengelolaan yang adaptif dan terukur [1]. Penyakit pada tanaman padi sering kali menjadi penyebab utama penurunan kualitas dan kuantitas gabah, sehingga upaya pengendalian Organisme Pengganggu Tanaman (OPT) menjadi prioritas yang mendesak bagi para pemangku kepentingan di sektor agraris [2].

Secara biologis, daun merupakan organ vital bagi tanaman padi karena berfungsi sebagai pusat fotosintesis. Serangan patogen pada daun dapat menghambat proses metabolisme tanaman secara drastis, yang pada akhirnya berdampak langsung pada pengisian bulir padi [3]. Di lapangan, identifikasi penyakit sering kali terlambat karena petani masih mengandalkan pengamatan visual manual yang sangat subjektif. Keterbatasan pengetahuan mengenai gejala spesifik penyakit dan minimnya jumlah penyuluh pertanian di daerah pedesaan sering menyebabkan kesalahan diagnosis, yang berujung pada penggunaan pestisida yang tidak tepat sasaran dan tidak efisien [4]. Oleh karena itu, diperlukan sebuah mekanisme deteksi yang lebih objektif dan dapat diakses dengan mudah untuk membantu petani mengambil keputusan pengendalian secara dini.

Perkembangan teknologi informasi menawarkan solusi konkret untuk mengatasi kendala tersebut. Implementasi sistem informasi berbasis web telah terbukti efektif dalam mendigitalisasi proses pengelolaan data pertanian, memungkinkan akses informasi yang cepat, akurat, dan tidak terbatas oleh kendala geografis [5]. Lebih jauh lagi, integrasi kecerdasan buatan (*Artificial Intelligence*) ke dalam sistem pertanian modern, atau yang dikenal dengan istilah *Smart Farming*, telah membuka peluang baru untuk meningkatkan presisi dalam pemantauan kesehatan tanaman [6]. Hal ini sejalan dengan visi pemerintah menuju pertanian Indonesia yang maju, mandiri, dan modern di era Revolusi Industri 4.0 [7].

Di antara berbagai metode kecerdasan buatan, *Deep Learning* dengan arsitektur *Convolutional Neural Network* (CNN) telah muncul sebagai standar emas dalam bidang visi komputer (*Computer Vision*). Kemampuan CNN untuk meniru cara kerja korteks visual otak manusia memungkinkannya mempelajari fitur-fitur kompleks dari citra digital secara mandiri (*feature learning*) [8]. Studi terdahulu menunjukkan bahwa CNN memiliki akurasi yang superior dalam mengenali pola visual penyakit tanaman dibandingkan metode konvensional, menjadikannya kandidat ideal untuk dikembangkan menjadi sistem deteksi otomatis [9]. Berdasarkan potensi tersebut, penelitian ini bertujuan untuk membangun sistem deteksi penyakit padi berbasis web yang mengintegrasikan model CNN terlatih, guna menyediakan alat bantu diagnosis yang akurat dan mudah digunakan oleh petani.

2 Tinjauan Literatur

Penerapan *Deep Learning* dalam ekosistem pertanian cerdas (*Smart Agriculture*) telah berkembang pesat sebagai solusi teknologi untuk mengatasi tantangan diagnosis penyakit tanaman yang kompleks. Dalam satu dekade terakhir, algoritma *Convolutional Neural Network* (CNN) telah mendominasi domain ini karena keunggulannya dalam mengekstraksi fitur visual secara otomatis dari citra digital tanpa memerlukan rekayasa fitur manual yang rumit [10]. Berbagai implementasi sistem cerdas, mulai dari yang berbasis pengolahan citra konvensional hingga yang terintegrasi dengan *Internet of Things* (IoT), telah membuktikan bahwa pendekatan komputasi modern mampu memberikan akurasi diagnosis yang setara atau bahkan melampaui kemampuan pengamatan mata manusia [11].


Sejumlah penelitian spesifik telah dilakukan untuk menguji efektivitas berbagai arsitektur CNN pada tanaman padi. Harakannavar *et al.* (2022) dan Shrivastava *et al.* (2019) sukses menerapkan teknik *Transfer Learning* menggunakan model pra-latih untuk mempercepat proses pelatihan. Penelitian mereka membuktikan bahwa model yang sudah ada dapat diadaptasi dengan baik untuk kasus baru sehingga proses komputasi menjadi lebih efisien [12], [13]. Sementara itu, Rahman *et al.* (2023) menekankan bahwa selain arsitektur model, variasi dan keseimbangan dataset memegang peranan vital dalam meningkatkan performa klasifikasi [14]. Sebagai pembanding, studi oleh Ananta *et al.* (2025) menggunakan metode *non-deep learning* seperti *K-Nearest Neighbor* (KNN) berbasis

fitur warna HSV juga menunjukkan hasil yang positif, namun CNN tetap unggul dalam menangkap pola tekstur yang lebih rumit [15].

