

Klasifikasi Penyakit Daun Tomat Menggunakan Convolutional Neural Network (CNN) Berbasis EfficientNetB0

Garet Alfirmansyah¹, Rizal Ronaldo²

^{1,2} Program Studi Teknologi Informasi, Fakultas Kesehatan dan Teknologi, Universitas Muhammadiyah Klaten, Klaten

Email: ¹garetalfirmansah@gmail.com , ²rizaladhie85@gmail.com.

ABSTRACT — This research is designed to develop a disease classification system on tomato leaves using the *Deep Learning* method with a *Convolutional Neural Network* (CNN) architecture based on the *EfficientNetB0* model architecture with a *Transfer Learning* approach. The dataset used for the research was taken from Kaggle (ashishmotwani/tomato) and consists of more than 20,000 images of tomato leaves divided into 11 classes, namely 10 classes of diseased leaves and 1 class of healthy leaves. The research was conducted using the *Google Colab* platform with a T4 GPU. The research stages include dataset preprocessing, dataset augmentation, train-validation-test data sharing, building an *EfficientNetB0*-based CNN model, model training with a fine-tuning mechanism, and performance evaluation using a *confusion matrix*, *precision*, *recall*, and *F1-score*. The configuration uses an input size of 224×224 pixels, a *batch size* of 32, an initial *learning rate* of 0.001 and a maximum of 50 *epochs*. The results show that the best *training accuracy* of all 50 *epochs* was 99.63% and the best *validation accuracy* was 87.27%, achieved in the 49th *epoch*. The best model was *restored* from the 49th *epoch* based on the highest *val accuracy* value. The classes *Powdery Mildew*, *Target Spot*, and *Tomato Yellow Leaf Curl Virus* obtained the highest *recall* values. The implementation of *EfficientNetB0* has proven effective in classifying tomato leaf diseases, making it suitable for application in mobile and web-based smart agriculture systems.

KEYWORDS — CNN, *Deep Learning*, *Image Classification*, *EfficientNetB0*, *Tomato Leaf Disease*, *Transfer Learning*

INTISARI — Penelitian ini dirancang untuk mengembangkan sistem klasifikasi penyakit pada daun tomat menggunakan metode *Deep Learning* dengan arsitektur *Convolutional Neural Network* (CNN) berbasis arsitektur model *EfficientNetB0* dengan pendekatan *Transfer Learning*. Dataset yang digunakan untuk penelitian diambil dari Kaggle (ashishmotwani/tomat) dan terdiri dari lebih 20.000 gambar daun tomat yang terbagi menjadi 11 kelas yaitu 10 kelas daun sakit dan 1 kelas daun sehat. Penelitian dilakukan menggunakan platform *Google Colab* dengan GPU T4. Tahapan penelitian meliputi preprocessing dataset, augmentasi dataset, pembagian data train-validation-test, pembangunan model CNN berbasis *EfficientNetB0*, pelatihan model dengan mekanisme *fine-tuning*, serta evaluasi performa menggunakan *confusion matrix*, *precision*, *recall*, dan *F1-score*. Konfigurasi menggunakan input size 224×224 pixel, *batch size* 32, *learning rate* awal 0,001 dan maksimal 50 *epoch*. Hasil menunjukkan bahwa seluruh penyelesaian 50 *epoch* dengan *training accuracy* terbaik adalah 99,63% dan *validation accuracy* terbaik adalah 87,27% yang dicapai pada *epoch* ke-49. Model terbaik di-*restore* dari *epoch* ke-49 berdasarkan nilai *val accuracy* tertinggi. Kelas *Powdery Mildew*, *Target Spot*, dan *Tomato Yellow Leaf Curl Virus* memperoleh nilai *recall* tertinggi. Implementasi *EfficientNetB0* terbukti efektif dalam melakukan klasifikasi penyakit daun tomat sehingga dapat untuk diterapkan pada sistem pertanian cerdas berbasis mobile maupun web.

