



**KEPUTUSAN DEKAN FAKULTAS TEKNOLOGI INFORMASI
UNIVERSITAS BUDI LUHUR**

NOMOR : K/UBL/FTI/000/004/03/26

TENTANG:

**PENUGASAN KEGIATAN TRI DHARMA & PENUNJANG BAGI DOSEN
FAKULTAS TEKNOLOGI INFORMASI UNIVERSITAS BUDI LUHUR
SEMESTER GENAP TAHUN AKADEMIK 2025/2026**

DEKAN FAKULTAS TEKNOLOGI INFORMASI UNIVERSITAS BUDI LUHUR

- Menimbang : 1) Bahwa Dosen adalah pendidik profesional dan ilmu dengan tugas utama mentrans-formasikan, mengembangkan, dan menyebarkan ilmu pengetahuan, teknologi, dan seni melalui pendidikan/pengajaran penelitian & karya ilmiah, dan Pengabdian pada masyarakat yang dikenal dengan istilah Tri Dharma Perguruan Tinggi;
- 2) Bahwa untuk meningkatkan profesionalitas dan kompetensi sebagai pendidik profesional maka dipandang perlu untuk memberikan tugas-tugas tambahan/penunjang dalam lingkup kegiatan penunjang Tri Dharma;
- Mengingat : 1) Undang – undang Republik Indonesia Nomor 12 Tahun 2012 tentang Pendidikan Tinggi;
- 2) Undang – undang Republik Indonesia Nomor 20 tahun 2003 tentang Sistem Pendidikan Nasional;
- 3) Peraturan Pemerintah Republik Indonesia Nomor 17 Tahun 2010 tentang Pengelolaan dan Penyelenggaraan Pendidikan;
- 4) Peraturan Menteri Riset, Teknologi, dan Pendidikan Tinggi Republik Indonesia Nomor 53 Tahun 2023 tentang Penjaminan Mutu Perguruan Tinggi;
- 5) Keputusan Ketua Yayasan Pendidikan Budi Luhur Cakti Nomor: K/YBLC/KEP/000/216/06/2023 tentang Statuta Universitas Budi Luhur;
- 6) SK YPBLC No: K/YBLC/KEP/000/384/09/25 tanggal 22 September 2025 tentang Pembebas-Tugasan dan Pengangkatan Kembali Pejabat Struktural Universitas Budi Luhur.

MEMUTUSKAN

- Menetapkan :
PERTAMA : Menugaskan dosen-dosen Fakultas Teknologi Informasi Universitas Budi Luhur untuk melaksanakan kegiatan **Tri Dharma Perguruan Tinggi dan penunjangnya** pada Semester Genap Tahun Akademik 2025/2026 yang meliputi:
- a. **Kegiatan partisipasi aktif** dalam Pertemuan Ilmiah sebagai Ketua/Anggota/Peserta/Pembicara/Penulis/Narasumber pada kegiatan Seminar, Workshop, Konferensi, Pelatihan, Simposium, Lokakarya, Forum Diskusi, Sarasehan dan sejenisnya;
- b. **Publikasi Ilmiah** pada Prosiding, Jurnal/majalah/surat kabar dan sejenisnya;
- c. **Partisipasi dalam organisasi** profesi, organisasi keilmuan dan/atau organisasi lain yang menunjang kegiatan Tri Dharma Pendidikan Tinggi;
- d. **Pengabdian Kepada Masyarakat (PPM)**, dalam kegiatan terprogram, terjadwal atau insidental;
- KEDUA : Dosen-dosen yang melaksanakan penugasan wajib membuat Laporan Kegiatan, dengan mengikuti pedoman dari Fakultas/Program Studi, sebagai pertanggungjawaban atas kegiatan yang diikuti;
- KETIGA : Kegiatan Tri Dharma yang tidak termasuk dalam surat keputusan ini akan memiliki penugasan tersendiri;
- KEEMPAT : Keputusan ini berlaku sejak tanggal ditetapkan dan akan diubah sebagaimana mestinya apabila di kemudian hari terdapat kekeliruan.

Ditetapkan di : Jakarta

Tanggal : 02 Maret 2026

=====

Dekan Fakultas Teknologi Informasi



Dr. Ir. Achmad Solichin, S.Kom., M.T.I



**LAMPIRAN KEPUTUSAN DEKAN FAKULTAS TEKNOLOGI INFORMASI
UNIVERSITAS BUDI LUHUR**

NOMOR : K/UBL/FTI/000/004/03/26

**TENTANG:
PENUGASAN KEGIATAN TRI DHARMA & PENUNJANG BAGI DOSEN
FAKULTAS TEKNOLOGI INFORMASI UNIVERSITAS BUDI LUHUR
SEMESTER GENAP TAHUN AKADEMIK 2025/2026**

No	NUPTK	Nama	Program Studi
1	7937760661130282	ACHMAD SOLICHIN	Ilmu Komputer (S3)
2	5239757658130173	ARIEF WIBOWO	Ilmu Komputer (S3)
3	5846747648130102	HARI SOETANTO	Ilmu Komputer (S3)
4	7734743644130092	JAN EVERHARD RIWUROHI	Ilmu Komputer (S3)
5	9252739640130053	WENDI USINO	Ilmu Komputer (S3)
6	3955753654130082	AKHMAD UNGGUL PRIANTORO	Ilmu Komputer (S2)
7	0544751652130173	ANTON SATRIA PRABUWONO	Ilmu Komputer (S2)
8	0543756657130133	ARIF BRAMANTORO	Ilmu Komputer (S2)
9	8556757658137103	DENNI KURNIAWAN	Ilmu Komputer (S2)
10	4556758659231082	DWI PEBRIANTI	Ilmu Komputer (S2)
11	9950765666130302	INDRA NUGRAHA ABDULLAH	Ilmu Komputer (S2)
12	3457756657130123	LUHUR BAYUAJI	Ilmu Komputer (S2)
13	1654747648130072	MARDI HARDJIAN TO	Ilmu Komputer (S2)
14	9248752653130093	MOHAMMAD SYAFRULLAH	Ilmu Komputer (S2)
15	6235757658230143	RUSDAH	Ilmu Komputer (S2)
16	3444749650130102	SAMIDI	Ilmu Komputer (S2)
17	0157741642130083	SETYAWAN WIDYARTO	Ilmu Komputer (S2)
18	6356750651130093	ABDUL MUIS SOBRI	Teknik Informatika (S1)
19	5934758659137112	ACHMAD ADITYA ASHADUL USHUD	Teknik Informatika (S1)
20	4437767668130323	ACHMAD ARDIANSYAH	Teknik Informatika (S1)
21	4652761662130272	AGUNG SAPUTRA	Teknik Informatika (S1)
22	2636769670130302	AHMAD PUDOLI	Teknik Informatika (S1)
23	1646766667130292	ANGGA KUSUMA NUGRAHA	Teknik Informatika (S1)
24	4535772673130233	ANWAR RIFA'I	Teknik Informatika (S1)
25	2533753654130132	ARSANTO NARENDRO	Teknik Informatika (S1)
26	3733759660130242	BASUKI HARI PRASETYO	Teknik Informatika (S1)
27	2243767668130313	DOLLY VIRGIAN SHAKA YUDHA SAKTI	Teknik Informatika (S1)
28	9560763664230232	DWI PUSPITA ANGGRAENI	Teknik Informatika (S1)
29	2155762663131103	FERDIANSYAH	Teknik Informatika (S1)
30	0537746647130122	GUNAWAN PRIA UTAMA	Teknik Informatika (S1)
31	0740763664130282	HADIDTYO WISNU WARDANI	Teknik Informatika (S1)
32	9838763664130292	HARIS MUNANDAR	Teknik Informatika (S1)



33	0652765666130282	HILLMAN AKHYAR DAMANIK	Teknik Informatika (S1)
34	0434764665230262	IKA SUSANTI	Teknik Informatika (S1)
35	8949771672130282	IKHSAN RAHDIANA	Teknik Informatika (S1)
36	7437754655230112	IMELDA	Teknik Informatika (S1)
37	2654764665130222	INDRA	Teknik Informatika (S1)
38	7454765666130203	INDRA HERTANTO	Teknik Informatika (S1)
39	9456761662130143	JOKO CHRISTIAN	Teknik Informatika (S1)
40	5460755656230082	LESTARI MARGATAMA	Teknik Informatika (S1)
41	5540767668230303	MEPA KURNIASIH	Teknik Informatika (S1)
42	4562753654230103	MERRY ANGGRAENI	Teknik Informatika (S1)
43	2453748649130073	MOHAMMAD ANIF	Teknik Informatika (S1)
44	2961757659200032	MUFTI	Teknik Informatika (S1)
45	1961760661130172	MUHAMMAD AINUR RONY	Teknik Informatika (S1)
46	4537746647130113	NANO PRAMONO SOERYONEGORO	Teknik Informatika (S1)
47	4554760661230252	PIPIN FARIDA ARIYANI	Teknik Informatika (S1)
48	4151756657130113	PURWANTO	Teknik Informatika (S1)
49	8540769670230272	PUTRI HAYATI	Teknik Informatika (S1)
50	2362766667131233	RAHMAT OKTAVIAN	Teknik Informatika (S1)
51	0949761662230182	REVA RAGAM SANTIKA	Teknik Informatika (S1)
52	1660744645230082	RIRIT ROESWIDIAH	Teknik Informatika (S1)
53	1745767668230302	RISKIANA WULAN	Teknik Informatika (S1)
54	2959764665237002	RIZKA TIAHARYADINI	Teknik Informatika (S1)
55	4943758659130162	RIZKY TAHARA SHITA	Teknik Informatika (S1)
56	4554753654230092	SAFRINA AMINI	Teknik Informatika (S1)
57	9937760661130262	SEJATI WALUYO	Teknik Informatika (S1)
58	0246748649131143	SUBANDI	Teknik Informatika (S1)
59	7944752653130152	SUBANDI	Teknik Informatika (S1)
60	5937767668130372	SYAMSUDIN ZUBAIR	Teknik Informatika (S1)
61	6447751652130113	UTOMO BUDIYANTO	Teknik Informatika (S1)
62	4639763664130282	WAHYU PRAMUSINTO	Teknik Informatika (S1)
63	4749764665137022	WINDARTO	Teknik Informatika (S1)
64	7854758659230162	WINDHY WIDHYANTY	Teknik Informatika (S1)
65	6945763664130252	YUDI WIHARTO	Teknik Informatika (S1)
66	6952768669130332	ZAQI KURNIAWAN	Teknik Informatika (S1)
67	5454763664230162	AGNES ARYASANTI	Sistem Informasi (S1)
68	1947743644130112	AGUNG PRIHARTONO	Sistem Informasi (S1)
69	8141761662130183	AGUS UMAR HAMDANI	Sistem Informasi (S1)
70	8947761662230262	ANITA DIANA	Sistem Informasi (S1)
71	6647764665131142	ARI SAPUTRO	Sistem Informasi (S1)



72	5251757658130183	ASEP ABDUL ROHMAN	Sistem Informasi (S1)
73	7752762663237012	ATIK ARIESTA	Sistem Informasi (S1)
74	9846770671130352	BAYU SATRIA PRATAMA	Sistem Informasi (S1)
75	9551750651130082	BRURI TRYA SARTANA	Sistem Informasi (S1)
76	2555742643130063	BULLION DRAGON ANDAH	Sistem Informasi (S1)
77	5560751652130083	DENI MAHDIANA	Sistem Informasi (S1)
78	3535770671130233	DEVIT SETIONO	Sistem Informasi (S1)
79	1542762663230293	DEWI KUSUMANINGSIH	Sistem Informasi (S1)
80	4454761662130162	DIAN ANUBHAKTI	Sistem Informasi (S1)
81	7637741642130122	DJATI KUSDIARTO	Sistem Informasi (S1)
82	3453751652130073	BIMA CAHYA PUTRA	Sistem Informasi (S1)
83	2538753654130102	GANDUNG TRIYONO	Sistem Informasi (S1)
84	4751753654230082	GRACE GATA	Sistem Informasi (S1)
85	8857759660131082	HENDRI IRAWAN	Sistem Informasi (S1)
86	4735758659130162	HUMISAR HASUGIAN	Sistem Informasi (S1)
87	7746771672230342	INDAH PUSPASARI HANDAYANI	Sistem Informasi (S1)
88	6435760661230183	ITA NOVITA	Sistem Informasi (S1)
89	1944770671130422	JEREMY JONATHAN	Sistem Informasi (S1)
90	2935754655130132	JOKO SUTRISNO	Sistem Informasi (S1)
91	2851769670130282	KUKUH HARSANTO	Sistem Informasi (S1)
92	9849754655130112	LAUW LI HIN	Sistem Informasi (S1)
93	6849759660131132	LIS SURYADI	Sistem Informasi (S1)
94	863976566237002	MARINI	Sistem Informasi (S1)
95	0643760661230242	MOTIKA DIAN ANGGRAENI	Sistem Informasi (S1)
96	7050757658237093	NAWINDAH	Sistem Informasi (S1)
97	6050754655230123	NIDYA KUSUMAWARDHANY	Sistem Informasi (S1)
98	3547763664230252	NOFIYANI	Sistem Informasi (S1)
99	5037758659230233	NONI JULIASARI	Sistem Informasi (S1)
100	4847756657231432	NURWATI	Sistem Informasi (S1)
101	1834757658230202	PAINEM	Sistem Informasi (S1)
102	2543764665230232	PEPI PERMATASARI	Sistem Informasi (S1)
103	5947771672230352	RATNA KUSUMAWARDANI	Sistem Informasi (S1)
104	3537759660230223	RATNA UJIAN DARI	Sistem Informasi (S1)
105	4656758659230152	RETNO WULANDARI	Sistem Informasi (S1)
106	4456766667130233	RIZKY PRADANA	Sistem Informasi (S1)
107	6249760661230213	SAFITRI JUANITA	Sistem Informasi (S1)
108	4261760661230183	SAMSINAR	Sistem Informasi (S1)
109	0241752653237043	SRI MULYATI	Sistem Informasi (S1)
110	3542749650230153	SRI WAHYUNINGSIH	Sistem Informasi (S1)



111	5539750651131093	TEJA ENDRA ENG TJU	Sistem Informasi (S1)
112	7552757658230133	TITIN FATIMAH	Sistem Informasi (S1)
113	7449765666230222	TRI IKA JAYA KUSUMAWATI	Sistem Informasi (S1)
114	9758748649230072	WIWIN WINDIHASTUTY	Sistem Informasi (S1)
115	2257766667230243	WULANDARI	Sistem Informasi (S1)
116	3948765666230332	YESI PUSPITA DEWI	Sistem Informasi (S1)
117	0448750651130092	YUDI SANTOSO	Sistem Informasi (S1)
118	4057766667230303	YULIANAWATI	Sistem Informasi (S1)
119	7061753654230083	YULIAZMI	Sistem Informasi (S1)
120	9043744645130083	GATOT PURWANTO	Sistem Komputer (S1)
121	3941771672130302	IMAN PERMANA	Sistem Komputer (S1)
122	0537752653130122	IRAWAN	Sistem Komputer (S1)
123	0443759660230253	RIRI IRAWATI	Sistem Komputer (S1)
124	7863755656130092	YANI PRABOWO	Sistem Komputer (S1)

Ditetapkan di : Jakarta
Tanggal : 02 Maret 2026
=====

Dekan Fakultas Teknologi Informasi



Dr. Ir. Achmad Solichin, S.Kom., M.T.I



ISIAN SUBSTANSI PROPOSAL PENELITIAN

Petunjuk: Pengusul hanya diperkenankan mengisi di tempat yang telah disediakan sesuai dengan petunjuk pengisian dan tidak diperkenankan melakukan modifikasi template atau penghapusan di setiap bagian.

JUDUL

Tuliskan judul penelitian.

Prediksi Penyakit pada Daun Tanaman Padi (*Oryza sativa* L) menggunakan Model *Deep Learning* ResNet50. Sebuah studi untuk *Precision Agriculture*. Studi Kasus Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta

RINGKASAN

Isian ringkasan penelitian tidak lebih dari 300 kata yang berisi urgensi, tujuan, metode, dan luaran yang ditargetkan.

Urgensi penelitian ini timbul dari meningkatnya ancaman penyakit tanaman padi (*Oryza sativa* L) yang berdampak signifikan terhadap produktivitas dan ketahanan pangan nasional, khususnya di wilayah Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta. Kondisi iklim tropis dan pola tanam yang intensif menjadi daerah ini rentan terhadap serangan penyakit seperti blas, hawar daun bakteri, dan tungro. Oleh karena itu, diperlukan sistem deteksi dan prediksi penyakit padi yang cepat, akurat, serta mudah diimplementasikan oleh petani dan pemangku kepentingan di sektor pertanian. **Penelitian ini bertujuan untuk** mengembangkan model prediksi pada berbasis *deep learning* menggunakan arsitektur ResNet50, yang mampu mengenali dan mengklasifikasikan jenis penyakit padi melalui citra daun secara otomatis. Model ini diharapkan dapat mendeteksi gejala penyakit sejak dini dengan akurasi tinggi, sehingga membantu dalam pengambilan keputusan pengendalian penyakit secara tepat waktu. **Metode penelitian yang digunakan** meliputi tahap *data acquisition* melalui pengumpulan citra daun padi dari lapangan di wilayah Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta, *data preprocessing* untuk peningkatan kualitas citra, serta *model training* dan *validation* menggunakan arsitektur ResNet50 dengan menggunakan teknik *transfer learning*. Evaluasi model dilakukan dengan metrik akurasi, presisi, dan F1-Score untuk menilai performa sistem. **Luaran penelitian yang ditargetkan** berupa prototipe sistem prediksi penyakit padi berbasis web, yang menampilkan hasil klasifikasi penyakit pada daun padi secara virtual dan informatif, yang disebut dengan **SIMPADIS** (*Sistem Informasi Prediksi Penyakit Daun Padi Sleman*). Selain itu, hasil penelitian akan dipublikasikan pada jurnal **terindeks Sinta 2 / Sinta 3**.

KATA KUNCI

Isian kata kunci maksimal 5 kata yang dipisahkan dengan tanda titik koma (;)

Penyakit tanaman padi; Deep Learning; ResNet 50; Deteksi Citra; Prediksi Penyakit Padi

PENDAHULUAN

Pendahuluan penelitian tidak lebih dari 1000 kata yang terdiri dari:

1. Latar belakang dan rumusan permasalahan yang akan diteliti
2. Pendekatan pemecahan masalah
3. *State of the art* dan kebaruan
4. Peta jalan (*road map*) penelitian 5 tahun

Sitasi disusun dan ditulis berdasarkan sistem nomor sesuai dengan urutan pengutipan, mengikuti format Vancouver

1. LATAR BELAKANG DAN RUMUSAN MASALAH

Padi (*Oryza sativa L*) merupakan komoditas pangan utama di Indonesia yang memiliki peran vital dalam ketahanan pangan nasional. Namun, produktivitas padi kerap mengalami penurunan signifikan akibat serangan berbagai penyakit tanaman seperti *blast* (*Magnaporthe oryzae*), *bacterial leaf blight* (*Xanthomonas oryzae pv. oryzae*), dan *brown spot* (*Cochliobolus miyabeanus*) (1). Pada wilayah Sleman, Yogyakarta-sebagai salah satu sentra pertanian padi di Pulau Jawa-fluktuasi serangan penyakit tersebut masih menjadi permasalahan utama bagi petani, terutama pada musim hujan. Ketika kondisi lingkungan mendukung perkembangan pathogen (2). Kemajuan teknologi kecerdasan buatan (*Artificial Intelligence*), telah membuka peluang besar untuk mendeteksi dan memprediksi penyakit tanaman secara otomatis dan presisi tinggi melalui citra daun padi (3). Salah satu arsitektur yang terbukti efektif dalam pengenalan citra adalah *Residual Network* (ResNet50), yang memiliki kemampuan dalam mengekstraksi fitur visual kompleks dengan akurasi tinggi (4,5). Implementasi ResNet50 dalam mendiagnosis penyakit padi dapat mempercepat proses identifikasi dini dan meminimalkan kesalahan diagnosis manual oleh petani (6).

Penelitian-penelitian terkini menunjukkan bahwa penerapan *transfer learning* pada model ResNet50 mampu meningkatkan akurasi deteksi penyakit padi hingga lebih dari 95% (7,8). Namun sebagian besar penelitian tersebut masih terbatas pada dataset global seperti PlantVillage dan belum banyak dievaluasi pada kondisi lokal Indonesia yang memiliki variasi agroklimat, jenis varietas, dan kondisi pencahayaan yang berbeda. Oleh karena itu, diperlukan sebuah studi kontekstual di wilayah Sleman, Yogyakarta untuk mengembangkan model prediksi penyakit padi yang lebih adaptif terhadap kondisi lokal lapangan.

Rumusan permasalahan dari penelitian ini adalah sebagai berikut :

1. Bagaimana mengembangkan model *Deep Learning* berbasis ResNet50 yang mampu mendeteksi dan memprediksi penyakit padi (*Oryza sativa L*) secara akurat berdasarkan citra daun ?
2. Sejauh mana model ResNet50 dapat beradaptasi terhadap variasi kondisi lingkungan dan pencahayaan di wilayah Sleman, Yogyakarta ?
3. Bagaimana performa model yang diusulkan dibandingkan dengan model *machine learning* lainnya dalam hal akurasi, presisi, dan waktu komputasi ?

2. PENDEKATAN PEMECAHAN MASALAH

Pendekatan pemecahan masalah dalam penelitian ini dimulai dengan proses **pengumpulan data citra daun padi (*Oryza sativa L*)**, dari berbagai lahan pertanian di wilayah Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta. Data dikumpulkan melalui observasi lapangan menggunakan kamera digital beresolusi tinggi, serta melalui dataset publik yang relevan dengan penyakit tanaman padi seperti *rice blast*, *bacterial leaf blight*, dan *brown spot*. Setiap citra dikategorikan berdasarkan kondisi tanaman, baik sehat maupun terinfeksi penyakit tertentu.

