

PENERAPAN CONVOLUTIONAL NEURAL NETWORK UNTUK IDENTIFIKASI PENYAKIT PADA TANAMAN PADI DARI CITRA DAUN MENGGUNAKAN MODEL RESNET-101

Muhammad Sidiq Pramono¹, Adityo Permana Wibowo²

¹Informatika, Fakultas Sains dan Teknologi, Universitas Teknologi Yogyakarta, Indonesia

²Sistem Informasi, Fakultas Sains & Teknologi, Universitas Teknologi Yogyakarta, Indonesia

Article Info

Article history:

Received: 28 Oktober 2024

Revised: 30 Oktober 2024

Accepted: 31 Oktober 2024

ABSTRACT

Abstrak

Penyakit pada tanaman padi merupakan salah satu faktor utama yang dapat menurunkan produktivitas dan kualitas hasil panen. Jika tidak ditangani dengan tepat, hal ini dapat menyebabkan kerugian ekonomi bagi para petani. Deteksi dini penyakit padi sangat penting, namun identifikasi manual oleh para ahli seringkali memakan waktu dan rentan terhadap kesalahan manusia. Untuk mengatasi masalah ini, penelitian ini mengusulkan penerapan Convolutional Neural Network (CNN) dengan arsitektur ResNet-101 untuk mengklasifikasikan penyakit pada tanaman padi berdasarkan citra daun secara otomatis. Langkah-langkah yang dilakukan meliputi pengumpulan data citra daun padi, preprocessing data, pembagian dataset, pelatihan model CNN, evaluasi model, serta implementasi model ke dalam sistem berbasis web. Hasil penelitian yang dilakukan menunjukkan bahwa model CNN ResNet-101 yang dibangun mampu mencapai akurasi 76.05% dalam mengklasifikasikan 4 kondisi daun padi (sehat, bercak coklat, blast daun, hispa) pada data validasi. Sistem ini diharapkan dapat membantu petani dalam mendeteksi penyakit tanaman padi secara dini dan akurat, sehingga tindakan pencegahan dan penanganan dapat dilakukan dengan tepat waktu.

Kata Kunci: Penyakit tanaman padi, Convolutional Neural Network, ResNet-101, Klasifikasi citra, Deteksi Dini.

Abstract

Rice plant diseases are one of the main factors that can reduce productivity and harvest quality. If not handled properly, this can cause economic losses for farmers. Early detection of rice diseases is crucial, however manual identification by experts is often time-consuming and prone to human error. To address this issue, this research proposes the implementation of Convolutional Neural Network (CNN) with ResNet-101 architecture to automatically classify rice plant diseases based on leaf images. The steps involved include collecting rice leaf image data, data preprocessing, dataset splitting, CNN model training, model evaluation, and model implementation into a web-based system. The research results show that the developed CNN ResNet-101 model achieved 76.05% accuracy in classifying 4 rice leaf conditions (healthy, brown spot, leaf blast, hispa) on validation data. This system is expected to help farmers detect rice plant diseases early and accurately, so that preventive measures and treatments can be carried out in a timely manner.

Keywords: Rice plant diseases, Convolutional Neural Network, ResNet-101, Image classification, Early Detection.

Djtechno: Jurnal Teknologi Informasi oleh Universitas Dharmawangsa Artikel ini bersifat open access yang didistribusikan di bawah syarat dan ketentuan dengan Lisensi

Internasional Creative Commons Attribution NonCommercial
ShareAlike 4.0 ([CC-BY-NC-SA](https://creativecommons.org/licenses/by-nc-sa/4.0/)).



Corresponding Author:

E-mail : sdigprmo.1@gmail.com

1. PENDAHULUAN

Tantangan global seperti keamanan pangan dan perubahan iklim telah mendorong pentingnya pengembangan teknologi dalam bidang pertanian. Salah satu permasalahan utama yang dihadapi petani adalah serangan penyakit pada tanaman padi yang dapat mengakibatkan penurunan hasil panen secara signifikan. Di Indonesia, beberapa penyakit yang umum menyerang tanaman padi meliputi bercak coklat yang disebabkan oleh jamur *Pyricularia grisea* dan *Magnaporthe grisea*, blast daun yang disebabkan oleh *Pyricularia oryzae*, serta hispa yang disebabkan oleh *Helminthosporium oryzae* (Cipta Sigitta Hariyono et al., 2023; Salimah et al., 2021). Menurut penelitian terbaru oleh Rahman et al. (2020), kerugian hasil panen akibat serangan penyakit pada tanaman padi dapat mencapai 10-30% dari total produksi, bahkan dalam kasus yang parah dapat mengakibatkan gagal panen. Menurut penelitian terbaru oleh (Hairani & Widiyaningtyas, 2024), kerugian hasil panen akibat serangan penyakit pada tanaman padi dapat mencapai 10-30% dari total produksi, bahkan dalam kasus yang parah dapat mengakibatkan gagal panen