KATA KUNCI — CNN, *Deep Learning*, Klasifikasi Citra, *EfficientNetB0*, Penyakit daun bawang, *Transfer Learning*

I. PENDAHULUAN

Tomat (*Solanum lycopersicum L.*) adalah sayuran dari Amerika Selatan yang dikenal akan dagingnya yang berlimpah, daun majemuk dan akan berhenti berkembang akibat pertumbuhan bunga atau kuncup pada ujung batang atau yang dikenal dengan sebutan *simpodial*[1]. Industri pengolahan tomat telah mengembangkan berbagai produk makanan berbahan dasar tomat, seperti saus, saus tomat, puree, dan jus. Tomat menjadi bahan makanan pokok di banyak negara karena warna, rasa, dan kandungan gizinya yang luar biasa[2]. Dalam pengaruhnya dalam dunia kesehatan seperti penurunan risiko penyakit kronis termasuk kanker, menjaga kesehatan jantung, menurunkan tekanan darah, mencegah kanker serta menawarkan beberapa manfaat kesehatan lainnya[3].

Tomat (*Solanum lycopersicum L.*) merupakan salah satu jenis sayuran yang sangat dihargai, tetapi karena variasi

genetiknya dan faktor lingkungan, tomat menjadi rentan terhadap berbagai penyakit seperti penyakit keriting daun tomat, virus nekrosis tunas kacang tanah, layu bakteri, dan hawar adalah ancaman besar yang mengurangi produktifitas. Mereka menjadi terpapar patogen karena menanam tomat di berbagai iklim dan kondisi yang berbeda beda, sementara kurangnya gen resistensi bawaan membuat mereka menjadi rentan terhadap penyakit. Meskipun metode pemuliaan konvensional telah digunakan untuk menciptakan varietas yang tahan penyakit, pemuliaan ketahanan telah ditingkatkan melalui integrasi genomika dan seleksi berbantuan penanda. Ini memungkinkan introgresi gen ketahanan dari spesies liar ke dalam tomat budidaya, meningkatkan ketahanan tanaman terhadap penyakit[4].

Perkembangan *Artificial Intelligence* (AI) telah memberikan dampak pada berbagai bidang termasuk bidang

pertanian yang melibatkan integrasi teknologi canggih untuk meningkatkan praktik pertanian dan mengatasi tantangan yang akan datang. Ini mencakup aplikasi pembelajaran mesin (*machine learning*), metodologi akuisisi data dan sistem pendukung keputusannya yang secara kolektif meningkatkan presisi pertanian, meningkatkan efisiensi dan produktivitas sekaligus mengatasi masalah praktik pertanian dan ketahanan pangan di seluruh dunia[5]. Satu hal yang sudah berkembang pesat adalah komputer vision karena dapat mengidentifikasi penyakit pada tanaman secara otomatis. Hal ini mampu membantu para petani mengidentifikasi penyakit pada tanaman secara cepat dan akurat agar hasil panen menjadi bahan yang lebih baik dan mengalami kerugian yang lebih sedikit.

Salah satu metode *deep learning* adalah *Convolution Neural Network* (CNN) yang dimaksudkan untuk digunakan dalam pengolahan data berbentuk citra. CNN bekerja menggunakan konvolusi lapisan yang dapat membantu memungkinkan mereka untuk mengekstrak fitur penting dari gambar seperti tepi, tekstur, dan pola dan dalam hal klasifikasi gambar, deteksi objek dan pengenalan wajah teknik ini telah banyak digunakan. Dalam penelitian ini kami memilih model *EfficientNetB0* karena dapat mengalahkan model transfer learning lainnya dengan akurasi 0,91 berkat pendekatan *fine-tuning* berbasis rekomendasi cerdas yang meningkatkan kinerja metrik seperti *recall*, *validation*, dan *F1-score*, yang dapat membantu diagnosis dini pada data[6], dan juga memiliki arsitektur yang memanfaatkan penskalaan gabungan untuk meningkatkan kinerja sekaligus mempertahankan efisiensi komputasi[7].

