

**PENERAPAN MODEL HYBRID RESNET50-EFFICIENTNETB0 DAN SMOTE
UNTUK DETEKSI PENYAKIT PADA DAUN KENTANG**Novita Anggraini¹

Fakultas Teknik, Universitas Tanjungpura

d1041211047@student.untan.ac.id**Abstrak**

Penelitian ini mengembangkan model hybrid ResNet50-EfficientNetB0 dengan teknik feature fusion berbasis concatenation untuk meningkatkan akurasi deteksi penyakit daun kentang. Dataset yang digunakan terdiri dari 1.705 citra dengan tujuh kategori dan rasio ketidakseimbangan kelas sebesar 9,66:1. Untuk mengatasi ketidakseimbangan tersebut, diterapkan metode Synthetic Minority Over-sampling Technique (SMOTE) pada ruang fitur pelatihan. Evaluasi dilakukan menggunakan Stratified 5-Fold Cross Validation terhadap enam skenario kombinasi arsitektur dan kondisi data. Hasil menunjukkan bahwa model Hybrid dengan SMOTE mencapai performa terbaik dengan akurasi 83,93%, presisi 84,51%, F1-Score 83,93%, dan ROC-AUC 0,9774, mengungguli arsitektur ResNet50 maupun EfficientNetB0 secara individual. SMOTE terbukti memberikan dampak positif, terutama pada EfficientNetB0 dengan peningkatan akurasi sebesar 1,94 poin persentase.

Sejarah Artikel*Submitted: 3 April 2026**Accepted: 6 April 2026**Published: 7 April 2026***Kata Kunci**

ResNet50, EfficientNetB0, Model Hibrida, SMOTE, Penyakit Daun Kentang, Klasifikasi Citra.

PENDAHULUAN

Kentang merupakan komoditas hortikultura strategis yang memiliki peran ganda sebagai bahan pangan sekaligus bahan baku industri dan pasar ekspor. Namun, kemampuan produksi dalam negeri belum sepenuhnya mampu memenuhi permintaan yang terus meningkat. Berdasarkan data badan pusat statistik (BPS), produksi kentang Indonesia pada tahun 2022 mencapai 1,5 juta ton, meningkat sekitar 10,5 % dibandingkan tahun 2021. Meski demikian, nilai ekspor justru mengalami penurunan sebesar 19,13%, hanya mencapai US\$ 4,82 juta (Rinawati, 2022). Kondisi ini menarik mengingat di tengah kenaikan produksi, Indonesia tetap mengimpor kentang untuk memenuhi kebutuhan industri akibat keterbatasan pasokan lokal.

Salah satu faktor utama yang menyebabkan rendahnya kualitas dan produktivitas kentang adalah serangan penyakit tanaman. Penyakit daun kentang yang disebabkan oleh bakteri, jamur, virus, hama, dan nematoda dapat menurunkan hasil panen hingga 50-70% pada kondisi lingkungan yang mendukung perkembangan patogen (Bekele, 2025). Secara global, kerugian akibat penyakit tanaman diperkirakan sangat signifikan. (Chai et al., 2022) melaporkan bahwa lima patogen jamur utama pada tanaman gandum menyebabkan kehilangan produksi hingga 62 juta ton per tahun, setara dengan 8,5% dari total produksi global. Biasanya kerugian ini sebagian besar disebabkan oleh keterlambatan dalam proses deteksi penyakit, sehingga tindakan pengendalian sering kali dilakukan pada tahap yang sudah terlambat.

Keterlambatan deteksi penyakit tanaman umumnya terjadi karena proses diagnosis masih mengandalkan pengamatan visual secara manual atau pengujian laboratorium. Meskipun metode laboratorium memiliki tingkat akurasi yang tinggi, pendekatan ini memerlukan biaya yang relatif mahal, waktu yang lama, serta akses yang terbatas bagi petani. Kondisi tersebut mendorong perlunya solusi alternatif yang lebih efisien, cepat, dan mudah diterapkan di lapangan. Salah satu pendekatan yang banyak dikembangkan adalah pemanfaatan kecerdasan buatan, khususnya Convolutional Neural Network (CNN), yang mampu mengekstraksi fitur

visual dari citra daun secara otomatis dan mendukung proses identifikasi penyakit secara cepat dan akurat.

Namun, penerapan CNN pada kondisi nyata di lapangan masih menghadapi berbagai tantangan. Perbedaan lingkungan antara data pelatihan dan data pengujian sering kali menyebabkan penurunan performa model yang signifikan. Penelitian yang dilakukan oleh (Fenu & Mallocci, 2022) menunjukkan bahwa beberapa arsitektur CNN populer, seperti EfficientNetB0, MobileNetV2, InceptionV2, ResNet50, dan VGG16, mengalami penurunan akurasi yang cukup drastis. Model yang awalnya mencapai akurasi sekitar 92,7% pada lingkungan laboratorium hanya mampu mempertahankan akurasi sebesar 54,4% ketika diuji menggunakan data dari lingkungan lapangan (field). Temuan ini menunjukkan bahwa model CNN yang dilatih pada data terkontrol belum tentu memiliki kemampuan generalisasi yang baik pada kondisi nyata.

Salah satu penyebab utama rendahnya performa tersebut adalah penggunaan dataset dari lingkungan terkontrol, seperti PlantVillage, yang memiliki latar belakang seragam, pencahayaan terstandarisasi, dan sudut pengambilan gambar yang homogen. Karakteristik ini tidak sepenuhnya merepresentasikan kondisi lapangan yang kompleks. Untuk mengatasi keterbatasan tersebut, penelitian ini menggunakan dataset yang diperkenalkan oleh Shabrina et al. (2024), yang terdiri dari citra daun kentang dengan tujuh kelas penyakit dan diambil pada lingkungan tidak terkendali. Meskipun demikian, hasil pengujian terhadap berbagai arsitektur CNN populer pada dataset tersebut masih menunjukkan performa yang relatif rendah. EfficientNetV2B3 hanya mencapai akurasi sebesar 73,6%, ResNet50 sebesar 66,2%, MobileNetV3-Large sebesar 70,4%, DenseNet121 sebesar 58,5%, dan VGG16 sebesar 56,3%. Hasil ini mengindikasikan bahwa penggunaan arsitektur tunggal masih belum optimal untuk menangani kompleksitas data lapangan.

Sebagian besar penelitian sebelumnya masih berfokus pada penggunaan model CNN tunggal, sehingga potensi penggabungan keunggulan dari beberapa arsitektur belum dimanfaatkan secara maksimal. ResNet50 memiliki keunggulan dalam menjaga stabilitas pelatihan jaringan yang dalam melalui mekanisme residual learning, sehingga mampu mengekstraksi fitur kompleks secara efektif (Ridhovan et al., 2022). Berbagai penelitian menunjukkan performa ResNet50 yang tinggi, seperti penelitian Pamungkas et al. (2023) pada klasifikasi penyakit daun jagung dengan akurasi 93%, serta penelitian Trihardianingsih et al. (2023) pada klasifikasi penyakit daun teh dengan akurasi mencapai 97,44%. Temuan ini menegaskan bahwa ResNet50 memiliki kemampuan yang baik dalam berbagai kasus deteksi penyakit tanaman.

Di sisi lain, EfficientNetB0 menerapkan pendekatan compound scaling yang menyeimbangkan kedalaman, lebar, dan resolusi jaringan, sehingga mampu mencapai efisiensi parameter yang tinggi tanpa mengorbankan kemampuan ekstraksi fitur visual. Penelitian Gifani et al. (2021) menunjukkan bahwa EfficientNetB0 merupakan model tunggal dengan performa terbaik di antara berbagai arsitektur CNN pra-latih pada dataset CT Scan COVID-19, dengan akurasi mencapai 82%. Selain itu, EfficientNetB0 juga memberikan kontribusi signifikan dalam model ensemble, yang menghasilkan peningkatan akurasi hingga 85,2%. Hasil tersebut menunjukkan bahwa EfficientNetB0 tidak hanya unggul secara individual, tetapi juga efektif ketika dikombinasikan dengan arsitektur lain.

