

Komparasi CNN dan Pretrain ResNet50 pada Klasifikasi Penyakit Daun Kentang

Hilda Imelia Grasia^{1*}, Supatman²

¹²Informatika, Universitas Mercu Buana, Yogyakarta, Indonesia

Email Penulis Korespondensi: ¹221110114@student.mercubuana-yogya.ac.id

Abstrak– Penyakit daun kentang menjadi ancaman serius bagi produktivitas pertanian apabila tidak terdeteksi sejak dini. Penelitian ini membangun model *Convolutional Neural Network (CNN)* untuk mengklasifikasikan empat kondisi daun kentang, yaitu *Early Blight*, *Late Blight*, *Leafroll Virus*, dan *Healthy*, dan membandingkan performanya dengan ResNet50 berbasis *transfer learning*. Dataset bersumber dari gabungan *PlantVillage* (Kaggle), *Potato Viral Disease Dataset* (Mendeley Data), serta 423 citra hasil pengambilan mandiri di wilayah Banjarnegara menggunakan kamera *smartphone*, sehingga total dataset berjumlah 4.423 citra yang dibagi dengan rasio 70:15:15 untuk data latih, validasi, dan uji. Hasil pengujian pada data validasi menunjukkan bahwa CNN dan ResNet50 sama-sama mencapai akurasi 99,70%. Pada data uji yang sepenuhnya mandiri, CNN memperoleh akurasi 99,25% dengan *loss* 0,0214, sementara ResNet50 memperoleh akurasi 98,95% dengan *loss* 0,0326. Meskipun selisih akurasi relatif kecil (0,30%), CNN yang dibangun dari nol mampu mengungguli ResNet50 dari sisi *test accuracy* dan *test loss*. ResNet50 mencapai konvergensi lebih cepat (*epoch* ke-8) dibandingkan CNN (*epoch* ke-31), namun total waktu training CNN justru lebih singkat (36 menit) dibandingkan ResNet50 (39 menit) karena bobot ResNet50 yang jauh lebih besar memperlambat setiap *epoch*. Penelitian ini membuktikan bahwa CNN yang dirancang secara spesifik untuk domain penyakit daun kentang mampu memberikan performa yang sedikit lebih baik dibandingkan ResNet50.

Kata Kunci: CNN, ResNet50, *Transfer Learning*, Klasifikasi Penyakit Daun Kentang, *Deep Learning*.

Abstract– Potato leaf disease poses a serious threat to agricultural productivity if not detected early. This study builds a Convolutional Neural Network (CNN) model to classify four potato leaf conditions: Early Blight, Late Blight, Leafroll Virus, and Healthy, and compares its performance with ResNet50 based on transfer learning. The dataset was compiled from PlantVillage (Kaggle), the Potato Viral Disease Dataset (Mendeley Data), and 423 self-collected images from Banjarnegara captured using a smartphone camera, totaling 4,423 images split at a 70:15:15 ratio for training, validation, and testing. On the validation set, both CNN and ResNet50 achieved identical accuracy of 99.70%. On the unseen test set, CNN achieved 99.25% accuracy with a loss of 0.0214, while ResNet50 reached 98.95% accuracy with a loss of 0.0326. Although the accuracy gap is relatively small (0.30%), CNN built from scratch outperformed ResNet50 in both test accuracy and test loss. ResNet50 converged faster (epoch 8) than CNN (epoch 31), yet CNN's total training time was shorter (36 minutes) compared to ResNet50 (39 minutes) because ResNet50's larger weight volume slows each epoch considerably. This study demonstrates that a CNN specifically designed for the potato leaf disease domain can achieve slightly better overall performance than ResNet50 while also being more time-efficient in total training.

Keywords: Convolutional Neural Network, ResNet50, Transfer Learning, Potato Leaf Disease Classification, Deep Learning.

1. PENDAHULUAN

Kentang (*Solanum tuberosum L.*) merupakan salah satu komoditas hortikultura yang memiliki nilai ekonomi tinggi dan banyak dibudidayakan di berbagai daerah dataran tinggi Indonesia. Selain menjadi sumber pangan alternatif, kentang juga berkontribusi terhadap peningkatan pendapatan petani dan pengembangan sektor pertanian nasional. Namun, produktivitas tanaman kentang sering mengalami penurunan akibat serangan berbagai penyakit yang menyerang bagian daun tanaman. Kerusakan pada daun dapat menghambat proses fotosintesis sehingga berdampak langsung terhadap kualitas maupun kuantitas hasil panen yang diperoleh petani [1], [2].