Studi ini kami buat dengan tujuan untuk membangun model klasifikasi penyakit daun tomat berbasis *EfficientNetB0* dengan dataset Kaggle untuk membedakan berbagai jenis penyakit yang menyerang pada daun tomat. Diharapkan bahwa sistem yang dikembangkan akan dapat mengidentifikasi jenis penyakit dengan tingkat akurasi yang tinggi agar dapat membantu proses pengawasan kesehatan tanaman secara otomatis.

II. TEORI DAN METODE

1. Convolution Neural Network (CNN)

Convolution Neural Network (CNN) adalah salah satu pendekatan *deep learning* yang sangat efektif untuk mengelola gambar digital dan arsitektur jaringan *multi-layer* untuk *training*. CNN juga sangat akurat dalam tugas-tugas seperti pengenalan gambar spasial. Aliran data dan output jaringan ini dipengaruhi oleh lapisan *convolutional*, *pooling*, *activation*, dan seluruhnya terhubung[8]. *Convolution Neural Network* (CNN) sendiri menerapkan filter pada gambar masukan dengan menggesernya melintasi bagian tertentu untuk menghasilkan peta aktivasi. Jaringan ini terdiri dari lapisan-lapisan yang menggunakan *backpropagation* untuk mempelajari fitur melalui *convolution*. Ini mengubah bobot dan bias untuk menghasilkan output yang akurat[9].

2. EfficientNetB0

Convol Model EfficientNetB0 menggunakan metode penskalaan gabungan untuk mengoptimalkan kedalaman, lebar, dan resolusi agar akurasi dan efisiensi komputasi tetap seimbang. Dengan menggunakan arsitektur neural yang meningkatkan kinerja sekaligus mengurangi jumlah sumber daya yang dibutuhkan sehingga cocok untuk lingkungan yang memiliki sumber daya terbatas[10]. Model ini bekerja dengan

arsitektur pembelajaran mendalam, yang memproses kumpulan data yang sangat besar dan menggunakan metode penskalaan gabungan untuk mengoptimalkan ukuran dan akurasi model[11]. Dalam hal keunggulan, model *EfficientNetB0* memiliki arsitektur yang ringan, parameter yang relatif kecil hingga efisien dalam komputasi. Hal ini memungkinkan akurasi yang tinggi (97,54%) dalam tugas klasifikasi sekaligus cocok untuk lingkungan dengan keterbatasan sumber daya[12]. Lalu kelebihan dalam *EfficientNetB0* yang lain adalah ideal untuk *mobile* atau *edge*, dan modelnya yang fleksibel untuk *Transfer Learning*.

3. Dataset

Dataset yang digunakan berasal dari Kaggle dengan nama dataset “Tomato Dataset”. Dataset terdiri dari 20.000 lebih gambar daun tomat dan terbagi menjadi 11 kelas, yaitu :

1. Bacterial Spot
2. Early Blight
3. Late Blight
4. Leaf Mold
5. Septoria Leaf Spot
6. Spider Mites
7. Target Spot
8. Tomato Yellow Leaf Curl Virus
9. Tomato Mosaic Virus
10. Healthy
11. Powder Mildew

Kemudian dataset dibagi data training 80% (25.852), validation 20% (6.683), dan testing (5.165). Jumlah data pada tiap kelas dapat dilihat pada Tabel I berikut.

TABEL I
JUMLAH GAMBAR SETIAP KELAS

Kelas	Jumlah Gambar
Bacterial Spot	2826
Early Blight	2455
Late Blight	3113
Leaf Mold	2754
Septoria Leaf Spot	2882
Spider Mites	1747
Target Spot	1827
Tomato Yellow Leaf Curl Virus	2039
Tomato Mosaic Virus	2153
Healthy	3051
Powder Mildew	1004

4. Preprocessing Data

Tahap preprocessing dilakukan untuk meningkatkan suatu kualitas pada data sebelum masuk kedalam proses training yang meliputi langkah berikut :

1. Resize gambar menjadi 224×224 piksel.
2. Normalisasi citra.
3. Augmentasi data menggunakan rotasi, zoom, horizontal flip, dan perubahan brightness.
4. Pembagian dataset menjadi train, validation, dan test.