Perkembangan teknologi kecerdasan buatan, khususnya dalam bidang pengolahan citra digital menggunakan *Convolutional Neural Network (CNN)*, telah membuka peluang baru dalam identifikasi penyakit tanaman secara lebih efektif dan efisien. CNN menawarkan pendekatan yang kuat dalam pengolahan citra dengan kemampuannya mengekstraksi fitur-fitur penting dari data citra (Borhani et al., 2022). Penelitian terkini oleh (Galih Wasis Wicaksono & Andreawan, 2023) menunjukkan bahwa pendekatan berbasis CNN mampu mengenali dan membedakan dengan akurat antara daun tanaman yang sehat dan yang terinfeksi penyakit. Lebih lanjut, studi yang

dilakukan oleh (Khalid & Karan, 2023) mengungkapkan bahwa implementasi deep learning dalam deteksi penyakit tanaman dapat mencapai tingkat akurasi hingga 98% pada beberapa kasus.

ResNet-101, yang dikembangkan oleh (He et al., 2016), merupakan salah satu arsitektur CNN yang menonjol dengan kemampuannya mengatasi masalah pelatihan yang dalam dan menunjukkan performa luar biasa dalam mengenali pola-pola kompleks pada citra. Arsitektur ini memiliki keunggulan dalam hal kedalaman network hingga 101 lapisan dan kemampuan transfer learning yang baik, memungkinkan penggunaan model yang telah dilatih pada dataset besar untuk diaplikasikan pada dataset yang lebih kecil (Torrey & Shavlik, 2010). Penelitian yang dilakukan oleh (Ridhovan & Suharso, 2022) mendemonstrasikan efektivitas ResNet dalam klasifikasi penyakit tanaman dengan tingkat akurasi mencapai 98%.


Implementasi teknologi deep learning dalam pertanian telah menunjukkan hasil yang menjanjikan, seperti yang dibuktikan dalam studi oleh (Kuswidiyanto et al., 2022), di mana sistem berbasis CNN berhasil mengidentifikasi berbagai penyakit tanaman dengan tingkat presisi tinggi dan waktu pemrosesan yang minimal. Selain itu, penelitian (Sharma et al., 2023) mengungkapkan bahwa integrasi teknologi computer vision dengan platform berbasis web dapat meningkatkan aksesibilitas dan adopsi teknologi oleh petani di lapangan.

Berdasarkan permasalahan tersebut, penelitian ini bertujuan untuk membangun sistem berbasis website yang dapat mengidentifikasi jenis penyakit padi dari input citra daun digital menggunakan CNN, serta menganalisis dan mengevaluasi tingkat akurasi sistem dalam mendeteksi 4 jenis penyakit pada data uji. Melalui integrasi teknologi kecerdasan buatan dalam praktik pertanian, diharapkan dapat memberikan solusi yang lebih cepat, akurat, dan efisien dalam menghadapi tantangan kompleks yang dihadapi oleh petani dalam memelihara tanaman padi.

2. METODE PENELITIAN

Pelaksanaan klasifikasi menggunakan model *Convolutional Neural Network (CNN)* dilakukan dalam beberapa tahapan, yang dirangkum pada Gambar 1. Pertama,

data dikumpulkan dari berbagai sumber. Setelah itu, data melalui proses pre-processing untuk persiapan pelatihan model. Setelah pre-processing selesai, model CNN diterapkan dan dilatih menggunakan data yang telah disiapkan. Akhirnya, model dievaluasi untuk menilai kinerja dan akurasi.



Gambar 1. Alur Penelitian

Tahapan penelitian berdasarkan gambar 1 dijelaskan lebih rinci sebagai berikut:

1) Pengumpulan Data:

Data yang digunakan dalam penelitian ini berupa gambar daun padi yang terdiri dari empat kelas: sehat, bercak coklat, blast daun, dan hispa. Dataset diperoleh dari platform Kaggle yang berjudul "*Rice Leafs*." Selain itu, data primer berupa gambar yang diunggah oleh pengguna juga digunakan untuk pengujian. Dataset ini dikumpulkan dan disusun untuk memastikan kualitas data, termasuk memperhatikan variasi pencahayaan dan sudut pengambilan gambar.


2) *Pre-Processing* Data:

Setelah data dikumpulkan, dilakukan pembagian dataset menjadi dua bagian: 80% untuk data latih dan 20% untuk data validasi. Proses augmentasi dilakukan untuk meningkatkan variasi data dan mencegah *overfitting*. Augmentasi yang diterapkan meliputi *RandomFlip*, *RandomRotation*, *RandomZoom*, dan *Rescaling*. Selain itu, seluruh gambar di-rescale ke ukuran yang konsisten, yaitu 224x224 piksel, agar sesuai dengan persyaratan input model.