Beberapa penyakit daun kentang yang umum ditemukan antara lain *Early Blight*, *Late Blight*, dan *Potato Leafroll Virus (PLRV)*. Penyakit *Early Blight* ditandai dengan munculnya bercak berwarna cokelat yang berkembang membentuk pola melingkar pada permukaan daun. Sementara itu, *Late Blight* merupakan penyakit yang disebabkan oleh *Phytophthora infestans* dan dikenal sebagai salah satu penyakit paling merusak pada tanaman kentang karena mampu menyebar dengan cepat pada kondisi lingkungan yang lembap. Adapun *Potato Leafroll Virus* menyebabkan daun menggulung, mengeras, dan mengalami perubahan warna sehingga mengganggu pertumbuhan tanaman secara keseluruhan [3], [4]. Ketiga penyakit tersebut memiliki gejala visual yang terkadang tampak serupa sehingga proses identifikasi secara manual sering kali membutuhkan pengalaman dan pengetahuan khusus dari petani maupun tenaga ahli pertanian.

Metode identifikasi penyakit yang masih mengandalkan pengamatan visual memiliki beberapa keterbatasan, seperti subjektivitas pengamat, perbedaan kondisi pencahayaan saat pengamatan, serta kemiripan gejala antar penyakit yang dapat menyebabkan kesalahan diagnosis. Selain itu, tidak semua petani memiliki akses terhadap tenaga ahli yang mampu melakukan identifikasi secara cepat dan akurat di lapangan. Oleh karena itu, diperlukan suatu sistem yang mampu membantu proses identifikasi penyakit daun kentang secara otomatis dengan tingkat akurasi yang tinggi [5], [6].

Perkembangan teknologi kecerdasan buatan, khususnya *Deep Learning*, telah membuka peluang baru dalam pengembangan sistem klasifikasi citra digital. Salah satu metode yang paling banyak digunakan adalah *Convolutional Neural Network (CNN)* karena memiliki kemampuan untuk mengekstraksi fitur visual secara otomatis tanpa memerlukan proses ekstraksi fitur manual. CNN bekerja secara hierarkis dengan mempelajari pola-pola visual mulai dari fitur sederhana seperti tepi dan tekstur hingga fitur yang lebih kompleks sehingga sangat baik digunakan pada berbagai permasalahan klasifikasi citra [7]. Berbagai penelitian menunjukkan bahwa CNN mampu menghasilkan performa yang sangat baik dalam mendeteksi dan mengklasifikasikan penyakit tanaman dari citra daun digital [8], [9].

Dalam implementasinya, terdapat dua pendekatan utama yang umum digunakan pada klasifikasi citra berbasis CNN. Pendekatan pertama adalah membangun model CNN secara mandiri (*from scratch*), di mana seluruh parameter model dipelajari langsung dari dataset yang digunakan. Pendekatan ini memberikan fleksibilitas tinggi dalam perancangan arsitektur, namun umumnya membutuhkan jumlah data yang cukup besar agar model dapat belajar secara maksimal. Pendekatan kedua adalah *transfer learning*, yaitu memanfaatkan model yang telah dilatih sebelumnya pada dataset berskala besar seperti *ImageNet* kemudian melakukan penyesuaian (*fine tuning*) untuk menyelesaikan tugas klasifikasi yang berbeda [10]. Salah satu model *transfer learning* yang banyak digunakan adalah ResNet50 yang diperkenalkan oleh He dkk. [11]. Arsitektur ini memanfaatkan konsep *residual learning* sehingga mampu mempertahankan performa meskipun memiliki jumlah lapisan yang cukup dalam. ResNet50 juga telah terbukti membawa hasil pada berbagai tugas klasifikasi citra dan menjadi salah satu model acuan dalam penelitian pengolahan citra modern.

Beberapa penelitian sebelumnya telah menerapkan metode *deep learning* untuk klasifikasi penyakit daun kentang. Lesmana dkk. [12] mengembangkan model CNN untuk mengidentifikasi penyakit daun kentang dan memperoleh tingkat akurasi yang baik pada dataset yang digunakan. Prasetyo dan Mahendra [13] menunjukkan bahwa konfigurasi arsitektur CNN memberikan pengaruh yang signifikan terhadap performa klasifikasi. Septian dan Suhendar [14] juga berhasil menerapkan CNN untuk mendeteksi penyakit daun kentang menggunakan citra digital dengan tingkat akurasi yang tinggi.

Pada pendekatan *transfer learning*, Santoso dkk. [15] memanfaatkan ResNet50 untuk klasifikasi penyakit daun kentang dan menunjukkan bahwa model *pre-trained* mampu mempercepat proses pelatihan sekaligus menghasilkan performa yang kompetitif. Penelitian lain oleh Gunawan dkk. [16] menggunakan MobileNetV2 berbasis *transfer learning* dan memperoleh hasil yang baik dengan waktu komputasi yang relatif lebih singkat. Sementara itu, Fauzi dan Nafi'iyah [17] melakukan evaluasi komparatif beberapa arsitektur CNN dan menemukan bahwa perbedaan struktur jaringan berpengaruh terhadap tingkat akurasi klasifikasi yang dihasilkan.