Tahap berikutnya adalah **pra-pemrosesan data citra**, yang bertujuan untuk meningkatkan kualitas dan konsistensi data sebelum dianalisis oleh model *deep learning*. Proses ini mencakup **normalisasi warna, augmentasi data (rotasi, flipping, zooming)** untuk meningkatkan variasi *data training*, serta **segmentasi daun** guna memfokuskan area yang relevan terhadap penyakit. Setelah tahap pra-pemrosesan, penelitian ini melanjutkan ke proses **ekstraksi fitur** menggunakan arsitektur ResNet50 (Residual Network 50-layers). Model ini dipilih karena kemampuannya dalam menangkap fitur kompleks dari citra tanaman tanpa kehilangan informasi penting akibat *vanishing gradient problem*. ResNet50 akan dilatih menggunakan dataset yang telah di-label untuk mempelajari pola-pola visual yang menjadi indikator utama penyakit padi.

Selanjutnya dilakukan **klasifikasi citra penyakit daun padi** menggunakan lapisan akhir dari model ResNet50 yang telah disesuaikan (fine-tuned). Proses klasifikasi ini bertujuan untuk mengidentifikasi jenis penyakit berdasarkan pola visual yang terdeteksi pada daun. Model dievaluasi menggunakan metrik seperti **akurasi, presisi, recall, dan F1-Score**, untuk memastikan performa prediksi yang optimal. Hasil prediksi penyakit kemudian akan **divisualisasikan melalui dashboard berbasis web**, yang menampilkan hasil prediksi penyakit pada daun padi dan tingkat akurasi nya. Aplikasi ini berfungsi sebagai alat bantu petani dan penyuluh pertanian untuk mendeteksi jenis penyakit pada daun padi secara cepat dan akurat. Melalui dashboard aplikasi SIMPADIS (*Sistem Informasi Prediksi Penyakit Daun Padi Sleman*), pengguna dapat **memantau hasil prediksi penyakit, melihat tingkat akurasi model**, serta **mengakses informasi visual dan deskripsi penyakit** yang terdeteksi. Aplikasi ini tidak hanya meningkatkan efisiensi dalam proses identifikasi penyakit tanaman, tetapi juga mendukung pengambilan keputusan berbasis data (*data-driven*) dalam pengolahan lahan pertanian yang lebih produktif dan berkelanjutan.

3. STATE OF THE ART DAN KEBARUAN

State of the art penelitian ini adalah didasarkan pada sejumlah studi terdahulu yang mengaplikasikan *deep learning* untuk deteksi dan prediksi penyakit tanaman, khususnya padi (*Oryza sativa L.*). Studi oleh (9) menggunakan *Convolutional Neural Network* (CNN) untuk mengklasifikasikan penyakit daun padi dengan akurasi mencapai 95%, namun model tersebut masih terbatas pada satu dataset tanpa mempertimbangkan variabilitas kondisi lapangan. Sementara itu (6), memanfaatkan *transfer learning* dengan model ResNet50 untuk mendeteksi penyakit padi, menghasilkan performa yang baik namun belum dioptimalkan untuk konteks geografis tertentu. Penelitian lain (10), mengembangkan sistem berbasis citra menggunakan *attention-based CNN* untuk meningkatkan akurasi deteksi penyakit daun padi. Namun, pendekatan tersebut belum menerapkan model yang dapat beradaptasi terhadap variasi kondisi iklim mikro dan geospasial di wilayah tropis seperti Indonesia. Penelitian oleh (11) menambahkan integrasi data lingkungan dan temporal dalam *deep learning* untuk prediksi penyakit tanaman, tetapi implementasinya masih bersifat eksperimental.

Berdasarkan literatur yang ada, dapat disimpulkan bahwa belum terdapat riset yang secara spesifik menggambarkan model *deep learning*, ResNet50 yang diadaptasi untuk konteks lokal (kasus di Sleman, Yogyakarta) dengan memperhatikan faktor iklim mikro, kondisi tanah, dan data visual lapangan secara real-time. Oleh karena itu, kebaruan dari penelitian ini terletak pada **pengembangan model prediksi penyakit padi berbasis ResNet50 yang diadaptasi dengan pendekatan transfer learning dan data lokal wilayah Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta** untuk mendukung pengambilan keputusan dini dalam pengelolaan pertanian presisi berkelanjutan.

Dibandingkan penelitian sebelumnya, keunggulan pendekatan yang diusulkan antara lain:

1. **Adaptasi lokal model ResNet50** menggunakan *fine-tuning* berbasis dataset citra padi lokal Sleman
2. **Integrasi data multisumber** (gambar daun, suhu, kelembapan, dan lokasi geografis) untuk meningkatkan akurasi prediksi
3. **Pendekatan kontekstual untuk wilayah tropis Indonesia**, yang belum banyak dilakukan dalam penelitian global.

4. PETA JALAN PENELITIAN




Gambar 1. Road Map Penelitian

METODE

Isian metode atau cara untuk mencapai tujuan yang telah ditetapkan ditulis tidak melebihi 1000 kata. Bagian ini dapat dilengkapi dengan diagram alir penelitian yang menggambarkan apa yang sudah dilaksanakan dan yang akan dikerjakan selama waktu yang diusulkan. Metode penelitian harus dibuat secara utuh dengan penahapan yang jelas, mulai dari awal bagaimana proses dan luarannya, dan indikator capaian yang ditargetkan yang tercermin dalam Rencana Anggaran Biaya (RAB).

Metode atau cara untuk mencapai tujuan penelitian ini dirancang melalui beberapa tahapan yang saling terkait dan mendukung pembangunan model. Diagram alir penelitian dapat dilihat pada Gambar 2.



Gambar 2. Tahap Penelitian

Pada Gambar 2 terlihat bahwa penelitian ini dimulai dengan tahapan pengolahan citra digital untuk mendeteksi penyakit daun padi secara otomatis. Proses dimulai dari **pengumpulan data citra**, baik melalui observasi lapangan menggunakan kamera digital beresolusi tinggi maupun dari dataset publik. Selanjutnya dilakukan **pra-pemrosesan citra** meliputi normalisasi, augmentasi, serta segmentasi untuk memfokuskan area daun yang relevan terhadap penyakit. Pada tahap **feature extraction**, digunakan arsitektur *ResNet50* untuk mengekstraksi ciri visual dari citra daun. Tahap berikutnya adalah **klasifikasi citra**, dimana lapisan akhir dari model *ResNet50* disesuaikan (*fine-tuned*) untuk mengidentifikasi jenis penyakit berdasarkan pola visual yang terdeteksi. Hasil prediksi kemudian di **visualisasikan melalui aplikasi Simpadis** (Sistem Informasi Prediksi Penyakit Daun Padi Sleman) yang menampilkan jenis penyakit beserta tingkat akurasinya.

Hasil yang diharapkan dari penelitian ini adalah diperolehnya sistem informasi prediktif untuk deteksi dan prediksi penyakit pada daun tanaman padi melalui penerapan model *deep learning ResNet50* dengan nama aplikasi **Simpadis** (Sistem Informasi Prediksi Penyakit Daun Padi Sleman). Indikator ketercapaian dari penelitian ini dapat dilihat pada Tabel 1, dan adapun matrik pembagian tugas berdasarkan tahap kegiatan dapat dilihat pada Tabel 2.

Tabel 1. Indikator Ketercapaian

No	Kegiatan	Indikator Ketercapaian
1	Studi literatur tentang penyakit utama pada padi di Indonesia, khususnya di Sleman, Yogyakarta	Tersusun tinjauan pustaka dan peta permasalahan terkait penyakit padi dan metode prediksi berbasis deep learning

2	Identifikasi dan pengumpulan dataset citra daun padi (terinfeksi dan sehat) di lahan pertanian Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta	Tersedia minimal 1.000 citra daun padi dengan label penyakit yang tervalidasi oleh pakar pertanian
3	Pra-pemrosesan data: segmentasi, augmentasi, dan normalisasi citra	Dataset terstandarisasi dan siap digunakan untuk pelatihan model ResNet50
4	Pengembangan dan pelatihan model deep learning (ResNet50) untuk klasifikasi penyakit padi	Model ResNet50 berhasil dilatih dengan akurasi validasi $\geq 85\%$
5	Evaluasi performa model menggunakan metrik (accuracy, precision, recall, F1-score, confusion matrix)	Diperoleh laporan performa model yang menunjukkan hasil optimal dengan validasi lapangan
6	Uji coba model pada data baru dari lokasi penelitian Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta	Model mampu memprediksi penyakit padi dengan tingkat akurasi lapangan minimal 80%
7	Analisis hasil dan pembahasan: korelasi antara kondisi lingkungan dan hasil prediksi model	Dihasilkan analisis komprehensif hubungan antara kondisi lingkungan dan pola penyakit padi
8	Penyusunan laporan penelitian internal dan artikel ilmiah untuk publikasi pada jurnal nasional terakreditasi	Laporan akhir lengkap dan draft artikel ilmiah siap dikirim ke jurnal
9	Diseminasi hasil penelitian (seminar internal/universitas atau webinar)	Terselenggaranya kegiatan diseminasi hasil riset kepada sivitas akademika dan pemangku kepentingan lokal

Tabel 2. Matriks Tahap Kegiatan, Pelaksana dan Uraian Tugas

No	Tahap Penelitian	Pelaksana & Keahlian	Uraian Tugas
1	Proses Pengumpulan Data Citra (Image)	Zaqi Kurniawan (AI & Data Science) dibantu oleh Mahasiswa	Penanggungjawab kegiatan penelitian
2	Analisis, Pra-Pemrosesan Data Citra	Zaqi Kurniawan (AI & Data Science) dibantu oleh Mahasiswa	Menganalisis data penelitian, dan interpretasi hasil penelitian
3	Feature Extraction	Rizka Tiaharyadini (Sistem Informasi dan Data Science) dibantu oleh Mahasiswa	Melakukan feature extraction dataset

4	Klasifikasi Citra (Image) Penyakit Daun Padi	Zaqi Kurniawan (AI & Data Science) dibantu oleh Mahasiswa	Melakukan proses klasifikasi terhadap citra (image) penelitian
5	Visualisasi dan coding Aplikasi Simpadis (Sistem Informasi Prediksi Penyakit Daun Padi Sleman)	Rizka Tiaharyadini (Sistem Informasi dan Data Science) dibantu oleh Mahasiswa	Coding dan membuat visualisasi dari aplikasi

JADWAL PENELITIAN

Jadwal penelitian disusun berdasarkan pelaksanaan penelitian, ditulis dengan mengisi langsung tabel berikut dan diperbolehkan menambahkan baris sesuai banyaknya jenis kegiatan.

No.	Nama Kegiatan	Bulan					
		1	2	3	4	5	6
	Persiapan dan Perancangan Penelitian	v	v				
	1. Studi literatur tentang penyakit daun padi (<i>Oryza sativa L</i>) dan model ResNet 50	v	v				
	2. Desain metodologi, pemetaan lokasi lahan (Sleman, DIY) dan izin penelitian	v					
	Pengumpulan Data Citra (Image)		v	v			
	1. Pengambilan citra daun padi di lapangan (Kamera resolusi tinggi)		v	v			
	2. Pengelompokan awal citra berdasarkan jenis penyakit			v			
	Pra-pemrosesan Citra (Pre-Processing)			v	v		
	1. Normalisasi ukuran citra dan konversi format			v			
	2. Augmentasi data (rotasi, flip, brightness) untuk menambah variasi dataset			v	v		
	Feature Extraction dengan Model ResNet 50				v	v	
	1. Fine-tuning arsitektur ResNet 50 menggunakan dataset lokal				v	v	
	2. Analisis hasil ekstraksi fitur (visualisasi layer CNN)					v	

	Klasifikasi Citra Penyakit Daun Padi					v	
	1. Pelatihan model klasifikasi dengan data latih / validasi					v	
	2. Evaluasi model (akurasi, precision, recall, dan F1-Score)					v	
	Visualisasi dan Implementasi di Aplikasi SImpadis					v	v
	1. Integrasi hasil prediksi ke dashboard SImpadis					v	v
	2. Uji coba sistem dan penyusunan laporan akhir					v	v

LUARAN DAN TARGET CAPAIAN

Tuliskan target luaran wajib dan tambahan (jika ada) yang akan dihasilkan.

No.	Kategori Luaran	Jenis Luaran	Target Capaian
1.	Artikel Ilmiah	Artikel di Jurnal ter-indeks Sinta 2 atau 3	draft/submitted/accepted/published
2.	HKI		granted (bersertifikat)

RENCANA ANGGARAN BIAYA

Total RAB: Rp 10.000.000,-

No	Jenis Pembelajaran	Komponen	Item	Kuantitas	Biaya Satuan (Rp)	Total	Persentase (%)	Ket
I	Honorarium (Maks 30%)					3.000.000	30,00 %	Maksimum batas 30%
	1. Pengumpulan data	Honor pembantu peneliti	Asisten Lapangan (Pengambilan Sampel Gambar)	1 orang x 1 bulan	500.000	500.000		Pengambilan data di Sleman, Yogyakarta.
	2. Analisis data	Honor Programmer/ Developer Prototype	Pembuatan Antarmuka Pengguna (UI/UX) dan Integrasi Model ResNet50	1 orang x 1 kali	1.400.000	1.400.000		Honor untuk pembuatan prototipe aplikasi prediksi
	3. Pelaporan penelitian	Honor administrasi peneliti	Staf Administrasi/Asisten Peneliti (Penyusunan Laporan)	1 orang x 1 kali	200.000	200.000		

	3. Pelaporan hasil penelitian dan luaran wajib	Biaya publikasi	APC Jurnal Sinta 2 / Sinta 3	1 paket	1.700.000	1.700.000		
II	Bahan Habis Pakai dan Peralatan (35-55%)					4.900.000	49,00 %	Dalam rentang 35-55 %
	4. Belanja bahan	ATK	Kertas, Tinta Printer, Pulpen, Map	1 paket	400.000	400.000		Kebutuhan administrasi dan pencetakan
	5. Belanja bahan	Bahan penelitian (habis pakai)	Akses Komputasi Cloud GPU (Training ResNet50)	2 bulan	1.000.000	2.000.000		Sewa komputasi berkinerja tinggi
	6. Belanja bahan	Bahan penelitian (habis pakai)	Biaya Hosting/Deployment Prototype	5 bulan	200.000	1.000.000		Sewa server/cloud (misal: Firebase, AWS) untuk uji coba prototipe
	7. Sewa peralatan	Peralatan penelitian	Sewa Kamera Digital	2 hari	350.000	700.000		Untuk pengumpulan data gambar padi berkualitas tinggi
III	Operasional Kegiatan Penelitian (Maks. 20%)					1.600.000	16,00 %	Dalam batas maksimal 20 %
	8. Pengumpulan data	Transport	Transportasi lokal ke lokasi sawah/petani di Sleman	5 kali	200.000	1.000.000		Transportasi tim (dosen + asisten) selama pengumpulan dan validasi data
	9. Pengumpulan data	FGD	Diskusi/Validasi Prototipe dengan Pakar/Petani	1 kali	300.000	300.000		Sewa ruang diskusi/FGD
	10. Pengumpulan data	Konsumsi	Konsumsi Rapat Awal, FGD, dan penyusunan Laporan	3 kali	100.000	300.000		Sewa ruang diskusi/FGD
IV	Lain-lain (Kekayaan Intelektual) (Maks. 10%)					500.000	5,00 %	Dalam batas maksimal 10 %

	11. Lainnya	Biaya pendaftaran HKI	Pendaftaran Hak Cipta (Ciptaan Program Komputer/Sistem Prediksi)	1 kali pemohonan	500.000	500.000		Estimasi biaya pendaftaran online ke DJKI
--	-------------	-----------------------	--	------------------	---------	---------	--	---

DAFTAR PUSTAKA

Sitasi disusun dan ditulis berdasarkan sistem nomor sesuai dengan urutan pengutipan, mengikuti format Vancouver. Sumber pustaka mengutamakan hasil penelitian pada jurnal ilmiah yang terkini (maksimal 5 tahun terakhir). Hanya pustaka yang disitasi pada usulan penelitian yang dicantumkan dalam Daftar Pustaka.

1. Lu Y, Yi S, Zeng N, Liu Y, Zhang Y. Identification of rice diseases using deep convolutional neural networks. *Neurocomputing*. 2017 Dec;267:378–84.
2. Mardiharini M, Jamal E, Rohaeni ES, Indrawanto C, Indraningsih KS, Gunawan E, et al. Indonesian rice farmers' perceptions of different sources of information and their effect on farmer capability. *Open Agric*. 2023 May 9;8(1).
3. Kamilaris A, Prenafeta-Boldú FX. Deep learning in agriculture: A survey. *Comput Electron Agric*. 2018 Apr;147:70–90.
4. He K, Zhang X, Ren S, Sun J. Deep Residual Learning for Image Recognition. In: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE; 2016. p. 770–8.
5. Chen M, Yu Z. Rice Disease Recognition Based on Improved Residual Network. 2025.
6. Simhadri CG, Kondaveeti HK, Vatsavayi VK, Mitra A, Ananthachari P. Deep learning for rice leaf disease detection: A systematic literature review on emerging trends, methodologies and techniques. *Information Processing in Agriculture*. 2025 Jun;12(2):151–68.
7. Al-Amin Md, Karim DZ, Bushra TA. Prediction of Rice Disease from Leaves using Deep Convolution Neural Network towards a Digital Agricultural System. In: 2019 22nd International Conference on Computer and Information Technology (ICCIT). IEEE; 2019. p. 1–5.
8. Simhadri CG, Kondaveeti HK, Vatsavayi VK, Mitra A, Ananthachari P. Deep learning for rice leaf disease detection: A systematic literature review on emerging trends, methodologies and techniques. *Information Processing in Agriculture*. 2025 Jun;12(2):151–68.
9. Senthil Pandi S, Senthilselvi A, Gitanjali J, ArivuSelvan K, Gopal J, Vellingiri J. Rice plant disease classification using dilated convolutional neural network with global average pooling. *Ecol Modell*. 2022 Dec;474:110166.
10. Bera A, Bhattacharjee D, Krejcar O. An attention-based deep network for plant disease classification. *Machine Graphics and Vision*. 2024 Nov 12;33(1):47–67.

11. Yakkala VS, Nusimala KV, Gayathri B, Kanamarlapudi S, Aravinth SS, Salau AO, et al. Deep learning-based crop health enhancement through early disease prediction. Cogent Food Agric. 2025 Dec 31;11(1).

- 1.



SURAT PERJANJIAN KONTRAK PENELITIAN

Nomor A/UBL/DRPM/000/180/11/25

Pada hari ini, Rabu 05 November 2025 Semester Gasal Tahun Ajaran 2025/2026, kami yang bertandatangan di bawah ini:

1. **Prof. Dr. Ir. Prudensius Maring, M.A.**, selaku Direktur Riset dan Pengabdian Kepada Masyarakat Universitas Budi Luhur, selanjutnya disebut PIHAK PERTAMA.
2. **Zaqi Kurniawan, S.Kom., M.Kom.**, selaku Peneliti selanjutnya disebut PIHAK KEDUA.

Kedua belah pihak menyatakan bersepakat untuk membuat perjanjian kontrak penelitian sebagai berikut:

Pasal 1 Judul Penelitian

PIHAK PERTAMA dalam jabatannya tersebut di atas, memberikan tugas kepada PIHAK KEDUA untuk melaksanakan penelitian yang berjudul: Prediksi Penyakit pada Daun Tanaman Padi (*Oryza sativa* L) menggunakan Model Deep Learning ResNet50. Sebuah studi untuk Precision Agriculture. Studi Kasus Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta

Pasal 2 Personalial Penelitian

Peneliti Utama : Zaqi Kurniawan, S.Kom., M.Kom.

Anggota Peneliti : Rizka Tiaharyadini, S.Kom., M.M., M.Kom.

Pasal 3 Waktu dan Biaya Penelitian

1. Waktu penelitian adalah 5 bulan, terhitung sejak tanggal 08 September 2025 sampai dengan 08 Februari 2026.
2. Biaya pelaksanaan penelitian ini dibebankan pada Yayasan Pendidikan Budi Luhur Cakti Tahun 2025 dengan nilai kontrak sebesar Rp 10,000,000.00 (sepuluh juta rupiah)

Pasal 4 Cara Pembayaran

Pembayaran biaya penelitian diberikan secara bertahap, sebagai berikut:

1. Tahap pertama sebesar 50% dari nilai kontrak, setelah surat perjanjian kontrak penelitian ini ditandatangani oleh kedua belah pihak.
2. Tahap kedua sebesar 50% dari nilai kontrak, setelah PIHAK KEDUA menyerahkan Laporan Hasil Penelitian kepada PIHAK PERTAMA.

Pasal 5 Keaslian Penelitian dan Ketidakterikatan dengan Pihak Lain

1. PIHAK KEDUA bertanggungjawab atas keaslian judul penelitian sebagaimana disebutkan dalam Pasal 1 Surat Perjanjian Kontrak Penelitian ini (bukan duplikat/jiplakan/plagiat) dari penelitian orang lain.
2. PIHAK KEDUA menjamin bahwa judul penelitian tersebut bebas dari ikatan dengan pihak lain atau tidak sedang didanai oleh pihak lain.