Selain permasalahan arsitektur, dataset yang digunakan dalam penelitian ini juga memiliki ketidakseimbangan kelas yang signifikan. Dataset Shabrina et al. (2024) menunjukkan dominasi kelas tertentu, seperti fungi dengan 748 citra dan pest dengan 611 citra, sementara kelas minoritas seperti nematode hanya memiliki 68 citra. Ketidakseimbangan ini berpotensi menyebabkan model cenderung bias terhadap kelas mayoritas dan gagal mengenali kelas minoritas secara akurat. Untuk mengatasi permasalahan tersebut, teknik Synthetic Minority

Over-sampling Technique (SMOTE) dapat digunakan untuk menyeimbangkan distribusi data dengan cara menghasilkan sampel sintetis pada kelas minoritas.

Efektivitas SMOTE dalam meningkatkan performa model pada dataset tidak seimbang telah dibuktikan oleh Joloudari et al. (2023), yang mengevaluasi berbagai metode penyeimbangan data pada 24 dataset berbeda. Hasil penelitian tersebut menunjukkan bahwa kombinasi SMOTE dengan CNN mampu meningkatkan akurasi hingga 99,08% pada dataset yang tidak seimbang. Temuan ini mengindikasikan bahwa penerapan SMOTE berpotensi meningkatkan kemampuan model dalam mengenali seluruh kelas secara lebih merata.

Berdasarkan permasalahan dan temuan penelitian sebelumnya, penelitian ini mengusulkan pendekatan berupa model hybrid ResNet50–EfficientNetB0 dengan mekanisme feature fusion untuk menggabungkan keunggulan masing-masing arsitektur dalam proses ekstraksi fitur. ResNet50 berperan dalam menangkap pola spasial dan tekstur yang kompleks, sedangkan EfficientNetB0 memperkaya representasi fitur melalui efisiensi parameter dan kemampuan generalisasi yang baik. Untuk mengatasi ketidakseimbangan kelas pada dataset, diterapkan metode SMOTE guna menghasilkan distribusi data yang lebih seimbang. Pendekatan ini diharapkan mampu meningkatkan akurasi dan stabilitas model dalam mendeteksi penyakit daun kentang pada kondisi lapangan yang kompleks. Berdasarkan perancangan tersebut, penelitian ini berjudul “Penerapan Model Hybrid ResNet50–EfficientNetB0 dan SMOTE untuk Deteksi Penyakit pada Daun Kentang”.

METODE

Penelitian ini termasuk dalam kategori penelitian eksperimen dengan pendekatan kuantitatif, khususnya pada ranah *Computer Vision* dan *deep learning* untuk mendeteksi penyakit pada daun kentang. Penelitian eksperimen dipilih karena adanya perlakuan sistematis terhadap data dan model, yakni melalui tahap pra-pemrosesan citra, penerapan algoritma pembelajaran mesin, serta pengujian performa menggunakan berbagai matrik evaluasi. Dalam pendekatan kuantitatif, data analisis secara numerik dan objektif guna menghasilkan temuan yang dapat diukur, dibandingkan, serta diuji validitasnya (Audrey et al., 2024).

Secara metodologis, penelitian ini menitikberatkan pada proses pengujian hipotesis kinerja model dengan membandingkan variasi arsitektur serta penerapan teknik penanganan terhadap data yang tidak seimbang (*imbalanced dataset*). Model yang digunakan merupakan kombinasi fitur (*feature fusion*) antara ResNet50 dan EfficientNetB0, dua arsitektur jaringan saraf konvolusional yang telah terbukti efektif dalam berbagai tugas klasifikasi citra, seperti yang telah dijelaskan pada bab 2. Pendekatan *hybrid feature fusion* dipilih karena mampu mengintegrasikan keunggulan masing-masing arsitektur, yakni kedalaman representasi fitur dari ResNet50 dan efisiensi komputasi dari EfficientNetB0, sehingga diharapkan menghasilkan performa klasifikasi yang lebih optimal.

Selain itu, penelitian ini menerapkan teknik *Synthetic Minority Over-Sampling Technique* (SMOTE) pada tahap pra-pemrosesan data untuk mengatasi masalah ketidakseimbangan distribusi kelas dalam dataset, dimana Ketidakseimbangan data merupakan salah satu tantangan utama dalam klasifikasi citra karena dapat menyebabkan bias model terhadap kelas mayoritas serta menurunkan akurasi pada kelas minoritas. Dengan memanfaatkan SMOTE, penelitian ini berupaya meningkatkan representasi kelas minoritas secara sintetis sehingga model dapat belajar lebih merata dari seluruh kelas yang tersedia.

Dengan demikian, penelitian ini dirancang secara sistematis melalui tahapan eksperimen mulai dari pengumpulan data, pra-pemrosesan berupa augmentasi dan Smote, dilanjutkan dengan pembangunan model hybrid berbasis *feature fusion*, hingga evaluasi kinerja menggunakan berbagai metrik, seperti *accuracy*, *precision*, *recall*, *F1-score*, *ROC-AUC*.

HASIL DAN PEMBAHASAN

Pengumpulan Data Dataset

Dataset yang digunakan dalam penelitian ini bersumber dari platform Mendeley Data dan terdiri dari 1.705 citra daun kentang yang terbagi ke dalam tujuh kategori kondisi, yaitu: Bacteria, Fungi, Healthy, Nematode, Pest, Phytophthora, dan Virus. Setiap citra memiliki format .jpg dengan resolusi bervariasi yang kemudian diseragamkan melalui proses pra-pemrosesan menjadi ukuran 224×224 piksel sesuai dengan persyaratan arsitektur ResNet50 dan EfficientNetB0.

Dataset ini mencerminkan kondisi lapangan yang sesungguhnya, di mana distribusi antar kelas tidak merata (imbalanced). Ketidakseimbangan distribusi semacam ini merupakan tantangan umum dalam aplikasi klasifikasi citra medis dan pertanian, karena model cenderung bias terhadap kelas mayoritas dan menghasilkan performa yang rendah pada kelas minoritas.

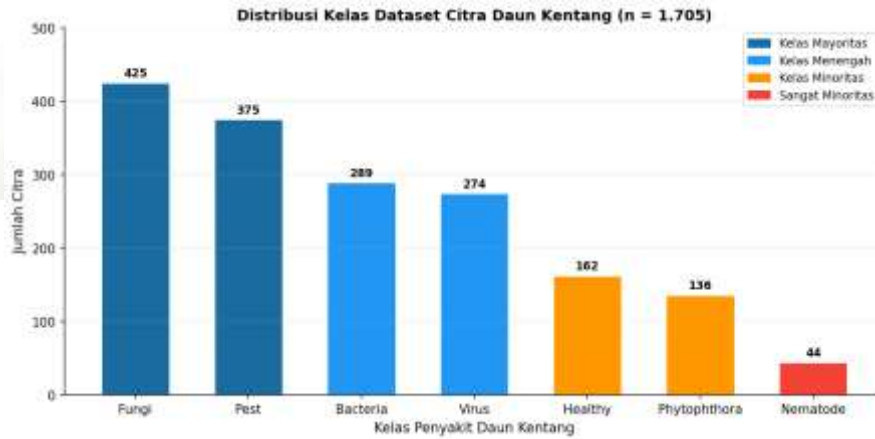
Analisis Distribusi Awal

Sebelum masuk ke tahap pra-pemrosesan, langkah penting yang dilakukan adalah menganalisis distribusi awal jumlah data pada masing-masing kelas. Tabel 3.1 menyajikan distribusi jumlah citra per kelas dalam dataset asli sebelum dilakukan augmentasi atau penyembnagan data.