3) Model CNN:

Dalam penelitian ini, digunakan arsitektur ResNet-101, sebuah model *Convolutional Neural Network* (CNN) yang dirancang untuk klasifikasi citra dengan kedalaman jaringan yang tinggi, terdiri dari 101 lapisan. ResNet-101 dikenal efektif karena arsitekturnya yang menggunakan blok

residual(Niswati et al., 2021), yang membantu mengatasi masalah *vanishing gradient* pada jaringan yang dalam, sehingga model dapat belajar dari fitur yang lebih kompleks tanpa kehilangan informasi penting. Dalam implementasinya, CNN umumnya terdiri dari dua jenis lapisan utama: lapisan *feature learning*, yang bertanggung jawab untuk mengekstraksi pola-pola penting dari data input, dan lapisan *classification*, yang berperan dalam mengklasifikasikan pola tersebut ke dalam kelas-kelas yang telah ditentukan. Seperti yang dijelaskan oleh (Albawi et al., 2017), lapisan *feature learning* biasanya mencakup lapisan konvolusi dan pooling yang digunakan untuk menangkap fitur dari gambar, sementara lapisan *classification* biasanya terdiri dari lapisan dense untuk mengklasifikasikan hasil dari lapisan sebelumnya.



Gambar 2. Arsitektur CNN

Proses yang terjadi dalam ResNet-101 pada dasarnya tidak berbeda jauh dengan uraian yang telah dijelaskan sebelumnya oleh peneliti. Hanya saja ResNet-101 melibatkan alur data yang lebih kompleks dibandingkan arsitektur CNN konvensional, dimana ciri khasnya adalah penggunaan skip connection atau residual blocks yang memungkinkan informasi mengalir langsung melewati beberapa lapisan. Pada Gambar 2, peneliti memberikan penjelasan global mengenai lapisan-lapisan mana yang akan dilewati oleh data gambar hingga menghasilkan nilai pada lapisan output.

Pada penelitian ini, ResNet-101 digunakan untuk mengenali pola dan fitur spesifik dari gambar daun padi yang dapat membedakan empat jenis kondisi: Hispa, bercak coklat, *blast* daun, dan sehat. Untuk mencapai tugas


ini, bagian atas (*top layer*) dari ResNet-101 yang asli diganti dengan lapisan kustom yang lebih sesuai dengan kebutuhan klasifikasi penyakit pada daun padi.

Model ResNet-101 yang digunakan adalah model pre-trained dari dataset ImageNet, di mana bagian top layer model dibuang dan digantikan dengan lapisan kustom yang sesuai dengan klasifikasi penyakit daun padi. Selama proses pelatihan, lapisan-lapisan pada model dasar dibekukan (tidak dilatih ulang), sedangkan lapisan kustom dilatih untuk klasifikasi.

Arsitektur ResNet (*Residual Network*) seperti pada Gambar 3 merupakan salah satu model *deep learning* yang revolusioner dalam *computer vision*. Struktur dasarnya dimulai dengan input layer yang dilanjutkan dengan Conv7-64 sebagai layer konvolusi pertama dan Maxpool untuk *downsampling* awal. Keunikan ResNet terletak pada penggunaan blok residual yang memungkinkan training jaringan yang sangat dalam tanpa masalah degradasi performa (Sarwinda et al., 2021).

Arsitektur ini memiliki 4 blok residual utama, dimana setiap blok terdiri dari kombinasi Conv1-64 (konvolusi 1x1), Conv3-64 (konvolusi 3x3) yang diulang dengan pola berbeda (x3, x4, x23, x3), dan Conv1-256 (konvolusi 1x1). Skip connection pada setiap blok berperan penting dalam mengatasi masalah *vanishing gradient* yang umum terjadi pada jaringan dalam (Erkamim et al., 2024).

Bagian akhir arsitektur menggunakan *average pooling* untuk reduksi dimensi, dilanjutkan dengan *fully connected layer* (FC-2) dan softmax sebagai aktivasi final untuk klasifikasi. Struktur ini mampu mencapai akurasi tinggi tanpa menambah kompleksitas komputasi secara signifikan. ResNet telah menginspirasi berbagai arsitektur modern dengan modifikasi seperti optimalisasi *skip connection*, penambahan *attention mechanism*, dan penggunaan layer normalisasi yang lebih efisien.



