

Model Deteksi Penyakit Padi yang Efektif Berbasis Deep Learning

Taryadi^{1*}, Era Yuniyanto², Hari Agung Budijanto³

¹²³ Sistem Informati, Fakultas Teknologi Informasi, Institut Widy Pratama, Pekalongan, Indonesia

^{1*} tari_ball@stmik-wp.ac.id, ² era.yuniyanto@gmail.com, ³ penulis3@email

ABSTRACT – In Indonesia, rice is a vital crop for both export and home consumption. For farmers, the frequency of rice infections presents a problem since it affects yields and may result in losses. Since human disease detection requires skill, early diagnosis is essential to preserving the health of rice plants. A method that combined augmentation and dilation rates was employed to address the dataset's small quantity of rice leaf images. One possible method for effectively diagnosing leaf diseases is the application of machine learning techniques. Nevertheless, issues with picture background, inadequate imaging data, and symptom variation plague current approaches. By using a Convolutional Neural Network (CNN) model designed especially for rice leaf pictures, this study successfully increased the accuracy of illness categorization. Three different disease classes were effectively detected and diagnosed using the suggested method: bacterial leaf blight, brown spot, and leaf spot. After a number of training iterations, the accuracy rate using the Convolutional Neural Network model of 92.63% was the most profitable.

Keywords: Rice Leaf; Deep learning; Detection; Classification;

ABSTRAK – Padi merupakan tanaman utama di Indonesia yang krusial bagi konsumsi masyarakat domestik maupun ekspor. Prevalensi infeksi padi menjadi tantangan tersendiri bagi petani dan memiliki dampak pada hasil panen dan dapat mengakibatkan kerugian. Identifikasi penyakit oleh manusia bergantung pada keahlian, sehingga diagnosis dini menjadi krusial untuk menjaga kesehatan tanaman padi. Untuk mengatasi keterbatasan jumlah citra daun padi dalam dataset, pendekatan yang digunakan dengan menggabungkan augmentasi dan laju dilasi. Penggunaan algoritma pembelajaran mesin menawarkan solusi yang menjanjikan untuk mendiagnosis penyakit daun pada secara efisien. Namun, metode yang ada menghadapi tantangan seperti latar belakang citra, data citra yang tidak memadai, dan variasi gejala. Penelitian ini memanfaatkan model Jaringan Saraf Tiruan Konvolusional (CNN) khusus untuk foto daun padi, yang secara efektif meningkatkan akurasi klasifikasi penyakit. Pendekatan yang diusulkan berhasil mengidentifikasi dan mendiagnosis tiga kelas berbeda: penyakit bercak daun, bercak cokelat, dan hawar daun bakteri. Setelah sejumlah iterasi pelatihan, tingkat akurasi dengan menggunakan model Jaringan Saraf Tiruan Konvolusional sebesar 92,63% adalah yang paling menguntungkan.

Kata Kunci: Deep learning; Deteksi; Klasifikasi; Penyakit Padi.

1. PENDAHULUAN

Padi, yang menempati peringkat pertama dalam hal luas tanam dan produksi di Indonesia, merupakan salah satu tanaman pangan terpenting di dunia. Padi merupakan sumber daya utama bagi jutaan orang di Asia. Pada tahun 2024, budidaya padi mencakup sekitar 21% dari seluruh lahan pertanian. Perlu diketahui, 114 dari 193 negara menanam padi, dengan 90% produksi dan konsumsi beras global terkonsentrasi di Asia. Produksi padi menjadi sangat penting dalam menjamin ketahanan pangan, terutama di Indonesia [1].

Untuk meningkatkan hasil panen padi, program pengendalian penyakit yang efektif sangat penting. Diagnosis dini di lapangan merupakan langkah awal dalam mengendalikan penemuan dan penyebaran penyakit padi. Namun, mengidentifikasi penyakit padi saat ini bergantung pada keahlian ahli patologi tanaman atau petani [2], [3]. Identifikasi yang tepat waktu sangat penting untuk mempertahankan produksi padi, sehingga memungkinkan penggunaan metode pengendalian pestisida [1].

Memprediksi dan memperkirakan penyakit yang menyerang daun padi sangat penting untuk menjaga kuantitas dan kualitas [4]. Deteksi dini memfasilitasi intervensi tepat waktu, mencegah perkembangan penyakit, dan mendorong pertumbuhan tanaman yang sehat, yang pada akhirnya meningkatkan produksi padi. Penyakit padi yang umum meliputi hawar pelepah, hawar bakteri, blas padi, hawar daun bakteri, bercak cokelat, dan bercak daun [2].