Meskipun banyak kemajuan telah dicapai, tantangan teknis masih sering ditemui di lapangan. Daniya dan Vigneshwari (2020) menyoroti masalah utama berupa kemiripan visual antar gejala penyakit (*inter-class similarity*) yang sering memicu kesalahan klasifikasi [16]. Selain itu, mayoritas penelitian sebelumnya cenderung berhenti pada evaluasi model matematis semata tanpa menyentuh aspek hilirisasi menjadi aplikasi yang dapat digunakan pengguna akhir. Merespons kesenjangan tersebut, penelitian ini mengusulkan pengembangan sistem *end-to-end* yang tidak hanya melatih model CNN dengan dataset seimbang, tetapi juga mengintegrasikannya ke dalam aplikasi web menggunakan metode pengembangan *Extreme Programming* (XP). Pendekatan XP dipilih untuk menjamin fleksibilitas dan adaptabilitas sistem terhadap kebutuhan petani yang dinamis [17].

3 Metode Penelitian

Penelitian ini dilaksanakan melalui serangkaian tahapan sistematis untuk memastikan sistem yang dibangun mampu mendeteksi penyakit daun padi dengan akurasi tinggi dan dapat digunakan secara praktis. Alur kerja penelitian secara keseluruhan diilustrasikan pada Gambar 1, yang mencakup empat fase utama: pengumpulan data, pra-pemrosesan, pengembangan model kecerdasan buatan, dan integrasi sistem web.



Gambar 1. Diagram alur tahapan penelitian

Berdasarkan alur tersebut, rincian pelaksanaan setiap tahapan adalah sebagai berikut:

3.1. Pengumpulan Dataset

Tahapan awal dimulai dengan pengadaan data citra digital daun padi yang bersumber dari repositori publik Kaggle. Dataset ini dipilih karena memiliki kualitas citra yang baik dan pelabelan yang terverifikasi. Total data yang digunakan berjumlah 2.800 citra yang terdistribusi secara seimbang (*balanced dataset*) ke dalam empat kelas, yaitu *Bacterial Blight*, *Brown Spot*, *Leaf Blast*, dan *Healthy*, dengan masing-masing kelas terdiri dari 700 citra. Keseimbangan jumlah data ini sangat penting untuk mencegah kecenderungan model memprediksi kelas mayoritas (bias) dan memastikan akurasi yang objektif.

3.2. Pra-pemrosesan dan Augmentasi Data

Tahapan ini bertujuan untuk menyiapkan data mentah agar siap diproses oleh algoritma. Pertama, seluruh citra diubah ukurannya (*resizing*) menjadi dimensi seragam 224x224 piksel dan dilakukan normalisasi nilai piksel untuk mempercepat konvergensi model. Dataset kemudian dibagi (*split*) dengan rasio 80:20, menghasilkan 2.240 citra sebagai data latih dan 560 citra sebagai data validasi.

Selain itu, teknik augmentasi data diterapkan pada data latih untuk memperkaya variasi visual dan meningkatkan ketangguhan (*robustness*) model. Transformasi yang dilakukan meliputi rotasi acak hingga 20 derajat, pergeseran (*shifting*), perbesaran (*zoom*), dan pembalikan (*flip*) citra. Langkah ini penting agar model mampu mengenali penyakit dari berbagai sudut pandang dan kondisi pengambilan gambar yang bervariasi [18].

3.3. Perancangan dan pelatihan Model CNN

Arsitektur *Convolutional Neural Network* (CNN) dirancang dengan empat blok konvolusi bertingkat menggunakan pustaka Keras dan TensorFlow [19], [20]. Setiap blok terdiri dari lapisan konvolusi untuk ekstraksi fitur, fungsi aktivasi ReLU, serta lapisan *Max Pooling* dan *Dropout* untuk mereduksi dimensi dan mencegah *overfitting*.

Model dikonfigurasi menggunakan algoritma optimasi *Adam* (*Adaptive Moment Estimation*) yang efisien. Proses pelatihan dijalankan sebanyak 50 *epoch* dengan ukuran *batch* 32, menggunakan fungsi kerugian *Categorical Crossentropy* untuk mengukur akurasi klasifikasi pada empat kategori penyakit.