Gambar 3. Arsitektur ResNet-101

4) *Training Model:*

Proses pelatihan model dilakukan menggunakan fungsi kerugian *Categorical Crossentropy* dan optimizer Adam dengan learning rate awal sebesar $1e^{-4}$. Model dilatih selama maksimal 70 epoch dengan *batch size* 32. *Callback* seperti *ModelCheckpoint*, *EarlyStopping*, dan *ReduceLROnPlateau* digunakan untuk menyimpan model dengan performa terbaik, menghentikan pelatihan jika tidak ada peningkatan, dan menyesuaikan learning rate secara otomatis.

5) *Evaluation Model:*

Setelah pelatihan selesai, model dievaluasi menggunakan dataset validasi untuk mengukur performanya. Model ResNet-101 menunjukkan akurasi validasi tertinggi sebesar 76,05% dalam klasifikasi penyakit daun padi. Evaluasi dilakukan dengan menghitung akurasi dan loss serta memvisualisasikan kinerja model pada setiap epoch untuk menganalisis proses pembelajaran model dari data yang diberikan.

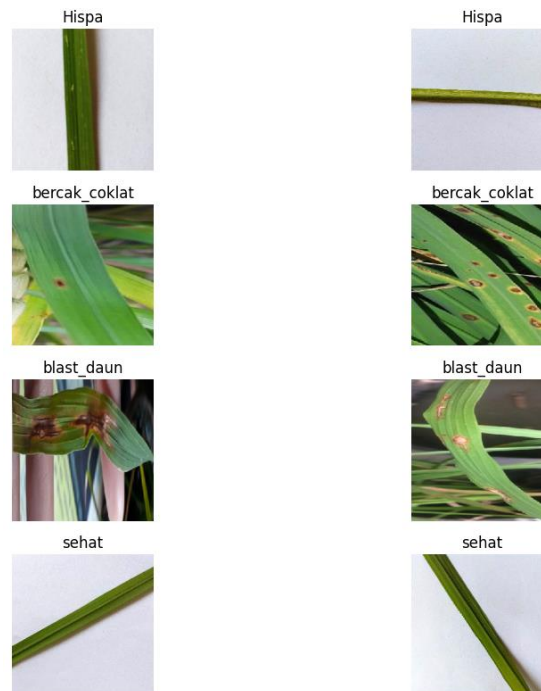
3. HASIL DAN PEMBAHASAN

Studi ini menggunakan 1610 dataset citra daun padi. Dataset yang dikumpulkan di bagi menjadi empat class: *Hispa*, *bercak coklat*, *blast daun*, dan *sehat*. Pembagian data ditunjukkan dalam Tabel 1. Tabel *class* daun padi.

Tabel 1. *class* daun padi

No	Class	Data
1	Hispa	400
2	Bercak Coklat	400
3	Blast Daun	400
4	Sehat	410
TOTAL		1610

Pada Gambar 4 di bawah ditunjukkan beberapa contoh sampel dataset daun padi yang digunakan dalam penelitian ini. Dataset terdiri dari empat kategori kondisi daun padi yaitu Hispa, bercak coklat, blast daun, dan sehat.



Gambar 4. Sampel dataset daun padi

Dalam penelitian ini, dataset citra daun padi dibagi menjadi dua bagian, yaitu data pelatihan dan data validasi. Pembagian dilakukan dengan proporsi 80% untuk pelatihan dan 20% untuk validasi, yang berarti dari total 1.610 gambar, sekitar 1.288 gambar digunakan untuk melatih model, sementara 322 gambar lainnya digunakan untuk menguji kinerja model. Pembagian ini bertujuan agar model dapat dilatih dengan jumlah data yang besar, sementara data validasi digunakan untuk mengevaluasi kemampuan model mengenali data baru, mengukur akurasi, dan memantau potensi *overfitting*.

Agar model lebih tangguh dan mampu mengenali pola dari data yang bervariasi, proses augmentasi diterapkan pada data pelatihan. Augmentasi meliputi beberapa teknik, di antaranya *RandomFlip* (membalik gambar secara horizontal untuk memvariasikan posisi gambar), *RandomRotation* (memutar gambar hingga 20 derajat untuk menciptakan orientasi berbeda), *RandomZoom* (melakukan pembesaran acak untuk menciptakan berbagai skala), dan *Rescaling* (mengubah skala warna gambar menjadi nilai antara 0 dan 1). Selain itu, digunakan juga *width shift* dan *height shift* untuk menggeser gambar secara horizontal dan vertikal hingga 20%. Proses augmentasi ini bertujuan menambah variasi dalam data pelatihan tanpa meningkatkan jumlah data secara aktual, yang membantu model lebih adaptif dalam mengenali pola, mengurangi risiko *overfitting*, dan meningkatkan akurasi saat dihadapkan pada data validasi.