Meskipun berbagai penelitian terdahulu telah menunjukkan performa yang baik dalam klasifikasi penyakit daun kentang, sebagian besar penelitian masih menggunakan dataset publik yang diperoleh dalam kondisi pengambilan citra yang relatif terkontrol [12], [15], [16]. Kondisi tersebut belum sepenuhnya merepresentasikan lingkungan nyata yang dihadapi petani di lapangan. Variasi pencahayaan, sudut pengambilan gambar, kualitas kamera, serta latar belakang objek berpotensi memengaruhi kemampuan model dalam melakukan klasifikasi secara akurat.

Selain itu, penelitian yang secara khusus membandingkan performa CNN yang dibangun dari awal (*from scratch*) dengan model *transfer learning* ResNet50 menggunakan dataset gabungan antara dataset publik dan citra lapangan masih relatif terbatas. Sebagian besar penelitian hanya berfokus pada satu jenis arsitektur atau menggunakan data yang berasal dari satu sumber dataset saja sehingga kemampuan generalisasi model pada kondisi nyata belum banyak dibahas.

Penelitian ini menawarkan kontribusi dalam dua aspek utama. Pertama, dataset yang digunakan merupakan gabungan antara dataset publik dari Kaggle dan Mendeley Data dengan 423 citra daun kentang yang diperoleh melalui pengambilan gambar secara langsung di wilayah Banjarnegara menggunakan kamera *smartphone Oppo A3 Pro 5G*. Penggabungan dataset tersebut diharapkan dapat meningkatkan keragaman data sehingga lebih merepresentasikan kondisi lapangan yang sebenarnya. Kedua, penelitian ini melakukan perbandingan secara langsung antara model CNN yang dirancang secara mandiri dan model *pre-trained ResNet50* dengan skenario pelatihan, validasi, dan pengujian yang sama sehingga hasil yang diperoleh dapat dibandingkan secara lebih objektif.

Berdasarkan latar belakang dan kesenjangan penelitian tersebut, penelitian ini bertujuan untuk membandingkan performa model CNN dan *pre-trained ResNet50* dalam mengklasifikasikan empat kondisi daun kentang, yaitu *Early Blight*, *Late Blight*, *Potato Leafroll Virus*, dan *Healthy*. Evaluasi dilakukan menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* pada data validasi maupun data uji. Hasil penelitian diharapkan dapat memberikan gambaran mengenai efektivitas masing-masing pendekatan serta menjadi referensi dalam pengembangan sistem deteksi penyakit tanaman berbasis kecerdasan buatan yang dapat diterapkan pada kondisi lapangan nyata.

2. METODOLOGI PENELITIAN

2.1 Dataset dan Pengumpulan Data

Dataset yang digunakan dalam penelitian ini berasal dari kombinasi beberapa sumber data. Data utama diperoleh dari *PlantVillage Dataset* yang menyediakan citra daun kentang kategori *Early Blight*, *Late Blight*, dan *Healthy*. Kelas *Leafroll Virus* diperoleh dari *Potato Viral Disease Dataset* (Mendeley Data). Untuk meningkatkan keberagaman data dan mendekati kondisi penggunaan di lapangan, penelitian ini juga menambahkan citra yang dikumpulkan secara mandiri di

wilayah Kabupaten Banjarnegara menggunakan kamera *smartphone* Oppo A3 Pro 5G, sebanyak 423 gambar yang terdiri atas 206 citra *Early Blight*, 23 citra *Late Blight*, 59 citra *Leafroll Virus*, dan 135 citra *Healthy*.

Seluruh citra dikumpulkan ke dalam empat kelas dan jumlah citra maksimum pada setiap kelas dibatasi hingga 1.300 gambar untuk menjaga keseimbangan distribusi data. Seluruh citra diubah ke format RGB dan distandarisasi ke ukuran 224×224 piksel menggunakan pustaka *Pillow (PIL)*. Dataset kemudian dibagi dengan rasio 70:15:15 menggunakan nilai *seed* 42 untuk memastikan reproduktibilitas eksperimen.



Gambar 1. Contoh Citra Dataset: (a) Late Blight, (b) Early Blight, (c) Leafroll Virus, (d) Healthy

2. 2 Preprocessing dan Augmentasi Data

Untuk CNN, gambar dinormalisasi ke rentang [0, 1] menggunakan $\text{rescale}=1./255$. Untuk ResNet50, gambar diproses menggunakan fungsi `preprocess_input` sesuai standar ImageNet. Augmentasi data diterapkan pada training set dengan parameter yang disamakan antara kedua model sebagaimana ditunjukkan pada Tabel 1.