3.4. Pengembangan Sistem Web

Tahap akhir penelitian ini implementasi model terlatih ke dalam sistem aplikasi berbasis web. Sistem ini dibangun dengan arsitektur *client-server*, di mana sisi *backend* dikembangkan menggunakan *framework* Flask untuk menangani pemuatan model (*model loading*) dan proses inferensi citra [21]. Sisi *frontend* menyediakan antarmuka pengguna yang intuitif untuk mengunggah gambar dan menampilkan hasil diagnosis secara *real-time*. Pengembangan perangkat lunak mengikuti standar rekayasa sistem untuk memastikan aplikasi berjalan stabil dan mudah digunakan oleh petani [22].


4 Hasil dan Pembahasan

4.1. Hasil Pra-pemrosesan Data

Tahapan awal penelitian berhasil mengelola dataset citra daun padi sebanyak 2.800 sampel. Melalui proses pra-pemrosesan, seluruh citra telah divalidasi dan diubah ukurannya (*resized*) menjadi 224x224 piksel. Pembagian data (*splitting*) dengan rasio 80:20 menghasilkan distribusi yang siap digunakan untuk pelatihan, terdiri dari 2.240 citra latih dan 560 citra validasi. Penerapan teknik augmentasi pada data latih juga telah memperkaya variasi visual, memastikan model memiliki eksposur yang cukup terhadap berbagai kondisi rotasi dan posisi objek sebelum masuk ke tahap pelatihan inti.

4.2. Kinerja Model CNN

Setelah data siap, arsitektur CNN dilatih selama 50 *epoch*. Visualisasi proses pelatihan ditunjukkan pada Gambar 2, yang memperlihatkan grafik pergerakan akurasi (*Accuracy*) dan *Loss* pada data latih maupun validasi.




Gambar 2. Grafik model accuracy dan model loss training dan validasi

Berdasarkan grafik tersebut, model menunjukkan konvergensi yang stabil. Pada pengujian akhir menggunakan data validasi, model mencatatkan metrik performa sebagai berikut:

- Akurasi: 77,50%
- Presisi: 82,98%
- Recall: 77,50%
- F1-Score: 72,84%

Analisis mendalam dilakukan menggunakan *Confusion Matrix* untuk memetakan distribusi prediksi benar dan salah secara detail, sebagaimana disarankan dalam evaluasi model klasifikasi multikelas [23]. Oleh karena itu, evaluasi dilanjutkan menggunakan *Confusion Matrix* sebagaimana ditampilkan pada Gambar 3.



Gambar 3. Grafik confusion matrix hasil klasifikasi daun padi

Rincian prediksi untuk setiap kelas disajikan dalam Tabel 1. Analisis matriks ini mengungkap temuan menarik terkait karakteristik penyakit:


Tabel 1. Confusion matrix hasil klasifikasi daun padi

Kelas Prediksi \ Aktual	Bacterial Blight	Brown Spot	Healthy	Leaf Blast
Bacterial Blight (BB)	140	0	0	0
Brown Spot (BS)	0	140	0	0
Healthy (H)	0	0	135	5
Leaf Blast (LB)	0	0	121	19

Dari data di atas, terlihat bahwa model memiliki sensitivitas sempurna dalam mendeteksi *Bacterial Blight* dan *Brown Spot*, yang mengindikasikan bahwa fitur visual kedua penyakit ini (garis basah kekuningan dan bercak oval) sangat khas dan berhasil diekstraksi dengan baik oleh CNN. Sebaliknya, tantangan signifikan ditemukan pada kelas *Leaf Blast*, di mana sebagian besar citra (121 sampel) salah diprediksi sebagai kondisi sehat (*Healthy*). Hal ini kemungkinan disebabkan oleh kemiripan visual yang tinggi antara gejala awal *Leaf Blast* (bercak kecil) dengan tekstur daun sehat pada resolusi input yang digunakan.


4.3. Implementasi Sistem Web

Sebagai langkah hilirisasi, model terbaik yang diperoleh diintegrasikan ke dalam sistem aplikasi berbasis web. Hasil implementasi antarmuka pengguna ditampilkan pada rangkaian gambar berikut.



Gambar 4. Halaman utama


Halaman utama (Gambar 4) dirancang dengan pendekatan minimalis, menampilkan menu navigasi di sisi kiri dan panel informasi pintas di bagian tengah untuk memudahkan akses pengguna. Untuk melakukan diagnosis, pengguna diarahkan ke halaman unggah citra (Gambar 5).