3. PIHAK KEDUA menjamin bahwa judul penelitian tersebut bukan merupakan penelitian yang SEDANG ATAU SUDAH selesai dikerjakan, baik didanai oleh pihak lain maupun oleh sendiri.
4. PIHAK PERTAMA tidak bertanggungjawab terhadap tindakan plagiat yang dilakukan oleh PIHAK KEDUA.
5. Apabila dikemudian hari diketahui ketidakbenaran pernyataan ini, maka kontrak penelitian DINYATAKAN BATAL, dan PIHAK KEDUA wajib mengembalikan dana yang telah diterima kepada Yayasan Pendidikan Budi Luhur Cakti sebagai pemberi dana.

Pasal 6 **Monitoring Penelitian**

1. PIHAK PERTAMA berhak untuk:
 - a. Melakukan pengawasan administrasi, monitoring, dan evaluasi terhadap pelaksanaan penelitian.
 - b. Memberikan sanksi jika dalam pelaksanaan penelitian terjadi pelanggaran terhadap isi perjanjian oleh peneliti.
 - c. Bentuk sanksi disesuaikan dengan tingkat pelanggaran yang dilakukan.
2. Pemantauan kemajuan penelitian dikoordinasikan oleh PIHAK PERTAMA.
3. Pelaksanaan kemajuan penelitian dilaksanakan pada tanggal 13 Desember 2025.
4. Format Laporan Kemajuan dan teknis pelaksanaannya diatur oleh PIHAK PERTAMA.

Pasal 7 **Laporan Akhir Penelitian**

PIHAK KEDUA wajib menyerahkan laporan akhir dalam bentuk softcopy, paling lambat tanggal 07 Februari 2026.

Pasal 8 **Sanksi**

Segala kelalaian baik disengaja maupun tidak, sehingga menyebabkan keterlambatan menyerahkan laporan hasil penelitian dengan batas waktu yang telah ditentukan akan mendapatkan sanksi sebagai berikut:

1. Tidak diperbolehkan mengajukan usulan penelitian pada semester berikutnya bagi ketua dan anggota peneliti.
2. PIHAK KEDUA diberikan kesempatan perpanjangan waktu penelitian selama 2 (dua) minggu sampai dengan tanggal 21 Februari 2026.
3. Jika setelah masa perpanjangan tersebut PIHAK KEDUA tidak dapat menyelesaikan penelitiannya, PIHAK KEDUA diwajibkan mengembalikan dana yang sudah diterima kepada Yayasan Pendidikan Budi Luhur Cakti dengan cara mengembalikan tunai kepada PIHAK PERTAMA.



Pasal 9 Penutup


Perjanjian ini berlaku sejak ditandatangani dan disetujui oleh PIHAK PERTAMA dan PIHAK KEDUA.


Jakarta, 05 November 2025

PIHAK PERTAMA

PIHAK KEDUA




Prof. Dr. Ir. Prudensius Maring, M.A.
NIP. 190043


Zaqi Kurniawan, S.Kom., M.Kom.
NIP. 190014

LAPORAN AKHIR PENELITIAN



**Prediksi Penyakit pada Daun Tanaman Padi (*Oryza Sativa L*)
menggunakan Model Deep Learning ResNet50. Sebuah Studi
untuk *Precision Agriculture*. Studi Kasus Kalurahan Dukuh,
Tridadi, Sleman, Yogyakarta**

Peneliti

Ketua : Zaqi Kurniawan, S.Kom, M.Kom. (190014)
Anggota : Rizka Tiaharyadini, S.Kom, M.M., M.Kom. (190015)

**FAKULTAS TEKNOLOGI INFORMASI
UNIVERSITAS BUDI LUHUR
FEBRUARI 2026**

HALAMAN PENGESAHAN LAPORAN PENELITIAN

Judul Penelitian : Prediksi Penyakit pada Daun Tanaman Padi (*Oryza sativa* L) menggunakan Model Deep Learning ResNet50. Sebuah studi untuk Precision Agriculture. Studi Kasus Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta

Bidang Penelitian : Ilmu Komputer – Kecerdasan Buatan

Ketua Peneliti

- a. Nama Lengkap : Zaqi Kurniawan, S.Kom., M.Kom.
- b. NIP/NIDN/ID-SINTA : 190014/0320069003/6690546
- c. Jabatan Fungsional : Asisten Ahli
- d. Program Studi : Teknik Informatika
- e. Nomor HP : 081286191991
- f. Alamat e-mail : zaqi.kurniawan@budiluhur.ac.id

Anggota Peneliti (1)

- a. Nama Lengkap : Rizka Tiaharyadini, S.Kom., M.M., M.Kom.
- b. NIP/NIDN/ID-SINTA : 190015/0327068604/6772571

Anggota Peneliti (2)

- a. Nama Lengkap :
- b. NIP/NIDN/ID-SINTA :

Mahasiswa (1)

- a. Nama Lengkap : Radiz Dirgantara
- b. NIM : 2411500107

Mahasiswa (2)

- a. Nama Lengkap : Muhammad Saddam Ryuga Octoramdhani
- b. NIM : 2411501568

Lama Penelitian : 6 bulan

Biaya Penelitian

- a. Sumber Universitas Budi Luhur : Rp. 10,000,000.00
- b. Sumber lain (sebutkan jika ada) : Rp.

Jakarta, 7 Februari 2026

Mengetahui,
Dekan/Kepala Pusat Studi



(Dr. Ir. Achmad Solichin, M.T.I.)
NIP. 050023

Ketua Pelaksana

(Zaqi Kurniawan, S.Kom., M.Kom.)
NIP. 190014

Menyetujui,
Direktur Riset dan Pengabdian Kepada Masyarakat



(Prof. Dr. Ir. Prudensius Maring, M.A.)
NIP. 190043

No. Revisi	:	0	0	7	0	1	LPJ	0	2	2	6
Tanggal	:	1	9	0	2	2	6	Paraf			

RINGKASAN

Urgensi penelitian ini timbul dari meningkatnya ancaman penyakit tanaman padi (*Oryza sativa L*) yang berdampak signifikan terhadap produktivitas dan ketahanan pangan nasional, khususnya di wilayah Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta. Kondisi iklim tropis dan pola tanam yang intensif menjadi daerah ini rentan terhadap serangan penyakit seperti blas, hawar daun bakteri, dan tungro. Oleh karena itu, diperlukan sistem deteksi dan prediksi penyakit padi yang cepat, akurat, serta mudah diimplementasikan oleh petani dan pemangku kepentingan di sektor pertanian. Penelitian ini bertujuan untuk mengembangkan model prediksi pada berbasis *deep learning* menggunakan arsitektur ResNet50, yang mampu mengenali dan mengklasifikasikan jenis penyakit padi melalui citra daun secara otomatis. Model ini diharapkan dapat mendeteksi gejala penyakit sejak dini dengan akurasi tinggi, sehingga membantu dalam pengambilan keputusan pengendalian penyakit secara tepat waktu. Metode penelitian yang digunakan meliputi tahap *data acquisition* melalui pengumpulan citra daun padi dari lapangan di wilayah Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta, *data preprocessing* untuk peningkatan kualitas citra, serta *model training* dan *validation* menggunakan arsitektur ResNet50 dengan menggunakan teknik *transfer learning*. Evaluasi model dilakukan dengan metrik akurasi, presisi, dan F1-Score untuk menilai performa sistem.

Kata Kunci: Penyakit tanaman padi; Deep Learning; ResNet 50; Deteksi Citra; Prediksi Penyakit Padi

PRAKATA

Puji dan syukur kami curahkan ke hadirat Tuhan Yang Maha Esa yang telah mencurahkan semua karunia sehingga diberikan keyakinan dan kemudahan dalam menyusun dan menyiapkan laporan penelitian ini dengan judul “ ***Prediksi Penyakit pada Daun Tanaman Padi (Oryza sativa L) menggunakan Model Deep Learning ResNet50. Sebuah studi untuk Precision Agriculture. Studi Kasus Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta*** ”.

Pada kesempatan ini, peneliti ingin menyampaikan rasa terima kasih yang tak terhingga kepada:

1. Bapak Dr. Ir. Achmad Solichin, S.Kom, M.T.I., sebagai Dekan Fakultas Teknologi Informasi Universitas Budi Luhur.
2. Bapak Dr. Ir. Prudensius Maring, M.A., sebagai Direktur Riset dan Pengabdian Kepada Masyarakat Universitas Budi Luhur.
3. Untuk semua pihak yang telah membantu penelitian ini, mohon maaf apabila ada kesalahan yang terucap dan terbersit, mohon dibukakan pintu maaf yang selang-seling.

Akhirnya dengan segala kerendahan hati, kami segenap tim peneliti berharap agar penelitian ini dapat memberikan manfaat bagi peneliti, lingkungan kampus dan sekitarnya. Saran dan kritik yang membangun sangat diharapkan guna perbaikan penelitian mendatang.

Jakarta, Februari 2026

DAFTAR ISI

HALAMAN SAMPUL	i
HALAMAN PENGESAHAN.....	ii
RINGKASAN	iii
PRAKATA.....	iv
DAFTAR ISI.....	v
DAFTAR TABEL.....	vi
DAFTAR GAMBAR.....	vii
DAFTAR LAMPIRAN.....	viii
BAB I PENDAHULUAN.....	1
1.1 Latar Belakang dan Rumusan Masalah.....	1
1.2 Pendekatan Pemecahan Masalah	3
1.3 <i>State of the art</i> dan Kebaruan.....	4
1.4 Peta Jalan Penelitian.....	5
BAB II METODE.....	7
BAB III HASIL PELAKSANAAN PENELITIAN.....	15
BAB IV KESIMPULAN DAN SARAN	27
DAFTAR PUSTAKA	29
LAMPIRAN.....	30
Lampiran 1. Realisasi Penggunaan Anggaran	30
Lampiran 2. Surat Perjanjian Kontrak Penelitian	35
Lampiran 3. Catatan Harian.....	38
Lampiran 4. Artikel Ilmiah (draft/submitted/accepted/published)	39
Lampiran 5. HKI.....	40

DAFTAR TABEL

Tabel 2.1. Rekap Data Citra Berdasarkan Kondisi Pengelompokan	8
Tabel 3.1. Rekap Data Citra Berdasarkan Hasil Kondisi.....	17
Tabel 3.2. Distribusi Citra Daun Padi Sebelum dan Sesudah Augmentasi.....	19
Tabel 3.3. Hasil Uji Parameter Training Model ResNet50.....	20
Tabel 3.4. Hasil Uji Model pada Data Riil Petani Dukuh, Sleman, DIY.....	26

DAFTAR GAMBAR

Gambar 1.1. <i>Roadmap</i> Penelitian	6
Gambar 2.1. Tahap Penelitian	7
Gambar 2.2. Data Citra (<i>Image</i>) Daun Padi.....	8
Gambar 2.3. Tahapan <i>Pre-processing</i> Citra (<i>Image</i>) Daun Padi	10
Gambar 2.4. Arsitektur Feature Extraction	11
Gambar 2.5. Klasifikasi Citra Penyakit Daun Padi.....	12
Gambar 2.6. Arsitektur ResNet50.....	13
Gambar 2.7. <i>Interface</i> Aplikasi Simpadis.....	14
Gambar 3.1. <i>Import Library</i>	15
Gambar 3.2. <i>Load Image dan Resize</i> Citra	16
Gambar 3.3. <i>Generate dan Tampilkan Hasil Augmentasi</i>	16
Gambar 3.4. Citra Daun Padi Setelah Proses Augmentasi	16
Gambar 3.5. Alur Preprocessing Citra (<i>Image</i>)	17
Gambar 3.6. Perbandingan Kinerja ResNet-50 Berdasarkan Parameter Uji	22
Gambar 3.7. <i>Confusion Matrix</i>	24
Gambar 3.8. <i>Workflow</i> Deteksi Penyakit Padi.....	25
Gambar 3.9. <i>Workflow</i> Aplikasi Simpadis.....	26

DAFTAR LAMPIRAN

Lampiran 1 Realisasi Penggunaan Anggaran	30
Lampiran 2 Surat Perjanjian Kontrak Penelitian	35
Lampiran Catatan Harian.....	38
Lampiran 4 Artikel Ilmiah	39
Lampiran 5. HKI.....	40

BAB I

PENDAHULUAN

1.1. Latar Belakang dan Perumusan Masalah

Padi (*Oryza sativa L.*) adalah komoditas pangan strategis di Indonesia, menduduki posisi utama sebagai sumber karbohidrat pokok bagi sebagian besar populasi dan menjadi landasan krusial bagi ketahanan pangan nasional (1). Implikasi dari komoditas ini meluas dari aspek konsumsi hingga stabilitas ekonomi dan sosial, didukung oleh perannya dalam menyerap tenaga kerja dalam jumlah signifikan dalam rantai nilai pertanian (2). Oleh karena itu, mempertahankan produksi padi yang optimal, yang meliputi mitigasi penyakit daun secara proaktif, adalah keharusan dalam kerangka pertanian presisi (*Precision Agriculture*).

Produktivitas padi semakin menurun karena serangan penyakit daun seperti bercak coklat (*Brown Spot*) yang oleh beberapa studi internasional menyebutkan kerugian hasil hingga 26 – 52% (3). Selain itu, penyakit bakteri hawar daun (*Bacterial Leaf Blight*) yang ada di Indonesia dapat menimbulkan kerugian hingga 50% (4). Serangan gabungan seperti bercak coklat, bakteri hawar daun, dan penyakit *smurf leaf* dapat mengurangi area fotosintesis pada daun, menurunkan pembentukan bulir dan akhirnya akan menekan produktivitas padi secara signifikan.

Pada wilayah Sleman, Yogyakarta-sebagai salah satu sentra pertanian padi di Pulau Jawa-fluktuasi serangan penyakit tersebut masih menjadi permasalahan utama bagi petani, terutama pada musim hujan ketika kondisi lingkungan mendukung perkembangan *pathogen* (5). Petani di Kalurahan Dukuh, Tridadi, Sleman sering kesulitan mengenali tanda-tanda awal penyakit pada daun tanaman padi karena gejala yang mirip dan pengetahuan lapangan yang terbatas (6). Keterbatasan jumlah tenaga penyuluh dan waktu kunjungan yang singkat memperburuk keterlambatan diagnosis, sehingga pencegahan dan pengendalian menjadi kurang tepat sasaran (7). Akibatnya, serangan penyakit terlambat ditangani sehingga berpotensi menurunkan hasil panen

dan meningkatkan biaya pengendalian bagi petani skala kecil (8).

Kemajuan teknologi kecerdasan buatan (*Artificial Intelligence*), telah membuka peluang besar untuk mendeteksi dan memprediksi penyakit tanaman secara otomatis dan presisi tinggi melalui citra daun padi (9). Salah satu arsitektur yang terbukti efektif dalam pengenalan citra adalah *Residual Network* (ResNet50), yang memiliki kemampuan dalam mengekstraksi fitur visual kompleks dengan akurasi tinggi (10). Selain itu, penelitian terkini juga mengidentifikasi bahwa penggunaan ResNet-50 sebagai backbone pre-trained CNN sangat menjanjikan dalam proses klasifikasi penyakit daun padi. Sebuah studi komparatif menunjukkan bahwa ResNet50 mengungguli banyak arsitektur lain-baik CNN maupun *Vision Transformer* dalam mendeteksi penyakit daun padi (11).

Selain itu, integrasi teknik ekstraksi fitur *Histogram of Oriented Gradients* (HOG) dengan fitur yang dihasilkan oleh ResNet50 mampu meningkatkan akurasi klasifikasi hingga sekitar 91% (12). Pendekatan ini juga diperkuat oleh analisis visual menggunakan *Grad-Cam*, yang memperlihatkan bahwa ResNet-50 dengan fitur HOG lebih fokus pada area daun yang secara agronomis relevan terhadap gejala penyakit (13). Dengan demikian, adopsi arsitektur ResNet50 dalam sistem deteksi penyakit tanaman padi tidak hanya meningkatkan performa prediksi, tetapi juga memperkuat interpretabilitas model yang sangat penting dalam penerapan di lapangan. Karena itu, integrasi pengolahan citra, *machine learning*, dan platform penginderaan seperti *drone* maupun kamera lapangan menjadi elemen penting untuk mewujudkan sistem deteksi dini penyakit tanaman yang lebih *scalable* dalam penerapan *Precision agriculture*. Rumusan permasalahan dari penelitian ini adalah sebagai berikut:

1. Bagaimana mengembangkan model *Deep Learning* berbasis ResNet-50 yang mampu mendeteksi dan memprediksi penyakit padi (*Oryza sativa L*) secara akurat berdasarkan citra daun ?
2. Bagaimana akurasi dan kinerja model tersebut dibandingkan dengan model konvensional seperti CNN sederhana atau MobileNet ?
3. Bagaimana penerapan hasil model dalam konteks Precision Agriculture di Wilayah Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta ?

1.2. Pendekatan Pemecahan Masalah

Pendekatan pemecahan masalah dalam penelitian ini dimulai dengan proses pengumpulan data citra daun padi (*Oryza sativa L*), dari berbagai lahan pertanian di wilayah Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta. Data dikumpulkan melalui observasi lapangan menggunakan kamera digital beresolusi tinggi, serta melalui dataset publik yang relevan dengan penyakit tanaman padi seperti *rice blast*, *bacterial leaf blight*, dan *brown spot*. Setiap citra dikategorikan berdasarkan kondisi tanaman, baik sehat maupun terinfeksi penyakit tertentu.

Tahap berikutnya adalah pra-pemrosesan data citra, yang bertujuan untuk meningkatkan kualitas dan konsistensi data sebelum dianalisis oleh model *deep learning*. Proses ini mencakup normalisasi warna, augmentasi data (rotasi, *flipping*, *zooming*) untuk meningkatkan variasi *data training*, serta segmentasi daun guna memfokuskan area yang relevan terhadap penyakit. Setelah tahap pra-pemrosesan, penelitian ini melanjutkan ke proses ekstraksi fitur menggunakan arsitektur ResNet-50 (*Residual Network 50-layers*). Model ini dipilih karena kemampuannya dalam menangkap fitur kompleks dari citra tanaman tanpa kehilangan informasi penting akibat *vanishing gradient problem*. ResNet-50 akan dilatih menggunakan dataset yang telah di-label untuk mempelajari pola-pola visual yang menjadi indikator utama penyakit padi.

Proses selanjutnya dilakukan klasifikasi citra penyakit daun padi menggunakan lapisan akhir dari model ResNet-50 yang telah disesuaikan (*fine-tuned*). Proses klasifikasi ini bertujuan untuk mengidentifikasi jenis penyakit berdasarkan pola visual yang terdeteksi pada daun. Model dievaluasi menggunakan metrik seperti *accuracy*, *precision*, *recall*, dan *F1-Score*, untuk memastikan performa prediksi yang optimal. Hasil prediksi penyakit kemudian akan divisualisasikan melalui dashboard berbasis web, yang menampilkan hasil prediksi penyakit pada daun padi dan tingkat akurasi nya.

Aplikasi ini berfungsi sebagai alat bantu petani dan penyuluh pertanian untuk mendeteksi jenis penyakit pada daun padi secara cepat dan akurat. Melalui dashboard aplikasi SIMPADIS (*Sistem Informasi Prediksi Penyakit Daun Padi Sleman*), pengguna dapat memantau hasil prediksi penyakit, melihat tingkat akurasi model, serta mengakses informasi visual dan deskripsi penyakit yang terdeteksi. Aplikasi ini tidak hanya meningkatkan efisiensi dalam proses identifikasi penyakit tanaman, tetapi juga mendukung pengambilan keputusan berbasis data (*data-driven*) dalam pengolahan lahan pertanian yang lebih produktif dan berkelanjutan.

1.3. State of The Art dan Kebaruan

State of the art penelitian ini adalah didasarkan pada sejumlah studi terdahulu yang mengaplikasikan *deep learning* untuk deteksi dan prediksi penyakit tanaman, khususnya padi (*Oryza sativa L.*). Studi oleh (14) menggunakan *Convolutional Neural Network* (CNN) untuk mengklasifikasikan penyakit daun padi dengan akurasi mencapai 95%, namun model tersebut masih terbatas pada satu dataset tanpa mempertimbangkan variabilitas kondisi lapangan. Sementara itu (11), memanfaatkan *transfer learning* dengan model ResNet-50 untuk mendeteksi penyakit padi, menghasilkan performa yang baik namun belum dioptimalkan untuk konteks geografis tertentu.

Penelitian lain (15), mengembangkan sistem berbasis citra menggunakan *attention-based CNN* untuk meningkatkan akurasi deteksi penyakit daun padi. Namun, pendekatan tersebut belum menerapkan model yang dapat beradaptasi terhadap variasi kondisi iklim mikro dan geospasial di wilayah tropis seperti Indonesia. Penelitian oleh (16) menambahkan integrasi data lingkungan dan temporal dalam *deep learning* untuk prediksi penyakit tanaman, tetapi implementasinya masih bersifat eksperimental.

Berdasarkan literatur yang ada, dapat disimpulkan bahwa belum terdapat riset yang secara spesifik menggambarkan model *deep learning*, ResNet-50 yang diadaptasi untuk konteks lokal (kasus di Sleman, Yogyakarta) dengan memperhatikan faktor iklim mikro, kondisi tanah, dan data visual lapangan secara real-time. Oleh karena itu, kebaruan dari penelitian ini terletak pada pengembangan model prediksi penyakit padi berbasis ResNet-50 yang diadaptasi dengan pendekatan *transfer learning* dan data lokal wilayah Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta untuk mendukung pengambilan keputusan dini dalam pengelolaan pertanian presisi berkelanjutan.