Tabel 3.1 Distribusi Awal

No.	Kelas Penyakit	Jumlah Citra	Persentase (%)	Kategori
1	Fungi	425	24.93	Mayoritas
2	Pest	375	22.00	Mayoritas
3	Bacteria	289	16.95	Menengah
4	Virus	274	16.07	Menengah
5	Healthy	162	9.50	Minoritas
6	Phytophthora	136	7.98	Minoritas
7	Nematode	44	2.58	Sangat Minoritas
	TOTAL	1.705	100.00	—

Berdasarkan Tabel 3.1 terlihat bahwa terdapat ketimpangan distribusi yang signifikan antara kelas Fungi (425 citra, 24,93%) sebagai kelas mayoritas dan kelas Nematode (44 citra, 2,58%) sebagai kelas sangat minoritas. Rasio ketidakseimbangan antara kelas terbesar dan terkecil mencapai 9,66:1, yang mengindikasikan bahwa tanpa intervensi, model akan cenderung mengklasifikasikan sampel ke kelas dengan representasi lebih besar.



Gambar 3.1 Distribusi Kelas Dataset Citra Daun Kentang

Pra-pemrosesan Data

Resize dan Normalisasi

Seluruh citra diubah ukurannya ke dimensi 224x224 piksel menggunakan metode interpolasi bilinear untuk menjaga konsistensi dimensi input yang dibutuhkan oleh arsitektur ResNet50 dan EfficientNet. Normalisasi nilai piksel dilakukan dengan membagi setiap piksel dengan 255, sehingga menghasilkan nilai dalam rentang [0.1]. Normalisasi ini bertujuan untuk mempercepat konvergensi pelatihan dan mengurangi sensitivitas terhadap perbedaan skala antar citra.

Augmentasi Data

Augmentasi data diterapkan pada data pelatihan untuk meningkatkan variabilitas dan mencegah overfitting. Teknik augmentasi yang digunakan meliputi:

- 1) horizontal flip dengan probabilitas 50%
- 2) rotasi acak dalam rentang ±15 derajat
- 3) pergeseran horizontal dan vertikal hingga 10% dari dimensi citra.
- 4) zoom acak antara 0,9 hingga 1,1, serta
- 5) penyesuaian brightness dan contrast secara acak.

Augmentasi hanya diterapkan pada split pelatihan dalam setiap fold, sementara data validasi dan pengujian tidak diaugmentasi untuk memastikan evaluasi yang objektif. Gambar 3.2 adalah contoh dari hasil augmentasi yang dilakukan.



Gambar 3.2 Visualisasi Augmentsai Citra

Penerapan SMOTE

Synthetic Minority Over-sampling Technique (SMOTE) diterapkan untuk mengatasi permasalahan ketidakseimbangan kelas pada data pelatihan. SMOTE bekerja dengan

menginterpolasi sampel sintetis baru di antara sampel minoritas yang sudah ada dalam ruang fitur. Dalam penelitian ini, SMOTE diterapkan setelah ekstraksi fitur dari layer Global Average Pooling kedua arsitektur dasar, sehingga interpolasi dilakukan dalam ruang fitur berformat vektor numerik berdimensi tinggi. Setelah penerapan SMOTE, jumlah sampel pelatihan meningkat dari 1.364 sampel (per fold rata-rata) menjadi 2.380 sampel dengan distribusi yang seimbang untuk setiap kelas (340 sampel per kelas).

Tabel 3.2 Distribusi Kelas Penerapan SMOTE

No.	Kelas	Sebelum SMOTE	Sesudah SMOTE	Pertambahan	Perubahan (%)
1	Bacteria	289	340	+51	+17,65
2	Fungi	425	340	-85	-20,00
3	Healthy	162	340	+178	+109,88
4	Nematode	44	340	+296	+672,73
5	Pest	375	340	-35	-9,33
6	Phytophthora	136	340	+204	+150,00
7	Virus	274	340	+66	+24,09
	TOTAL	1.705	2.380	+675	+39,59

Tabel 3.2 memperlihatkan bahwa SMOTE berhasil menyeimbangkan jumlah sampel pada setiap kelas menjadi 340 sampel per kelas dalam satu fold pelatihan. Kelas Nematode mengalami peningkatan terbesar yakni +672,73% dari hanya 44 menjadi 340 sampel sintetis, sementara kelas Fungi dan Pest mengalami pengurangan karena diatur pada nilai tengah distribusi. Total sampel pelatihan meningkat sebesar 39,59% dari 1.705 menjadi 2.380 sampel.

Skenario Pengujian

Penelitian ini dirancang dalam enam skenario eksperimen yang merupakan kombinasi tiga arsitektur dan dua kondisi data. Tabel 3.3 merangkum konfigurasi seluruh skenario beserta kode identifikasinya.

Tabel 3.3 Konfigurasi Enam Skenario Eksperimen

No	Skenario	Arsitektur	Penyeimbangan	Total Data Latih
1	ResNet50 (Tanpa SMOTE)	ResNet50	Tidak	1.364
2	EfficientNetB0 (Tanpa SMOTE)	EfficientNetB0	Tidak	1.364
3	Hybrid (Tanpa SMOTE)	Hybrid	Tidak	1.364
4	ResNet50 + SMOTE	ResNet50	SMOTE	2.380
5	EfficientNetB0 + SMOTE	EfficientNetB0	SMOTE	2.380
6	Hybrid + SMOTE	Hybrid	SMOTE	2.380

Seluruh skenario menggunakan konfigurasi yang identik dalam hal ukuran input 224×224 piksel, batch size 32, jumlah epoch maksimum 50, fungsi optimasi Adam dengan learning rate 1×10^{-4} , dan fungsi loss categorical crossentropy. Inisialisasi bobot menggunakan pre-trained weights dari ImageNet untuk mempercepat konvergensi dan memanfaatkan representasi fitur yang telah terbukti efektif


Pembangunan Model

Skenario Eksperimen Tanpa SMOTE

Kelompok eksperimen pertama dilakukan tanpa penerapan SMOTE, menggunakan data asli yang tidak seimbang. Tujuannya adalah untuk menetapkan baseline performa masing-masing arsitektur sebelum intervensi penyeimbangan data

Skenario 1

Gambar 3.3 Menampilkan grafik terbaik ResNet50 pada setiap epoch dalam kondisi tanpa SMOTE.



Gambar3.3 Grafik Terbaik ResNet50 tanpa SMOTE

Berdasarkan kurva training S1 yaitu ResNet50 Tanpa SMOTE, grafik Loss menunjukkan penurunan yang tajam dan konsisten dari epoch awal hingga sekitar epoch ke-10, setelah itu kedua kurva training dan validasi menstabilkan diri di kisaran nilai rendah. Tidak terdapat indikasi overfitting yang signifikan karena kurva training dan validasi bergerak berdekatan sepanjang proses pelatihan. Grafik Accuracy menunjukkan pola serupa: akurasi naik dengan cepat pada epoch awal dan kemudian konvergen di kisaran 0,85–0,90, dengan kurva validasi yang mengikuti kurva training secara konsisten. Hal ini mengindikasikan bahwa model mampu belajar dengan baik dari data pelatihan dan melakukan generalisasi dengan stabil pada data validasi.