Augmentasi dilakukan menggunakan ImageDataGenerator pada TensorFlow.

5. Arsitektur Model

Model yang dibangun dengan menggunakan model *EfficientNetB0 pretrained ImageNet* sebagai *feature extractor*. Setelah itu beberapa layer ditambahkan seperti *GlobalAveragePooling2D*, *BatchNormalization*, *Dropout* dan *Dense*. Konfigurasi model meliputi beberapa hal sebagai berikut :

1. Input size : $224 \times 224 \times 3$
2. Optimizer : Adam
3. Epoch : 50
4. Batch size : 32
5. Activation : Softmax
6. Loss Function : Categorical Crossentropy

6. Arsitektur EfficientNetB0

Penelitian ini menggunakan *transfer learning* dengan model *EfficientNetB0* sebagai model utama yang dilatih pada dataset *ImageNet*. Arsitektur dapat dilihat pada Tabel II berikut.

TABEL II
ARSITEKTUR EFFICIENTNETB0

Layer(type)	Output Shape	Parameter
efficientnetb0 (Functional)	(None, 7, 7, 1280)	4.049.571
global_average_pooling2d (GlobalAveragePooling2D)	(None, 1280)	0
batch_normalization (BatchNormalization)	(None, 1280)	5.120
dense (Dense)	(None, 512)	655.872
dense_1 (Dense)	(None, 256)	131.328
dense_2 (Dense)	(None, 11)	2.827
Total parameter : 4.049.571		
Trainable parameter : 793.611		
Non-trainable parameter : 4.053.155		

III. HASIL

Dengan menggunakan dataset Kaggle dengan dataset 20.000 lebih gambar tentang penyakit pada daun tomat, penelitian ini menghasilkan model klasifikasi penyakit dengan basis model *EfficientNetB0* yang telah dilatih. Pelatihan yang telah dilakukan sebanyak 50 *epochs* sesuai dengan konfigurasi yang telah ditetapkan dan dibantu dengan mekanisme *ReduceLROnPlateau* aktif untuk menyesuaikan dengan tingkat pembelajaran secara otomatis

1. Performa Model

1.1. Akurasi Training dan Pengujian

Hasil evaluasi pada model data validasi menunjukkan bahwa model mencapai akurasi terbaik pada validasi sebesar 87,27% pada *epochs* ke-49 dan akurasi pelatihan sebesar 99,63% pada *epochs* ke-50. Kurva pada akurasi pelatihan menunjukkan peningkatan yang konsisten dari *epochs* pertama (87,86%) hingga *epochs* ke-50 (99,60%), sementara akurasi validasi meningkat secara bertahap dari 46,00% pada *epochs* pertama menjadi perbedaan yang cukup besar antara ketepatan pelatihan dan ketepatan validasi, sehingga menunjukkan adanya overfitting. Namun seiring berjalannya pelatihan dengan bantuan mekanisme *ReduceLROnPlateau*, model terus menunjukkan tren peningkatan validasi yang signifikan.

Model terus mengalami peningkatan akurasi yang signifikan selama proses pelatihan pada dataset sebanyak 50 *epochs*. *Training accuracy* pada *epochs* pertama mencapai 87,86% dengan *val accuracy* 46,00% dan *val loss* 5,4121. Penyesuaian pada tingkat pembelajaran oleh *ReduceLROnPlateau* telah meningkatkan tingkat akurasi validasi. Ini menurunkan *LR* dari 0,001 menjadi 0,0005 pada *epochs* ke-11 lalu menjadi 0,00025 pada *epochs* ke-30 dan seterusnya. Dengan *val accuracy* 87,27% dan *val loss* 0,8212 model terbaik di-restrore dari *epochs* ke-49. *Val Loss* yang berhasil ditekan dari 5,41 pada *epochs* pertama menjadi 0,82 pad *epochs* ke-49 telah menunjukkan konvergensi yang baik. Namun masih terdapat gap diantara pelatihan dan validasi yang perlu diperhatikan kembali.