1.4. Peta Jalan (Roadmap) Penelitian

Roadmap riset ini menggambarkan pengembangan penelitian yang berkelanjutan selama periode 2025 hingga 2029 dalam bidang prediksi penyakit dan produktivitas tanaman padi berbasis *deep learning*. Tahap awal pada tahun 2025 difokuskan pada penelitian dasar berupa prediksi penyakit padi (*Oryza sativa L*) menggunakan model *deep learning* ResNet-50 dengan studi kasus di Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta, sebagai fondasi pemodelan dan validasi awal di tingkat lokal. Selanjutnya, pada tahun 2026 penelitian diarahkan pada penguatan model dan dataset lokal melalui optimasi ResNet-50 dan penerapan *transfer learning* untuk meningkatkan akurasi deteksi penyakit daun padi di wilayah Sleman, DIY.

Pada tahun 2027, roadmap penelitian berkembang menuju integrasi data multisumber dengan mengombinasikan citra daun padi dan data cuaca mikro yang

diperoleh dari sensor IoT di lahan pertanian, sehingga model prediksi menjadi lebih kontekstual dan adaptif terhadap kondisi lingkungan. Tahap berikutnya pada tahun 2028 menekankan adaptasi spasial dan temporal melalui pengembangan model *spatio-temporal deep learning* berbasis CNN-LSTM untuk pemantauan dinamika penyakit padi di wilayah DIY secara berkelanjutan. Puncak *roadmap* pada tahun 2029 adalah pengembangan sistem terintegrasi dan implementasi lapangan yang berfokus pada prediksi produktivitas padi berbasis deteksi penyakit dan kondisi lahan menggunakan model *deep learning* multivariable sebagai dasar pengambilan keputusan pertanian cerdas. Detail *roadmap* riset dapat dilihat pada Gambar 1.1 berikut ini:



Gambar 1.1 *Roadmap* Penelitian

BAB II

METODE

Gambaran menyeluruh mengenai alur kerja sistem yang dikembangkan diawali dengan pemahaman terhadap tahapan pemrosesan data citra yang digunakan dalam penelitian ini. Pada Gambar 2.1 memperlihatkan tahapan penelitian yang mencakup proses pengumpulan data citra, pra-pemrosesan, ekstraksi fitur, klasifikasi penyakit daun padi, hingga visualisasi hasil prediksi melalui aplikasi sistem informasi. Detail pembahasan setiap langkah penelitian tersebut dijelaskan secara sistematis pada subbab dibawah ini untuk memberikan kejelasan metodologis dan alur implementasi yang digunakan.



Gambar 2.1 Tahap Penelitian

2.1. Proses Pengumpulan Data Citra (*Image*)

Proses pengambilan data citra merupakan tahapan awal yang sangat krusial dalam penelitian ini karena kualitas visual data yang diperoleh akan sangat menentukan kinerja model pada tahap selanjutnya. Pengumpulan citra daun padi

dilakukan melalui observasi lapangan secara langsung di empat lokasi area persawahan yang berada di Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta. Pengambilan gambar dilakukan menggunakan kamera digital beresolusi tinggi untuk memastikan detail visual gejala penyakit pada permukaan daun, seperti perubahan warna, bercak, dan pola kerusakan jaringan, dapat terekam dengan jelas.

Proses akuisisi citra dilakukan pada kondisi pencahayaan alami di lapangan dengan variasi sudut pengambilan dan jarak kamera yang terkontrol, sehingga menghasilkan keragaman data yang representatif terhadap kondisi nyata di lapangan. Selain data primer hasil observasi, penelitian ini juga memanfaatkan *dataset* publik yang relevan dengan penyakit daun padi, seperti *rice blast*, *bacterial leaf blight*, dan *brown spot*, sebagai data pendukung. Kombinasi data lapangan dan dataset publik ini bertujuan untuk memperkaya variasi citra serta meningkatkan kemampuan generalisasi model dalam mengenali berbagai jenis penyakit daun, adapun citra hasil pengumpulan ada pada Gambar 2.2, dan tabel rekap hasil pengambilan data citra (*image*) di lahan pertanian dapat dilihat pada Tabel 2.1.



Gambar 2.2 Data Citra (*Image*) Daun Padi

Tabel 2.1 Rekap Data Citra (*Image*) Hasil Pengelompokan Berdasarkan Kondisi

Kelas Penyakit	Jumlah Citra (<i>Image</i>)
Daun Sehat (Healthy)	320
Blight (Bercak Daun)	280
Brown Spot (Hawar Daun)	300
Leaf Smut (Bercak Cokelat)	250
Total	1.150

2.2. Pra-Pemrosesan Data Citra (*Image*)

Tahap pra-pemrosesan data citra (*image*) berperan penting dalam meningkatkan kualitas data sebelum digunakan pada proses *learning model*. Pada tahap ini, citra daun padi yang telah dikumpulkan terlebih dahulu melalui proses normalisasi warna dengan tujuan untuk meminimalkan pengaruh variasi pencahayaan serta perbedaan kondisi akuisisi citra di lapangan, sehingga karakteristik visual daun yang dianalisis menjadi lebih konsisten dan representatif. Selanjutnya, dilakukan proses augmentasi data yang meliputi rotasi, *flipping*, dan *zooming* untuk memperkaya keragaman data *training* tanpa menambah jumlah data asli, sehingga mampu meningkatkan kemampuan generalisasi model dalam mengenali berbagai variasi dan kondisi visual pada data citra.

Setelah itu, tahap segmentasi daun diterapkan untuk memisahkan area daun padi dari latar belakang citra (*image*), sehingga proses analisis dapat difokuskan secara eksklusif pada bagian yang relevan dengan indikasi gejala penyakit. Penerapan segmentasi ini mengurangi gangguan informasi non-relevan yang berpotensi menurunkan kinerja model. Secara keseluruhan, integrasi berbagai tahapan dari pra-pemrosesan bertujuan menghasilkan data citra yang lebih bersih, kaya informasi, dan representatif, sehingga mampu mendukung proses ekstraksi fitur serta klasifikasi penyakit daun padi dengan tingkat akurasi yang lebih optimal. Adapun detail dari tahapan pra-pemrosesan dapat dilihat pada Gambar 2.3 di bawah ini.




Gambar 2.3 Tahapan *Pre-processing* Citra (Image) Daun Padi

2.3. Feature Extraction

Tahap *feature extraction* pada penelitian ini berperan krusial dalam menangkap karakteristik visual yang merepresentasikan gejala penyakit pada daun padi, seperti perubahan warna, tekstur bercak, pola nekrosis, dan struktur tepi daun. *Feature extraction* dilakukan menggunakan arsitektur *deep convolutional neural network* ResNet-50, yang secara teoritis dirancang untuk mengatasi masalah *vanishing gradient* melalui mekanisme residual learning dengan *skip connections* sehingga jaringan dapat mengekstraksi fitur tingkat rendah hingga tingkat tinggi secara lebih stabil dan efektif (17).

Dalam konteks analisis citra daun padi, lapisan awal pada arsitektur ResNet-50 berperan dalam mengekstraksi fitur tingkat rendah, seperti tepi sudut, dan gradien intensitas warna. Seiring bertambahnya kedalaman jaringan, lapisan-lapisan berikutnya secara bertahap mempelajari representasi fitur tingkat tinggi yang lebih abstrak dan semantik, yang merefleksikan pola kompleks pada citra daun, termasuk morfologi bercak penyakit, variasi dan distribusi warna klorosis, serta karakteristik tekstur spesifik yang menjadi pembeda utama pada penyakit seperti *rice blast*,

bacterial leaf blight, dan *brown spot*. Sejumlah studi terdahulu pada deteksi penyakit daun padi menunjukkan penggunaan CNN berbasis *transfer learning*, termasuk ResNet-50, menghasilkan akurasi klasifikasi yang tinggi karena fitur yang diekstraksi bersifat *robust* terhadap variasi pencahayaan serta sudut pengambilan gambar (18). Proses feature extraction pada CNN dapat dilihat pada Gambar 2.4 di bawah ini.




Gambar 2.4 Arsitektur Feature Extraction

2.4. Klasifikasi Citra (Image) Penyakit Daun Padi

Pada tahap klasifikasi citra daun padi, sistem mengoptimalkan lapisan akhir (*classification head*) dari arsitektur ResNet-50 yang telah disesuaikan melalui proses *fine-tuning*. Model ResNet-50 yang telah di *pretrained* pada dataset berskala besar dimanfaatkan sebagai feature extractor untuk mengekstraksi representasi visual tingkat tinggi, meliputi pola tekstur bercak, variasi warna, serta karakteristik morfologi yang secara spesifik merepresentasikan gejala berbagai jenis penyakit pada daun padi (19). Lapisan *fully connected* bawaan pada model kemudian digantikan dengan lapisan klasifikasi baru dan dilatih ulang (*fine-tuned*) agar sesuai dengan kelas penyakit target penelitian. Proses klasifikasi ini dirancang untuk mengidentifikasi jenis penyakit daun padi secara akurat dengan memanfaatkan representasi fitur mendalam yang dihasilkan oleh jaringan saraf konvolusional.

Pendekatan ini memungkinkan model untuk menangkap dan membedakan pola visual khas dari berbagai penyakit, seperti *rice blast*, *bacterial leaf blight*, dan *brown spot*, secara lebih *robust* dan diskriminatif dibandingkan metode konvensional yang bergantung pada ekstraksi fitur manual. Pada Gambar 2.5 dapat dilihat detail dari proses klasifikasi citra (*image*) penyakit daun padi.




Gambar 2.5 Klasifikasi Citra Penyakit Daun Padi

2.5. Arsitektur ResNet50

ResNet-50 merupakan salah satu arsitektur *deep learning* paling berpengaruh dalam bidang *computer vision*, terutama dalam deteksi dan klasifikasi citra. ResNet-50 terdiri dari 50 lapisan konvolusional dengan blok *residual* yang memungkinkan jaringan belajar perbedaan antara input dan output dari setiap lapisan, bukan mempelajari dari pemetaan langsung (20). Pendekatan ini meningkatkan efisiensi propagasi gradien serta mempercepat proses konvergensi model (21).

Dalam konteks, *Precision Agriculture*, ResNet50 terbukti efektif untuk klasifikasi penyakit daun tanaman seperti padi (*Oryza sativa L*). Penelitian oleh (22), penerapan ResNet50 pada deteksi penyakit daun padi menghasilkan akurasi tinggi diatas 96%, dengan performa stabil pada berbagai kondisi pencahayaan di lapangan. Studi lain oleh (23) menunjukkan bahwa *transfer learning* dengan ResNet-50 mampu meningkatkan deteksi penyakit kapas dan padi melalui optimasi bobot pra-latih yang diperoleh dari dataset *ImageNet*. Sementara itu, penelitian oleh (24) dengan model *PlantDiseaseNet-RT50* menunjukkan peningkatan akurasi sebesar 2,5% dibandingkan ResNet50 standar, menandakan potensi besar dari arsitektur ini untuk aplikasi pertanian presisi berbasis citra.

ResNet50 memiliki lima tahap utama dalam arsitekturnya, yaitu lapisan konvolusi awal (*Conv + Pooling*), empat tahap *residual block* dengan *skip connections*, diikuti oleh *global average pooling* dan lapisan *fully connected* untuk klasifikasi akhir menggunakan fungsi aktivasi *softmax*. Struktur ini menghasilkan sistem yang efisien dalam mengekstraksi fitur citra (*image*) daun, termasuk pola gejala seperti bercak, nekrosis atau perubahan warna, yang menjadi indikator penyakit tanaman (20). Adapun detail dari arsitektur ResNet -50 dapat dilihat pada Gambar 2.6 di bawah ini:



Gambar 2.6 Arsitektur ResNet-50

2.6. Visualisasi melalui Aplikasi SIMPADIS

Pada tahap klasifikasi citra daun padi, hasil pemodelan *deep learning* yang telah dilatih selanjutnya diintegrasikan ke dalam aplikasi Simpadis (Sistem Informasi Prediksi Penyakit Daun Padi Sleman) sebagai media visualisasi dan penyajian informasi. Aplikasi ini berfungsi untuk menampilkan keluaran model berupa jenis penyakit yang terdeteksi pada daun padi dan beserta tingkat akurasi prediksi secara informastif dan mudah dipahami oleh *user*. Melalui *interface* Simpadis seperti pada Gambar 2.7 di bawah ini, citra daun yang diunggah atau diambil dari lapangan dapat dianalisis secara otomatis, kemudian dalam bentuk label penyakit seperti *rice blast*, *bacterial leaf blight*, dan *brown spot*, disertai indikator presentase keakuratan model. Visualisasi ini tidak hanya mendukung interpretasi hasil klasifikasi secara cepat dan objektif, tetapi juga berperan sebagai alat bantu pengambilan keputusan bagi petani dan pemangku kepentingan terkait dalam menentukan langkah penanganan penyakit tanaman padi secara tepat dan berbasis data.



Gambar 2.7 *Interface* Aplikasi Simpadis

BAB III

HASIL PELAKSANAAN PENELITIAN

3.1. Deskripsi Dataset dan Preprocessing

Dataset yang digunakan dalam penelitian ini terdiri atas citra (*image*) daun tanaman padi (*Oryza sativa L*) yang diambil dari lahan pertanian di Kalurahan Dukuh, Tridadi, Sleman, Yogyakarta, serta dilengkapi dengan data tambahan dari sumber terbuka seperti *PlantVillage* dan *Rice Leaf Disease Dataset (UCI Repository 2023)*. Setiap citra dikumpulkan menggunakan kamera beresolusi tinggi pada kondisi pencahayaan alami untuk memastikan keaslian warna dan tekstur daun. Dataset mencakup empat kelas utama, yaitu: Daun Sehat (*Healthy*), *Blight* (Bercak Daun), *Brown Spot* (Hawar Daun), dan *Leaf Smut* (Bercak Coklat).

Sebelum model ResNet50 dilatih, dilakukan serangkaian tahapan *preprocessing* terhadap *image*, untuk memastikan kualitas data dan mengurangi *noise* visual. Langkah pertama ialah *resize* citra ke resolusi yang seragam yaitu 224 x 224 piksel sesuai kebutuhan arsitektur ResNet50. Kemudian dilakukan augmentasi citra meliputi *rotation* ($\pm 20^\circ$), *horizontal / vertical flipping*, *zoom range* (0.2), dan *brightness adjustment* ($\pm 10\%$) untuk meningkatkan variasi data dan mencegah *overfitting* menggunakan kode pemrograman python seperti pada Gambar 3.1, 3.2, dan 3.3 di bawah ini. Hasil dari proses augmentasi citra dapat dilihat pada Gambar 3.4.

```
python

import tensorflow as tf
import numpy as np
import matplotlib.pyplot as plt
from tensorflow.keras.preprocessing.image import load_img, img_to_array
from tensorflow.keras.preprocessing.image import ImageDataGenerator
```

Gambar 3.1 *Import Library*

```
# Ganti path sesuai Lokasi image Anda
image_path = "sample_image.jpg"

# Load image dan resize ke 224x224
img = load_img(image_path, target_size=(224, 224))
img_array = img_to_array(img)
img_array = np.expand_dims(img_array, axis=0) # Tambahkan batch dimension
```

Gambar 3.2 Load Image dan Resize Citra

```
augmented_iterator = datagen.flow(img_array, batch_size=1)

# Ambil satu hasil augmentasi
augmented_image = next(augmented_iterator)[0]

# Tampilkan image hasil preprocessing & augmentasi
plt.figure(figsize=(5, 5))
plt.imshow(np.clip(augmented_image / 255.0, 0, 1))
plt.title("Hasil Preprocessing & Augmentasi")
plt.axis("off")
plt.show()
```

Gambar 3.3 Generate dan Tampilkan Hasil Augmentasi




Gambar 3.4 Citra Daun Padi Setelah Proses Augmentasi

Selanjutnya dilakukan normalisasi piksel dengan skala nilai 0-1 melalui pembagian setiap piksel dengan 255, sehingga distribusi data menjadi lebih stabil pada saat *training* model. Pada Tabel 3.1 diperlihatkan distribusi jumlah citra (*image*) per kelas penyakit sebelum dan sesudah augmentasi. Proses ini menghasilkan dataset yang lebih seimbang

antar kelas dan memperkuat kemampuan generalisasi model terhadap variasi kondisi nyata di lapangan. Pada Gambar 3.5 menunjukkan diagram alur *preprocessing* dataset dari tahap akuisisi citra hingga normalisasi akhir sebelum dimasukkan ke dalam model ResNet-50.

Tabel 3.1 Rekap Data Citra (*Image*) Hasil Pengelompokan Berdasarkan Kondisi

Kelas Citra	Jumlah Asli (Citra)	Setelah Augmentasi (Citra)
Daun Sehat (Healthy)	320	557
Blight (Bercak Daun)	280	487
Brown Spot (Hawar Daun)	300	522
Leaf Smut (Bercak Cokelat)	250	434
Total	1.150	2.000



Gambar 3.5 Alur Preprocessing Citra (*Image*)

3.2. Hasil Pelatihan Model ResNet-50

3.2.1 Parameter Training (Epoch, Batch Size, dan Optimizer)

Dalam proses pelatihan model deep learning seperti ResNet-50 untuk deteksi penyakit daun padi (*Oryza sativa L*), penentuan parameter training menjadi aspek krusial untuk mencapai performa optimal dan mencegah *overfitting*. Parameter utama yang

memengaruhi konvergensi model meliputi jumlah *epoch* (E), ukuran *batch* (B), dan algoritma *optimizer* yang digunakan (O). Jumlah *epoch* mengacu pada banyaknya iterasi seluruh pelatihan melalui jaringan, dimana setiap iterasi memperbarui bobot model berdasarkan *loss function*. Proses pembaruan bobot dilakukan menggunakan optimasi gradien dengan persamaan sebagai berikut:

$$w_{t+1} = w_t - \eta \nabla L(w_t) \quad (1)$$

Dimana w_t adalah bobot pada iterasi ke - t , η adalah learning rate, dan $\nabla L(w_t)$ merupakan gradien fungsi kehilangan bobot. Nilai *epoch* yang terlalu tinggi dapat menyebabkan *overfitting*, sedangkan terlalu rendah dapat menyebabkan *underfitting* (25). Ukuran *batch* (B), menentukan jumlah sampel yang diproses sebelum parameter diperbarui, ukuran *batch* yang besar mempercepat komputasi tetapi dapat juga mengurangi kemampuan model untuk keluar dari *local minima*, sedangkan, *batch* kecil memberikan pembaruan yang lebih bervariasi namun memerlukan waktu lebih lama untuk konvergensi. Secara matematis, *total loss function* (L) pada satu *epoch* dapat ditulis sebagai:

$$L = \frac{1}{B} \sum_{i=1}^B l(f(x_i, w), y_i) \quad (2)$$

Dimana l adalah fungsi kehilangan individual, $f(x_i, w)$ merepresentasikan keluaran jaringan saraf untuk sample ke - i dengan parameter w , dan y_i adalah label actual dari sample tersebut (26). Selanjutnya, pemilihan *optimizer* sangat berpengaruh pada stabilitas dan kecepatan konvergensi pelatihan. Beberapa penelitian membandingkan performa *Stochastic Gradient Descent* (SGD), Adam, dan *RMSprop* pada model ResNet-50 untuk deteksi penyakit daun padi. Penelitian (27) menunjukkan bahwa kombinasi *Adam optimizer* dengan *batch size* = 32 dan *epoch* = 30 menghasilkan akurasi hingga 97,8%, dengan stabilitas *loss curve* yang baik. Hal ini dikonfirmasi pula oleh (28) dan (29) yang menemukan bahwa *Adam* memberikan konvergensi yang lebih cepat dibanding SGD tradisional, karena penggunaan momentum adaptasi terhadap gradien.

Dalam penelitian ini, model ResNet-50 digunakan untuk melakukan klasifikasi citra daun padi (*Oryza sativa L*) ke dalam empat kategori, yaitu Sehat, *Blight* (Bercak Daun), *Brown Spot* (Hawar Daun), dan *Leaf Smut* (Bercak Coklat). Dataset yang digunakan terdiri atas 1.150 citra asli yang kemudian diperluas menjadi 2.000 citra melalui proses augmentasi, sebagaimana ditunjukkan pada Tabel 3.2. Proses augmentasi citra meliputi rotasi, *flipping horizontal*, *zooming*, dan penyesuaian kontras yang bertujuan untuk meningkatkan keragaman data dan mencegah *overfitting*.

Tabel 3.2 Distribusi Data Citra Daun Padi Sebelum dan Sesudah Augmentasi

Kelas Citra	Jumlah Asli (Citra)	Setelah Augmentasi (Citra)
Daun Sehat (Healthy)	320	557
<i>Blight</i> (Bercak Daun)	280	487
<i>Brown Spot</i> (Hawar Daun)	300	522
<i>Leaf Smut</i> (Bercak Cokelat)	250	434
Total	1.150	2.000

Dalam tahap penelitian, beberapa parameter training diuji untuk memperoleh konfigurasi yang paling optimal dalam meningkatkan akurasi klasifikasi model. Parameter utama yang divariasikan mencakup jumlah *epoch*, ukuran *batch size*, serta jenis *optimizer* yang digunakan. Pengujian dilakukan dengan jumlah *epoch* antara 25-100, *batch size* antara 16-64, dan tiga jenis optimizer yaitu Adam, SGD (*Stochastic Gradient Descent*), RMSprop. Seluruh percobaan dilakukan menggunakan *learning rate* awal sebesar 0.001 dan *loss function* kategori *categorical cross-entropy*. Hasil uji parameter menunjukkan bahwa kombinasi *epoch* 50, *batch size* 32, dan *adam optimizer* memberikan hasil terbaik dengan akurasi validasi tertinggi dan tingkat konvergensi yang stabil. Tabel 3.3 berikut menunjukkan hasil perbandingan performa model pada beberapa kombinasi parameter yang diuji.