Semakin banyaknya aplikasi berbasis deep learning [5] telah mendorong para peneliti untuk mengeksplorasi potensinya dalam mengatasi deteksi penyakit padi. Salah satunya yang dilakukan oleh Naji [6] dengan model VGG-16 pada kumpulan data untuk mendeteksi enam kelas penyakit dan mencapai akurasi 96,08%. Namun, ketergantungan pada model CNN yang tersedia secara komersial menimbulkan batasan yang signifikan. Demikian pula Latief et.al. [7] yang menggunakan berbagai model pada kumpulan data yang berisi sembilan penyakit padi umum, mencapai akurasi 98%, namun demikian ketergantungan pada model CNN menimbulkan kekhawatiran memilih jaringan saraf konvolusional (CNN) untuk mengekstraksi fitur dari

gambar daun padi, sebagai alternatif Jiang [8] menggunakan SVM untuk klasifikasi dan mencapai akurasi 96,8%. Model CNN membutuhkan metodologi kompleks yang melibatkan ekstraksi fitur sebelum klasifikasi. Demikian pula yang dilakukan Lu et.al. [9] yang mengusulkan pendekatan pembelajaran mendalam untuk mengidentifikasi 10 penyakit padi umum, mencapai akurasi 95,48% dengan CNN. Sementara itu, Mathulapransan et.al. [10] mencapai akurasi 98% menggunakan ResNets dan DenseNets pada database K5RD tetapi hasil nilai akurasi yang kurang signifikan dan mengandalkan model CNN yang sudah ada [11].


Diagnosis secara tradisional bergantung pada analisis visual, sebuah metode yang mahal, padat karya, dan memakan waktu [12]. Kemajuan terkini, yang memanfaatkan deep learning dan kecerdasan buatan, menawarkan alternatif yang efisien dan hemat biaya untuk diagnosis dini penyakit di berbagai bidang pertanian.

Artikel ini menyajikan metodologi komprehensif untuk meningkatkan akurasi klasifikasi penyakit daun padi [13].

Dengan memanfaatkan model Jaringan Saraf Tiruan Konvolusional (CNN) [14] yang dirancang khusus untuk citra daun padi, pendekatan yang diusulkan dapat mengidentifikasi penyakit hawar daun bakteri, bercak coklat, dan bercak daun dengan andal. Mengatasi tantangan dataset yang terbatas, diatasi dengan menerapkan beragam teknik augmentasi citra dan menyesuaikan dimensi kernel pada lapisan konvolusional model CNN tanpa mengubah parameter.

2. METODOLOGI

Bagian ini akan memberikan analisis terperinci mengenai metodologi yang mendasari pendekatan yang direkomendasikan untuk mengidentifikasi penyakit padi. Tahapan utama prosedur ini digambarkan pada (Gambar 1).



Gambar 1. Kerangka Umum Model yang diusulkan


Prapemrosesan adalah langkah pertama dalam metodologi yang diusulkan, yang bertujuan untuk menyiapkan citra masukan untuk langkah selanjutnya dan memastikan berfungsi dengan teknik yang disarankan [15]. Tahap ini mencakup operasi seperti mengubah ukuran citra masukan dan memperbaikinya. Setelah itu, penjelasan detail tentang semua lapisan dalam model berbasis CNN yang dirancang khusus untuk citra penyakit padi akan diberikan. Lapisan masukan, konvolusi, unit fungsi aktivasi, penggabungan, terhubung penuh (FC), dan keluaran merupakan beberapa lapisan yang membentuk model. Tahap pertama adalah menyiapkan lapisan masukan agar dapat menerima citra penyakit padi berukuran 224x224 piksel. Selanjutnya, penerapan lapisan konvolusional dilakukan. Dalam konteks ini, disarankan dua lapisan konvolusi, dan keduanya membantu dalam analisis fitur citra penyakit padi. Masing-masing lapisan konvolusi ini memiliki fungsi aktivasi yang disebut unit linier penyearah (LeakyReLU). Setiap lapisan konvolusi individual diikuti oleh lapisan