2. Classification Report

Laporan klasifikasi digunakan untuk memeriksa performa pada model secara lebih terperinci yang mencakup nilai *accuracy*, *recall* dan *F1-score* pada setiap kelas yang ada. Hasil selengkapnya dapat dilihat pada Tabel III berikut.

TABEL III
HASIL CLASSIFICATION REPORT


Kelas	Precision	Recall	F1-Score	Support
Bacterial Spot	0,99	0,18	0,30	732
Early Blight	0,97	0,19	0,31	643
Late Blight	1,00	0,53	0,69	792
Leaf Mold	0,97	0,85	0,90	739
Septoria Leaf Spot	0,56	0,83	0,67	746

Kelas	Precision	Recall	F1-Score	Support
Spider Mites	0,84	0,89	0,86	435
Target Spot	0,48	0,98	0,64	457
Tomato Yellow Leaf Curl Virus	0,66	0,98	0,79	498
Tomato Mosaic Virus	0,92	0,97	0,95	584
Healthy	0,68	0,81	0,74	805
Powdery Mildew	0,42	0,99	0,59	225
Macro Avg	0,77	0,74	0,68	6656
Weighted Avg	0,81	0,70	0,67	6656


Pada Tabel III telah menunjukkan bahwa kelas *Target Spot* memiliki *recall* yang paling tinggi dengan nilai 0,98 lalu diikuti oleh *Tomato Yellow Leaf Curl Virus* sebesar 0,98 dan *Powdery Mildew* sebesar 0,99. Karena jumlah sampel yang digunakan paling sedikit, kelas *Powdery Mildew* juga menerima *F1-score* yang paling sebanding dengan kelas yang lain. Sebaliknya dengan *Powdery Mildew*, pada kelas *Bacterial Spot* memiliki keakuratan tertinggi dengan nilai 0,99, tetapi keakuratannya menjadi rendah dengan nilai 0,18 dan hasil dari *F1-score* hanya 0,30. *Early Blight* juga memiliki keakuratan tinggi dedngan nilai 0,97 namun dengan nilai keakuratan 0,19. Hasil ini menunjukkan bahwa model sangat berhati hati dalam memprediksi setiap data dari setiap kelas tersebut dengan sedikit *false positive* namun banyak *false negative* dalam sampel sebenarnya. Secara keseluruhan, nilai *F1-score* tertimbang pada rata rata adalah 0,67 deengan akurasi *validation* 70,27%. Hal itu menunjukkan bahwa model yang digunakan menghadapi kesulitan dalam membedakan setiap kelas yang ada dengan kemiripan visual yang tinggi.

3. Confusion Matrix

GAMBAR I. CONFUSION MATRIX (COUNT)



GAMBAR II. CONFUSION MATRIX (%)



Prediksi yang telah dihasilkan oleh model untuk setiap kelas ditunjukkan oleh *Confusion Matrix* hasil prediksi model pada data validasi. Secara umum untuk kelas tertentu model mampu langsung mengklasifikasikan sebagian besar sampel ke kelas yang benar. Namun beberapa kelas mengalami misklasifikasi yang signifikan. *Bacterial Spot Class* mengalami misklasifikasi terbesar dari yang lain, hanya 17,6% sampel yang dianggap benar sementara 30,7% sampel dianggap sebagai *Septoria Leaf Spot* dan 28,1% sebagai *Target Spot*. Pada kelas *Early Blight* juga mengalami masalah serupa hanya dengan 18,7% akurasi per kelas dan banyak sampel dianggap sebagai *Septoria Leaf Spot* dengan nilai 35,5% dan *Target spot* dengan nilai 34,2%. Pada *Powdery Mildew* memiliki akurasi tertinggi sebesar 98,7% per kelasnya dan diikuti oleh virus bercak kuning pada daun dengan nilai 98,2%, virus mosaik tomat dengan nilai 97,1%. Ini mungkin terjadi karena disebabkan oleh fakta bahwa bercak bakteri, *Early Blight*, *Septoria Leaf*, dan titik tujuan memiliki beberapa kemiripan visual dimana hal tersebut telah menyulitkan model untuk membedakan keempat kelas tersebut.