Tabel 3.4 Hasil Evaluasi ResNet50 Tanpa SMOTE


Fold ke-	Akurasi	Presisi	Recall	F1-Score	ROC-AUC
1	0,8534	0,8620	0,8534	0,8531	0,9803
2	0,8563	0,8572	0,8563	0,8553	0,9818
3	0,8299	0,8384	0,8299	0,8304	0,9687
4	0,8270	0,8312	0,8270	0,8268	0,9760
5	0,8270	0,8285	0,8270	0,8247	0,9824
Rata-rata	0,8387 ± 0,0132	0,8435 ± 0,0137	0,8387 ± 0,0132	0,8381 ± 0,0133	0,9778 ± 0,0051

ResNet50 tanpa SMOTE menghasilkan akurasi rata-rata sebesar 83,87% dengan standar deviasi 1,32% yang mengindikasikan stabilitas performa yang baik antar fold. Nilai F1-Score

rata-rata adalah 83,81% dan ROC-AUC sebesar 97,78% yang menunjukkan kemampuan yang kuat.

Skenario 2

Gambar 3.4 Menampilkan grafik terbaik EfficientNetB0 pada setiap epoch dalam kondisi tanpa SMOTE.



Gambar 3.4 Grafik Terbaik EfficientNetB0 tanpa SMOTE

Berdasarkan kurva training tersebut (EfficientNetB0 Tanpa SMOTE), grafik Loss memperlihatkan penurunan yang lebih lambat dibandingkan ResNet50, dengan nilai loss validasi yang sedikit lebih tinggi pada akhir pelatihan. Grafik Accuracy menunjukkan konvergensi pada kisaran 0,80–0,82, yang lebih rendah dibandingkan ResNet50. Meskipun tidak terdapat overfitting yang mencolok, jarak antara kurva training dan validasi yang sedikit lebih lebar pada beberapa epoch mengindikasikan bahwa model mengalami kesulitan dalam menggeneralisasi pola dari data yang tidak seimbang.


Tabel 3.5 Hasil Evaluasi EfficientNetB0 Tanpa SMOTE

Fold ke-	Akurasi	Presisi	Recall	F1-Score	ROC-AUC
1	0,8006	0,8065	0,8006	0,8006	0,9749
2	0,8065	0,8133	0,8065	0,8059	0,9729
3	0,7977	0,7989	0,7977	0,7972	0,9709
4	0,8035	0,8093	0,8035	0,8010	0,9744
5	0,8094	0,8128	0,8094	0,8057	0,9775
Rata-rata	0,8035 ± 0,0041	0,8082 ± 0,0053	0,8035 ± 0,0041	0,8021 ± 0,0033	0,9741 ± 0,0022

EfficientNetB0 tanpa SMOTE menunjukkan performa paling rendah di antara semua skenario dengan akurasi rata-rata 80,35% dan standar deviasi yang sangat kecil, yaitu 0,41%. Nilai koefisien variasi yaitu, 0,52% juga merupakan yang terendah dari semua skenario, mengindikasikan konsistensi yang sangat tinggi namun pada level akurasi yang lebih rendah. Hal ini menunjukkan bahwa EfficientNetB0 mengalami kesulitan lebih besar dalam menangani ketidakseimbangan kelas pada dataset ini.

Skenario 3

Gambar 3.4 Menampilkan grafik terbaik Hybrid pada setiap epoch dalam kondisi tanpa SMOTE.



Gambar3.5 Grafik Terbaik Hybrid tanpa SMOTE

Berdasarkan kurva training S3, yaitu Hybrid Tanpa SMOTE, grafik Loss memperlihatkan penurunan yang cepat pada epoch awal, namun dengan fluktuasi yang lebih besar dibandingkan dua skenario sebelumnya, terutama pada epoch 20 ke atas. Grafik Accuracy menunjukkan konvergensi di kisaran 0,83–0,89, namun dengan osilasi yang lebih nyata antara kurva training dan validasi. Variasi ini konsisten dengan nilai standar deviasi antar fold yang lebih tinggi, yaitu 2,40%, mengindikasikan sensitivitas model Hybrid terhadap komposisi data pada setiap fold.


Tabel 3.6 Hasil Evaluasi Model Hybrid Tanpa SMOTE

Fold ke-	Akurasi	Presisi	Recall	F1-Score	ROC-AUC
1	0,8504	0,8514	0,8504	0,8503	0,9787
2	0,8622	0,8695	0,8622	0,8613	0,9760
3	0,8035	0,8092	0,8035	0,8029	0,9734
4	0,8035	0,8112	0,8035	0,8001	0,9716
5	0,8358	0,8444	0,8358	0,8349	0,9812
Rata-rata	0,8311 ± 0,0240	0,8372 ± 0,0235	0,8311 ± 0,0240	0,8299 ± 0,0247	0,9762 ± 0,0035

Model Hybrid tanpa SMOTE menghasilkan akurasi rata-rata 83,11% dengan standar deviasi tertinggi di antara skenario non SMOTE, yaitu 2,40%. Variasi yang lebih tinggi ini mencerminkan sensitivitas model terhadap komposisi fold, sebagaimana terlihat dari perbedaan yang cukup besar antara fold terbaik sebesar 86,22% dan fold terburuk, yaitu 80,35%. Meskipun demikian, Hybrid tanpa SMOTE mengungguli EfficientNetB0 tunggal, menunjukkan manfaat dari penggabungan fitur dua arsitektur.

Skenario Eksperimen Menggunakan SMOTE Skenario 4

Gambar 3.6 Menampilkan grafik terbaik ResNet50 pada setiap epoch dalam kondisi SMOTE.



Gambar3.6 Grafik Terbaik ResNet50 Dengan SMOTE

Berdasarkan kurva training S4, yaitu ResNet50 + SMOTE grafik Loss menunjukkan pola penurunan yang serupa dengan S1, namun dengan sedikit peningkatan gap antara kurva training dan validasi pada pertengahan pelatihan. Hal ini mengindikasikan adanya sedikit noise yang diperkenalkan oleh data sintetis SMOTE. Grafik Accuracy juga menunjukkan konvergensi di kisaran yang serupa dengan S1, yaitu 0,85–0,92, namun dengan variasi yang lebih besar antar epoch. Pola ini konsisten dengan hipotesis bahwa data sintetis dapat memperkenalkan noise interpolasi pada model berkapasitas tinggi seperti ResNet50


Tabel 3.7 Performa ResNet50 setelah penerapan SMOTE.

Fold ke-	Akurasi	Presisi	Recall	F1-Score	ROC-AUC
1	0,8387	0,8414	0,8387	0,8381	0,9769
2	0,8299	0,8340	0,8299	0,8281	0,9781
3	0,8182	0,8194	0,8182	0,8181	0,9687
4	0,8152	0,8184	0,8152	0,8146	0,9686
5	0,8739	0,8781	0,8739	0,8741	0,9874
Rata-rata	0,8352 ± 0,0211	0,8383 ± 0,0218	0,8352 ± 0,0211	0,8346 ± 0,0214	0,9759 ± 0,0070

ResNet50 yang dikombinasikan dengan SMOTE memperoleh akurasi rata-rata sebesar 83,52% dengan standar deviasi 2,11%, menunjukkan performa yang tetap stabil pada setiap fold. Jika dibandingkan dengan skenario tanpa SMOTE, yaitu 83,87%, terlihat penurunan yang sangat tipis. Penurunan akurasi ini dibandingkan Skenario tanpa SMOTE dapat diinterpretasikan sebagai konsekuensi penambahan data sintetis SMOTE yang berpotensi memperkenalkan noise interpolasi pada model berkapasitas tinggi seperti ResNet50.

Skenario 5

Gambar 3.7 Menampilkan grafik terbaik EfficientNetB0 pada setiap epoch dalam kondisi SMOTE.



Gambar3.7 Grafik Terbaik EfficientNet Dengan SMOTE

Berdasarkan kurva training S5, yaitu EfficientNetB0 + SMOTE, grafik Loss memperlihatkan penurunan yang lebih cepat dan lebih smooth dibandingkan S2, dengan kurva training dan validasi yang bergerak lebih berdekatan. Grafik Accuracy menunjukkan konvergensi yang lebih tinggi dibandingkan S2, mencapai kisaran 0,82–0,88. Perbaikan ini mengindikasikan bahwa penyeimbangan kelas melalui SMOTE memberikan manfaat nyata bagi EfficientNetB0, membantu model untuk belajar fitur dari kelas minoritas yang sebelumnya sulit dideteksi.