Tabel 1. Teknik Augmentasi Data pada Training Set

Teknik Augmentasi	Parameter CNN	Parameter ResNet50
Rotasi (rotation_range)	30 derajat	30 derajat
Zoom (zoom_range)	0.25	0.25
Horizontal Flip	Aktif	Aktif
Vertical Flip	Aktif	Aktif
Brightness Range	[0.7 – 1.3]	[0.7 – 1.3]
Shear Range	0.15	0.15
Width/Height Shift	0.1	0.1
Fill Mode	nearest	nearest

2. 3 Pembagian Dataset

Dataset gabungan kemudian dibagi menjadi tiga subset menggunakan rasio 70:15:15 untuk data latih, validasi, dan uji. Pembagian tiga arah ini dilakukan agar performa model dapat dievaluasi secara lebih ketat: data validasi digunakan selama proses pelatihan untuk memantau perkembangan model dan menentukan *epoch* terbaik, sementara data uji yang sepenuhnya independen digunakan untuk menilai kemampuan generalisasi model pada data yang belum pernah dilihat sama sekali. Hasil pembagian dataset disajikan pada Tabel 2.

Table 2. Hasil Pembagian Dataset

Subset	Jumlah Citra	Persentase
Data Latih (Train)	3.095	70%
Data Validasi (Val)	661	15%
Data Uji (Test)	667	15%
Total	4.423	100%

2. 4 Arsitektur CNN

Model CNN dibangun dengan pendekatan from-scratch menggunakan arsitektur Sequential. Model terdiri atas lima blok konvolusi bertingkat dengan lapisan Conv2D (kernel 3×3, aktivasi ReLU) dan BatchNormalization di setiap lapisan. Empat blok pertama menggunakan dua lapisan konvolusi secara berurutan (double convolution) dengan jumlah filter 32, 64, 128, 256, dan 512. Global Average Pooling (GAP) digunakan sebagai pengganti Flatten untuk mengurangi risiko

overfitting. Dua lapisan fully connected (512 dan 256 neuron) dengan Batch Normalization dan Dropout (0,5 dan 0,3) melengkapi arsitektur sebelum lapisan output Softmax empat kelas. Model dikompilasi dengan optimizer Adam (learning rate 0,001) dan fungsi loss categorical_crossentropy.

Tabel 3. Arsitektur CNN

Layer	Konfigurasi	Aktivasi & Regulasi	Output
Input	Citra RGB	Ukuran 224×224×3	224×224×3
Block 1	Conv2D (32) → BN → Conv2D (32) → BN → MaxPool	ReLU	112×112×32
Block 2	Conv2D (64) → BN → Conv2D (64) → BN → MaxPool	ReLU	56×56×64
Block 3	Conv2D (128) → BN → Conv2D (128) → BN → MaxPool	ReLU	28×28×128
Block 4	Conv2D (256) → BN → Conv2D (256) → BN → MaxPool	ReLU	14×14×256
Block 5	Conv2D (512) → BN → MaxPool	ReLU	7×7×512
GAP	GlobalAveragePooling2D	-	512
FC 1	Dense (512 neuron)	ReLU + BN + Dropout(0.5)	512
FC 2	Dense (256 neuron)	ReLU + BN + Dropout(0.3)	256
Output	Dense (4 neuron)	Softmax	4 kelas

2. 5 Arsitektur ResNet50 sebagai Model Pembanding

Model pembanding menggunakan ResNet50 dengan bobot pretrained dari *ImageNet*. Pada tahap *fine-tuning*, 30 lapisan terakhir diizinkan untuk diperbarui sedangkan lapisan lainnya dibekukan. Bagian klasifikasi bawaan ResNet50 diganti dengan *Global Average Pooling*, lapisan *Dense 128 neuron (ReLU)*, *Dropout 0,5*, dan lapisan *Softmax* empat kelas. Model dikompilasi dengan *optimizer Adam (learning rate 0,0001)*.

2. 6 Strategi Pelatihan dan Callback

Table 4. Strategi Pelatihan

Parameter	CNN	ResNet50
Optimizer	Adam	Adam
Learning Rate	0.001	0.0001
Batch Size	16	16
Max Epoch	50	50
Early Stopping	7	7
ReduceLROnPlateau (patience)	3	3
Min LR	1e-7	1e-7

Kedua model menggunakan konfigurasi *callback* yang sepenuhnya disamakan: *Early Stopping* dengan *patience 7*, *ReduceLROnPlateau* dengan *patience 3* dan *min_lr 1e-7*, serta *ModelCheckpoint* untuk menyimpan model terbaik berdasarkan *val_accuracy*.