4. Performa pada Epochs

Selama *training*, mekanisme *ReduceLROnPlateau* aktif sebanyak empat kali. Penurunan rasio pembelajaran dari 0,001 menjadi 0,0005 terjadi pertama kali pada *epochs* ke-11 yang menghasilkan peningkatan rasio keakuratan dari 50,23% menjadi 55,21% pada *epochs* ke-12. Penurunan kedua terjadi pada *epochs* ke-30 dari 0,0005 menjadi 0,00025 yang menghasilkan peningkatan signifikan dari 67,58% menjadi 73,05% pada *epochs* ke-33. *Training* kemudian menyelesaikan seluruh 50 *epochs* sesuai konfigurasi dengan model terbaik dikembalikan dari *epochs* ke-49 berdasarkan *val_accuracy* tertinggi sebesar 87,27% dan *val_loss* sebesar 86,70%. Selanjutnya ada penurunan keempat dari 0,000125 menjadi 0,0000625 pada *epochs* ke-47 yang menghasilkan lonjakan terakhir dari 83,10% menjadi 86,70% pada *epochs* ke-48 dan puncak sebesar 87,27% pada *epochs* ke-49.

IV. PEMBAHASAN

Dalam *epochs* ke-49, model CNN berbasis *EfficientNetB0* yang dikembangkan dalam penelitian ini mencapai akurasi pembelajaran terbaik sebesar 99,63% dan akurasi validasi terbaik sebesar 87,27%. Hasil penelitian ini menunjukkan bahwa teknik transfer pembelajaran menggunakan

EfficientNetB0 yang dilatih pada dataset *ImageNet* sangat efektif dalam tugas klasifikasi gambar penyakit daun tomat. Kumpulan data yang menggabungkan gambar lapangan nyata dan data Kaggle PlantVillage menghasilkan klasifikasi penyakit daun tomat yang sangat akurat. Ini menunjukkan keefektifannya untuk aplikasi pertanian khusus ini[13].

Transfer learning memungkinkan model menggunakan pengetahuan dari tugas tugas yang terkait dengan kumpulan data berlabel lebih besar untuk meningkatkan kinerja pada kumpulan data yang lebih kecil. Ini memungkinkan model memanfaatkan representasi fitur yang telah dipelajari dari data skala besar, yang menghasilkan penyatuan yang lebih cepat dan kinerja yang lebih baik pada kumpulan data yang lebih kecil. Teknik ini mencegah *overfitting* dan mempercepat konvergensi, sehingga sangat efektif dalam penggunaannya.[14].

Performa ini sejalan dengan penelitian sebelumnya yang menggunakan arsitektur CNN berbasis *transfer learning* untuk klasifikasi penyakit pada tanaman. Bergantung dengan kualitas dan ukuran dataset yang digunakan, model biasanya mencapai akurasi 85% hingga 99%.[15]. *Target Spot* memperoleh *F1-score* tertinggi sebesar 0,98 pada *recall*, sedangkan *Tomato Yellow Leaf Curl Virus* dan *Tomato Mosaic Virus* menunjukkan kinerja *recall* yang sangat baik masing-masing 0,98 dan 0,97. Sebaliknya, kelas *Bacterial Spot* dan *Early Blight* menunjukkan kinerja *recall* yang sangat rendah, masing-masing 0,18 dan 0,19 yang menunjukkan bahwa kedua kelas ini memiliki model kesulitan mendeteksi meskipun tingkat ketepatannya tinggi. Ini mungkin karena distribusi visual yang tumpang tindih dengan *Septoria Leaf Spot* dan *Late Blight*. Ada *overfitting*, yang wajar karena model dilatih dengan 25.851 sampel pelatihan versus hanya 6.683 sampel validasi. Ada gap besar antara ketepatan pelatihan (99,63 %) dan ketepatan validasi (87,27 %). Terbukti bahwa penggunaan variasi data tambahan, seperti rotasi, zoom, flip horizontal, dan perubahan kecerahan untuk membantu meningkatkan generalisasi model. Untuk penelitian mendatang disarankan untuk mempelajari metode penyempurnaan lebih lanjut pada lapisan dasar *EfficientNetB0*. Ini akan melibatkan penggunaan dataset yang lebih luas dari lingkungan pertanian nyata serta penerapan model untuk pengujian lapangan langsung melalui aplikasi mobile atau web.[16].