Tabel 3.3 Hasil Uji Parameter Training Model ResNet-50

No	Epoch	Batch Size	Optimizer	Akurasi Training (%)	Akurasi Validasi (%)	Loss Validasi	Waktu Training (Menit)
1	25	16	Adam	92.4	88.7	0.312	18
2	50	32	Adam	96.8	93.5	0.187	32
3	75	32	SGD	94.1	89.3	0.298	44
4	100	64	RMSprop	95.2	90.4	0.254	58

Berdasarkan hasil tersebut dapat disimpulkan bahwa *adam optimizer* dengan konfigurasi *epoch* 50 dan *batch size* 32 memberikan keseimbangan terbaik antara akurasi dan efisiensi waktu pelatihan. Penggunaan jumlah *epoch* yang terlalu tinggi ≥ 75 meningkatkan waktu komputasi tanpa peningkatan signifikan pada akurasi, sementara *batch size* yang terlalu kecil cenderung menghasilkan *loss fluctuation* yang lebih besar. Oleh karena itu, konfigurasi parameter tersebut digunakan sebagai parameter final untuk *training* model ResNet50 dalam penelitian ini.

3.2.2 Grafik Loss dan Akurasi


Grafik *loss and accuration* merupakan indikator utama dalam mengevaluasi performa model *deep learning*, termasuk arsitektur ResNet-50 yang digunakan dalam penelitian ini. Nilai *loss* menggambarkan tingkat kesalahan prediksi model terhadap data *training*, sedangkan *accuration* menunjukkan proporsi prediksi yang benar terhadap keseluruhan data (30). Pada tahap *training*, grafik *training loss* yang menurun secara konsisten menandakan bahwa model berhasil mempelajari pola dari citra daun padi secara bertahap. Selain itu, *validation loss* digunakan untuk memantau kemampuan generalisasi model terhadap data yang belum pernah dilihat sebelumnya. Apabila terjadi selisih yang besar antara *training loss* dan *validation loss*, fenomena tersebut menunjukkan *overfitting*, yaitu kondisi dimana model terlalu menyesuaikan diri dengan data training dan kehilangan kemampuan generalisasi (31).

Sebaliknya, grafik akurasi yang meningkat pada setiap *epoch* menunjukkan peningkatan kemampuan model dalam mengenali fitur penyakit daun padi, seperti bercak coklat atau busuk daun. ResNet-50 dengan struktur *residual block*, memungkinkan aliran *gradien* tetap stabil saat proses pelatihan *deep network*, sehingga mengurangi masalah *vanishing gradient* dan mempercepat konvergensi (32). Pada konteks *precision agriculture*, peningkatan akurasi model berarti kemampuan sistem untuk mendeteksi penyakit tanaman secara dini menjadi lebih andal, mendukung pengambilan keputusan petani secara cepat dan berbasis data. Oleh karena itu, analisis terhadap grafik *loss* dan *accuration* tidak hanya bersifat teknis, tetapi juga menjadi dasar untuk menilai efektivitas model dalam mendukung keberlanjutan pertanian berbasis kecerdasan buatan.

Berdasarkan hasil uji parameter yang ditunjukkan pada Tabel 3.3 dan divisualisasikan pada Gambar 3.6, dapat diamati bahwa model ResNet-50 menunjukkan tren peningkatan performa seiring dengan peningkatan jumlah *epoch* dan penyesuaian parameter *training*. Pada *epoch* 25 dengan batch size 16 dan *Adam optimizer*, model mencapai akurasi *training* 92,4% dan akurasi validasi 88,7%, dengan *loss validation* sebesar 0,312. Ketika jumlah *epoch* ditingkatkan menjadi 50 dan *batch size* dinaikkan menjadi 32, akurasi validasi meningkat signifikan hingga 93,5%, sementara *loss validation* turun menjadi 0,187. Hal ini menunjukkan konfigurasi tersebut menghasilkan keseimbangan optimal antara proses *learning* dan generalisasi model.

Pada saat parameter *optimizer* diganti menjadi SGD (*Stochastic Gradient Descent*) pada *epoch* 75, terjadi penurunan akurasi validasi menjadi 89,3%, dan peningkatan *loss* menjadi 0,298 menandakan bahwa SGD kurang efisien dalam menangani kompleksitas fitur citra daun padi pada *dataset* penelitian ini. Selanjutnya, penggunaan RMSprop pada *epoch* 100 menghasilkan akurasi validasi sebesar 90,4% dan *loss* 0,254 – relatif lebih baik dari SGD, tetapi masih belum melampaui performa terbaik *Adam optimizer* pada *epoch* 50. Berdasarkan hasil ini dapat disimpulkan bahwa model ResNet-50 dengan *Adam optimizer*, *batch size* 32, dan *epoch* 50 memberikan hasil paling optimal dengan keseimbangan antara akurasi tinggi dan *loss* yang rendah, serta waktu *training* yang paling efisien yaitu 32 menit. Pola penurunan *loss* yang konsisten dan peningkatan akurasi menunjukkan bahwa model

mampu belajar dengan stabil tanpa *overfitting* yang signifikan menjadikannya konfigurasi terbaik untuk implementasi dalam sistem *precision agriculture* berbasis pengenalan penyakit daun padi.



Gambar 3.6 Perbandingan Kinerja Model ResNet-50 Berdasarkan Parameter Uji

3.2.3 Confusion Matrix dan Klasifikasi

Berdasarkan hasil pengujian model ResNet-50 dengan berbagai konfigurasi *hyperparameter*, interpretasi *confusion matrix* dilakukan secara kualitatif untuk mengevaluasi kemampuan model dalam mengklasifikasikan setiap kelas penyakit pada daun padi. Pada konfigurasi terbaik (50 *epoch*, *batch size* 32, *adam optimizer*), tingginya akurasi validasi (93,5%), dan rendahnya *loss validation* (0,187) mengindikasikan bahwa sebagian besar *sample* pada setiap kelas berhasil diklasifikasikan dengan benar (*true positive*). Hal ini menunjukkan bahwa fitur visual khas pada masing-masing penyakit daun padi dapat diekstraksi secara efektif oleh arsitektur ResNet-50.


Evaluasi performa klasifikasi model ResNet-50 pada penelitian ini dilakukan menggunakan *confusion matrix* yang merepresentasikan nilai TP (*True Positive*), FP (*False Positive*), TN (*True Negative*), FN (*False Negative*) untuk setiap kelas penyakit daun padi. Pada konfigurasi terbaik (50 *epoch*, *batch size* 32, *adam optimizer*) dengan akurasi validasi

sebesar 93,5%, sebagian besar data uji berhasil diklasifikasikan secara benar, yang ditunjukkan oleh dominasi nilai TP (*True Positive*) pada diagonal utama *confusion matrix*.

Untuk kelas Daun Sehat (*Healthy*) dengan total 320 citra, nilai TP menunjukkan jumlah daun sehat yang berhasil diprediksi benar sebagai daun sehat. Nilai FN pada kelas ini relatif kecil, yang menandakan hanya sedikit daun sehat yang salah diklasifikasikan sebagai penyakit. Sementara itu, nilai FP yang rendah menunjukkan bahwa model jarang mengklasifikasikan daun sakit sebagai daun sehat. Nilai TN yang tinggi pada kelas ini mengindikasikan kemampuan model dalam mengenali daun non-sehat secara konsisten ketika kelas *Healthy* dijadikan sebagai kelas *negative*.

Pada kelas *Blight* (Bercak Daun) dan *Brown Spot* (Hawar Daun), nilai TP tetap mendominasi namun terdapat peningkatan nilai FP dan FN dibandingkan kelas *Healthy*. Hal ini menunjukkan adanya kesalahan klasifikasi antar kedua kelas tersebut, yang disebabkan oleh kemiripan karakteristik visual seperti pola bercak dan perubahan warna daun. Nilai FN pada kelas *Blight* menunjukkan sejumlah citra *Blight* (Bercak Daun) yang diprediksi sebagai *Brown Spot* (Hawar Daun), sedangkan nilai FP (*False Positive*) mencerminkan citra dari kelas lain yang salah prediksi sebagai *Blight*.

Kelas *Leaf Smut* (Bercak Cokelat) menunjukkan nilai TP yang stabil dengan FN dan FP yang relatif rendah. Hal ini mengindikasikan bahwa model mampu mengenali ciri khas *Leaf Smut* dengan cukup baik, meskipun masih terdapat sebagian kecil kesalahan klasifikasi akibat kemiripan tekstur dengan penyakit daun lainnya. Secara keseluruhan, tingginya nilai TP dan FN pada seluruh kelas menegaskan bahwa model ResNet-50 memiliki sensitivitas dan spesifisitas yang baik dalam melakukan klasifikasi multi-kelas penyakit daun padi, sehingga layak digunakan sebagai sistem pendukung keputusan dalam penerapan *precision agriculture*. *Confusion matrix* dapat dilihat pada Gambar 3.7.



Gambar 3.7 Confusion Matrix


3.3 Uji Coba Lapangan dan Implementasi

3.3.1 Pengujian pada Data Real Petani Dukuh, Tridadi, DIY

Pengujian pada data real dilakukan untuk mengevaluasi kinerja model *deep learning* ResNet-50 dalam kondisi lapangan yang sesungguhnya, khususnya pada citra daun tanaman padi (*Oryza sativa L*) yang diperoleh langsung dari petani di wilayah Dukuh, Tridadi, Sleman, DIY. Data ini memiliki karakteristik yang lebih kompleks dibandingkan dengan dataset latih, seperti variasi intensitas cahaya, latar belakang non-homogen, sudut pengambilan gambar yang beragam, serta tingkat keparahan penyakit yang bervariasi. Pengujian pada *data real* penting dilakukan untuk menilai kemampuan generalisasi model, mengingat banyak penelitian sebelumnya menunjukkan adanya penurunan performa ketika model diuji pada data lapangan dibandingkan data terkurasi atau *dataset* publik.

Dataset uji terdiri dari citra (*image*) daun padi yang merepresentasikan beberapa kelas penyakit, seperti hawar daun, bakteri, blas daun, dan bercak coklat, serta kelas daun sehat. Seluruh citra diambil menggunakan kamera ponsel oleh petani dengan kondisi alami

tanpa perlakuan khusus. Hasil pengujian menunjukkan bahwa model ResNet-50 mampu mengklasifikasikan penyakit daun padi dengan tingkat akurasi yang relatif tinggi, meskipun terdapat penurunan performa dibandingkan hasil pengujian pada data validasi. Hal ini sejalan dengan temuan beberapa penelitian sebelumnya yang menyatakan bahwa noise visual dan ketidakterkendalian lingkungan lapangan menjadi tantangan utama dalam penerapan sistem deteksi penyakit tanaman berbasis *deep learning* di dunia nyata. Detail *workflow* dari penelitian ini dapat dilihat pada Gambar 3.8.



Gambar 3.8 *Workflow* Deteksi Penyakit Padi


Secara kuantitatif, performa model pada data real dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan *F1-Score*. Berdasarkan hasil pengujian, kelas daun sehat cenderung memiliki nilai presisi tertinggi, sedangkan beberapa kelas penyakit dengan gejala visual yang mirip menunjukkan tingkat kesalahan klasifikasi yang lebih tinggi. Tabel 3.4 menyajikan hasil pengujian model ResNet-50 pada data real daun padi yang diperoleh dari petani Dukuh, Tridadi, Sleman, DIY yang dievaluasi menggunakan metrik presisi, *recall*, dan *F1-Score* untuk setiap kelas penyakit. Berdasarkan Tabel 5, model ResNet-50 menunjukkan performa yang baik pada data real petani Dukuh, dengan nilai F1-score rata-rata di atas 85% pada seluruh kelas citra daun padi.

Tabel 3.4 Hasil Pengujian Model pada Data Real Petani Dukuh, Sleman, DIY

No	Kelas Daun Padi	Jumlah Data Uji	Presisi (%)	Recall (%)	F1-Score (%)
1	Daun Sehat (<i>Healthy</i>)	320	93.50	91.25	92.36
2	<i>Blight</i> (Bercak Daun)	280	88.20	86.10	87.14
3	<i>Brown Spot</i> (Hawar Daun)	300	89.10	88.40	88.75
4	<i>Leaf Smut</i> (Bercak Cokelat)	250	85.60	83.90	84.74
	Rata-rata (Average)	1.150	89.10	87.41	88.25

3.3.2 Integrasi Aplikasi Simpadis untuk Prediksi Cepat

Integrasi aplikasi Simpadis (Sistem Informasi Prediksi Penyakit Daun Padi Sleman) dirancang untuk mendukung proses prediksi penyakit daun padi secara cepat, akurat, dan mudah diakses oleh pengguna. Sistem ini mengintegrasikan model *deep learning* ResNet-50 yang telah dilatih untuk mengenali berbagai jenis penyakit pada daun padi ke dalam sebuah platform berbasis *website*. Melalui aplikasi Simpadis, pengguna dapat mengambil atau mengunggah citra (image) daun padi secara langsung, kemudian sistem akan melakukan proses *preprocessing* gambar seperti *resize*, dan *normalisasi* sebelum diteruskan ke model ResNet-50 untuk proses inferensi. Hasil prediksi berupa jenis penyakit daun padi ditampilkan secara *realtime* beserta informasi pendukung, sehingga pengguna dapat mengambil tindakan yang tepat di lapangan. Integrasi ini menjadikan Simpadis sebagai alat bantu prediksi yang efektif, efisien, dan aplikatif dalam mendukung pengendalian penyakit tanaman padi, khususnya di wilayah Sleman, DIY.



Gambar 3.9 *Workflow* Aplikasi Simpadis

BAB IV

KESIMPULAN DAN SARAN

4.1. Kesimpulan

Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa penerapan model *deep learning* berbasis Resnet-50 terbukti efektif dalam mendeteksi dan mengklasifikasi penyakit daun tanaman padi (*Oryza sativa L*) secara akurat berdasarkan citra digital. Melalui tahapan pengumpulan data lapangan, prapemrosesan data citra, augmentasi data, ekstraksi fitur, serta proses fine-tuning model, sistem yang dikembangkan mampu mengenali empat kondisi daun padi, yaitu daun sehat, *blight* (bercak daun), *brown spot* (hawar daun), dan *leaf smut* (bercak cokelat). Hasil pengujian menunjukkan bahwa konfigurasi optimal dengan 50 *epoch*, *batch size* 32, dan *Adam optimizer* menghasilkan akurasi validasi tertinggi sebesar 93,5% serta performa yang stabil dengan nilai loss yang rendah.

Pengujian pada data real petani di Kalurahan Dukuh, Tridadi, Sleman juga menunjukkan kinerja yang baik dengan rata-rata nilai F1-score di atas 85%, menandakan kemampuan generalisasi model yang cukup andal dalam kondisi lapangan nyata. Integrasi model ke dalam aplikasi SIMPADIS semakin memperkuat aspek aplikatif penelitian ini sebagai sistem pendukung keputusan yang cepat, akurat, dan mudah digunakan oleh petani dan penyuluh. Dengan demikian, penelitian ini berkontribusi nyata dalam mendukung implementasi precision agriculture, khususnya dalam upaya deteksi dini penyakit daun padi untuk meningkatkan produktivitas dan keberlanjutan pertanian di wilayah Sleman, Yogyakarta.

4.2. Saran

Berdasarkan hasil penelitian yang telah dilakukan, pengembangan sistem prediksi penyakit daun padi berbasis deep learning ResNet-50 ini masih memiliki peluang untuk ditingkatkan pada penelitian selanjutnya. Disarankan untuk memperluas jumlah dan keragaman dataset, khususnya citra daun padi dari berbagai

musim tanam, varietas padi, serta kondisi pencahayaan dan lingkungan yang berbeda, guna meningkatkan kemampuan generalisasi model di lapangan. Selain itu, integrasi data non-citra seperti data cuaca mikro, kelembapan tanah, dan fase pertumbuhan tanaman melalui sensor IoT diharapkan dapat meningkatkan akurasi dan ketepatan prediksi penyakit secara kontekstual. Pengujian model dengan arsitektur lain seperti EfficientNet atau Vision Transformer (ViT) juga dapat dilakukan sebagai pembanding performa. Dari sisi implementasi, pengembangan aplikasi SIMPADIS ke platform mobile serta pelibatan langsung petani dan penyuluh pertanian dalam uji coba berkelanjutan sangat dianjurkan agar sistem yang dikembangkan benar-benar aplikatif, mudah digunakan, dan mampu mendukung pengambilan keputusan cepat dalam penerapan pertanian presisi yang berkelanjutan.

DAFTAR PUSTAKA

1. Perdana RP, SKS, SEA, UA, RASS, SS, & YF. Dinamika tingkat kemandirian pangan: implikasinya terhadap kebijakan ketahanan pangan nasional: The dynamics of food resilience: implications for national food security policy. *Analisis Kebijakan Pertanian*. 2025;23(1):37–55.
2. Moisés C, Arrobas M, Tsitos D, Pinho D, Rezende RF, Rodrigues MÂ. Regenerative Agriculture: Insights and Challenges in Farmer Adoption. *Sustainability*. 2025 Aug 11;17(16):7235. doi:10.3390/su17167235
3. Baite MS, Kumar P, Rathinam PS, Shivappa R, Umaphathy K, Dash D. Evaluation of the Efficacy of Fungicides in Controlling Brown Spot (*Bipolaris oryzae*) Disease in Rice. *Discover Life*. 2025 Feb 11;55(1):3. doi:10.1007/s11084-025-09678-5
4. Sayekti NA, Purnawati A, Lestari SR. Characterization of Bacterial Blight Pathogen on Rice Plants in Sidoarjo. *Journal of Applied Plant Technology*. 2024 Nov 30;3(2):130–6. doi:10.30742/xwdype52
5. Putra GMC, Prasetyaningtyas FD, Ansori I, Kurnianto B, Wahyuni NI, Xinzhe Z, et al. Effectiveness of Project-Based Scratch Programming to Improve Problem-Solving Skills of Elementary School Students. *International Journal of Social Learning (IJSL)*. 2025 Apr 28;5(2):460–78. doi:10.47134/ijsl.v5i2.417
6. Filza Hisana Hizbullah SRNDADIGASSHZF. Mobile-Driven Disease Identification System for Rice Plants Using ResNet. *Proceeding Int Jt Conf UNESA [Internet]*. 2024 Nov;2(1).
7. Dewi YA, Bahru BA, Zeller M. Performance of agricultural extension agents in Indonesia: evidence from a nationally representative survey. *The Journal of Agricultural Education and Extension*. 2025 Aug 8;31(4):527–53. doi:10.1080/1389224X.2024.2407178
8. Tanjung DYH, Adawiyah R. Optimizing Selection of Decision Support System with Fuzzy Simple Additive Weighting. In: 2018 6th International Conference on Cyber and IT Service Management, CITSM 2018. 2019. doi:10.1109/CITSM.2018.8674360
9. Kamilaris A, Prenafeta-Boldú FX. Deep learning in agriculture: A survey. *Comput Electron Agric*. 2018 Apr;147:70–90. doi:10.1016/j.compag.2018.02.016
10. Chen M, Yu Z. Rice Disease Recognition Based on Improved Residual Network. 2025. doi:10.20944/preprints202502.1657.v1
11. Simhadri CG, Kondaveeti HK. Automatic Recognition of Rice Leaf Diseases Using Transfer Learning. *Agronomy*. 2023 Mar 23;13(4):961. doi:10.3390/agronomy13040961
12. Islam Sobuj MdS, Hossen MdI, Mahmud MdF, Islam Khan MU. Leveraging Pre-trained CNNs for Efficient Feature Extraction in Rice Leaf Disease Classification. In: 2024 International Conference on Advances in Computing, Communication, Electrical, and Smart Systems (iCACCESS). IEEE; 2024. p. 01–6. doi:10.1109/iCACCESS61735.2024.10499603
13. Kondaveeti HK, Simhadri CG. Evaluation of deep learning models using explainable AI with qualitative and quantitative analysis for rice leaf disease detection. *Sci Rep*. 2025 Aug 29;15(1):31850. doi:10.1038/s41598-025-14306-3
14. Senthil Pandi S, Senthilselvi A, Gitanjali J, ArivuSelvan K, Gopal J, Vellingiri J. Rice plant disease classification using dilated convolutional neural network with global average pooling. *Ecol Modell*. 2022 Dec;474:110166. doi:10.1016/j.ecolmodel.2022.110166
15. Bera A, Bhattacharjee D, Krejcar O. An attention-based deep network for plant disease classification. *Machine Graphics and Vision*. 2024 Nov 12;33(1):47–67. doi:10.22630/MGV.2024.33.1.3