Perbedaan yang disengaja hanya terdapat pada *learning rate*. CNN menggunakan learning rate 0,001 karena dibangun dari nol sehingga memerlukan langkah pembaruan yang lebih besar agar konvergensi berlangsung dalam waktu yang wajar. Sebaliknya, ResNet50 menggunakan learning rate 0,0001 karena bobotnya sudah terlatih dari *ImageNet*, sebab penggunaan *learning rate* terlalu besar akan merusak representasi fitur yang sudah terbentuk, kondisi yang dikenal sebagai *catastrophic forgetting*.


2. 7 Metrik Evaluasi

Kinerja model dievaluasi menggunakan akurasi, *precision*, *recall*, dan *F1-Score* yang diturunkan dari *confusion matrix*. Evaluasi dilakukan pada dua tahap: data validasi untuk memantau pelatihan dan menentukan *epoch* terbaik, serta data uji independen untuk menilai kemampuan generalisasi model.

3. HASIL DAN PEMBAHASAN

3.1 Hasil Pelatihan CNN

Model CNN dilatih menggunakan 3.095 citra data *training* dengan maksimum 50 *epoch*. Hasil pelatihan menunjukkan bahwa model mencapai performa optimal pada *epoch* ke-31 dengan nilai *train accuracy* sebesar 98,16% dan *validation accuracy* sebesar 99,70%. Nilai *train loss* dan *validation loss* masing-masing sebesar 0,0561 dan 0,0232.



Gambar 2. Grafik Accuracy dan Loss per Epoch CNN


Table 5. Hasil Training CNN

Parameter	Nilai
Best Epoch	31
Train Accuracy	98,16%
Validation Accuracy	99,70%
Train Loss	0,0561
Validation Loss	0,0232
Waktu Training	36 menit

Nilai *validation accuracy* yang lebih tinggi dari *train accuracy* mengindikasikan bahwa model tidak mengalami *overfitting*. Augmentasi yang agresif pada data *training* menyebabkan data *training* lebih sulit dipelajari, sehingga *validation accuracy* tampak lebih tinggi, karena kondisi ini lazim terjadi ketika augmentasi diterapkan hanya pada *training set*.

3.2 Hasil Pelatihan Pre-trained ResNet50

Model ResNet50 dengan pendekatan *transfer learning* mencapai performa terbaik pada *epoch* ke-8 dengan *train accuracy* 99,10% dan *validation accuracy* 98,70%. Nilai *train loss* dan *validation loss* masing-masing sebesar 0,0267 dan 0,0204.



Gambar 3. Grafik Accuracy dan Loss per Epoch – ResNet50

Table 6. Hasil Pre-trained ResNet50

Parameter	Nilai
Best Epoch	8
Train Accuracy	99,10%
Validation Accuracy	98,70%
Train Loss	0,0269
Validation Loss	0,204

Parameter	Nilai
Waktu Training	39 menit

ResNet50 mencapai konvergensi jauh lebih cepat dari sisi jumlah *epoch* berkat bobot *pretrained ImageNet*. Menariknya, meskipun *epoch* jauh lebih sedikit, total waktu *training* ResNet50 (39 menit) justru lebih lama dibandingkan CNN (36 menit). Hal ini disebabkan oleh bobot ResNet50 yang jauh lebih besar, yaitu 30 lapisan akhir yang di-*unfreeze* memerlukan komputasi lebih berat per *epoch*.


3.3 Evaluasi Pada Data Validasi

Table 7. Evaluasi Pada Data Validasi

Parameter	Accuracy	Loss
CNN	99,70%	0,0232
ResNet50	99,70%	0,0204

Kedua model mencapai *validation accuracy* yang identik sebesar 99,70%. ResNet50 memiliki *validation loss* yang sedikit lebih rendah (0,0204 vs 0,0232), mengindikasikan prediksi yang sedikit lebih tajam pada data validasi. Namun, keunggulan ini tidak bertahan pada data uji mandiri sebagaimana ditunjukkan pada bagian berikutnya.

3.4 Confusion Matrix dan Classification Report CNN pada Data Validasi




Gambar 4. Confusion Matrix CNN

Table 8. Classification Report CNN

Kelas	Precision	Recall	F1-Score	Support
Early blight	1,0000	0,9889	0,9944	180
Healthy	0,9827	1,0000	0,9913	170
Late blight	1,0000	1,0000	1,0000	153
Leafroll virus	1,0000	0,9937	0,9968	158
Accuracy	—	—	0,9955	661
Macro avg	0,9957	0,9957	0,9956	661
Weighted avg	0,9955	0,9955	0,9955	661

Pada data validasi, CNN mencapai akurasi 99,70% dengan *F1-score* 1,0000 pada kelas *Late Blight*. Kesalahan hanya terjadi pada *Early Blight* (2 citra salah prediksi ke *Healthy*) dan *Leafroll Virus* (1 citra). Kelas *Late Blight* dan *Healthy* mencapai *recall* 1,0000.