V. KESIMPULAN

Studi ini mengembangkan model klasifikasi penyakit daun tomat dengan menggunakan *Convolutional Neural Network* (CNN) berbasis model arsitektur *EfficientNetB0* dan pendekatan *transfer learning*, dataset Kaggle yang terdiri dari 25.851 gambar pelatihan dan 6.683 gambar validasi dibagi ke dalam sebelas kelas, dengan total 50 *epochs training* digunakan untuk mempelajari model. Berdasarkan hasil eksperimen, model mencapai tingkat akurasi tertinggi sebesar 99,63% dan tingkat akurasi tertinggi sebesar 87,27% pada *epochs* ke-49. Kelas *Powdery Mildew* memiliki *recall* tertinggi 0,99, sedangkan *Bacterial Spot* dan *Early Blight* memiliki *recall* terendah karena gejala visualnya mirip dengan kelas lain. Secara keseluruhan model menunjukkan akurasi validasi sebesar 70,27% pada data evaluasi, dengan *F1-score* yang ditimbang sebesar 0,67. Penelitian ini menunjukkan bahwa *EfficientNetB0* dapat menggunakan *transfer learning* untuk mengidentifikasi penyakit pada daun tomat dengan akurasi sebesar 89%. Untuk meningkatkan kinerja dan ketahanan model dalam berbagai lingkungan pertanian, penelitian lebih lanjut harus berfokus

pada penggabungan data lapangan nyata dan metode penyempurnaan lanjutan[17].