Pada penelitian ini menggunakan model ResNet-101 dalam tiga percobaan menunjukkan perbedaan pengaturan dan strategi pelatihan untuk mengeksplorasi konfigurasi yang dapat menghasilkan model terbaik. Fokus utama dalam tiap percobaan adalah pada pengaturan layer yang dilatih, penyesuaian learning rate, serta penggunaan *callback* seperti *Early Stopping* dan *ReduceLRonPlateau*. *Callback* ini membantu mengoptimalkan hasil pelatihan, mencegah pelatihan yang berlebihan, serta mengurangi risiko *overfitting*, terutama saat model berhenti mengalami peningkatan pada data validasi.

Pada percobaan pertama, seluruh layer dasar ResNet-101 dibekukan sehingga model hanya melatih layer tambahan di atas arsitektur ResNet-101. Learning rate awal

yang digunakan adalah $1e^{-4}$. Selama proses pelatihan, model berhenti setelah 64 epoch karena *Early Stopping* mendeteksi tidak adanya peningkatan signifikan pada *loss* validasi. Meskipun akurasi pelatihan mencapai 81,09%, akurasi validasi lebih rendah di 70,63%, mengindikasikan bahwa model mengalami *overfitting*. Hal ini berarti model cenderung belajar terlalu detail pada data pelatihan, tetapi kesulitan dalam mengenali pola pada data validasi.

Percobaan kedua menggunakan pengaturan serupa dengan percobaan pertama, di mana hanya layer tambahan yang dilatih dan seluruh layer ResNet-101 tetap dibekukan. Namun, ada perbedaan dalam pengaturan *callback ReduceLROnPlateau*, yang dibuat lebih agresif agar *learning rate* menurun lebih cepat ketika performa model stagnan pada data validasi. Hal ini membantu model beradaptasi lebih baik dan menghentikan pelatihan pada epoch ke-48. Hasil akhirnya menunjukkan akurasi validasi 69,38%, sedikit lebih rendah dari percobaan pertama. Namun, stabilitas hasil validasi pada percobaan kedua lebih baik dibandingkan percobaan pertama, meskipun tidak ada peningkatan yang signifikan.

Pada percobaan ketiga, perubahan dilakukan dengan membuka beberapa layer terakhir dari ResNet-101 untuk *fine-tuning*, yang memungkinkan model menyesuaikan bobot pada layer-layer ini agar lebih spesifik terhadap data citra daun padi. Proses *fine-tuning* ini membantu model mengenali pola lebih detail dan relevan dalam dataset. Dengan penggunaan *callback* yang sama, model berhasil mencapai akurasi validasi tertinggi sebesar 76,05% dan berhenti pada *epoch* ke-52. Hasil ini menunjukkan bahwa model mampu menggeneralisasi lebih baik tanpa mengalami *overfitting*. Berdasarkan *confusion matrix*, model dalam percobaan ketiga dapat mengklasifikasi data dengan lebih akurat dibandingkan percobaan lainnya, menjadikannya model terbaik dari ketiga percobaan. Tabel 2 Perbandingan Hasil Percobaan.

Tabel 2. Perbandingan Hasil Percobaan

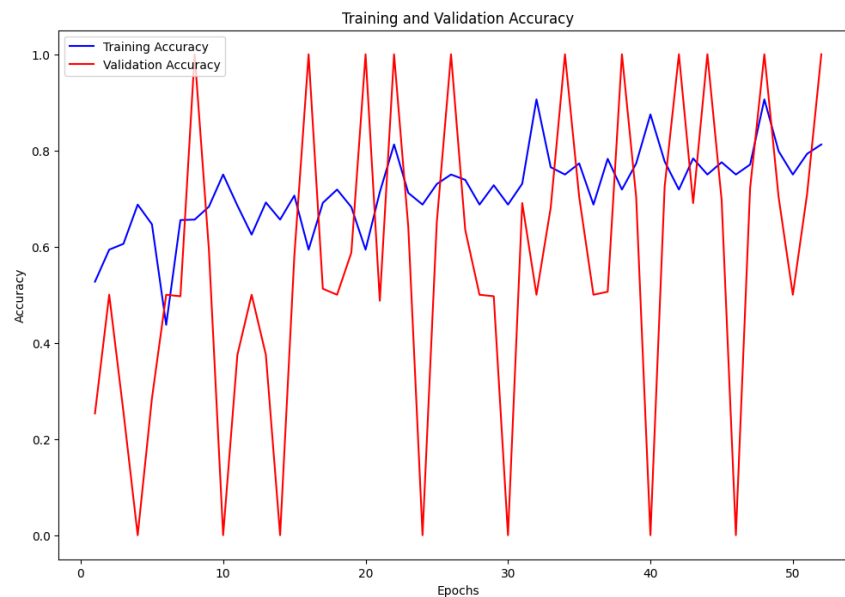
Percobaan	Epoch Berhenti	Akurasi Pelatihan (%)	Loss Pelatihan	Akurasi Validasi (%)	Loss Validasi
1	64	81,09	0,93	70,63	1,11