3.5 Confusion Matrix dan Classification Report ResNet50 pada Data Validasi



Gambar 5. Confusion Matrix ResNet50

Table 9. Classification Report ResNet50

Kelas	Precision	Recall	F1-Score	Support
Early blight	1,0000	0,9889	0,9944	180
Healthy	1,0000	0,9941	0,9971	170
Late blight	0,9808	1,0000	0,9903	153
Leafroll virus	1,0000	1,0000	1,0000	158
Accuracy	—	—	0,9955	661
Macro avg	0,9952	0,9958	0,9954	661
Weighted avg	0,9955	0,9955	0,9955	661

ResNet50 pada data validasi juga mencapai akurasi 99,70% dengan keunggulan pada kelas *Leafroll Virus* yang memperoleh *F1-score* 1,0000. Kesalahan terjadi pada kelas *Early Blight* (2 citra) dan *Healthy* (1 citra diprediksi sebagai *Late Blight*).


3.6 Evaluasi Model Pada Data Testing

Table 10. Hasil Evaluasi Data Testing

Parameter	Accuracy	Loss
CNN	99,25%	0,0214
ResNet50	98,95%	0,0326

Pada data uji yang sepenuhnya independen, CNN mempertahankan performa tinggi dengan akurasi 99,25% dan *loss* 0,0214. ResNet50 mencapai akurasi 98,95% dengan *loss* 0,0326. Selisih akurasi sebesar 0,30% dan selisih *loss* yang cukup signifikan (0,0112) menunjukkan bahwa CNN memiliki kemampuan generalisasi yang lebih baik pada data baru.

3.7 Classification Report CNN pada Data Testing



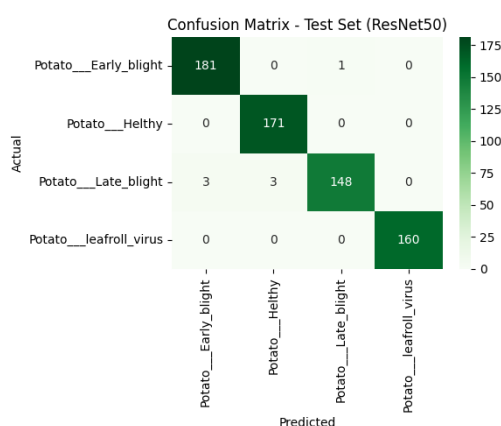
Gambar 6. Visualisasi Confusion Matrix CNN Pada Data Testing

Table 11. Classification Report CNN Pada Data Testing

Kelas	Precision	Recall	F1-Score	Support
Early blight	0,9838	1,0000	0,9918	182
Healthy	0,9942	0,9942	0,9942	171
Late blight	1,0000	0,9805	0,9902	154
Leafroll virus	0,9938	0,9938	0,9938	160
Accuracy	—	—	0,9925	667
Macro avg	0,9929	0,9921	0,9925	667
Weighted avg	0,9926	0,9925	0,9925	667

CNN pada data *testing* menunjukkan performa yang sangat seimbang di seluruh kelas. *Confusion matrix* menunjukkan hanya 5 kesalahan dari 667 citra: kelas *Healthy* 1 citra salah, *Late Blight* 3 citra salah prediksi ke *Early Blight*, dan *Leafroll Virus* 1 citra salah. Kelas *Early Blight* berhasil memperoleh recall 1,0000.

3. 8 Classification Report ResNet50 pada Data Testing



Gambar 7. Confusion Matrix ResNet50

Table 12. Confusion Matrix ResNet50

Kelas	Precision	Recall	F1-Score	Support
Early blight	0,9837	0,9945	0,9891	182
Healthy	0,9828	1,0000	0,9913	171

Kelas	Precision	Recall	F1-Score	Support
Late blight	0,9933	0,9610	0,9769	154
Leafroll virus	1,0000	1,0000	1,0000	160
Accuracy	—	—	0,9895	667
Macro avg	0,9899	0,9889	0,9893	667
Weighted avg	0,9896	0,9895	0,9895	667

ResNet50 mencatat keunggulan signifikan pada kelas *Leafroll Virus* dengan *F1-score* 1,0000 dan kelas *Healthy* dengan recall 1,0000. Namun, kelas *Late Blight* menunjukkan *F1-score* terendah (0,9769) dengan 6 citra salah diprediksi ke kelas lain, jumlah yang lebih banyak dibandingkan CNN. *Confusion matrix* menunjukkan 7 kesalahan total dari 667 citra.