penggabungan dalam proses konvolusi. Lapisan ini secara efisien meminimalkan ukuran data dengan memanfaatkan operasi windowing dan maksimum. Arsitektur dilanjutkan dengan pengenalan lapisan perataan (flatten layer). Lapisan khusus ini mengubah data dua dimensi menjadi representasi satu dimensi. Setelah itu, pengklasifikasi digunakan. Metode pembelajaran mendalam yang disebut pengklasifikasi SoftMax disesuaikan untuk mengakomodasi jumlah kategori. Metode ini sering diterapkan pada permasalahan yang melibatkan banyak klasifikasi. Evaluasi empiris digunakan untuk menentukan dimensi ideal dari desain CNN yang disarankan [16]. Hal ini memerlukan peningkatan elemen konvolusional dan pengumpulan maksimum secara bertahap, kemudian menyesuaikan jumlah filter secara metodis. Jaringan dengan kinerja terbaik adalah jaringan yang pada akhirnya akan dipilih. Tabel 1 memberikan garis besar struktur CNN yang disarankan.

Tabel 1. Ringkasan arsitektur CNN yang diusulkan

Layer	Ukuran Filter	Aktivasi	No. Filter	Input	output	Parameter
Conv1	3x3	Leaky ReLU	20	224,224,3	220, 220, 20	560
Max Pool 2D	4x4	-	-	220, 220, 20	55,55,20	0
Conv2	3x3	Leaky ReLU	10	55, 55, 20	51, 51,10	1810
Max Pool 2D	2x2	-	-	51, 51, 10	12, 12, 10	0
Flatten	-	-	-	-	1440	0
Full Connec	-	Leaky ReLU	256	1440	256	253
Drop Out	0,5	-	-	256	256	0
Out Layer	-	SoftMax	-	256	3	771
Total Parameter : 372037						
Parameter Training : 372037						

Selain itu, (Gambar 2) menunjukkan arsitektur yang mendasari model CNN yang diusulkan.




Gambar 2. Arsitektur pendekatan yang diusulkan

3. HASIL DAN PEMBAHASAN

Dengan menggunakan lingkungan Python3 dari Google Colab, pendekatan yang direkomendasikan untuk memverifikasi penyakit padi dijalankan pada GPU Nvidia Tesla K80 dengan RAM 12GB dan memori 16GB. Basis data penyakit padi dari [15] di Kaggle digunakan untuk menilai efektivitas metode yang disarankan. Ukuran efikasi keseluruhan dari teknik pengenalan yang diusulkan adalah metrik dan akurasi F1_score.

3.1 Dataset

Terdapat 120 citra jpeg daun padi yang terserang penyakit (bercak daun, bercak cokelat, dan hawar daun bakteri) dalam basis data penyakit padi yang digunakan. Berdasarkan jenis penyakitnya, citra dibagi menjadi tiga kelas. Setiap kelas berisi empat puluh citra. Gambar 3 menggunakan contoh foto untuk menunjukkan beberapa kesulitan dalam basis data yang digunakan.



Gambar 3. Contoh gambar marker dalam database

3.2 Evaluasi Kinerja Teknik yang Diusulkan melalui Akurasi dan Skor F1


Basis data diproses terlebih dahulu untuk meningkatkan resolusi gambar, dan kumpulan data dibagi menjadi dua bagian: 20% digunakan untuk pengujian dan 80% digunakan untuk pelatihan. Jumlah gambar yang terbatas, yang menghadirkan masalah signifikan dalam pelatihan model CNN, diatasi dengan menerapkan teknik augmentasi sebelum menggabungkan foto ke dalam model pelatihan. Fungsi Softmax digunakan sebagai metode klasifikasi selama fase pelatihan pada platform pembelajaran mendalam Keras. Pelatihan dilakukan sebanyak 100 epoch dan fungsi Leaky_ReLU untuk menginisialisasi

bobot setiap lapisan konvolusi. Untuk menentukan parameter model yang ideal, sejumlah besar eksperimen dirancang dan diperiksa. Setelah sejumlah iterasi pelatihan, tingkat akurasi 92,63% adalah yang paling menguntungkan. Hasil ini terjadi ketika 20 kernel digunakan dalam lapisan konvolusi pertama dan 10 kernel digunakan dalam lapisan konvolusi kedua. Dimensi kernel untuk konvolusi pertama dan kedua adalah 3x3, dengan menggunakan Maxpooling 4x4. Teknik *dilation_rate* juga digunakan untuk mengatasi overfitting, karena lebih dari satu dimensi diuji dan hasilnya dibandingkan untuk mencapai akurasi tertinggi. Hasil evaluasi berbagai parameter jaringan diuraikan dalam (Tabel 2). Tabel ini secara sistematis menilai parameter lapisan konvolusi dan pooling, dengan memvariasikan *dilation_rate* sambil menjaga parameter lainnya tetap konstan. Metrik evaluasi untuk teknik yang diusulkan mencakup akurasi dan skor F1.