2	48	76,97	1,22	69,38	1,33
3	52	81,53	0,92	76,05	1,35

Dari ketiga percobaan yang dilakukan dapat disimpulkan bahwa pendekatan *fine-tuning* layer terakhir pada percobaan ketiga memberikan hasil terbaik dalam hal akurasi validasi dan kemampuan generalisasi model. Percobaan pertama menunjukkan akurasi pelatihan yang tinggi (81,09%), tetapi diiringi dengan *overfitting* yang signifikan, karena akurasi validasi hanya mencapai 70,63%. Percobaan kedua, meskipun menggunakan strategi *callback* yang lebih agresif, tidak berhasil meningkatkan akurasi validasi, yang tetap di angka 69,38%. Namun, percobaan ketiga, dengan melakukan *fine-tuning* pada beberapa layer terakhir, berhasil mencapai akurasi validasi tertinggi sebesar 76,05% dan menunjukkan stabilitas yang lebih baik dalam klasifikasi. Hal ini menunjukkan bahwa membuka beberapa layer untuk penyesuaian dapat membantu model mengenali pola yang lebih relevan dengan dataset, serta mengurangi risiko *overfitting*. Dengan demikian, strategi pengaturan dan pelatihan yang tepat sangat penting untuk meningkatkan performa model dalam klasifikasi citra. Tabel 3. Hasil Model Terbaik

Tabel 3. Hasil Model Terbaik

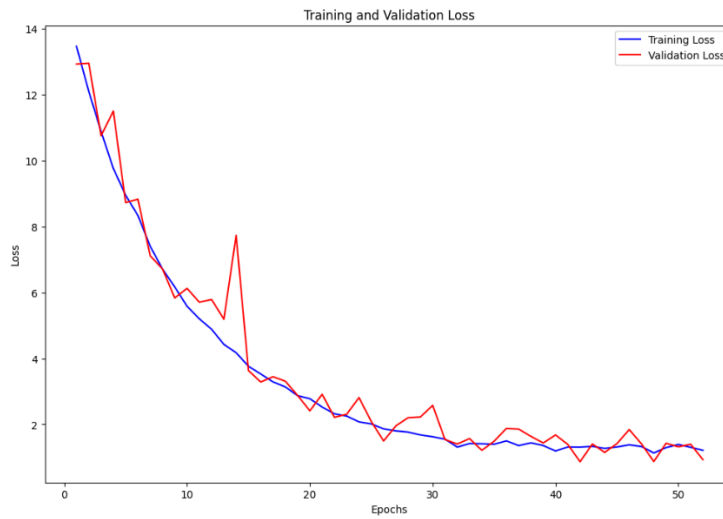
Percobaan	Epoch Berhenti	Akurasi Pelatihan (%)	Loss Pelatihan	Akurasi Validasi (%)	Loss Validasi
3	38	81,53	0,92	76,05	1,35




Gambar 5. Perbandingan akurasi pelatihan dan validasi model terbaik

Pada Gambar 5 ditampilkan grafik perbandingan akurasi antara data pelatihan dan validasi dari model terbaik. Grafik menunjukkan bahwa model mencapai akurasi pelatihan sebesar 81.53% dan akurasi validasi 76.05%, dengan proses pelatihan berhenti pada epoch ke-52 karena mekanisme *early stopping*. Perbedaan yang relatif kecil antara akurasi pelatihan dan validasi mengindikasikan bahwa model tidak mengalami overfitting yang signifikan, menunjukkan kemampuan generalisasi yang baik.

Sedangkan Gambar 6 di bawah merupakan hasil visualisasi perbandingan nilai *loss* antara data pelatihan dan validasi selama proses pembelajaran model. *Loss* pelatihan mencapai nilai 0.92 sementara *loss* validasi berada di angka 1.35. Kedua nilai *loss* menunjukkan pola penurunan yang stabil sepanjang proses pelatihan. Meskipun terdapat sedikit perbedaan antara *loss* pelatihan dan validasi, hal ini masih dalam batas wajar dan menunjukkan bahwa model memiliki kemampuan generalisasi yang baik terhadap data baru.