3. 9 Perbandingan Menyeluruh CNN dan ResNet50

Table 13. Perbandingan CNN dan ResNet50

Aspek	CNN	ResNet50	Unggul
Val Accuracy	99,70%	99,70%	—
Val Loss	0,0232	0,0204	ResNet50 (sedikit)
Test Accuracy	99,25%	98,95%	CNN (+0,30%)
Test Loss	0,0214	0,0326	CNN
Best Epoch	31	8	ResNet50 (4× lebih sedikit)
Waktu Training	36 menit	39 menit	CNN (3 mnt lebih cepat)
Kesalahan Test	5 citra	7 citra	CNN
F1 Late Blight (test)	0,9902	0,9769	CNN
F1 Leafroll (test)	0,9938	1,0000	ResNet50
Arsitektur	From scratch	Pretrained ImageNet	—

Perbandingan menyeluruh menunjukkan bahwa CNN mengungguli ResNet50 pada mayoritas metrik kunci: *test accuracy*, *test loss*, waktu *training* total, dan jumlah kesalahan klasifikasi. Hasil yang paling menarik adalah meskipun ResNet50 mencapai konvergensi dalam 8 epoch (dibandingkan 31 *epoch* CNN), total waktu *training* ResNet50 justru lebih lama (39 vs 36 menit). Hal ini disebabkan oleh bobot ResNet50 yang jauh lebih besar, di mana 30 lapisan akhir yang di-*unfreeze* memerlukan komputasi jauh lebih berat per *epoch*, sehingga keunggulan "cepat konvergen" tidak secara otomatis berarti hemat waktu secara keseluruhan.

ResNet50 tetap unggul pada kelas *Leafroll Virus* dengan *F1-score* 1,0000, menunjukkan bahwa representasi fitur *pretrained ImageNet* manjur untuk mengenali pola visual yang khas pada kelas tersebut. CNN sebaliknya lebih unggul pada kelas *Late Blight* yang memiliki gejala visual mirip *Early Blight*, mengindikasikan bahwa arsitektur dan augmentasi yang lebih spesifik membantu membedakan kedua kelas tersebut.

Dari perspektif generalisasi, selisih antara *val accuracy* dan *test accuracy* CNN (0,45 poin persentase) lebih kecil dibandingkan ResNet50 (0,75 poin persentase), mengindikasikan bahwa CNN memiliki konsistensi yang lebih baik antara performa validasi dan pengujian.

4. KESIMPULAN

Penelitian ini berhasil membangun dan membandingkan CNN dengan ResNet50 untuk klasifikasi empat kelas penyakit daun kentang menggunakan dataset gabungan dari *PlantVillage*, *Potato Viral Disease Dataset*, dan citra hasil pengambilan mandiri di wilayah Banjarnegara. Pada data validasi, kedua model mencapai akurasi yang identik sebesar 99,70%. Namun pada data uji yang sepenuhnya mandiri, CNN mengungguli ResNet50 dengan akurasi 99,25% (loss 0,0214) dibandingkan ResNet50 yang mencapai 98,95% (loss 0,0326).

Hasil yang paling menarik dari penelitian ini adalah kejanggalan ketepatan waktu: meskipun ResNet50 mencapai konvergensi hanya dalam 8 *epoch* (jauh lebih sedikit dari CNN yang memerlukan 31 *epoch*), total waktu *training* ResNet50 justru lebih lama (39 menit) dibandingkan CNN (36 menit). Hal ini membuktikan bahwa jumlah *epoch* bukan satu-satunya penentu ketepatan, sebab bobot model yang lebih besar meningkatkan beban komputasi per *epoch* secara signifikan.

CNN menunjukkan keunggulan pada sebagian besar kelas, khususnya *Late Blight*, sementara ResNet50 unggul pada kelas *Leafroll Virus* dengan *F1-score* 1,0000. Pola kesalahan pada kedua model menunjukkan bahwa *Early Blight* dan *Late Blight* masih menjadi pasangan kelas yang paling sering tertukar akibat kemiripan visual bercak pada kedua penyakit tersebut.

Untuk pengembangan ke depan, penambahan jumlah citra lapangan, khususnya kelas *Late Blight* yang jumlahnya masih terbatas, dapat meningkatkan keseimbangan dan keragaman dataset. Eksplorasi teknik augmentasi yang lebih canggih serta arsitektur CNN yang lebih ringan untuk implementasi pada perangkat *mobile* juga merupakan arah penelitian yang cocok.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada seluruh pihak yang telah mendukung penelitian ini, baik berupa fasilitas komputasi, bimbingan ilmiah, maupun masukan konstruktif. Apresiasi juga disampaikan kepada penyedia dataset *PlantVillage* melalui platform Kaggle serta tim *peneliti Potato Viral Disease Dataset* pada Mendeley Data yang telah membuka akses data secara terbuka demi kemajuan penelitian pertanian presisi berbasis *deep learning*.