Tabel 2. Hasil kinerja penilaian teknik yang diusulkan

No Conv1	Max P1	Dil Rate	No Conv 2	Max P2	Dil Rate	Akurasi	F1 Score
20	4x4	2, 2	10	4x4	2, 2	92,33	91,29
20	3x3(20)	2, 2	10	4x4	4, 4	90,11	90,00
20	3x3(20)	4, 4	10	4x4	4, 4	91,70	90,50
20	3x3(20)	2, 2	10	4x4	6, 6	88,23	88,23
20	3x3(20)	4, 4	10	4x4	6, 6	89,62	88,24
20	3x3(20)	6, 6	10	4x4	6, 6	87,15	86,41

Hubungan antara jumlah iterasi yang digunakan selama proses pelatihan dan akurasi jaringan yang direkomendasikan juga digambarkan dalam (Gambar 4).



Gambar 4. Akurasi model yang diusulkan


Grafik yang ditampilkan menunjukkan peningkatan akurasi awal yang signifikan. Setelah itu, peningkatan yang stabil terlihat sekitar epoch ke-20. Akurasi kemudian menunjukkan osilasi antara epoch ke-20 dan ke-88 sebelum stabil di sekitar epoch ke-88.

4. KESIMPULAN

Penelitian ini mengkaji penerapan Jaringan Saraf Tiruan Konvolusional (CNN) untuk mengidentifikasi penyakit padi, dengan menekankan tantangan yang ditimbulkan oleh kumpulan data citra yang terbatas. Percobaan ini menggunakan kumpulan data 120 citra yang mewakili tiga jenis penyakit padi. Keefektifan CNN

3.3 Visualisasi Konvolusional Layer melalui Teknik Peta Fitur

Pada bagian ini, yang dilakukan adalah mengevaluasi dan mempelajari prediksi model menggunakan teknik peta fitur. Metode ini memudahkan pemahaman bagaimana model mempelajari berbagai filter dan bagaimana masukan bergerak melalui berbagai tingkatan. Diasumsikan bahwa peta fitur yang lebih dekat dengan masukan menangkap detail yang kecil atau halus, sedangkan peta fitur yang lebih dekat dengan keluaran model menangkap fitur yang lebih besar. Peta fitur visual dari lapisan konvolusional pertama, yang terdiri dari 20 filter, ditunjukkan pada (Gambar 5). Grafik berikut mengilustrasikan beragam karakteristik yang dihasilkan ketika filter pada lapisan konvolusional pertama diterapkan.



Gambar 5. Visualisasi Peta Fitur di Lapisan Konvolusi Awal dengan 20 Filter Interpretabilitas

dalam ekstraksi fitur, pembelajaran pola yang rumit, dan generalisasi dari kumpulan data representatif menghasilkan tingkat keberhasilan 92% yang patut dipuji dalam pengenalan penyakit padi. Selain itu, penelitian ini mengkaji dampak teknologi *dilation_rate* terhadap hasil model yang disarankan. Secara keseluruhan, temuan ini memberikan wawasan optimis dalam mengatasi tantangan terkait identifikasi penyakit padi dari kumpulan

foto yang terbatas. Integrasi dengan teknologi drone di bidang pertanian dapat semakin meningkatkan deteksi penyakit padi.

5. UCAPAN TERIMA KASIH

Penelitian ini didanai oleh Direktorat Riset, Teknologi, dan Pengabdian kepada Masyarakat,