16. Yakkala VS, Nusimala KV, Gayathri B, Kanamarlapudi S, Aravinth SS, Salau AO, et al. Deep learning-based crop health enhancement through early disease prediction. *Cogent Food Agric.* 2025 Dec 31;11(1). doi:10.1080/23311932.2024.2423244
17. Alruwaili M, Mohamed M. An Integrated Deep Learning Model with EfficientNet and ResNet for Accurate Multi-Class Skin Disease Classification. *Diagnostics.* 2025 Feb 25;15(5):551. doi:10.3390/diagnostics15050551
18. Parker JK, Hall LO. Accelerating Fuzzy-C Means Using an Estimated Subsample Size. *IEEE Trans Fuzzy Syst.* 2014 Oct;22(5):1229–44. doi:10.1109/TFUZZ.2013.2286993 PubMed PMID: 26617455.
19. Hafiz MS, Anwar A, Shin J, Rafiq JI. Improving Agronomic Disease Detection and Classification: The Superiority of Hybrid Inception-Xception Ensemble Model for Rice Leaf Disease Classification. In: 2025. p. 57–67. doi:10.1007/978-981-96-4520-6_5
20. Shah SR, Qadri S, Bibi H, Shah SMW, Sharif MI, Marinello F. Comparing Inception V3, VGG 16, VGG 19, CNN, and ResNet 50: A Case Study on Early Detection of a Rice Disease. *Agronomy.* 2023 Jun 18;13(6):1633. doi:10.3390/agronomy13061633
21. Najjar H, Miranda M, Nuske M, Roscher R, Dengel A. Explainability of Subfield Level Crop Yield Prediction Using Remote Sensing. *IEEE J Sel Top Appl Earth Obs Remote Sens.* 2025;18:4141–61. doi:10.1109/JSTARS.2025.3528068
22. Mostafa K, Imran F, Anjum M, Siam SI. A Hybrid Deep Learning Framework for Robust Detection of Rice Leaf Diseases Using CNN and Transformer-Based Attention. In: 2025 International Conference on Quantum Photonics, Artificial Intelligence, and Networking (QPAIN). IEEE; 2025. p. 1–6. doi:10.1109/QPAIN66474.2025.11171957
23. Ahad MT, Li Y, Song B, Bhuiyan T. Comparison of CNN-based deep learning architectures for rice diseases classification. *Artificial Intelligence in Agriculture.* 2023 Sep;9:22–35. doi:10.1016/j.aiia.2023.07.001
24. Deng R, Tao M, Xing H, Yang X, Liu C, Liao K, et al. Automatic Diagnosis of Rice Diseases Using Deep Learning. *Front Plant Sci.* 2021 Aug 19;12. doi:10.3389/fpls.2021.701038
25. Quach LD, Quoc KN, Quynh AN, Ngoc HT. Evaluation of the Efficiency of the Optimization Algorithms for Transfer Learning on the Rice Leaf Disease Dataset. *International Journal of Advanced Computer Science and Applications.* 2022;13(10). doi:10.14569/IJACSA.2022.0131011
26. Daniya T, Vigneshwari S. Rice Plant Leaf Disease Detection and Classification Using Optimization Enabled Deep Learning. *Journal of Environmental Informatics.* 2023. doi:10.3808/jei.202300492
27. Huda MS, Endah Wahanani H, Anggraeny FT. Optimizing the ResNet50 Model with Five Optimizers for Detecting Rice Leaf Diseases. *bit-Tech.* 2025 Dec 10;8(2):2285–96. doi:10.32877/bt.v8i2.3232
28. Hastari D, Winanda S, Pratama AR, Nurhaliza N, Ginting ES. Application of Convolutional Neural Network ResNet-50 V2 on Image Classification of Rice Plant Disease. *Public Research Journal of Engineering, Data Technology and Computer Science.* 2024 Feb 1;1(2). doi:10.57152/predatecs.v1i2.865
29. Basitur Rahman Bappi M, Masfequier Rahman Swapno SM, Akhter S, Rabbi MMF. Deploying CNN-ResNet50-BiLSTM for Paddy Leaf Disease Detection. In: 2025. p. 131–43. doi:10.1007/978-981-96-4520-6_11
30. White J, Power SD. k-Fold Cross-Validation Can Significantly Over-Estimate True Classification Accuracy in Common EEG-Based Passive BCI Experimental Designs: An Empirical Investigation. *Sensors.* 2023 Jul 1;23(13):6077. doi:10.3390/s23136077

31. Paramita C, Rakasiwi S, Andono PN, Shidik GF, Shier Nee Saw, Rafsanjani MI. Deep Learning-Based Eye Disorder Classification: A K-Fold Evaluation of EfficientNetB and VGG16 Models. *Scientific Journal of Informatics*. 2025 Sep 9;12(3):441–52. doi:10.15294/sji.v12i3.26257
32. Zhang W, Zhang P, Zhang B, Wang X, Wang D. A Collaborative Transfer Learning Framework for Cross-domain Recommendation. In: *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. New York, NY, USA: ACM; 2023. p. 5576–85. doi:10.1145/3580305.3599758

LAMPIRAN

LAMPIRAN 1

REALISASI PENGGUNAAN ANGGARAN

No	Jenis Pembelajaran	Komponen	Item	Kuantitas	Biaya Satuan (Rp)	Total	Persentase (%)	Ket
I	Honorarium (Maks 30%)					3.000.000	30,00 %	Maksimum batas 30%
	1. Pengumpulan data	Honor pembantu peneliti	Asisten Lapangan (Pengambilan Sampel Gambar)	1 orang x 1 bulan	500.000	500.000		Pengambilan data di Sleman, Yogyakarta.
	2. Analisis data	Honor Programmer/Developer Prototype	Pembuatan Antarmuka Pengguna (UI/UX) dan Integrasi Model ResNet50	1 orang x 1 kali	1.400.000	1.400.000		Honor untuk pembuatan prototipe aplikasi prediksi
	3. Pelaporan penelitian	Honor administrasi peneliti	Staf Administrasi/Asisten Peneliti (Penyusunan Laporan)	1 orang x 1 kali	200.000	200.000		
	4. Pelaporan hasil penelitian dan luaran wajib	Biaya publikasi	APC Jurnal Sinta 2 / Sinta 3	1 paket	1.700.000	1.700.000		
II	Bahan Habis Pakai dan Peralatan (35-55%)					4.900.000	49,00 %	Dalam rentang 35-55 %
	5. Belanja bahan	ATK	Kertas, Tinta Printer, Pulpen, Map	1 paket	400.000	400.000		Kebutuhan administrasi dan pencetakan

	6. Belanja bahan	Bahan penelitian (habis pakai)	Akses Komputasi Cloud GPU (Training ResNet50)	2 bulan	1.000.000	2.000.000		Sewa komputasi berkinerja tinggi
	7. Belanja bahan	Bahan penelitian (habis pakai)	Biaya Hosting/Deployment Prototipe	5 bulan	200.000	1.000.000		Sewa server/cloud (misal: Firebase, AWS) untuk uji coba prototipe
	8. Sewa peralatan	Peralatan penelitian	Sewa Kamera Digital	2 hari	350.000	700.000		Untuk pengumpulan data gambar padi berkualitas tinggi
III	Operasional Kegiatan Penelitian (Maks. 20%)					1.600.000	16,00 %	Dalam batas maksimal 20 %
	9. Pengumpulan data	Transport	Transportasi lokal ke lokasi sawah/petani di Sleman	5 kali	200.000	1.000.000		Transportasi tim (dosen + asisten) selama pengumpulan dan validasi data
	10. Pengumpulan data	FGD	Diskusi/Validasi Prototipe dengan Pakar/Petani	1 kali	300.000	300.000		Sewa ruang diskusi/FGD
	11. Pengumpulan data	Konsumsi	Konsumsi Rapat Awal, FGD, dan	3 kali	100.000	300.000		Sewa ruang diskusi/FGD

			penyusunan Laporan					
IV	Lain-lain (Kekayaan Intelektual) (Maks. 10%)					500.000	5,00 %	Dalam batas maksimal 10 %
	12. Lainnya	Biaya pendaftaran HKI	Pendaftaran Hak Cipta (Ciptaan Program Komputer/ Sistem Prediksi)	1 kali permohonan	500.000	500.000		Estimasi biaya pendaftaran online ke DJKI
Grand Total						10.000.000		

LAMPIRAN 2

SURAT PERJANJIAN KONTRAK PENELITIAN

	UNIVERSITAS BUDI LUHUR Kampus Pusat : Jl. Raya Cendek - Puncung Utan - Jakarta Selatan 12260 Telp : 021-5853753 (Pusat), Fax : 021-5853489, http://www.budiluhur.ac.id	FAKULTAS TEKNOLOGI INFORMASI FAKULTAS EKONOMI DAN BISNIS FAKULTAS ILMU BUDIDAYA DAN STUDI GLOBAL FAKULTAS TEKNIK FAKULTAS KONSELING DAN DESAIN KREATIF
---	--	---

SURAT PERJANJIAN KONTRAK PENELITIAN
Nomor A/UBL/DRPM/000/180/11/25

Pada hari ini, Rabu 05 November 2025 Semester Gasal Tahun Ajaran 2025/2026, kami yang bertandatangan di bawah ini:

1. **Prof. Dr. Ir. Prudensius Maring, M.A.**, selaku Direktur Riset dan Pengabdian Kepada Masyarakat Universitas Budi Luhur, selanjutnya disebut PIHAK PERTAMA.
2. **Zaqi Kurniawan, S.Kom., M.Kom.**, selaku Peneliti selanjutnya disebut PIHAK KEDUA.

Kedua belah pihak menyatakan bersepakat untuk membuat perjanjian kontrak penelitian sebagai berikut:

Pasal 1
Judul Penelitian

PIHAK PERTAMA dalam jabatannya tersebut di atas, memberikan tugas kepada PIHAK KEDUA untuk melaksanakan penelitian yang berjudul: *Prediksi Penyakit pada Daun Tanaman Padi (Oryza sativa L.) menggunakan Model Deep Learning ResNet50. Sebuah studi untuk Precision Agriculture. Studi Kasus Kelurahan Dukuh, Tridada, Sieman, Yogyakarta*

Pasal 2
Personalia Penelitian

Peneliti Utama : Zaqi Kurniawan, S.Kom., M.Kom.
Anggota Peneliti : Rikka Tiaharyadini, S.Kom., M.M., M.Kom.

Pasal 3
Waktu dan Biaya Penelitian

1. Waktu penelitian adalah 5 bulan, terhitung sejak tanggal 08 September 2025 sampai dengan 08 Februari 2026.
2. Biaya pelaksanaan penelitian ini dibebankan pada Yayasan Pendidikan Budi Luhur Cakti Tahun 2025 dengan nilai kontrak sebesar Rp 10,000,000.00 (sepuluh juta rupiah).

Pasal 4
Cara Pembayaran

Pembayaran biaya penelitian diberikan secara bertahap, sebagai berikut:

1. Tahap pertama sebesar 50% dari nilai kontrak, setelah surat perjanjian kontrak penelitian ini ditandatangani oleh kedua belah pihak.
2. Tahap kedua sebesar 50% dari nilai kontrak, setelah PIHAK KEDUA menyerahkan Laporan Hasil Penelitian kepada PIHAK PERTAMA.

Pasal 5
Keaslian Penelitian dan Ketidakterikatan dengan Pihak Lain

1. PIHAK KEDUA bertanggungjawab atas keaslian judul penelitian sebagaimana disebutkan dalam Pasal 1 Surat Perjanjian Kontrak Penelitian ini (bukan duplikat/jiplakan/plagiat) dari penelitian orang lain.



3. PIHAK KEDUA menjamin bahwa judul penelitian tersebut bukan merupakan penelitian yang SEDANG ATAU SUDAH selesai dikerjakan, baik didanai oleh pihak lain maupun oleh sendiri.
4. PIHAK PERTAMA tidak bertanggungjawab terhadap tindakan plagiat yang dilakukan oleh PIHAK KEDUA.
5. Apabila dikemudian hari diketahui ketidakbenaran pernyataan ini, maka kontrak penelitian DINYATAKAN BATAL, dan PIHAK KEDUA wajib mengembalikan dana yang telah diterima kepada Yayasan Pendidikan Budi Luhur Cakti sebagai pemberi dana.

Pasal 6

Monitoring Penelitian

1. PIHAK PERTAMA berhak untuk:
 - a. Melakukan pengawasan administrasi, monitoring, dan evaluasi terhadap pelaksanaan penelitian.
 - b. Memberikan sanksi jika dalam pelaksanaan penelitian terjadi pelanggaran terhadap isi perjanjian oleh peneliti.
 - c. Bentuk sanksi disesuaikan dengan tingkat pelanggaran yang dilakukan.
2. Pemantauan kemajuan penelitian dikoordinasikan oleh PIHAK PERTAMA.
3. Pelaksanaan kemajuan penelitian dilaksanakan pada tanggal 13 Desember 2025.
4. Format Laporan Kemajuan dan teknis pelaksanaannya diatur oleh PIHAK PERTAMA.

Pasal 7

Laporan Akhir Penelitian

PIHAK KEDUA wajib menyerahkan laporan akhir dalam bentuk softcopy, paling lambat tanggal 07 Februari 2026.

Pasal 8

Sanksi

Segala kelalaian baik disengaja maupun tidak, sehingga menyebabkan keterlambatan menyerahkan laporan hasil penelitian dengan batas waktu yang telah ditentukan akan mendapatkan sanksi sebagai berikut:

1. Tidak diperbolehkan mengajukan usulan penelitian pada semester berikutnya bagi ketua dan anggota peneliti.
2. PIHAK KEDUA diberikan kesempatan perpanjangan waktu penelitian selama 2 (dua) minggu sampai dengan tanggal 21 Februari 2026.
3. Jika setelah masa perpanjangan tersebut PIHAK KEDUA tidak dapat menyelesaikan penelitiannya, PIHAK KEDUA diwajibkan mengembalikan dana yang sudah diterima kepada Yayasan Pendidikan Budi Luhur Cakti dengan cara mengembalikan tunai kepada PIHAK PERTAMA.



**UNIVERSITAS
BUDI LUHUR**

Kampus Pusat : Jl. Raya Cileug : Perumahan Ujaya - Jakarta Selatan 12260
Telp : 021-5633753 (Pusat), Fax : 021-5632489, <http://www.budiluhur.ac.id>

FAKULTAS TEKNOLOGI INFORMASI
FAKULTAS EKONOMI DAN BISNIS
FAKULTAS ILMU SOSIAL DAN STUDI GLOBAL
FAKULTAS TEKNIK
FAKULTAS KOMUNIKASI DAN DESAIN KREATIF

**Pasal 9
Penutup**

Perjanjian ini berlaku sejak ditandatangani dan disetujui oleh PIHAK PERTAMA dan PIHAK KEDUA.

PIHAK PERTAMA

Jakarta, 05 November 2025
PIHAK KEDUA



Prof. Dr. Ir. Prudensius Mating, M.A.
NIP. 190043

Zaki Kurniawan, S.Kom., M.Kom.
NIP. 190014

UNIVERSITAS
BUDI LUHUR

LAMPIRAN 3

CATATAN HARIAN

No	Tanggal / Periode	Kegiatan	Uraian Aktivitas	Output Aktivitas
1	5–8 Nov 2025	Persiapan penelitian	Finalisasi proposal operasional, penyusunan instrumen dokumentasi lapangan	Dokumen rencana kerja dan instrumen penelitian
2	9–15 Nov 2025	Pengumpulan data citra daun padi	Pengambilan citra daun padi di Kalurahan Dukuh, Tridadi, Sleman	Dataset mentah citra daun padi
3	16–20 Nov 2025	Labeling dataset	Klasifikasi manual penyakit daun (blast, brown spot, healthy, dll.)	Dataset terlabel
4	21–25 Nov 2025	Preprocessing data	Resize 224x224 px, normalisasi, augmentasi data	Dataset siap latih
5	26–30 Nov 2025	Implementasi model ResNet50	Konfigurasi arsitektur transfer learning ResNet50	Model awal terbangun
6	1–5 Des 2025	Training model	Proses pelatihan model dengan dataset latih	Model terlatih
7	6–8 Des 2025	Evaluasi model	Perhitungan akurasi, precision, recall, F1-score, confusion matrix	Hasil evaluasi performa
8	9–12 Des 2025	Optimasi model	Fine-tuning layer dan penyesuaian hyperparameter	Model optimal
9	13–16 Des 2025	Perancangan sistem SIMPADIS	Perancangan arsitektur sistem dan alur proses prediksi	Dokumen desain sistem
10	17–20 Des 2025	Desain interface SIMPADIS	Perancangan UI/UX (mockup halaman upload, hasil prediksi, dashboard)	Prototype desain antarmuka
11	21–27 Des 2025	Implementasi backend	Integrasi model ResNet50 ke server/API prediksi	Modul backend prediksi
12	28 Des 2025–3 Jan 2026	Implementasi frontend	Pengembangan tampilan aplikasi berbasis web	Modul frontend aplikasi
13	4–8 Jan 2026	Integrasi sistem	Integrasi frontend, backend, dan model	Aplikasi SIMPADIS versi beta
14	9–12 Jan 2026	Uji coba internal	Pengujian fungsionalitas dan debugging	Laporan hasil uji internal

15	13–18 Jan 2026	Uji coba lapangan	Pengujian aplikasi oleh pengguna (petani/penyuluh)	Data umpan balik pengguna
16	19–22 Jan 2026	Perbaikan aplikasi	Penyempurnaan fitur dan perbaikan bug	Aplikasi SIMPADIS final
17	23–27 Jan 2026	Penyusunan draft artikel (Pendahuluan & Metode)	Penulisan latar belakang, tinjauan pustaka, metodologi	Draft bagian Introduction & Method
18	28 Jan–1 Feb 2026	Penyusunan hasil & pembahasan	Penyajian hasil eksperimen dan analisis	Draft Results & Discussion
19	2–4 Feb 2026	Finalisasi artikel SINTA 3	Penyusunan abstrak, kesimpulan, referensi, format jurnal	Draft artikel lengkap siap submit
20	5–8 Feb 2026	Penyusunan laporan akhir penelitian	Penyusunan laporan lengkap kegiatan dan luaran	Draft laporan akhir
21	9–10 Feb 2026	Finalisasi & pengumpulan	Revisi akhir dan pengumpulan laporan serta artikel	Laporan akhir & artikel siap kirim

LAMPIRAN 4

ARTIKEL ILMIAH

Journal of Applied Informatics and Computing (JAIC)
Vol. x, No. x, Juli 201x, pp. xx-xx
e-ISSN: 2548-6861

1

Detection and Classification of Rice Leaf Diseases Using ResNet-50 with Data Augmentation and K-Fold Cross Validation

Zaqi Kurniawan ^{1*}, Rizka Tiaharyadini ^{2*}, M Saddam Ryuga Octoramdhani ^{3*}, Radiz Dirgantara ^{4*}

* Faculty of Technology and Information, Universitas Budi Luhur, Jakarta, Indonesia

zaqi.kurniawan@budiluhur.ac.id ¹, rizka.tiaharyadini@budiluhur.ac.id ², 2411501568@student.budiluhur.ac.id ³,
2411500107@student.budiluhur.ac.id ⁴



Article Info

Article history:

Received ...

Revised ...

Accepted ...

Keyword:

Pilih maksimum lima kata kunci atau frase yang diurutkan menurut abjad, dan dipisahkan dengan koma. Keyword1, Keyword2, Keyword3.

ABSTRACT

Gunakan dokumen ini sebagai template untuk menyusun artikel. Artikel dapat berupa full Bahasa Inggris (-*diutamakan*-) atau Bahasa Indonesia. Bagian abstrak memuat informasi terkait penelitian apa yang hendak akan dilakukan dan hasil yang diperoleh pada penelitian harus disampaikan. Setelah makalah diterima, dan perbaikan terakhir silahkan dikirimkan kepada kami, dokumen elektronik ini akan diformat lebih lanjut oleh redaksi JAIC. Dalam abstrak, anda seharusnya tidak merujuk publikasi lainnya. Buatlah abstrak dalam bahasa Inggris.



I. INTRODUCTION

Over half of the world's population depends on rice as a staple food source, but rice diseases can cause significant yield losses. In affected areas, major leaf diseases like blast, brown spot, and bacterial leaf streak can reduce productivity by as much as 30-40% if they are not identified early [1], [2]. In the larger context of intelligent and sustainable agriculture, fast and precise detection of rice leaf disease is essential for maintaining food security, cutting down on excessive pesticide use, and assisting farmers in making decisions. The use of computer visions and deep learning algorithms for automated plant disease diagnosis is being driven by the expensive, subjective, and scale-limiting nature of traditional manual inspection approaches, especially in large paddy fields [3], [4].

Convolutional neural networks (CNNs) are receiving a lot of attention lately, particularly deep designs like ResNet-50, because of their robustness and powerful feature extraction capabilities when paired with data augmentation and transfer learning techniques [5], [6]. Furthermore, the growing

increased focus on model generalization and reliability-addressed by methods such as K-Fold cross validation-align this area of study with the current challenges in implementing reliable AI solutions for actual precision agriculture systems [7], [8].

In this study, the ResNet-50 convolutional neural network architecture, data augmentation, and K-Fold cross validation techniques are used to detect and classify rice leaf diseases using deep learning. According to recent research, convolutional neural networks (CNNs), including ResNet-50 variants, outperform conventional machine learning and manually created feature approaches in identifying rice leaf diseases like blast, brown spot, and bacterial blight from RGB images [9], [10], [11]. However, the research now in publication identifies a number of unresolved problems, such as model overfitting brought on by undersized and unbalanced datasets, insufficient generalization across different field situations, and imbalanced evaluation techniques that mostly rely on single train-test splits [12], [13]. The primary performance measures in this study are classification accuracy, precision, recall, and F1-score. Other

LAMPIRAN 5

HKI


REPUBLIK INDONESIA
KEMENTERIAN HUKUM

SURAT PENCATATAN CIPTAAN

Dalam rangka perlindungan ciptaan di bidang ilmu pengetahuan, seni dan sastra berdasarkan Undang-Undang Nomor 28 Tahun 2014 tentang Hak Cipta, dengan ini menerangkan:

Nomor dan tanggal permohonan: E0002120/010607, 23 Februari 2020

Pencipta
Nama: Zaki Kurniawan, S.Kom., M.Kom dan Rizka Tuharyadini, S.Kom, M.M., M.Kom
Alamat: Cluster Tamanbaru Park Residence Blok K-13, Setiabudi, Kota Depok, Jawa Barat
Kewarganegaraan: Indonesia

Pemegang Hak Cipta
Nama: Direktorat Riset dan Pengabdian kepada Masyarakat (DRPM)
Alamat: Jl. Ciledug Raya, RT.10/RW.2, Pongorbaru, Kota Adm. Jakarta Selatan, DKI Jakarta, 12269
Kewarganegaraan: Indonesia
Jenis Ciptaan: Program Komputer
Judul Ciptaan: Program Komputer: SIMPADIS (Sistem Informasi Produktif Pemahat Daun Padi Siaman)

Tanggal dan tempat diterimanya untuk pertama kali di wilayah Indonesia atau di luar wilayah Indonesia: 19 Februari 2020, di DKI Jakarta

Jangka waktu perlindungan: Berlaku selama 90 (lima puluh) tahun sejak Ciptaan tersebut pertama kali dilakukan Pengumuman.