REFERENCES

- [1] Badan Pusat Statistik, "Statistik Hortikultura 2023," Badan Pusat Statistik.
- [2] Badan Pusat Statistik, "Statistik Hortikultura 2024," Badan Pusat Statistik.
- [3] J. Park et al., "Isolation and Identification of *Alternaria alternata* from Potato Plants Affected by Leaf Spot Disease in Korea: Selection of Effective Fungicides," *J. Fungi*, vol. 10, no. 1, 2024, doi: 10.3390/jof10010053.
- [4] M. McGrath, "Virus and Viroid Diseases of Potato," *Cornell Vegetables*. [Online]. Available: <https://www.vegetables.cornell.edu/pest-management/disease-factsheets/virus-and-viroid-diseases-of-potato/>
- [5] S. P. Mohanty, D. P. Hughes, and M. Salathé, "Using deep learning for image-based plant disease detection," *Front. Plant Sci.*, vol. 7, no. September, pp. 1–10, 2016, doi: 10.3389/fpls.2016.01419.
- [6] M. Nawaz, A. Javed, and A. K. J. Saudagar, "PotatoGuardNet: a refined deep learning framework for potato leaf disease detection," *Front. Plant Sci.*, vol. 17, no. January, pp. 1–18, 2026, doi: 10.3389/fpls.2026.1720276.
- [7] M. H. Reza et al., "A comprehensive review of convolutional neural networks: foundations, enhancements and applications," *Neural Comput. Appl.*, vol. 38, no. 4, 2026, doi: 10.1007/s00521-025-11827-w.
- [8] S. Sladojevic, M. Arsenovic, A. Anderla, D. Culibrk, and D. Stefanovic, "Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification," *Comput. Intell. Neurosci.*, vol. 2016, p. 3289801, 2016, doi: 10.1155/2016/3289801.
- [9] M. Jung et al., "Construction of deep learning-based disease detection model in plants," *Sci. Rep.*, vol. 13, no. 1, pp. 1–13, 2023, doi: 10.1038/s41598-023-34549-2.
- [10] Y. A. Wijaya, P. Studi, T. Informatika, S. I. Cirebon, and J. Barat, "OPTIMALISASI CONVOLUTIONAL NEURAL NETWORK KONTRA VGG16 KLASIFIKASI CITRA DAUN SAWI Rio Febriyan *, Ade Irma Purnamasari, Denni Pratama, Puji Pramudya Marta," vol. 6, no. 1, pp. 30–34, 2026.
- [11] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.
- [12] A. M. Lesmana, R. P. Fadhillah, and C. Rozikin, "Identifikasi Penyakit pada Citra Daun Kentang Menggunakan Convolutional Neural Network (CNN)," *J. Sains dan Inform.*, vol. 8, no. 1, pp. 21–30, Jun. 2022, doi: 10.34128/jsi.v8i1.377.
- [13] K. Prasetyo and R. Mahendra, "Analisis Kinerja Convolutional Neural Networks Baseline untuk Identifikasi Jenis Penyakit Kentang," *MALCOM Indones. J. Mach. Learn. Comput. Sci.*, vol. 5, no. 2, pp. 609–615, Mar. 2025, doi: 10.57152/malcom.v5i2.1722.
- [14] A. Dicky Septian and A. Suhendar, "IMPLEMENTASI ALGORITMA CONVOLUTIONAL NEURAL NETWORK UNTUK DETEKSI PENYAKIT DAUN KENTANG MENGGUNAKAN CITRA DIGITAL," *J. Inform. Teknol. dan Sains*, 2024.
- [15] C. Budy Santoso, R. I. A. Effendi, and J. H. Siregar, "Deep Learning-Based Detection of Potato Leaf Diseases Using ResNet-50 with Mobile Application Deployment," *J. Tek. Inform.*, vol. 7, no. 1, pp. 647–661, Feb. 2026, doi: 10.52436/1.jutif.2026.7.1.5186.
- [16] R. Gunawan, F. Salim, A. I. Wahyudhy, A. Y. Wibowo, G. Yordan, and R. F. Filamori, "Klasifikasi Penyakit Daun Kentang dengan Transfer Learning Menggunakan CNN optimalisasi Arsitektur MobileNetV2," *J. CoSciTech (Computer Sci. Inf. Technol.)*, vol. 6, no. 2, pp. 254–258, Sep. 2025, doi: 10.37859/coscitech.v6i2.8599.
- [17] J. Alfia Afifah Fauzi and N. Nafi'iyah, "Evaluasi Komparatif Arsitektur Convolutional Neural Network pada Klasifikasi Penyakit Daun Kentang," *J. Algoritma*, vol. 23, no. 1, May 2026, doi: 10.33364/algoritma/v.23-1.3273.