Gambar 5. Halaman upload citra

Pada halaman halaman ini, fitur *drag & drop* diterapkan untuk mempermudah proses input data. Setelah citra diunggah dan diproses, sistem menampilkan hasil diagnosis secara *real-time* seperti terlihat pada Gambar 6. Informasi yang disajikan mencakup jenis penyakit yang terdeteksi serta skor keyakinan (*confidence score*) yang transparan, memungkinkan petani untuk menilai tingkat validitas prediksi sistem.

1. Visualisasi Hasil



Gambar 6. Hasil deteksi

Hasil Pengujian fungsional menggunakan metode *Black Box Testing* mengonfirmasi bahwa seluruh fitur, mulai dari proses *login*, unggah gambar, hingga penampil hasil prediksi, berjalan lancar tanpa kendala teknis atau *error* [24]. Dalam simulasi penggunaan riil, sistem mampu memberikan hasil diagnosis beserta skor akurasi dalam waktu rata-rata di bawah 5 detik, sehingga memenuhi standar efisiensi untuk kebutuhan operasional di lapangan.

5 Kesimpulan

Penelitian ini berhasil menjawab tujuan utamanya melalui pengembangan sistem deteksi penyakit padi berbasis web menggunakan algoritma *Convolutional Neural Network* (CNN) yang terbukti mampu melakukan diagnosis visual secara otomatis dan *real-time*. Temuan kunci dari evaluasi model menunjukkan pencapaian akurasi sebesar 77,50% dengan performa sempurna dalam mendeteksi *Bacterial Blight* dan *Brown Spot*, meskipun masih ditemukan tingkat kesalahan yang signifikan pada identifikasi *Leaf Blast* yang sering terprediksi sebagai kondisi sehat. Secara implikasi, sistem ini memberikan kontribusi praktis sebagai alat bantu keputusan yang efisien bagi petani untuk pengendalian dini hama, serta memperkaya literatur teoritis mengenai efektivitas penggunaan *balanced dataset* dalam pelatihan *deep learning*. Kendati demikian, penelitian ini memiliki keterbatasan pada resolusi input yang menyebabkan model kesulitan menangkap fitur visual halus pada varian penyakit tertentu. Oleh karena itu, direkomendasikan strategi perbaikan melalui penerapan teknik segmentasi citra atau eksplorasi arsitektur *state-of-the-art* seperti ResNet guna meningkatkan sensitivitas deteksi, serta pengembangan aplikasi *mobile* untuk mendukung aksesibilitas penggunaan secara *offline* di lahan pertanian.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih yang sebesar-besarnya kepada komunitas Kaggle atas penyediaan dataset publik yang sangat berharga bagi perkembangan riset *computer vision*.

Referensi

- [1] Badan Pusat Statistik, "Luas Panen dan Produksi Padi di Indonesia 2023 (Angka Sementara)," *Berita Resmi Statistik*, No. 75/10/Th. XXVI, Jakarta: BPS, 2023.
- [2] A. S. Putra and H. A. Wibawa, "Sistem Pakar Diagnosa Penyakit Tanaman Padi menggunakan Metode *Certainty Factor*," *Jurnal Ilmiah Informatika*, Vol. 7, No. 1, pp. 25–32, 2019, DOI: 10.33884/jif.v7i1.921.
- [3] H. Semangun, *Penyakit-Penyakit Tanaman Pangan di Indonesia*. Yogyakarta: Gadjah Mada University Press, 2008.
- [4] D. Nugraha and R. W. Pratiwi, "Identifikasi Penyakit Padi berdasarkan Citra Daun menggunakan *Algoritma K-Nearest Neighbor*," *Jurnal Algoritma*, Vol. 18, No. 2, pp. 450–458, 2021, DOI: 10.33364/algoritma.v18i2.921.
- [5] M. Glen, "Implementasi Sistem Informasi berbasis Web untuk meningkatkan Efisiensi Pengelolaan Data," *Journal of Informatics, Business, Education, and Innovation Technology*, Vol. 18, No. 1, 2022, DOI: 10.18196/st.v18i1.708.
- [6] S. Kusumadewi, *Artificial Intelligence (Teknik dan Aplikasinya)*. Yogyakarta: Graha Ilmu, 2003.
- [7] R. R. Rachmawati, "Smart Farming 4.0 untuk mewujudkan Pertanian Indonesia Maju, Mandiri, dan Modern," *Forum Penelitian Agro Ekonomi*, Vol. 38, No. 2, pp. 137–154, 2020, DOI: 10.21082/fae.v38n2.2020.137-154.
- [8] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. Cambridge: MIT Press, 2016.
- [9] B. Santoso and I. Kurniawan, "Penerapan *Deep Learning* untuk Klasifikasi Hama Tanaman Padi menggunakan Metode CNN," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, Vol. 4, No. 4, pp. 780–787, 2020, DOI: 10.29207/resti.v4i4.2201.
- [10] P. K. R., V. Deshmukh, S. U. Bhandari, R. Raut, and R. Kharat, "Rice Leaf Disease Detection using *Convolutional Neural Network*," *International Journal on Recent and Innovation Trends in Computing and Communication*, Vol. 11, No. 5s, pp. 136–141, 2023, DOI: 10.17762/ijritcc.v11i5s.6636.
- [11] Md. J. Hasan et al., "An IoT based System with Edge Intelligence for Rice Leaf Disease Detection using Machine Learning," in *2021 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)*, 2021, pp. 1–6, DOI: 10.1109/IEMTRONICS52119.2021.9422587.