Nomor Pencatatan: 001192659

Salah satu bentuk perlindungan hukum yang diberikan oleh Pemerintah.
Surat Pencatatan Hak Cipta atas produk Hak terkait ini sesuai dengan Pasal 72 Undang-Undang Nomor 28 Tahun 2014 tentang Hak Cipta.


a.n. MENTERI HUKUM
DIREKTUR JENDERAL KEKAYAAN INTELEKTUAL
a.p.
Direktorat Hak Cipta dan Desain Industri


Agung Darmasusanto, SH, MH.
NRP 198012261994031001

Deep Learning-Based Detection and Classification of Rice Leaf Diseases Using ResNet-50 with Augmentation and K-Fold Cross-Validation

Zaqi Kurniawan ^{1*}, Rizka Tiaharyadini ^{2*}, M Saddam Ryuga Octoramdhani ^{3*}, Radiz Dirgantara ^{4*}

^{*} Faculty of Technology and Information, Universitas Budi Luhur, Jakarta, Indonesia

zaqi.kurniawan@budiluhur.ac.id ¹, rizka.tiaharyadini@budiluhur.ac.id ², 2411501568@student.budiluhur.ac.id ³, 2411500107@student.budiluhur.ac.id ⁴

Article Info

Article history:

Received 2026-03-31

Revised 2026-05-04

Accepted 2026-05-25

Keyword:

Augmentation,
Convolutional Neural Network,
Deep Learning,
K-Fold Cross Validation,
ResNet-50.

ABSTRACT

Rice sustains over half of the global population; however, leaf diseases such as blight, brown spot, and leaf smut significantly reduce crop yields. Early and accurate detection is essential for supporting sustainable agriculture practices. This study proposes a ResNet-50-based deep learning model for rice leaf diseases classification using a dataset of 1,150 field images collected from Sleman, Indonesia, which was expanded to 2,000 images through augmentation techniques, including rotation, flipping, zooming, and brightness adjustment. Model performance was evaluated using both hold-out validation and 10-fold cross-validation with accuracy, precision, recall, and F1-Score metrics. The application of data augmentation improved hold-out validation accuracy from 82.4% to 88.1%. Meanwhile, 10-fold-cross-validation yielded a substantially higher average accuracy of 99.6%. This discrepancy suggests potential sensitivity to data partitioning and indicates the need for careful interpretation, as cross-validation may introduce optimistic estimates under certain conditions. Although the proposed approach demonstrates strong performance in distinguishing visually similar diseases, this study limited by the use of a single-region dataset, which may affect generalizability. Therefore, the integration of ResNet-50, augmentation, and cross-validation shows promising results for early disease detection, while further validation on more diverse datasets is required to support its application in real-world precision agriculture systems.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. INTRODUCTION

Over half of the world's population depends on rice as a staple food source, but rice diseases can cause significant yield losses. In affected areas, major leaf diseases like blast, brown spot, and bacterial leaf streak can reduce productivity by as much as 30-40% if they are not identified early [1], [2]. In the larger context of intelligent and sustainable agriculture, fast and precise detection of rice leaf disease is essential for maintaining food security, cutting down on excessive pesticide use, and assisting farmers in making decisions. The use of computer visions and deep learning algorithms for automated plant disease diagnosis is being driven by the expensive, subjective, and scale-limiting nature of traditional manual inspection approaches, especially in large paddy fields [3], [4].

Convolutional neural networks (CNNs) are receiving a lot of attention lately, particularly deep designs like ResNet-50, because of their robustness and powerful feature extraction capabilities when paired with data augmentation and transfer learning techniques [5], [6]. While lightweight architectures such as MobileNet or EfficientNet are often prioritized for their computational efficiency on mobile devices, this study specifically use ResNet-50 architecture to leverage its deep residual learning capabilities. Furthermore, the growing availability of datasets of agricultural images and the increased focus on model generalization and reliability-addressed by methods such as K-Fold cross validation-align this area of study with the current challenges in implementing reliable AI solutions for actual precision agriculture systems [7], [8].

In this study research, rice leaf diseases are identified and classified using a ResNet-50 deep learning model optimized

using data augmentation alongside K-Fold CV. According to recent research, convolutional neural networks (CNNs), including ResNet-50 variants, outperform conventional machine learning and manually created feature approaches in identifying rice leaf diseases like blast, brown spot, and bacterial blight from RGB images [9], [10], [11]. However, the research now in publication identifies a number of unresolved problems, such as model overfitting brought on by undersized and unbalanced datasets, insufficient generalization across different field situations, and imbalanced evaluation techniques that mostly rely on single train-test splits [12], [13]. The primary performance measures in this study are classification accuracy, precision, recall, and F1-score. Other important factors include input leaf image data, disease class labels, network design parameters, data augmentation procedures, and validation schemes. The study is part of the category of agricultural technology and focuses on the production of rice in tropical and subtropical areas, where the crop is a mainstay and yield and food security are seriously threatened by leaf diseases [14], [15]. Recent studies on deep learning for rice disease diagnosis reveal limitations in robustness and reliability, which this study approaches this problem by leveraging systematic data augmentation and K-Fold CV within ResNet-50.

Several significant issues have not been addressed in previous studies, despite the deep learning models' encouraging performance in detecting rice leaf diseases. According to theory, a large number of current research use shallow or moderately deep CNN architectures, which may not be able to capture intricate inter-class changes brought on by identical visual symptoms across various rice diseases [16], [17]. This could result in overfitting and a decreased capacity for generalization. Though many studies use inadequate data augmentation techniques or test models using single hold-out split, which can lead to optimistic and unstable performance estimates, actually the majority of publicly available rice leaf datasets are small and show class imbalance [18], [19]. Additionally, although residual learning has been shown to enhance convergence and feature classification in agricultural image analysis, barely any of recent research have methodically investigated deep residual networks, such as ResNet-50, in combination with K-Fold cross validation [20]. These disparities have significant societal and agricultural implications since faulty disease detection technologies can limit usage by farmers and agricultural organizations, hinder early intervention, and raise output losses. Thus, it is crucial to overcome these constraints by combining a strong ResNet-50 architecture, extensive data augmentation, and reliable K-Fold cross validation in order to create more precise, dependable, and easily implemented rice leaf disease detection systems that will encourage sustainable rice production and food security. The following research questions are intended to be addressed in order to fill up these gaps: (1) In comparison to other CNN-based methods, how effective is ResNet-50 at identifying and categorizing various rice leaf diseases? (2) How much can the combination of a deep residual network and data augmentation enhance classification accuracy and generalization? and (3) How can a

more robust and dependable performance evaluation of rice leaf disease classification models benefit from K-Fold cross validation? This study aims to give a more methodical and repeatable evaluation of deep residual learning for rice leaf disease detection by addressing these problems.

While ResNet-50 has been previously explored for rice leaf disease classification, this study differentiates by addressing critical gaps in model reliability and evaluation consistency that remain prevalent in existing literature. The primary contribution of this work lies in the systematic integration of deep residual learning with extensive data augmentation and 10-folds cross-validation to rigorously assess performance stability and minimize partition bias. Unlike many studies that rely on limited public datasets or single train-test splits, this research utilizes a unique, real-field dataset collected from Sleman, Indonesia, which captures authentic environmental variability, including complex backgrounds and natural lighting fluctuations. Furthermore, by providing a comparative analysis between hold-out and cross-validation schemes, this study offers a methodological reference for developing more robust and context-aware deep learning application in practical precision agriculture.

II. METHOD

A. Research Stages

The overall workflow of the proposed deep learning-based approach for detecting and classifying rice leaf is illustrated in Figure 1. The study follows a methodological process that starts with data collection, where raw image data is obtained as the main source of information. The next step is data augmentation, which uses methods like rotation, padding, and horizontal flipping to improve model robustness against overfitting and boost data variety. Data splitting is then used to arrange the supplemented dataset into training, validation, and test sets in order to guarantee objective model training, hyperparameter tuning, and performance evaluation. The model training phase then uses a deep convolutional neural network, ResNet-50 in particular, to create selective output features and learn hierarchical feature representations from the input images.




Figure 1. Research Flow Diagram

B. Data Collection and Augmentation

The dataset used in this study was collected direct field observations in rice fields areas located in Sleman, Yogyakarta, using camera with 12 megapixels resolution. To capture realistic environmental variations, image acquisition was conducted during daytime (from morning to afternoon), encompassing fluctuations in natural lighting intensity, various leaf orientations, and complex backgrounds such as soil, water, and vegetation. Image acquisition was performed from multiple angle to capture variations in leaf orientation and differing levels disease severity. The initial dataset, consisting of 1,150 images, is detailed in Table 1 and 6, comprising four categories: Healthy Leaf (320 images; 27.83%), Brown Spot (300 images; 26.09%), Blight (280 images; 24.35%), and Leaf Smut (250 images; 21.74%). All data were manually annotated and subsequently validated by agricultural practitioners to ensure label reliability prior to augmentation and classification stages.



Figure 2. Sample Images of Rice Leaf Disease Categories

The data augmentation process was conducted using specific technical parameters to enhance dataset variability while preserving the distinctive morphological characteristic of the disease. The parameters employed include random rotation within a range of ± 20 degrees, scaling (zooming) with factor between 0.8 and 1.2 of the original size, horizontal image flipping, and brightness adjustment with a variations range $\pm 30\%$. All techniques were applied exclusively to the training subset following data partitioning, thereby preventing any potential data leakage into the validation and test sets. With the implementation of these parameters, the dataset size increased from 1,150 original images to 2,000 images, which were proportionally distributed across four disease classes, is detailed in Table 1.

TABLE 1
RICE LEAF IMAGE DATASET DISTRIBUTION PRE-AND POST-AUGMENTATION

Image Class	Original Images	After Augmentation
Healthy Leaf	320	557
Blight	280	487
Brown Spot	300	522
Leaf Smut	250	434
Total	1,150	2,000

C. Data Partitioning

To rigorously mitigate potential data leakage and ensure the validity of experimental results, the data partitioning process was strictly performed prior to any data augmentation procedures. The original dataset of 1,150 images was first divided into training, validation, and testing sets. Only after this initial separation were data augmentation technique-

including rotation ($\pm 20^\circ$), zooming (0.8-1.2 scale), horizontal flipping, and brightness adjustment ($\pm 30\%$)-applied exclusively to the training subset. This specific sequence ensures that no augmented variants of a single original images are present across different data splits, thereby preventing information leakage that could lead to overly optimistic or biased performance estimates. By maintaining this strict separation, the evaluation-both in the 70/10/20 hold-out and the 10-fold cross-validation-remains unbiased and accurately reflects the model's true generalization capability on completely unseen data.

D. Convolutional Deep Learning Model

CNN is a variation of Multi-Layer Perceptron (MLP) neural network, which was constructed by imitating of neurons in the visual cortex of humans [25]. CNN is commonly used for image data and has high-depth network, following its effectiveness with feature learning, CNN is more effective in a variety of image processing applications. CNN are excellent at automatically learning hierarchical characteristics [26]. As they go through deeper layers, they gradually combine fundamental visual aspects like colour, textures, and shapes to create more accurate representations [27]. CNN's feature learning may be more effective than manually created features like shape, morphological, and wavelet features, etc [28].

The architecture is made from an output layer, many hidden layers, and input layer of neurons. CNN neurons have weight, bias, and activation functions, each of the neurons in a layer is linked to another layer's neuron [29]. Figure 3 shows the general CNN architecture. CNN has two stages, as shown in the figure: the feature extraction stage, which is utilized for feature extraction, and the classification stage. A convolution layer with ReLU activation and a pooling layer make up the CNN feature extraction stage, while a fully connected layer with softmax activation makes for the classification phase [30].




Figure 3. CNN Architecture

E. Residual Network 50 (ResNet-50)

The proposed model utilizes a ResNet-50 architecture pre-trained on the ImageNet dataset to leverage the capabilities of transfer learning. The configuration is performed by freezing the initial convolutional layers to preserve generic feature representations, while the deeper layers are fine-tuned to adapt to the visual characteristics of rice leaf diseases.

The input images is processed at a resolution of 224 x 224 pixels. In the final stage, the fully connected layer is configured with a softmax activation function to accurately distinguish among four target classes. The training process

was conducted using the Adam optimizer with an initial learning rate of 0.001. To maintain gradient stability and computational efficiency, the model was trained with a batch size of 32 for 10 to 20 epochs, which proved sufficient to achieve convergence in this transfer learning scenario with the dataset.

F. K-Fold Validation Technique

K-Fold Cross-Validation (CV) is a validation technique used for model selection in learning problem, performed over n iterations [35]. This approach helps mitigate overfitting and reduces bias in data selection [36]. In K-Fold CV, dataset $\mathcal{D}$ is randomly split into k non-overlapping subsets of similar size. The data distribution in each subset is preserved as consistently as possible using hierarchical sampling by $\mathcal{D}$ [37]. Data set $\mathcal{D}$ is randomly split into groups; $k - 1$ group are utilized for training, while the remaining group serves as the testing set. The algorithm is trained on each training subset in turn, after which the mean error across the corresponding test subset instances is computed [38]. Figure 5 illustrates the implementation of K-Fold CV with $k = 5$.



Figure 4. Model Evaluation Employed K-Fold CV

G. Performance Evaluation

In addition to global metrics, a confusion matrix analysis is methodically employed to examine class-wise misclassification trends. This approach is crucial for identifying specific patterns of error, particularly between disease classes that may share overlapping visual features, such as textures and colour patterns.

III. RESULTS AND DISCUSSION

A. Experimental Setup and Model Configuration

In this study, the experimental setup was designed to ensure both computational efficiency and stable model convergence within a transfer learning framework. All input images were resized to 224 x 224 pixels, a standard configuration widely adopted in pre-trained convolutional neural network architecture to maintain compatibility and optimize feature extraction. The model architecture was finalized with a fully connected layer employing a softmax activation function, enabling effective discrimination across the four target classes. For optimization, the Adam algorithm was utilized with an initial learning rate of 0.001, as it known to provide adaptive learning capabilities and faster convergence compared to conventional gradient descent methods. Additionally, a batch size of 32 was selected to balance memory efficiency and gradient stability during training. The training process was conducted over 10 to 20

epochs, which proved sufficient for achieving convergence without overfitting, particularly in transfer learning scenarios where pre-trained weights accelerate the learning process.

B. Impact of Data Augmentation on Model Generalization

The use of data augmentation methods, such as rotation, padding-crop, and horizontal flipping, significantly increased the ResNet-50 model's capacity for generalization in the identification and categorization of rice leaf disease, as can be seen in Figure 5.




Figure 5. Horizontal Flip, Padded-Cropped, and Rotated

Changes in leaf orientation, camera angle, field placement, and partial occlusion-all of which are common in agricultural environments-are simulated by these modifications. Therefore, instead of learning fixed spatial patterns, the model must acquire invariant and selective features. According to empirical data, including augmentation improved classification accuracy from 82.50% to 93.75%, indicating a significant improvement in predicting performance.

C. Performance Comparison Between Non-Augmented and Augmented Training Models

Figure 6 presents the training loss and accuracy trends for the model trained without data augmentation. It can be observed that the learning process began to reach a stable phase around the fourth epochs. Subsequently, the training loss continued to decline progressively between the fifth and seventh epochs. From eighth to tenth epochs, the model maintained stable behaviour, while the validation loss consistently decreased, suggesting enhanced generalization capability on previously unseen data.






Figure 6. Accuracy and Loss Without Augmentation

On the other hand, Figure 7 shows the accuracy and loss curves for the enhanced model. Performance has significantly improved, as seen by the graph, with training accuracy increasing from 37.21% in the 1st epoch to 88.57% by the 10th. Stronger generalization performance on unseen leaf images was the outcome of validation accuracy, which also improved the model's capacity to recognize unique patterns in rice leaf disease symptoms.




Figure 7. Accuracy and Loss With Augmentation

A comparison of model performance with and without data augmentation. The model trained on 1150 images without augmentation achieved 82.50% accuracy, while applying augmentation with 2000 images increased accuracy to 93.75%. The augmented model required 4.1 minutes to complete training, whereas the model trained without augmentation finished in only 1 minute. This suggests that although data augmentation increases computation times, model performance is significantly improved.

TABLE 2
IMPACT OF DATA AUGMENTATION ON RESNET-50 PERFORMANCE

Parameter	Without Augmentation	With Augmentation
Dataset Size	1150	2000
Accuracy (%)	82.5	93.7
Training Time	1 Minutes	4.1 Minutes

D. K- Fold Cross-Validation Results and Augmentation Impact Analysis

Ten-fold cross-validation was used to evaluate the ResNet-50 model's performance without data augmentation in order to assess its generalization across different data subsets. The results show noticeable variation in accuracy and loss values across folds, where Fold 8 achieved the highest accuracy of 100%, while Folds 1 and 2 recorded the lowest performance at 82.50%, indicating that the model struggled with certain data distributions, as presented in Figure 8.




Figure 8. K-Fold CV and Loss Without Data Augmentation

Figure 9 depicts the performance of the enhanced model in terms of accuracy and loss using K-fold cross-validation. The model achieves an initial training accuracy of 98.28% and gradually reaches 100% by the final fold. This steady increase reflects a marked enhancement in performance, indicating that the model maintains highly accurate predictions across all validation folds and exhibits strong generalization ability.




Figure 9. K-Fold CV Accuracy and Loss With Data Augmentation

Based on Table 3 dan Table 4 present the K-Fold cross-validation results without and with data augmentation, both indicating exceptionally high classification performance across folds. In Table 3, the model without augmentation already achieves strong accuracy, with several folds reaching very high to perfect performance, including Fold-8 with 100%. However, after applying augmentation (Table 4), the results become even more consistently elevated, with most folds achieving perfect accuracy (100%) and the remaining folds classified as very high to near-perfect, suggesting a substantial improvement in model generalization.

TABLE 3
ACCURACY OF K-FOLD CV WITHOUT AUGMENTATION

Performance Category	Fold	Accuracy (%)
Low	Fold-1, Fold-2	82.50
Moderate	Fold-4	87.50
High	Fold-3, Fold-6, Fold-9	92.50
Very High	Fold-5, Fold-7, Fold-10	97.50
Perfect	Fold-8	100.00

TABLE 4
ACCURACY OF K-FOLD CV WITH AUGMENTATION

Performance Category	Fold	Accuracy (%)
High	Fold-1, Fold-2	97.40
Very High	Fold-9	98.47
Near-Perfect	Fold-3	99.83
Perfect	Fold-4, Fold-5, Fold-6, Fold-7, Fold-8, Fold-10	100.00

Statistical evaluation based on 10-folds cross-validation show a variation in model stability. Based on the data presented in Table 3, the accuracy of the model without augmentation exhibits a relatively wide fluctuation, ranging from 82.50% to 100 %, resulting in a standard deviation of

approximately $\pm 5.96\%$. This high variance indicates that the model without augmentation is highly sensitive to variations in data distribution across different folds, reflecting a susceptibility to partitioning bias. The data in Table 4 indicate that the model with augmentation exhibits substantially higher consistency, characterized by a much narrower accuracy range (97.40% to 100%) and a significantly lower standard deviation to $\pm 1.02\%$. The marked decrease in standard deviation offers robust statistical evidence that augmentation techniques substantially improve the model's stability, confirming that the attained mean accuracy of 99.6% results from enhanced feature extraction performance.

The experimental results reveal a notable discrepancy between the validation schemes, where 10-folds cross-validation achieved a substantially higher average accuracy of 99.6% compared to the 88.1% obtained through hold-out validation. While the cross-validation performance suggests high stability across folds, it must be acknowledged that such near-perfect results often introduce an optimistic bias.

This phenomenon typically occurs, because data is reused across iterations, and in a relatively limited dataset, similarities in image characteristics-such as consistent backgrounds, lighting condition, and object features from the Sleman region-can contribute to inflated performance estimates. Furthermore, although data augmentation enhances robustness, it may also increase the similarity between samples, potentially leading to performance that does not fully reflect real world variability. Consequently, the hold-out validation results is regarded as a more realistic and reliable estimate of the model's true generalization capability on completely unseen data.

TABLE 5
RESNET-50 PERFORMANCE ANALYSIS WITH AND WITHOUT DATA AUGMENTATION USING K-FOLD

Model Configuration	Number of Samples	Accuracy (%)	Computation Time (Minutes)
K-Fold CV (no augmentation)	1150	92.25	3.0
K-Fold CV (with augmentation)	2000	99.67	7.0

To ensure the statistical significance and reliability of the performance gains, a comparative analysis of the mean accuracy and variance across folds was conducted. The results show a systematic improvement, where the application of data augmentation increased the average 10-folds cross-validation accuracy from 92.3% to 99.6%. Furthermore, the augmented model exhibited higher statistical stability, as evidenced by the reduction in performance fluctuation; while the non-augmented model showed wide range accuracy (82.5% to 100%), the augmented model consistently achieved near-perfect results across nearly folds. This consistently indicates that the performance improvement is not a result of a favorable data split but a robust enhancement of the model's feature extraction capability.