REFERENSI

- [1] S. Kimura and N. Sinha, "Tomato (*Solanum lycopersicum*): A Model Fruit-Bearing Crop," *Cold Spring Harb. Protoc.*, vol. 2008, no. 11, p. pdb.emo105, Nov. 2008, doi: 10.1101/pdb.emo105.
- [2] Z. S. Ilić, N. Kapoulas, and L. Šunić, "Tomato Fruit Quality from Organic and Conventional Production," in *Organic Agriculture Towards Sustainability*, InTech, 2014. doi: 10.5772/58239.
- [3] J. Li, "Analysis of Nutritional Composition of Mediterranean Diet and Application of This Model," *Highlights in Science, Engineering and Technology*, vol. 123, pp. 243–248, Dec. 2024, doi: 10.54097/1f21p481.
- [4] A. Kaushal *et al.*, "A Rapid Disease Resistance Breeding in Tomato (*Solanum lycopersicum* L.)," in *Accelerated Plant Breeding, Volume 2*, Cham: Springer International Publishing, 2020, pp. 17–55. doi: 10.1007/978-3-030-47298-6_2.
- [5] M. P. Diwakar, V. R. Ghule, N. S. Sharma, and S. Dixit, "Harnessing Intelligence: A Comprehensive Exploration of AI in Agriculture," in *Industry 5.0 for Society 5.0: Revolutionizing Smart Farming, Manufacturing, and Green Computing (Part 2)*, BENTHAM SCIENCE PUBLISHERS, 2025, pp. 1–21. doi: 10.2174/9798898810849125010004.
- [6] V. Anand, D. Koundal, W. Y. Alghamdi, and B. M. Alsharbi, "Smart grading of diabetic retinopathy: an intelligent recommendation-based fine-tuned EfficientNetB0 framework," *Front. Artif. Intell.*, vol. 7, Apr. 2024, doi: 10.3389/frai.2024.1396160.
- [7] W. Zheng, "Comparison of transfer-learning for lightweight pre-trained model on image classification," *Applied and Computational Engineering*, vol. 53, no. 1, pp. 56–63, Mar. 2024, doi: 10.54254/2755-2721/53/20241244.
- [8] Y. Lee, "The CNN: The Architecture Behind Artificial Intelligence Development," *Journal of Student Research*, vol. 12, no. 4, Nov. 2023, doi: 10.47611/jsrhs.v12i4.5579.
- [9] A. Pajankar and A. Joshi, "Convolutional Neural Networks," in *Hands-on Machine Learning with Python*, Berkeley, CA: Apress, 2022, pp. 261–284. doi: 10.1007/978-1-4842-7921-2_14.
- [10] A. Rakhmadi, S. Khairunnisa, M. S. Adhantoro, S. Riyadi, A. Yudhana, and Sunardi, "EfficientNetB0-Based Recognition of Arabic Sign Language for Quranic Recitation Support," in *2025 12th International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*, IEEE, Sep. 2025, pp. 137–143. doi: 10.1109/EECSI67060.2025.11290662.
- [11] C. H. Patel, D. Undaviya, H. Dave, S. Degadwala, and D. Vyas, "EfficientNetB0 for Brain Stroke Classification on Computed Tomography Scan," in *2023 2nd International Conference on Applied Artificial Intelligence and Computing (ICAAIC)*, IEEE, May 2023, pp. 713–718. doi: 10.1109/ICAAIC56838.2023.10141195.

- [12] A. Philip, “Optimizing Food101 Classification with Transfer Learning: A Fine-Tuning Approach Using EfficientNetB0,” *International Journal of Intelligent Information Systems*, vol. 13, no. 4, pp. 59–77, Aug. 2024, doi: 10.11648/j.ijis.20241304.11.
- [13] T. F. Prasetyo, Sunardi, and A. Fadlil, “Model Prediktif Penyakit Tanaman Tomat Menggunakan Arsitektur EfficientNetB0,” *TEMATIK*, vol. 12, no. 2, pp. 212–222, Jan. 2026, doi: 10.38204/tematik.v12i2.2722.
- [14] A. H. Ali, Mohanad G. Yaseen, Mohammad Aljanabi, and Saad Abbas Abed, “Transfer Learning: A New Promising Techniques,” *Mesopotamian Journal of Big Data*, vol. 2023, pp. 29–30, Feb. 2023, doi: 10.58496/MJBD/2023/004.
- [15] A. Anton, S. Rustad, G. F. Shidik, and A. Syukur, “COMPARATIVE ANALYSIS OF CNN ARCHITECTURES FOR TOMATO LEAF DISEASE CLASSIFICATION USING TRANSFER LEARNING,” *JITK (Jurnal Ilmu Pengetahuan dan Teknologi Komputer)*, vol. 11, no. 1, pp. 125–135, Aug. 2025, doi: 10.33480/jitk.v11i1.7014.
- [16] M. S. Krishna, P. Machado, R. I. Otuka, S. W. Yahaya, F. Neves dos Santos, and I. K. Ihianle, “Plant Leaf Disease Detection Using Deep Learning: A Multi-Dataset Approach,” *J (Basel)*, vol. 8, no. 1, p. 4, Jan. 2025, doi: 10.3390/j8010004.
- [17] T. F. Prasetyo, Sunardi, and A. Fadlil, “Model Prediktif Penyakit Tanaman Tomat Menggunakan Arsitektur EfficientNetB0,” *TEMATIK*, vol. 12, no. 2, pp. 212–222, Jan. 2026, doi: 10.38204/tematik.v12i2.2722.