- [1] H. Herdiyanti, Eko Sulistyono, and Purwono, "Pertumbuhan dan Produksi Beberapa Varietas Padi (*Oryza sativa* L.) pada Berbagai Interval Irigasi," *Jurnal Agronomi Indonesia (Indonesian Journal of Agronomy)*, vol. 49, no. 2, pp. 129–135, Sep. 2021, doi: 10.24831/jai.v49i2.36558.
- [2] M. Ulfi, M. I. A. Supriyanto, C. M. Sari, and S. A. Nuswantoro, "Identifikasi Penyakit pada Tanaman Padi Menggunakan Convolutional Neural Network (CNN)," *Jurnal Sains Komputer dan Teknologi Informasi*, vol. 7, no. 2, pp. 89–96, May 2025, doi: 10.33084/jsakti.v7i2.10061.
- [3] R. Sharma *et al.*, "Plant Disease Diagnosis and Image Classification Using Deep Learning," *Computers, Materials & Continua*, vol. 71, no. 2, pp. 2125–2140, 2022, doi: 10.32604/cmc.2022.020017.
- [4] A. Nayak, S. Chakraborty, and D. K. Swain, "Application of smartphone-image processing and transfer learning for rice disease and nutrient deficiency detection," *Smart Agricultural Technology*, vol. 4, p. 100195, Aug. 2023, doi: 10.1016/j.atech.2023.100195.
- [5] N. W. D. Ayuni, W. H. Utthavi, and N. N. Lasmini, "Artificial Neural Networks: A Deep Learning Approach in Financial Distress Prediction," 2024, pp. 99–108. doi: 10.2991/978-94-6463-587-4_12.
- [6] D. S. Alwan and Mohammed. H. Naji, "Rice Diseases Classification by Residual Network 50 (RESNET50) and Support Vector Machine (SVM) Modeling," *Journal of Kufa for Mathematics and Computer*, vol. 10, no. 1, pp. 96–101, Mar. 2023, doi: 10.31642/JoKMC/2018/100114.
- [7] G. Latif, S. E. Abdelhamid, R. E. Mallouhy, J. Alghazo, and Z. A. Kazimi, "Deep Learning Utilization in Agriculture: Detection of Rice Plant Diseases Using an Improved CNN Model," *Plants*, vol. 11, no. 17, p. 2230, Aug. 2022, doi: 10.3390/plants11172230.

Direktorat Jenderal Pendidikan Tinggi Riset dan Teknologi, Kementerian Pendidikan, Kebudayaan, Riset dan Teknologi tahun anggaran 2025 melalui skema penelitiia dosen pemula.

DAFTAR PUSTAKA

- [8] F. Jiang, Y. Lu, Y. Chen, D. Cai, and G. Li, "Image recognition of four rice leaf diseases based on deep learning and support vector machine," *Comput Electron Agric*, vol. 179, p. 105824, Dec. 2020, doi: 10.1016/j.compag.2020.105824.
- [9] Y. Liu, X. Yu, J. X. Huang, and A. An, "Combining integrated sampling with SVM ensembles for learning from imbalanced datasets," *Inf Process Manag*, vol. 47, no. 4, pp. 617–631, 2011, doi: <https://doi.org/10.1016/j.ipm.2010.11.007>.
- [10] S. Mathulapransan, K. Lanthong, D. Jetpipattanapong, S. Sateanpattanakul, and S. Patarapuwadol, "Rice Diseases Recognition Using Effective Deep Learning Models," in *2020 Joint International Conference on Digital Arts, Media and Technology with ECTI Northern Section Conference on Electrical, Electronics, Computer and Telecommunications Engineering (ECTI DAME & NCON)*, IEEE, Mar. 2020, pp. 386–389. doi: 10.1109/ECTIDAMTNCN48261.2020.9090709.
- [11] V. Rajpoot, A. Tiwari, and A. S. Jalal, "Automatic early detection of rice leaf diseases using hybrid deep learning and machine learning methods," *Multimed Tools Appl*, vol. 82, no. 23, pp. 36091–36117, Sep. 2023, doi: 10.1007/s11042-023-14969-y.
- [12] K. M, V. D, M. K. Nath, and M. M, "Machine Learning Approaches for Automatic Disease Detection from Paddy Crops - A Review," *International Journal of Engineering Trends and Technology*, vol. 70, no. 12, pp. 392–405, Dec. 2022, doi: 10.14445/22315381/IJETT-V70I12P237.
- [13] F. H. Hawari, F. Fadillah, M. R. Alviandi, and T. Arifin, "KLASIFIKASI PENYAKIT TANAMAN PADI MENGGUNAKAN ALGORITMA CNN (CONVOLUTIONAL NEURAL NETWORK)," *Jurnal Responsif: Riset*

- Sains dan Informatika*, vol. 4, no. 2, pp. 184–189, Aug. 2022, doi: 10.51977/jti.v4i2.856.
- [14] Y. Irmak, E. Akyumuk, G. Çetin, and S. Sani Bozkurt, *Otizm Spektrum Bozukluğunda Yapay Zekâ Kullanımı: Sistematik Alanyazın Taraması*. 2024.
- [15] N. Japkowicz and M. Shah, *Evaluating Learning Algorithms*. Cambridge University Press, 2011. doi: 10.1017/CBO9780511921803.
- [16] P. N. Tan, M. Steinbach, and V. Kumar, *Introduction to Data Mining*. Pearson Education India, 2016.