Tabel 3.8 menyajikan performa EfficienNetB0 setelah penerapan SMOTE.


Fold ke-	Akurasi	Presisi	Recall	F1-Score	ROC-AUC
1	0,8299	0,8317	0,8299	0,8284	0,9762
2	0,8358	0,8395	0,8358	0,8352	0,9766
3	0,7947	0,7991	0,7947	0,7954	0,9703
4	0,8270	0,8236	0,8270	0,8239	0,9774
5	0,8270	0,8300	0,8270	0,8230	0,9799
Rata-rata	0,8229 ± 0,0144	0,8248 ± 0,0138	0,8229 ± 0,0144	0,8212 ± 0,0136	0,9761 ± 0,0032

EfficientNetB0 dengan SMOTE memperlihatkan peningkatan akurasi rata-rata dari 80,35% menjadi 82,29%, yang merupakan peningkatan sebesar 1,94 poin persentase. Hal ini menunjukkan bahwa EfficientNetB0 mendapatkan manfaat yang lebih besar dari SMOTE dibandingkan ResNet50, mengingat tingkat akurasi awalnya yang lebih rendah. Standar deviasi juga tetap terjaga pada level yang relatif rendah, yaitu 1,44%.

Skenario 6

Gambar 3.8 Menampilkan grafik terbaik Hybrid pada setiap epoch dalam kondisi SMOTE.





Gambar 3.8 Grafik Terbaik Hybrid Dengan SMOTE

Berdasarkan kurva training S6, yaitu Hybrid + SMOTE, grafik Loss menunjukkan penurunan yang paling konsisten dan mulus di antara semua skenario, dengan nilai loss yang mencapai level terendah pada akhir pelatihan, mendekati 0,05. Grafik Accuracy menunjukkan konvergensi tertinggi di antara semua skenario, dengan kurva training mencapai 0,92 dan kurva validasi mengikuti di kisaran 0,82–0,88. Meskipun terdapat sedikit gap antara training dan validasi pada akhir epoch, hal ini masih berada dalam batas yang wajar dan tidak menunjukkan overfitting yang serius. Pola kurva ini secara visual mengkonfirmasi bahwa kombinasi arsitektur Hybrid dengan SMOTE menghasilkan representasi fitur yang paling kaya dan pelatihan yang paling efektif.

Tabel 3.9 menyajikan performa HYBRID setelah penerapan SMOTE.

Fold ke-	Akurasi	Presisi	Recall	F1-Score	ROC-AUC
1	0,8622	0,8705	0,8622	0,8635	0,9814
2	0,8592	0,8649	0,8592	0,8583	0,9791
3	0,7889	0,8005	0,7889	0,7903	0,9687
4	0,8416	0,8434	0,8416	0,8416	0,9786
5	0,8446	0,8463	0,8446	0,8430	0,9790
Rata-rata	0,8393 ± 0,0265	0,8451 ± 0,0246	0,8393 ± 0,0265	0,8393 ± 0,0259	0,9774 ± 0,0045

Skenario Hybrid yang dikombinasikan dengan SMOTE mencatat performa paling tinggi dengan akurasi rata-rata 83,93% dan F1-Score yang juga 83,93%, sehingga bisa dianggap sebagai skenario terbaik dalam penelitian ini. Nilai presisi rata-rata mencapai 84,51%, yang merupakan angka tertinggi dibandingkan skenario lainnya. Memang standar deviasinya sedikit lebih besar, yaitu 2,65%, tetapi hal ini masih tergolong wajar. Perbedaan tersebut dipengaruhi variasi antar fold, bukan karena modelnya tidak stabil. Terlihat juga bahwa rentang akurasi tiap fold masih berada di kisaran 78,89% hingga 86,22%, sehingga performanya tetap konsisten.

Analisis Model

Tabel 3.10 merangkum performa rata-rata semua skenario untuk memudahkan perbandingan langsung antar konfigurasi model dan kondisi data.

Tabel 3.10 Perbandingan Kinerja Enam Skenario Eksperimen

No.	Skenario	SMOTE	Akurasi (%)	Presisi (%)	F1-Score (%)	ROC-AUC	Rank
S6	Hybrid + SMOTE	Ya	83,93	84,51	83,93	0,9774	1

No.	Skenario	SMOTE	Akurasi (%)	Presisi (%)	F1-Score (%)	ROC-AUC	Rank
S1	ResNet50 (Tanpa SMOTE)	Tidak	83,87	84,35	83,81	0,9778	2
S4	ResNet50 + SMOTE	Ya	83,52	83,83	83,46	0,9759	3
S3	Hybrid Tanpa SMOTE	Tidak	83,11	83,72	82,99	0,9762	4
S5	EfficientNetB0 + SMOTE	Ya	82,29	82,48	82,12	0,9761	5
S2	EfficientNetB0 (Tanpa SMOTE)	Tidak	80,35	80,82	80,21	0,9741	6

Berdasarkan Tabel 3.10, dapat ditarik beberapa kesimpulan utama. Pertama, Skenario S6, yaitu Hybrid + SMOTE, mencapai akurasi dan F1-Score tertinggi sebesar 83,93%, mengonfirmasi bahwa kombinasi arsitektur hybrid dan penyeimbangan data SMOTE memberikan hasil terbaik. Kedua, ResNet50 secara konsisten mengungguli EfficientNetB0 dalam kondisi tanpa SMOTE maupun dengan SMOTE, yang menunjukkan bahwa kapasitas representasional ResNet50 lebih sesuai untuk dataset ini. Ketiga, penerapan SMOTE memberikan peningkatan performa yang lebih signifikan pada EfficientNetB0 sebesar 1,94% poin dibandingkan ResNet50 yang menurun 0,35% poin, mengindikasikan bahwa model yang lebih rentan terhadap ketidakseimbangan kelas mendapat manfaat lebih besar dari penyeimbangan data. Dampak SMOTE juga menunjukkan pola yang berbeda tiap arsitektur, seperti yang dirangkum pada Tabel 3.11 berikut.

Tabel 3.11 Dampak Penerapan SMOTE pada tiap Arsitektur

Arsitektur	Akurasi (Tanpa SMOTE)	Akurasi (Dengan SMOTE)	Δ Akurasi (%)	Δ F1-Score (%)	Δ ROC-AUC
ResNet50	83,87	83,52	-0,35	-0,35	-0,0019
EfficientNetB0	80,35	82,29	+1,94	+1,91	+0,0020
Hybrid	83,11	83,93	+0,82	+0,94	+0,0012

EfficientNetB0 mendapatkan peningkatan akurasi terbesar, bertambah 1,94% poin, mengindikasikan bahwa arsitektur yang lebih ringan dengan kapasitas representasional lebih terbatas lebih rentan terhadap ketidakseimbangan kelas dan karenanya lebih diuntungkan oleh oversampling sintetis. Model Hybrid juga mendapatkan peningkatan yang berarti, yaitu bertambah 0,82 poin, mengkonfirmasi bahwa kombinasi kapasitas representasional tinggi dengan data yang lebih seimbang menghasilkan performa optimal. Sebaliknya, ResNet50 mengalami penurunan 0,35 poin, yang dapat dikaitkan dengan fakta bahwa ResNet50 memiliki kapasitas yang cukup untuk mengatasi ketidakseimbangan kelas secara lebih baik bahkan tanpa SMOTE.