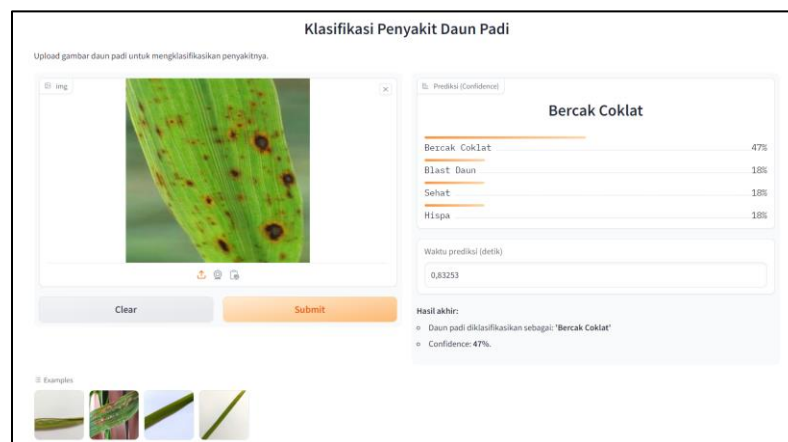
Gambar 6. Perbandingan *loss* pelatihan dan validasi model terbaik



Gambar 7. *Confusion matrix*

Berdasarkan Gambar 7. *Confusion matrix*, model menunjukkan bahwa model klasifikasi ini memiliki performa yang bervariasi untuk empat kelas: Hispa, bercak coklat, blast daun, dan sehat. Model sangat baik dalam mengidentifikasi kelas bercak coklat, di mana seluruh 80 sampel terklasifikasi dengan benar tanpa ada kesalahan klasifikasi, menunjukkan akurasi sempurna. Namun, model memiliki kelemahan dalam mengenali kelas Hispa, di mana terdapat 33 sampel yang diklasifikasikan dengan benar, tetapi banyak kesalahan terjadi dengan 29 sampel salah diklasifikasikan sebagai blast daun dan 17 sampel sebagai sehat. Untuk kelas blast daun, model berhasil

mengidentifikasi 31 sampel dengan benar, tetapi 49 sampel dari kelas ini salah diklasifikasikan sebagai bercak coklat, menunjukkan bahwa model mengalami kebingungan antara blast_daun dan bercak coklat. Sementara itu, kelas sehat memiliki 22 sampel yang teridentifikasi dengan benar, namun terdapat kesalahan signifikan karena 28 sampel sehat salah diklasifikasikan sebagai Hispa. Secara keseluruhan, meskipun model sangat akurat pada kelas bercak coklat, diperlukan peningkatan akurasi pada kelas Hispa, blast daun, dan sehat untuk mengurangi kesalahan klasifikasi dan mencapai performa yang lebih konsisten di semua kelas.



Gambar 8. Console hasil pengujian

Gambar 8 ini menunjukkan hasil antarmuka web yang berfungsi mengklasifikasikan penyakit pada daun padi berdasarkan gambar yang diunggah. Di sebelah kiri, terdapat panel untuk mengunggah gambar daun padi, dan tersedia tombol Clear dan Submit untuk menghapus atau mengunggah gambar baru. Di sebelah kanan, sistem memberikan hasil klasifikasi dengan prediksi bahwa daun tersebut mengidap penyakit apa sebagai contoh seperti pada gambar merupakan daun yang diklasifikasikan sebagai Bercak Coklat dengan tingkat keyakinan 47%, sementara tiga kategori lain, yaitu Blast Daun, Sehat, dan Hispa, masing-masing memiliki keyakinan sebesar 18%. Waktu yang dibutuhkan untuk menghasilkan prediksi ini adalah sekitar 0,83 detik.

4. SIMPULAN

Penelitian ini telah berhasil mengimplementasikan model *Convolutional Neural Network* (CNN) dengan arsitektur ResNet-101 untuk mengidentifikasi penyakit pada tanaman padi melalui citra daun. Melalui serangkaian eksperimen dan optimasi, model berhasil mencapai akurasi validasi tertinggi sebesar 76,05% dalam mengklasifikasikan empat kondisi daun padi, yaitu sehat, bercak coklat, blast daun, dan hispa. Pendekatan fine-tuning pada beberapa layer terakhir ResNet-101 terbukti paling efektif dalam meningkatkan performa klasifikasi. Analisis *confusion matrix* menunjukkan bahwa model memiliki kemampuan sempurna dalam mengidentifikasi bercak coklat, meskipun masih menghadapi tantangan dalam mengklasifikasikan kelas Hispa dan blast daun, serta beberapa kesalahan klasifikasi antara kelas sehat dan Hispa. Penerapan teknik augmentasi data dan strategi pelatihan yang tepat, termasuk penggunaan *callback* seperti *Early Stopping* dan *ReduceLROnPlateau*, berperan penting dalam mencegah *overfitting* dan mengoptimalkan performa model. Meskipun masih memerlukan pengembangan lebih lanjut untuk meningkatkan akurasi pada beberapa kelas tertentu, sistem ini menunjukkan potensi yang menjanjikan untuk membantu petani dalam mendeteksi penyakit tanaman padi secara dini dan akurat, sehingga dapat mendukung pengambilan keputusan yang lebih baik dalam pengelolaan tanaman padi.

