

Identifikasi 29 Jenis Penyakit Tanaman Menggunakan Deep Learning EfficientNetB3

Adhitho Satyo Bayangkari Karno¹, Widi Hastomo², Indra Sari Kusuma Wardhana³, Sutarno⁴ dan Dodi Arif⁵
Sistem Informasi, Universitas Gunadarma^{1,5}

Jl. Margonda Raya No. 100, Depok, Jawa Barat 16424, Indonesia^{1,5}
Teknologi Informasi, ITB Ahmad Dahlan Jakarta²

Jl. Ir H. Juanda No.77, Cireundeu, Tangerang Selatan, Banten, 15419 Indonesia²
Sistem Informasi, STMIK Jakarta STI&K^{3,4}

Jl. BRI No.17, Radio Dalam, Kebayoran Baru, Jakarta Selatan 12140, Indonesia^{3,4}
adh1t10.2@gmail.com¹, Widie.has@gmail.com²

Diterima: 08 Aug 2022 | Direvisi: 18 Aug 2022

Disetujui: 27 Aug 2022 | Dipublikasi: 31 Aug 2022

Abstrak

Upaya meningkatkan produksi tanaman dari petani sangat diperlukan untuk menopang kebutuhan pangan dunia di tengah krisis pangan global saat ini. Kegagalan panen yang dialami petani karena serangan penyakit tanaman harus ditekan dengan cara memberikan kemudahan informasi untuk mengetahui jenis penyakit tanamannya sehingga upaya lebih dini untuk pengendalian dapat lebih dilakukan. Penelitian ini berupaya membangun suatu model klasifikasi 29 jenis penyakit tanaman dengan teknologi Deep Learning (DL) menggunakan salah satu arsitektur Convolutional Neural Network (CNN) yaitu EfficientNetB3. Tahap training dengan 57.067 image data train dan 3.170 image data validasi menghasilkan model. Untuk pengujian model dilakukan tahap testing dengan 3.171 image data test, hasil pengujian secara keseluruhan menghasilkan score akurasi dan f1-score yang sangat baik yaitu 0.99%.

Kata kunci: Convolutional Neural Network, Deep Learning, EfficientNetB3

Abstract

To supply the world's food needs in the midst of the existing food crisis, farmers urgently need to expand crop production. By establishing it simple to recognize the kind of plant disease so that earlier control efforts could be conducted, farmers' harvest failures driven on by disease attacks must be prevented. In this study, one of the Convolutional Neural Network (CNN) architectures known EfficientNetB3 is applied to generate a classification model for 29 different types of

plant diseases. A model is created after 3,170 image data are used for validation and 57,067 image data were utilized for training. 3,171 image data tests were conducted as part of the model testing phase, and the total test results were produced an extraordinarily high accuracy score of 0.99 percentage and an F1-score.

Keywords: Convolution Neural Network, Deep Learning, EfficientNetB3

I. PENDAHULUAN

Ekonomi global yang belum pulih akibat pandemi covid-19, ditambah tekanan karena adanya invasi rusia ke ukraina. Sehingga mengakibatkan terganggunya rantai pasok telah menyulut naiknya krisis inflasi dan pangan global di banyak negara [1]. Upaya meningkatkan produksi tanaman sangat diperlukan sebagai upaya memenuhi kebutuhan pangan yang semakin menipis [2]. Gagal panen yang dialami petani karena serangan penyakit tanaman harus ditekan sebagai upaya memenuhi kebutuhan pangan [3]. Kemampuan petani untuk dapat mengidentifikasi jenis penyakit pada suatu tanaman sangat diperlukan [4], sehingga petani dapat mengetahui bagaimana mengidentifikasi jenis penyakit secara dini dan cara pengendalian yang tepat dari penyakit tanaman [5].

Kurangnya informasi dan ketidak tahuan para petani untuk mendeteksi dini penyakit tanaman

dapat mengakibatkan gagal panen serta kerugian yang besar dari biaya yang telah dikeluarkan sebelumnya [6]. Banyaknya gagal panen dari para petani dapat berdampak besar akan kebutuhan pangan suatu negara. Masih sedikitnya para pakar tanaman dalam memberikan penyuluhan kepada petani menjadi salah satu faktor utama petani untuk memperoleh informasi [7].