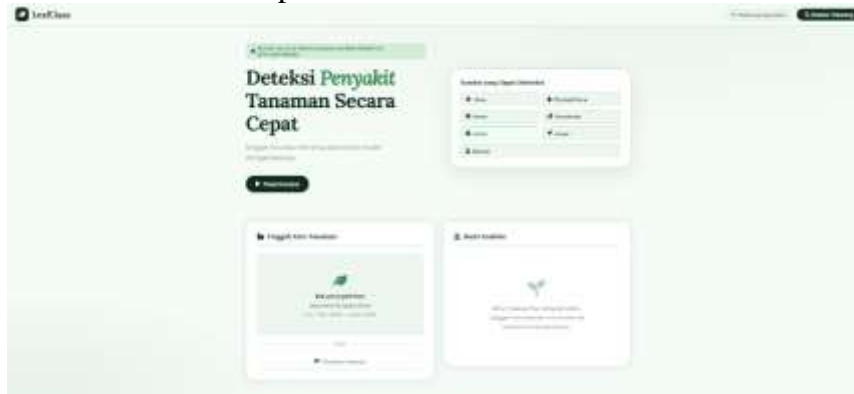
Hasil Uji Coba Sistem

Sistem deteksi penyakit daun kentang dikembangkan menggunakan model terbaik, Skenario S6 Hybrid + SMOTE yang telah disimpan dalam format keras. Pengujian sistem

dilakukan menggunakan pendekatan black box testing yang berfokus pada kesesuaian antara input yang diberikan dan output yang dihasilkan tanpa mempertimbangkan implementasi internal model.

Antarmuka sistem

Sistem dirancang dengan antarmuka web sederhana yang memungkinkan pengguna untuk mengunggah citra daun kentang dalam format .jpg. Sistem kemudian memproses citra melalui pipeline pra-pemrosesan otomatis, resize ke 224×224, normalisasi, mengekstraksi fitur menggunakan model Hybrid yang telah dilatih, dan menampilkan hasil klasifikasi beserta nilai probabilitas untuk setiap kelas.



Gambar3.9 Antarmuka Sistem

Skenario Pengujian

Pengujian dilakukan terhadap citra representatif dari setiap kategori penyakit. Masing-masing kategori akan memiliki 10 data uji yang diambil dari kaggle, dan hasil probabilitas pada table akan merepresentasikan keseluruhan data uji tiap kelas. Tabel 3.13 menyajikan hasil uji coba sistem menggunakan model terbaik

Tabel 3.12 Skenario Pengujian Web

No.	Jenis Penyakit (Label Sebenarnya)	Klasifikasi Sistem	Probabilitas (%)	Kesimpulan
1	Bacteria	Bacteria	87,3	Sesuai
2	Fungi	Fungi	91,2	Sesuai
3	Healthy	Healthy	94,7	Sesuai
4	Nematode	Nematode	72,1	Sesuai
5	Pest	Pest	88,6	Sesuai
6	Phytophthora	Phytophthora	79,4	Sesuai
7	Virus	Virus	85,9	Sesuai

Berdasarkan Tabel 3.13, sistem berhasil mengklasifikasikan seluruh tujuh kategori citra uji dengan benar. Nilai probabilitas tertinggi diperoleh pada kelas Healthy sebesar 94,7%, yang secara intuitif masuk akal karena daun sehat memiliki karakteristik visual yang lebih seragam dan berbeda jelas dari kelas penyakit. Nilai probabilitas terendah diperoleh pada kelas Nematode, sebesar 72,1%, konsisten dengan fakta bahwa Nematode adalah kelas dengan jumlah data pelatihan paling sedikit dan gejala visual yang kurang spesifik. Hasil uji coba ini mengkonfirmasi bahwa sistem mampu berfungsi sesuai dengan tujuan yang ditetapkan dalam tahap analisis kebutuhan.

Kesimpulan dan Saran

Kesimpulan

Berdasarkan hasil penelitian dan pembahasan yang telah dilakukan terhadap pengembangan model hybrid ResNet50-EfficientNetB0 dengan teknik feature fusion dan penerapan SMOTE untuk deteksi penyakit daun kentang, dapat ditarik kesimpulan sebagai berikut:

a. Model hybrid ResNet50-EfficientNetB0

Model hybrid ResNet50-EfficientNetB0 dengan teknik feature fusion berhasil dikembangkan dan terbukti mampu meningkatkan kemampuan deteksi penyakit daun kentang. Model hybrid ini bekerja dengan menggabungkan representasi fitur dari kedua backbone secara paralel melalui mekanisme concatenation, sehingga menghasilkan ruang fitur yang lebih kaya dan komprehensif. ResNet50 mengekstraksi fitur tekstur dan pola makro pada level semantik tinggi melalui arsitektur residual-nya, sementara EfficientNetB0 mengekstraksi fitur detail lokal yang efisien melalui MBConv blocks-nya.

Kombinasi keduanya pada Skenario S6, yaitu Hybrid + SMOTE yang menghasilkan performa terbaik dengan akurasi 83,93%, presisi 84,51%, F1-Score 83,93%, dan ROC-AUC 0,9774 dalam klasifikasi tujuh kategori penyakit daun kentang menggunakan Stratified 5-Fold Cross Validation. Capaian ini mengungguli arsitektur individual ResNet50, yaitu 83,52% maupun EfficientNetB0 dengan akurasi 82,29% pada kondisi yang setara, mengkonfirmasi bahwa pendekatan arsitektur hybrid memberikan nilai tambah nyata melalui komplementaritas representasi fitur yang digabungkan.

b. Penerapan metode SMOTE

Penerapan metode SMOTE terbukti efektif dalam memperbaiki ketidakseimbangan kelas pada dataset citra daun kentang dan memberikan dampak yang berbeda-beda terhadap performa masing-masing arsitektur model. SMOTE berhasil menyeimbangkan distribusi kelas dari rasio ketidakseimbangan sebesar 9,66:1 (kelas Fungi 425 citra vs. kelas Nematode 44 citra) menjadi distribusi yang merata dengan 340 sampel per kelas per fold pelatihan. Dampak terbesar didapatkan oleh EfficientNetB0 yang mengalami peningkatan akurasi sebesar 1,94 poin dari 80,35% menjadi 82,29%, mengindikasikan bahwa arsitektur yang lebih ringan dengan kapasitas representasional lebih terbatas lebih rentan terhadap ketidakseimbangan kelas dan lebih diuntungkan oleh oversampling sintesis.

Model Hybrid juga memperoleh peningkatan yang sebesar 0,82 poin dari 83,11% menjadi 83,93% saat dikombinasikan dengan SMOTE. Meskipun ResNet50 mengalami penurunan sebesar -0,35 poin persentase, hal ini mengindikasikan bahwa kapasitas ResNet50 sudah cukup untuk menangani ketidakseimbangan kelas secara lebih baik bahkan tanpa intervensi SMOTE. Secara keseluruhan, SMOTE terbukti menjadi komplement yang efektif bagi model hybrid dalam mencapai performa klasifikasi yang optimal.

Saran

Berdasarkan Berdasarkan temuan dan keterbatasan penelitian ini, beberapa saran diajukan untuk pengembangan dan penelitian lebih lanjut, antara lain:

a. Peningkatan teknik penyeimbang data

Eksplorasi teknik penyeimbangan data yang lebih canggih perlu dipertimbangkan sebagai alternatif atau pelengkap SMOTE. Teknik seperti ADASYN, Borderline-SMOTE, atau pendekatan berbasis GAN, Generative Adversarial Network untuk menghasilkan citra sintesis dalam ruang piksel dapat dieksplorasi lebih lanjut. Pendekatan berbasis GAN khususnya berpotensi menghasilkan sampel sintesis yang lebih realistis dan beragam secara visual dibandingkan interpolasi linear yang diterapkan SMOTE dalam ruang fitur.

b. Mekanisme Feature Fusion yang lebih adaptif

Pengembangan mekanisme feature fusion yang lebih adaptif disarankan untuk penelitian selanjutnya. Penelitian ini menggunakan pendekatan concatenation sederhana untuk menggabungkan fitur dari kedua backbone. Mekanisme fusion yang lebih canggih seperti attention-based fusion, weighted feature fusion, atau cross-attention mechanism dapat dieksplor untuk memungkinkan model secara adaptif menentukan bobot kontribusi masing-masing backbone berdasarkan karakteristik input citra, berpotensi menghasilkan representasi yang lebih diskriminatif dan akurasi klasifikasi yang lebih tinggi.