- [12] S. S. Harakannanavar, J. M. Rudagi, V. I. Puranikmath, A. Siddiqua, and R. Pramodh, "Rice Leaf Disease Detection with Transfer Learning Approach," in *2022 IEEE International Conference on Distributed Computing, VLSI, Electrical Circuits and Robotics (DISCOVER)*, 2022, pp. 206–211, DOI: 10.1109/DISCOVER55800.2022.9974955.
- [13] V. K. Shrivastava, M. K. Pradhan, S. Minz, and M. P. Thakur, "Rice Plant Disease Classification using Transfer Learning of Deep Convolution Neural Network," *Int. Arch. Photogramm. Remote Sens. Spatial Inf. SCI.*, Vol. XLII-3/W6, pp. 297–304, 2019, DOI: 10.5194/isprs-archives-XLII-3-W6-297-2019.
- [14] C. R. Rahman *et al.*, "Identification of Various Rice Plant Diseases using Optimized Convolutional Neural Network," *Agriculture*, Vol. 13, No. 8, p. 1505, 2023, DOI: 10.3390/agriculture13081505.
- [15] A. Ananta, S. C. Kumajas, and E. Moningkey, "Sistem Klasifikasi Tingkat Kematangan Cabai Rawit menggunakan Algoritma K-Nearest Neighbor (KNN) berbasis Web," *IKRAITH-INFORMATIKA*, Vol. 9, No. 3, pp. 216–224, 2025, DOI: 10.37817/ikraith-informatika.v9i3.
- [16] T. Daniya and S. Vigneshwari, "Rice Leaf Diseases Classification using CNN with Transfer Learning," in *2020 IEEE Calcutta Conference (CALCON)*, 2020, pp. 215–220, DOI: 10.1109/CALCON49167.2020.9106540.
- [17] K. Santa, S. Ropa, and E. R. S. Moningkey, "Pengembangan Sistem Informasi Inventaris Barang berbasis Web menggunakan Metode Extreme Programming (XP)," *Journal of Informatics, Business, Education, and Innovation Technology*, Vol. 2, No. 1, 2023.
- [18] T. Wibowo, "Analisis Efek Augmentasi Data pada Klasifikasi Citra Digital menggunakan Convolutional Neural Network," *Indonesian Journal of Computer Science*, Vol. 9, No. 2, pp. 112–120, 2020, DOI: 10.33022/ijcs.v9i2.285.
- [19] F. Chollet, *Deep Learning with Python*, 2nd ed. Manning Publications, 2021.
- [20] I. P. Sari and D. A. P. Putri, "Implementasi Library Keras dan TensorFlow untuk Pengenalan Pola Citra Digital," *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, Vol. 4, No. 9, pp. 3021–3028, 2020.
- [21] S. Riyadi, "Pengembangan Aplikasi Web Deteksi Penyakit Tanaman berbasis Framework Flask dan TensorFlow," *Jurnal Teknologi Informasi dan Ilmu Komputer (JTIK)*, Vol. 8, No. 5, pp. 985–994, 2021, DOI: 10.25126/jtiik.202185457.
- [22] R. S. Pressman, *Software Engineering: A Practitioner's Approach*, 8th ed. New York: McGraw-Hill Education, 2014.
- [23] R. Lestari, "Evaluasi Kinerja Model Klasifikasi menggunakan Confusion Matrix dan ROC Curve," *Jurnal Statistika dan Komputasi*, Vol. 5, No. 1, pp. 34–42, 2021, DOI: 10.32665/jsk.v5i1.255.
- [24] A. Hidayat and M. K. Anam, "Pengujian Black Box pada Aplikasi Sistem Informasi Akademik menggunakan Teknik Equivalence Partitioning," *Jurnal Informatika Terpadu*, Vol. 6, No. 2, pp. 89–95, 2020, DOI: 10.54914/jit.v6i2.255.