PUSTAKA

- Albawi, S., Mohammed, T. A., & Al-Zawi, S. (2017). Understanding of a convolutional neural network. *2017 International Conference on Engineering and Technology (ICET)*, 1–6. <https://doi.org/10.1109/ICEngTechnol.2017.8308186>
- Borhani, Y., Khoramdel, J., & Najafi, E. (2022). A deep learning based approach for automated plant disease classification using vision transformer. *Scientific Reports*, 12(1). <https://doi.org/10.1038/s41598-022-15163-0>
- Cipta Sigitta Hariyono, R., Mega Saraswati, N., Noor Prasetyono, R., Zidan Alfariki, M., Peradaban Program Studi Informatika Fakultas Sains dan Teknologi Jln Raya Pagojengan Km, U., & Brebes, P. (2023). Rito Cipta Sigitta H, Deteksi Penyakit Bercak Coklat, Coklat Sempit Dan Hawar Melalui Spektrum Warna Citra Digital... DETEKSI PENYAKIT BERCAK COKLAT, COKLAT SEMPIIT DAN HAWAR MELALUI SPEKTRUM WARNA CITRA DIGITAL DAUN PADI MENGGUNAKAN METODE CONVOLUTIONAL NEURAL NETWORK. In *ZONAsi: Jurnal Sistem Informasi* (Vol. 5, Issue 2).
- Erkamim, M., Prihatin, T., Saraswati, S. D., & Tonggiroh, M. (2024). Optimalisasi Throughput Pada Penerapan Load Balancing Dalam Jaringan Cloud Menggunakan Round Robin dan Least Connection. In *Journal of System and Computer Engineering (JSCE) ISSN* (Vol. 5, Issue 1).
- Galih Wasis Wicaksono, & Andreawan. (2023). ResNet101 Model Performance Enhancement in Classifying Rice Diseases with Leaf Images. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 7(2), 345–352. <https://doi.org/10.29207/resti.v7i2.4575>

- Hairani, H., & Widiyaningtyas, T. (2024). Augmented Rice Plant Disease Detection with Convolutional Neural Networks. *INTENSIF: Jurnal Ilmiah Penelitian Dan Penerapan Teknologi Sistem Informasi*, 8(1), 27–39. <https://doi.org/10.29407/intensif.v8i1.211168>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Khalid, M. M., & Karan, O. (2023). Deep Learning for Plant Disease Detection. *International Journal of Mathematics, Statistics, and Computer Science*, 2, 75–84. <https://doi.org/10.59543/ijmscs.v2i.8343>
- Kuswidiyanto, L. W., Noh, H.-H., & Han, X. (2022). Plant Disease Diagnosis Using Deep Learning Based on Aerial Hyperspectral Images: A Review. *Remote Sensing*, 14(23), 6031. <https://doi.org/10.3390/rs14236031>
- Niswati, Z., Hardatin, R., Muslimah, M. N., & Hasanah, S. N. (2021). Perbandingan Arsitektur ResNet50 dan ResNet101 dalam Klasifikasi Kanker Serviks pada Citra Pap Smear. *Faktor Exacta*, 14(3), 160. <https://doi.org/10.30998/faktorexacta.v14i3.10010>
- Ridhovan, A., & Suharso, A. (2022). PENERAPAN METODE RESIDUAL NETWORK (RESNET) DALAM KLASIFIKASI PENYAKIT PADA DAUN GANDUM. *JlPI (Jurnal Ilmiah Penelitian Dan Pembelajaran Informatika)*, 7(1), 58–65. <https://doi.org/10.29100/jlpi.v7i1.2410>
- Salimah, N. A., Tutik Kuswinanti, & Andi Nasruddin. (2021). Eksplorasi dan Penentuan Ras Penyebab Penyakit Blas Padi di Kabupaten Maros. *Jurnal Fitopatologi Indonesia*, 17(2), 41–48. <https://doi.org/10.14692/jfi.17.2.41-48>
- Sarwinda, D., Paradisa, R. H., Bustamam, A., & Anggia, P. (2021). Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer. *Procedia Computer Science*, 179, 423–431. <https://doi.org/10.1016/j.procs.2021.01.025>
- Sharma, A., Aswal, U. S., Rana, A., Vani, V. D., Sankhyan, A., & Shekhar. (2023). Real Time Plant Disease Detection Model using Deep Learning. *2023 6th International Conference on Contemporary Computing and Informatics (IC3I)*, 2695–2699. <https://doi.org/10.1109/IC3I59117.2023.10398070>
- Torrey, L., & Shavlik, J. (2010). Transfer Learning. In *Handbook of Research on Machine Learning Applications and Trends* (pp. 242–264). IGI Global. <https://doi.org/10.4018/978-1-60566-766-9.ch011>