DAFTAR PUSTAKA

- Amanda Prawita Ningrum, Sri Winarno, & Vincentius Praskatama. (2024). Klasifikasi Kualitas Biji Kedelai Menggunakan Transfer Learning Convolutional Neural Network Dan SMOTE. *Journal of Applied Computer Science and Technology*, 5(2), 155–164. <https://doi.org/10.52158/jacost.v5i2.1002>
- Apriliansyah, R., Handayanto, A., & Saputro, N. D. (2025). Penerapan Arsitektur EfficientNetB0 pada Model Convolutional Neural Network untuk Deteksi Dini Mata Katarak Application of EfficientNetB0 on Convolutional Neural Network Model for Early Detection of Cataract. In *Journal of Computer Engineering, System and Science* (Vol. 10, Issue 2). <https://jurnal.unimed.ac.id/2012/index.php/cess>
- Audrey, M., Iskandar, H., Destinasi, C., Berkunjung, K., & Enam, P. (2024). Analisis Pengaruh Citra Destinasi terhadap Keputusan Berkunjung Pada Wisata Kuliner di Petak Enam Kata kunci. *Jurnal Ilmiah Ilmu Pendidikan*, 7, 7011–7016. <https://doi.org/https://doi.org/10.54371/jiip.v7i7.5347>
- Azmi, K., Defit, S., & Putra Indonesia YPTK Padang Jl Raya Lubuk Begalung-Padang-Sumatera Barat, U. (n.d.). *Implementasi Convolutional Neural Network (CNN) Untuk Klasifikasi Batik Tanah Liat Sumatera Barat*. 16(1), 2023.
- Bekele, B. (2025). Potato Late Blight (*Phytophthora infestans*) Disease Management and Yield Loss Assessment in East Gojjam, North Western Ethiopia. *Journal of Plant Sciences*, 13(2), 80–85. <https://doi.org/10.11648/j.jps.20251302.17>
- Chai, Y., Senay, S., Horvath, D., & Pardey, P. (2022). Multi-peril pathogen risks to global wheat production: A probabilistic loss and investment assessment. *Frontiers in Plant Science*, 13. <https://doi.org/10.3389/fpls.2022.1034600>
- Clara Sari, I., Krisdayani Manurung, M., Rekayasa Perangkat Lunak, T., & Wilmar Bisnis Indonesia, P. (2024). INTEGRASI MODEL DEEP LEARNING EFFICIENTNET-B0 UNTUK DETEKSI PENYAKIT DAUN TOMAT PADA APLIKASI SELULER BERBASIS FLUTTER. *Jurnal Teknologi Informasi*, 5(2). <https://doi.org/10.46576/djtechno>
- Dede Kurniadi, Asri Indah Pertiwi, & Asri Mulyani. (2025). Ensemble Voting Classifier Berbasis Multi-Algoritma dan Metode SMOTE untuk Klasifikasi Penyakit Jantung. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 14(2), 145–153. <https://doi.org/10.22146/jnteti.v14i2.17157>
- Desiana, P., Ayu, W., & Pradipta, G. A. (2024). SqueezeNet Feature Extraction dan Gradient Boosting untuk Klasifikasi Penyakit Monkeypox pada Citra Kulit. *JURNAL SISTEM DAN INFORMATIKA (JSI)*. <https://doi.org/https://doi.org/10.30864/jsi.v18i2.612>
- Devi Putri, A. A., Hasanah, S., Bahrul Subkhi, M., Suciati, N., Teknik Informatika, D., Teknologi Elektro dan Informatika Cerdas, F., Teknologi Sepuluh Nopember, I., Studi Sistem dan Teknologi Informasi, P., Keperawatan, F., & dan Teknologi, B. (n.d.). *Analisis Penggunaan Pra-proses pada Metode Transfer Learning untuk Mendeteksi Penyakit Daun Singkong Analysis of Pre-processing Use of Transfer Learning Methods for Cassava Leaves Diseases Detection* (Vol. 22, Issue 2).
- Fenu, G., & Mallocci, F. M. (2022). Evaluating Impacts between Laboratory and Field- Collected Datasets for Plant Disease Classification. *Agronomy*, 12(10). <https://doi.org/10.3390/agronomy12102359>
- Gajiwala, C. (2025). The Rise of Deep Learning and Neural Networks: Revolutionizing Artificial Intelligence. *European Journal of Computer Science and Information Technology*, 13(17), 88–98. <https://doi.org/10.37745/ejcsit.2013/vol13n178898>

- gifani, P., Shalhaf, A., & Vafaezadeh, M. (2021). Automated detection of COVID-19 using ensemble of transfer learning with deep convolutional neural network based on CT scans. *International Journal of Computer Assisted Radiology and Surgery*, 16(1), 115–123. <https://doi.org/10.1007/s11548-020-02286-w>
- Handoko Adji Pangestu, & Kusriani. (2024a). Peningkatan kinerja arsitektur ResNet50 untuk Menangani Masalah Overfitting dalam Klasifikasi Penyakit Kulit. *TEMATIK*, 11(1), 65–71. <https://doi.org/10.38204/tematik.v11i1.1876>
- Handoko Adji Pangestu, & Kusriani. (2024b). Peningkatan kinerja arsitektur ResNet50 untuk Menangani Masalah Overfitting dalam Klasifikasi Penyakit Kulit. *TEMATIK*, 11(1), 65–71. <https://doi.org/10.38204/tematik.v11i1.1876>
- Jannah, H. F. K., Karyanto, A., & Agustiansyah, A. (2024). PENGARUH UKURAN UMBI BIBIT DAN PACLOBUTRAZOL PADA PERTUMBUHAN DAN HASIL UMBI TANAMAN KENTANG (*Solanum tuberosum* L.). *Jurnal Agrotek Tropika*, 12(4), 984. <https://doi.org/10.23960/jat.v12i4.7616>
- Joloudari, J. H., Marefat, A., Nematollahi, M. A., Oyelere, S. S., & Hussain, S. (2023). Effective Class-Imbalance Learning Based on SMOTE and Convolutional Neural Networks. *Applied Sciences (Switzerland)*, 13(6). <https://doi.org/10.3390/app13064006>
- Kartini Parawansa, A., Tasrif, A., Studi Agroteknologi Fakultas Pertanian UMI Makassar, P., & Pembangunan Pertanian Bogor, P. (2024). Intensitas Serangan Penyakit Hawar Daun (*Phytophthora infestans*) pada Tanaman Kentang di. In *Kabupaten Gowa Jurnal AGrotekMAS* (Vol. 5, Issue 1). <https://jurnal.fp.umi.ac.id/index.php/agrotekmas>
- Kaya, Y., Akat, E., & Yıldırım, S. (2025). Fusion-Brain-Net: A Novel Deep Fusion Model for Brain Tumor Classification. *Brain and Behavior*, 15(5). <https://doi.org/10.1002/brb3.70520>
- Khadijah, Kusumaningrum, R., Rismiyati, & Sabilly, N. (2025). EfficientNet Model for Multiclass Classification of The Correctness of Wearing Face Mask. *Indonesian Journal of Electrical Engineering and Informatics*, 13(1), 18–29. <https://doi.org/10.52549/ijeei.v13i1.5197>
- Lasniari, S., Sanjaya, S., Yanto, F., & Affandes, M. (2022). Pengaruh Hyperparameter Convolutional Neural Network Arsitektur ResNet-50 Pada Klasifikasi Citra Daging Sapi dan Daging Babi. *Universitas Islam Negeri Sultan Syarif Kasim Riau Jl. H.R Soebrantas No. 155 KM, 5(3)*, 28293.
- Liyanta, M. S., Shata, M., Latifah, N., Bimantoro, F., & Informatika, T. (2024). *Klasifikasi Tumor Otak Menggunakan CNN Dengan Arsitektur Resnet50* (Vol. 3). <https://www.kaggle.com/datasets/thomasdubail/brain-tumors-256x256>
- Maulana, H. K. (2025). PENERAPAN ARSITEKTUR CNN-EFFICIENTNETB2 DENGAN TRANSFER LEARNING PADA KLASIFIKASI GAMBAR TOKOH WAYANG KULIT. *Jurnal Informatika Dan Teknik Elektro Terapan*, 13(1). <https://doi.org/10.23960/jitet.v13i1.5626>
- Maulana, I., Rahaningsih, N., & Suprpti, T. (2023). ANALISIS PENGGUNAAN MODEL YOLOV8 (YOU ONLY LOOK ONCE) TERHADAP DETEKSI CITRA SENJATA BERBAHAYA. In *Jurnal Mahasiswa Teknik Informatika* (Vol. 7, Issue 6).
- Miranda, N. D., Novamizanti, L., & Rizal, S. (2020). CONVOLUTIONAL NEURAL NETWORK PADA KLASIFIKASI SIDIK JARI MENGGUNAKAN RESNET-50. *Jurnal Teknik Informatika (Jutif)*, 1(2), 61–68. <https://doi.org/10.20884/1.jutif.2020.1.2.18>
- Natasya, & Girsang, A. S. (2023). Modified EDA and Backtranslation Augmentation in Deep Learning Models for Indonesian Aspect-Based Sentiment Analysis. *Emerging Science Journal*, 7(1), 256–272. <https://doi.org/10.28991/ESJ-2023-07-01-018>