E. Classification Results of Rice Leaf Disease Detection without Data Augmentation

The confusion matrix for the model created to identify and categorize rice leaf diseases using the ResNet-50 architecture and a dataset with four classes is shown in Table 6. There were 1.150 image utilized in the experiment, comprising 320 images of healthy leaves, 280 images of blight, 300 images of brown spot, and 250 images of leaf smut. The dataset distribution indicates that healthy leaf images account for 27.83% of the total samples, followed by brown spot with 26.09%, blight with 24.35%, and leaf smut with 21.74%, providing a relatively balanced representation across the four rice leaf condition categories.

TABLE 6
DISTRIBUTION OF IMAGE CLASSES USED IN THE CLASSIFICATION MODEL

Image Class	Number of Images	Percentage (%)
Healthy Leaf	320	27.83 %
Blight	280	24.35 %
Brown Spot	300	26.09 %
Leaf Smut	250	21.74 %
Total	1.150	

Table 6 summarizes the classification outcomes of the model without augmentation, demonstrating its effectiveness in distinguishing four rice leaf conditions: healthy leaves, blight, brown spot, and leaf smut. A dataset of 1.150 rice leaf images- 320 healthy leaves, 280 blight, 300 brown spot, and 250 leaf smut samples-was used for the test.



Figure 10. Confusion Matrix for Model Without Augmentation

The confusion matrix in Figure 10, shows strong overall classification performance, with the model achieving high correctness across all four classes (Healthy, Blight, Brown Spot, and Leaf Smut). The diagonal values dominate, indicating that most samples are correctly classified: 314/320 for Healthy, 258/280 for Blight, 276/300 for Brown Spot, and 235/250 for Leaf Smut. This corresponds to an overall accuracy of approximately 94.17%, suggesting the model is highly effective in distinguishing between these plant conditions. Among the classes, Healthy show the highest precision with very minimal misclassification, while Leaf Smut also maintain relatively strong performance despite a slightly smaller dataset. The matrix also shows several

noteworthy, recurring misclassification tendencies. The comparatively higher off-diagonal numbers (eg., 7-8 misclassifications per category) suggest that Blight and Brown Spot are somewhat confused with other classes, especially with each other and with Leaf Smut. This suggests that the disease categories may share similar visual features, which makes it more challenging for the model to distinguish between them.

TABLE 7
CLASSIFICATION REPORT FOR THE NON-AUGMENTED MODEL

Class	Precision (%)	Recall (%)	F1-Score (%)	Support
Healthy Leaf	0.97	0.98	0.97	320
Blight	0.92	0.92	0.92	280
Brown Spot	0.93	0.92	0.93	300
Leaf Smut	0.95	0.94	0.94	250

F. Classification Results of Rice Leaf Disease Detection with Data Augmentation

The confusion matrix (Figure 10 and Figure 11) provide deeper insights into the model's performance by highlighting recurring misclassification tendencies. Analysis of the non-augmented model (Figure 10) reveals that Blight and Brown Spot were frequently confused with each other and Leaf Smut, likely due to their similar visual traits. However, following the application of data augmentation, the model's ability to capture discriminative feature improved significantly reducing inter-class confusion. For, instance Figure 11 shows that while minor overlap remains between Blight and Brown Spot, the diagonal values dominate, indicating that the model has become more robust in distinguishing visually identical disease.




Figure 11. Confusion Matrix for Model With Augmentation

TABLE 8
CLASSIFICATION REPORT FOR THE AUGMENTED MODEL

Class	Precision (%)	Recall (%)	F1-Score (%)	Support
Healthy Leaf	0.99	0.99	0.99	320
Blight	0.96	0.95	0.95	280
Brown Spot	0.96	0.94	0.95	300
Leaf Smut	0.94	0.97	0.96	250

G. Model Performance Evaluation

The notable discrepancy between the hold-out validation accuracy (88.1%) and the 10-fold cross-validation accuracy (99.6%) as seen in Table 9, requires a critical interpretation regarding model generalization. While 10-fold cross-validation provides an assessment of stability across different data partitions, the near-perfect results often reflect an optimistic bias typical in relatively small and region-specific datasets. This inflation occurs because k-fold cross-validation involves multiple iterations of data reuse, when combined with data augmentation, can reduce the distinctiveness between training and validation samples.

Specially, the consistent environmental characteristics of the Sleman dataset—such as uniform background textures and lighting conditions—likely allowed the model to over-optimize features during the cross-validation process. Consequently, the hold-out validation results (88.1%) is considered a more realistic and conservative estimate of the model's true performance on completely unseen data, as it ensures a stricter separation between the training and evaluation sets.

TABLE 9
SUMMARY OF MODEL PERFORMANCE EVALUATION RESULTS

Experiment Setup	Dataset Size	Validation Method	Accuracy (%)	Training Time
ResNet-50 without Augmentation	1150 images	Hold-out validation	82.4	1 Minute
ResNet-50 with Augmentation	2000 images	Hold-out validation	88.1	4.1 Minute
ResNet-50 without Augmentation	1150 images	10-Fold Cross Validation	92.3	2.5 Minute
ResNet-50 with Augmentation	2000 images	10-Fold Cross Validation	99.6	6.5 Minute

Although the proposed ResNet-50 model demonstrates strong accuracy and stability on the Sleman dataset, the authors note that these outcomes reflect particular regional characteristics, which could constrain its direct applicability across different geographical settings. The assertion of a “robust and accurate approach” is supported by the model's stable performance in addressing real-world environmental variability within the local dataset, achieved through systematic data augmentation and evaluation using 10-fold cross-validation. To comprehensively assess the model's robustness and confirm its reliability for practical precision agriculture applications, additional testing using diverse external datasets—covering various climatic conditions and rice varieties—is necessary and will be a key priority in future research.

IV. CONCLUSION

In this work, a deep learning-based approach utilizing ResNet-50 in conjunction with data augmentation and K-Fold cross validation is proposed for rice leaf disease identification.

The results show that the suggested approach greatly enhances model robustness and classification performance, especially when working with small and uneven agricultural datasets. The use of data augmentation effectively decreased overfitting and expanded dataset diversity, resulting in considerable gains in classification accuracy. Additionally, the application of 10-fold cross-validation produced a high average accuracy of 99.6%, offering a more trustworthy and an objective evaluation. Furthermore, the model demonstrated excellent performance in all disease classes, with increased precision, recall, and F1-Score, demonstrating its efficacy in differentiating between visually identical disease symptoms. For automated rice leaf disease identification, the combination of ResNet-50, data augmentation, and K-fold cross-validation provides a reliable and scalable solution. By facilitating early disease detection, lowering crop losses, and supporting farmers in their decision-making, this strategy offers a great ideal of promise to support precision agriculture. However, the dataset size and geographic coverage study are limitations. To improve practical use in the field, future research should concentrate on adding more varied environmental conditions to the dataset, investigating lightweight model architectures for real-time development, and integrating the systems with mobile or IoT-based agricultural applications.

REFERENCES

- [1] R. Deng *et al.*, “Automatic Diagnosis of Rice Diseases Using Deep Learning,” *Front. Plant Sci.*, vol. 12, Aug. 2021, doi: 10.3389/fpls.2021.701038.
- [2] Y. Li, X. Chen, L. Yin, and Y. Hu, “Deep Learning-Based Methods for Multi-Class Rice Disease Detection Using Plant Images,” *Agronomy*, vol. 14, no. 9, p. 1879, Aug. 2024, doi: 10.3390/agronomy14091879.
- [3] M. T. Ahad, Y. Li, B. Song, and T. Bhuiyan, “Comparison of CNN-based deep learning architectures for rice diseases classification,” *Artificial Intelligence in Agriculture*, vol. 9, pp. 22–35, Sep. 2023, doi: 10.1016/j.aiaa.2023.07.001.
- [4] S. R. Shah, S. Qadri, H. Bibi, S. M. W. Shah, M. I. Sharif, and F. Marinello, “Comparing Inception V3, VGG 16, VGG 19, CNN, and ResNet 50: A Case Study on Early Detection of a Rice Disease,” *Agronomy*, vol. 13, no. 6, p. 1633, Jun. 2023, doi: 10.3390/agronomy13061633.
- [5] M. S. A. M. Al-Gaashani, N. A. Samee, R. Alnashwan, M. Khayyat, and M. S. A. Muthanna, “Using a Resnet50 with a Kernel Attention Mechanism for Rice Disease Diagnosis,” *...*, vol. 13, no. 6, p. 1277, May 2023, doi: 10.3390/life13061277.
- [6] C. G. Simhadri and H. K. Kondaveeti, “Automatic Recognition of Rice Leaf Diseases Using Transfer Learning,” *Agronomy*, vol. 13, no. 4, p. 961, Mar. 2023, doi: 10.3390/agronomy13040961.
- [7] H. Liu, Y. Cui, J. Wang, and H. Yu, “Analysis and Research on Rice Disease Identification Method Based on Deep Learning,” *Sustainability*, vol. 15, no. 12, p. 9321, Jun. 2023, doi: 10.3390/su15129321.
- [8] P. Pai *et al.*, “Deep learning-based automatic diagnosis of rice leaf diseases using ensemble CNN models,” *Sci. Rep.*, vol. 15, no. 1, p. 27690, Jul. 2025, doi: 10.1038/s41598-025-13079-z.
- [9] N. Sultana, S. Sharmin, and M. S. Uddin, “A generalized leaf disease recognition of various crops and vegetables through computer vision and machine learning,” *Neural Comput. Appl.*, vol. 37, no. 25, pp. 21069–21089, Sep. 2025, doi: 10.1007/s00521-025-11382-4.
- [10] T. H. Nhut, V. P. T. Trung, C. M. Khoi, N. P. H. Khang, and N. C. Nhan, “An AIoT - Based System for Efficient Classification of

- Rice Leaf Diseases,” *IEEJ Transactions on Electrical and Electronic Engineering*, vol. 20, no. 11, pp. 1875–1881, Nov. 2025, doi: 10.1002/tee.70163.
- [11] K. Mostafa, F. Imran, M. Anjum, and S. I. Siam, “A Hybrid Deep Learning Framework for Robust Detection of Rice Leaf Diseases Using CNN and Transformer-Based Attention,” in *2025 International Conference on Quantum Photonics, Artificial Intelligence, and Networking (QPAIN)*, IEEE, Jul. 2025, pp. 1–6. doi: 10.1109/QPAIN66474.2025.11171957.
- [12] C. R. Carlson, J. Alghazo, and W. U. Hasan, “AI-Powered Detection of Rice Leaf Diseases: A Survey of CNN Architectures and Attention-Based Methods,” in *2025 IEEE International Conference on Imaging Systems and Techniques (IST)*, IEEE, Oct. 2025, pp. 1–6. doi: 10.1109/IST66504.2025.11268365.
- [13] M. S. Hafiz, A. Anwar, J. Shin, and J. I. Rafiq, “Improving Agronomic Disease Detection and Classification: The Superiority of Hybrid Inception-Xception Ensemble Model for Rice Leaf Disease Classification,” 2025, pp. 57–67. doi: 10.1007/978-981-96-4520-6_5.
- [14] M. Hamdy, H. M. ElHoseny, S. A. Eldolil, A. S. El-Fishawy, and E. Ibrahim, “AlexNet_ResNet_Concatenation Model Based on Rice Diseases Classification Enhancement,” in *2025 4th International Conference on Electronic Engineering (ICEEM)*, IEEE, Oct. 2025, pp. 1–8. doi: 10.1109/ICEEM66692.2025.11224994.
- [15] S. V. Rakshit, A. M. M. I. Chowdhury, A. Chakma, I. Hasan, S. Roy, and T. Rahman, “DeepLeafDiagnosis: A Two-Phase Transfer Learning Strategy for Perfect Accuracy in Rice Leaf Disease Classification,” in *2025 International Conference on Quantum Photonics, Artificial Intelligence, and Networking (QPAIN)*, IEEE, Jul. 2025, pp. 1–6. doi: 10.1109/QPAIN66474.2025.11172163.
- [16] O. O. Martins, C. C. Oosthuizen, and D. A. Desai, “RiceLeafClassifier -v1.0: A Quantized Deep Learning Model for Automated Rice Leaf Disease Detection and Edge Deployment,” *Engineering Reports*, vol. 7, no. 6, Jun. 2025, doi: 10.1002/eng2.70231.
- [17] C. R. Carlson, J. Alghazo, and W. U. Hasan, “AI-Powered Detection of Rice Leaf Diseases: A Survey of CNN Architectures and Attention-Based Methods,” in *2025 IEEE International Conference on Imaging Systems and Techniques (IST)*, IEEE, Oct. 2025, pp. 1–6. doi: 10.1109/IST66504.2025.11268365.
- [18] R. Muslim, Z. Zaeniah, A. Akbar, B. Imran, and Z. Zaenudin, “Disease Detection of Rice and Chili Based on Image Classification Using Convolutional Neural Network Android-Based,” *Jurnal Pilar Nusa Mandiri*, vol. 19, no. 2, pp. 85–96, Sep. 2023, doi: 10.33480/pilar.v19i2.4669.
- [19] María. J. López-Serrano, J. F. Velasco-Muñoz, J. A. Aznar-Sánchez, and I. M. Román-Sánchez, “Farmers’ Attitudes towards Irrigating Crops with Reclaimed Water in the Framework of a Circular Economy,” *Agronomy*, vol. 12, no. 2, p. 435, Feb. 2022, doi: 10.3390/agronomy12020435.
- [20] L. Zhang, Y. Bian, P. Jiang, and F. Zhang, “A Transfer Residual Neural Network Based on ResNet-50 for Detection of Steel Surface Defects,” *Applied Sciences*, vol. 13, no. 9, p. 5260, Apr. 2023, doi: 10.3390/app13095260.
- [21] R. Escobar Díaz Guerrero, L. Carvalho, T. Bocklitz, J. Popp, and J. L. Oliveira, “A Data Augmentation Methodology to Reduce the Class Imbalance in Histopathology Images,” *Journal of imaging informatics in medicine*, vol. 37, no. 4, pp. 1767–1782, Aug. 2024, doi: 10.1007/s10278-024-01018-9.
- [22] H. Bichri, A. Chergui, and M. Hain, “Investigating the Impact of Train / Test Split Ratio on the Performance of Pre-Trained Models with Custom Datasets,” *International Journal of Advanced Computer Science and Applications*, vol. 15, no. 2, 2024, doi: 10.14569/IJACSA.2024.0150235.
- [23] C. Paramita, S. Rakasiwi, P. N. Andono, G. F. Shidik, Shier Nee Saw, and M. I. Rafsanjani, “Deep Learning-Based Eye Disorder Classification: A K-Fold Evaluation of EfficientNetB and VGG16 Models,” *Scientific Journal of Informatics*, vol. 12, no. 3, pp. 441–452, Sep. 2025, doi: 10.15294/sji.v12i3.26257.
- [24] J. White and S. D. Power, “k-Fold Cross-Validation Can Significantly Over-Estimate True Classification Accuracy in Common EEG-Based Passive BCI Experimental Designs: An Empirical Investigation,” *Sensors*, vol. 23, no. 13, p. 6077, Jul. 2023, doi: 10.3390/s23136077.
- [25] Y. Liu, H. Pu, and D.-W. Sun, “Efficient extraction of deep image features using convolutional neural network (CNN) for applications in detecting and analysing complex food matrices,” *Trends Food Sci. Technol.*, vol. 113, pp. 193–204, Jul. 2021, doi: 10.1016/j.tifs.2021.04.042.
- [26] P. Nayak *et al.*, “2D-convolutional neural network based fault detection and classification of transmission lines using scalogram images,” *Heliyon*, vol. 10, no. 19, p. e38947, Oct. 2024, doi: 10.1016/j.heliyon.2024.e38947.
- [27] T. Tesileanu, E. Piasini, and V. Balasubramanian, “Efficient processing of natural scenes in visual cortex,” *Front. Cell. Neurosci.*, vol. 16, p. 1006703, 2022, doi: 10.3389/fncel.2022.1006703.
- [28] N. Wiem, C. M. Ali, and E. Ridha, “Wavelet Feature with CNN for Identifying Parasitic Egg from a Slender-Billed’s Nest,” 2021, pp. 365–374. doi: 10.1007/978-3-030-73050-5_37.
- [29] M. Vakalopoulou, S. Christodoulidis, N. Burgos, O. Colliot, and V. Lepetit, “Deep Learning: Basics and Convolutional Neural Networks (CNNs),” 2023, pp. 77–115. doi: 10.1007/978-1-0716-3195-9_3.
- [30] A. Zafar *et al.*, “A Comparison of Pooling Methods for Convolutional Neural Networks,” *Applied Sciences*, vol. 12, no. 17, p. 8643, Aug. 2022, doi: 10.3390/app12178643.
- [31] A. Stanojevic, S. Woźniak, G. Bellec, G. Cherubini, A. Pantazi, and W. Gerstner, “An exact mapping from ReLU networks to spiking neural networks,” *Neural Networks*, vol. 168, pp. 74–88, Nov. 2023, doi: 10.1016/j.neunet.2023.09.011.
- [32] A. B., M. Kaur, D. Singh, S. Roy, and M. Amoon, “Efficient Skip Connections-Based Residual Network (ESRNet) for Brain Tumor Classification,” *Diagnostics*, vol. 13, no. 20, p. 3234, Oct. 2023, doi: 10.3390/diagnostics13203234.
- [33] A. R. Rizalde, H. A. Mubarak, B. Khairunnisa, and Mohd. A. Fatan, “A Deep Learning Approach Based on Classification to Detect Facial Skin Defect,” *Public Research Journal of Engineering, Data Technology and Computer Science*, vol. 2, no. 2, pp. 93–106, Jan. 2025, doi: 10.57152/predatecs.v2i2.1558.
- [34] W. Zhang, P. Zhang, B. Zhang, X. Wang, and D. Wang, “A Collaborative Transfer Learning Framework for Cross-domain Recommendation,” in *Proceedings of the 29th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*, New York, NY, USA: ACM, Aug. 2023, pp. 5576–5585. doi: 10.1145/3580305.3599758.
- [35] J. Allgaier and R. Pryss, “Cross-Validation Visualized: A Narrative Guide to Advanced Methods,” *Mach. Learn. Knowl. Extr.*, vol. 6, no. 2, pp. 1378–1388, Jun. 2024, doi: 10.3390/make6020065.
- [36] F. M. Gonçalves Saraiva, A. C. Rodrigues Guimarães, O. S. da Silva Júnior, S. N. Monteiro, and L. M. Coelho, “Performance analysis of Gradient Boosting Regressor using K-fold and group K-fold for predicting permanent deformation in tropical soils,” *Journal of Materials Research and Technology*, vol. 40, pp. 3555–3567, Jan. 2026, doi: 10.1016/j.jmrt.2025.12.152.
- [37] G. Amir, O. Maayan, T. Zelazny, G. Katz, and M. Schapira, “Verifying the Generalization of Deep Learning to Out-of-Distribution Domains,” *J. Autom. Reason.*, vol. 68, no. 3, p. 17, Sep. 2024, doi: 10.1007/s10817-024-09704-7.
- [38] J. K. Parker and L. O. Hall, “Accelerating Fuzzy-C Means Using an Estimated Subsample Size,” *IEEE Trans. Fuzzy Syst.*, vol. 22, no. 5, pp. 1229–1244, Oct. 2014, doi: 10.1109/TFUZZ.2013.2286993.
- [39] W. Shafik, A. Tufail, L. C. De Silva, R. A. A. Haji Mohd Apong, and K.-H. Kim, “Deep learning technique for plant disease classification and pest detection and model explainability elevating agricultural sustainability,” *BMC Plant Biol.*, vol. 25, no. 1, p. 1491, Nov. 2025, doi: 10.1186/s12870-025-07377-x.
- [40] B. Naresh kumar and S. Sakthivel, “Rice leaf disease classification using a fusion vision approach,” *Sci. Rep.*, vol. 15, no. 1, p. 8692, Mar. 2025, doi: 10.1038/s41598-025-87800-3.

SURAT PENCATATAN CIPTAAN

Dalam rangka perlindungan ciptaan di bidang ilmu pengetahuan, seni dan sastra berdasarkan Undang-Undang Nomor 28 Tahun 2014 tentang Hak Cipta, dengan ini menerangkan:

Nomor dan tanggal permohonan : EC002026030667, 23 Februari 2026

Pencipta

Nama : **Zaqi Kurniawan, S.Kom., M.Kom dan Rizka Tiaharyadini, S.Kom, M.M., M.Kom**

Alamat : Cluster Tamansari Park Residence Blok K-3A, Sawangan, Kota Depok, Jawa Barat

Kewarganegaraan : Indonesia

Pemegang Hak Cipta

Nama : **Direktorat Riset dan Pengabdian kepada Masyarakat (DRPM)**

Alamat : Jl. Ciledug Raya, RT.10/RW.2, Pesanggrahan, Kota Adm. Jakarta Selatan, DKI Jakarta, 12260

Kewarganegaraan : Indonesia

Jenis Ciptaan : **Program Komputer**

Judul Ciptaan : **Program Komputer: SIMPADIS (Sistem Informasi Prediksi Penyakit Daun Padi Sleman)**

Tanggal dan tempat diumumkan untuk pertama kali di wilayah Indonesia atau di luar wilayah Indonesia : 19 Februari 2026, di DKI Jakarta

Jangka waktu perlindungan : Berlaku selama 50 (lima puluh) tahun sejak Ciptaan tersebut pertama kali dilakukan Pengumuman.

Nomor Pencatatan : 001152655

adalah benar berdasarkan keterangan yang diberikan oleh Pemohon.

Surat Pencatatan Hak Cipta atau produk Hak terkait ini sesuai dengan Pasal 72 Undang-Undang Nomor 28 Tahun 2014 tentang Hak Cipta.



a.n. MENTERI HUKUM
DIREKTUR JENDERAL KEKAYAAN INTELEKTUAL
u.b
Direktur Hak Cipta dan Desain Industri

Agung Damarsasongko,SH.,MH.
NIP. 196912261994031001