- Naufal, M. F. (2021). ANALISIS PERBANDINGAN ALGORITMA SVM, KNN, DAN CNN UNTUK KLASIFIKASI CITRA CUACA. *Jurnal Teknologi Informasi Dan Ilmu Komputer (JTIK)*, 8, 311–318. <https://doi.org/10.25126/jtiik.202184553>
- Pamungkas, W. G., Wardhana, M. I. P., Sari, Z., & Azhar, Y. (2023). Leaf Image Identification: CNN with EfficientNet-B0 and ResNet-50 Used to Classified Corn Disease. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 7(2), 326–333. <https://doi.org/10.29207/resti.v7i2.4736>
- Prakash, U. M., Iniyana, S., Dutta, A. K., Alsubai, S., Naga Ramesh, J. V., Mohanty, S. N., & Dudekula, K. V. (2025). Multi-scale feature fusion of deep convolutional neural networks on cancerous tumor detection and classification using biomedical images. *Scientific Reports*, 15(1). <https://doi.org/10.1038/s41598-024-84949-1>
- Pratama Sembiring, E., Marina Herawati, M., & Kristen Satya Wacana, U. (n.d.). PENINGKATAN PRODUKSI TANAMAN KENTANG (*Solanum tuberosum* L.) DENGAN MENGGUNAKAN KOMPOS KIPAHIT (*Tithonia diversifolia*) DAN PUPUK KANDANG AYAM. *BIOEDUSAINS: Jurnal Pendidikan Biologi Dan Sains*, 7(2), 2598–7453. <https://doi.org/10.31539/bioedusains.v7i2.11157>
- Pujiati, R., & Rochmawati, N. (2022). Identifikasi Citra Daun Tanaman Herbal Menggunakan Metode Convolutional Neural Network (CNN). *Journal of Informatics and Computer Science*, 03. <https://doi.org/https://doi.org/10.26740/jinacs.v3n03.p351-357>
- Ridhovan, A., Suharso, A., Fakultas,), Komputer, I., Karawang, S., Ronggo Waluyo, J. H., Timur, T., & Karawang, K. (2022). *PENERAPAN METODE RESIDUAL NETWORK (RESNET) DALAM KLASIFIKASI PENYAKIT PADA DAUN GANDUM*.
- Rinawati. (2022). *ANALISIS KINERJA PERDAGANGAN KENTANG Pusat Data dan Sistem Informasi Pertanian Kementerian Pertanian 2022*. Pusat Data dan Sistem Informasi Pertanian Kementerian Pertanian.
- Santoso, I., Michaelangelo Manurung, A., & Subhiyakto, E. R. (2025a). Comparison of ResNet-50, EfficientNet-B1, and VGG-16 Algorithms for Cataract Eye Image Classification. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 9, Issue 2). <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Santoso, I., Michaelangelo Manurung, A., & Subhiyakto, E. R. (2025b). Comparison of ResNet-50, EfficientNet-B1, and VGG-16 Algorithms for Cataract Eye Image Classification. In *Journal of Applied Informatics and Computing (JAIC)* (Vol. 9, Issue 2). <http://jurnal.polibatam.ac.id/index.php/JAIC>
- Shabrina, N. H., Indarti, S., Maharani, R., Kristiyanti, D. A., Irmawati, Prastomo, N., & Adilah M, T. (2024). A novel dataset of potato leaf disease in uncontrolled environment. *Data in Brief*, 52, 109955. <https://doi.org/10.1016/J.DIB.2023.109955>
- Shahab, M. S., Junaidi, A., & Sihananto, A. N. (2024). KLASIFIKASI CITRA PLANKTON DENGAN ALGORITMA HIBRIDA CONVOLUTIONAL NEURAL NETWORK DAN EXTREME LEARNING MACHINE. *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(3S1). <https://doi.org/10.23960/jitet.v12i3s1.5219>
- Sriani, S., & Nabila, A. (2024). IMPLEMENTASI DEEP LEARNING UNTUK MENGIDENTIFIKASI UMUR MANUSIA MENGGUNAKAN CONVOLUTIONAL NEURAL NETWORK (CNN). *Jurnal Informatika Dan Teknik Elektro Terapan*, 12(3). <https://doi.org/10.23960/jitet.v12i3.4457>
- Sulistiyono, M., Pristyanto, Y., Adi, S., & Gumelar, G. (2021). SISTEMASI: Jurnal Sistem Informasi Implementasi Algoritma Synthetic Minority Over-Sampling Technique untuk Menangani Ketidakseimbangan Kelas pada Dataset Klasifikasi. *Jurnal Sistem Informasi*, 445–459. <https://doi.org/https://doi.org/10.32520/stmsi.v10i2.1303>

- Theckedath, D., & Sedamkar, R. R. (2020). Detecting Affect States Using VGG16, ResNet50 and SE-ResNet50 Networks. *SN Computer Science*, 1(2). <https://doi.org/10.1007/s42979-020-0114-9>
- Trihardianingsih, L., Sunyoto, A., & Hidayat, T. (2023). Classification of Tea Leaf Diseases Based on ResNet-50 and Inception V3. *Sinkron*, 8(3), 1564–1573. <https://doi.org/10.33395/sinkron.v8i3.12604>
- Wiliani, N., Khawa, T., & Ramli, S. (2025). Peningkatan Kontras Pada Preprocessing Gambar Permukaan Solar Panel dengan Histogram. *Innovation and Technology*, 2(1).
- Wulandari, I., Yasin, H., & Widiharih, T. (2020). *KLASIFIKASI CITRA DIGITAL BUMBU DAN REMPAH DENGAN ALGORITMA CONVOLUTIONAL NEURAL NETWORK (CNN)*. 9. <https://ejournal3.undip.ac.id/index.php/gaussian/>