Penggunaan teknologi komputasi mendorong ilmuwan data dan ahli agronomi untuk merancang alat dan teknik analitis untuk mengatur manajemen lapangan secara akurat dan mengatasi masalah baru, tantangan yang dihadapi (semisal deteksi serangan jamur, prediksi hasil panen, penyemprotan lanjutan, dan lainnya)[8]. Kemajuan terbaru dalam aplikasi berbasis kecerdasan buatan (AI) memiliki dampak yang kuat dalam hal ini. Mereka telah berkontribusi pada kemajuan yang signifikan dari visi komputer [9]–[12], pembelajaran mesin [13], dan solusi pembelajaran mendalam dalam pengembangan sistem otomatis dan tangguh [14]. Kemajuan teknologi terkini dalam visi komputer memungkinkan untuk membantu dalam diagnosis dini menggunakan gambar daun multispektral tanaman [15].

Penelitian terkait yang telah dilakukan oleh [16] menggunakan *dataset* dari daun tomat dan anggur, dengan pendekatan algoritme CNN *Visual Geometry Group* (VGG), dengan hasil akurasi mencapai 98.40% untuk anggur dan 95.71% untuk tomat. Penelitian yang telah dilakukan oleh [17] menggunakan *dataset* daun kopi, menggunakan metode *MobileNetV2* dengan hasil akurasi mencapai 96%. Penelitian yang dilakukan oleh [18] menggunakan metode *Trilinear CNN* dengan hasil akurasi mencapai 84,11%.

Penelitian terkait deteksi penyakit pada daun cabe, menggunakan metode *squeeze-and-excitation-based convolutional neural network* (SECNN) yang dilakukan oleh [18] dengan capaian akurasi 99,28%. Penelitian yang dilakukan oleh [19] menggunakan metode CNN dan *bi-directional long-short term memory* (Bi-LSTM) dengan hasil akurasi mencapai 95,56%.

Berdasarkan dari paparan latar belakang tersebut, penelitian ini bertujuan untuk memprediksi penyakit tanaman, dengan melakukan proses *training* dan *testing* dari sejumlah banyak citra daun tanaman dengan menggunakan teknologi *Deep Learning* (DL)

yaitu metode *Convolutional Neural Network* (CNN) dengan arsitektur *EfficientNetB3*.

Metode CNN adalah metode umum dan sangat optimal digunakan dalam melakukan klasifikasi image, dengan memilih arsitektur *EfficientNetB3* dan kombinasi lapisan CNN untuk proses *training* dan *testing* [20]. Hasil dari proses *training* dan *testing* adalah model bobot matrik akurasi tinggi yang diharapkan dapat digunakan untuk memprediksi penyakit melalui gambar daun tanaman. Dengan menanamkan model bobot matrik ini dalam suatu aplikasi *web* akan memudahkan para petani, kapanpun dan dimanapun untuk mengidentifikasi jenis penyakit tanaman dengan hanya mengambil *image* dari daun tanaman.

II. TINJAUAN PUSTAKA

A. *Convolutional Neural Network* (CNN)

CNN adalah tipe khusus dari *Deep Neural Network* (DNN), yang terinspirasi oleh ilmu saraf. Arsitektur CNN berbeda dari model DL yang lain. Alih-alih menggunakan pendekatan yang sepenuhnya terhubung, CNN menggunakan koneksi lokal untuk mengekstrak fitur kontekstual informasi. Selain itu, dalam menetapkan bobot untuk masing-masing masukan secara terpisah, CNN menggunakan bobot bersama untuk mengurangi jumlah parameter. Berdasarkan karakteristik ini, CNN cenderung memberikan generalisasi yang lebih baik ketika menghadapi masalah visualisasi pada proses komputasi.

B. *EfficientNetB3*

EfficientNetB3 merupakan jaringan saraf *convolutional* yang dilatih pada lebih dari satu juta gambar dari *database ImageNet* [21]. Jaringan dapat mengklasifikasikan gambar ke dalam 1000 kategori objek, seperti *keyboard*, pensil, *mouse* dan banyak objek lainnya. Akibatnya, jaringan telah mempelajari representasi fitur yang kaya untuk berbagai gambar. Jaringan memiliki ukuran input gambar 224x224.

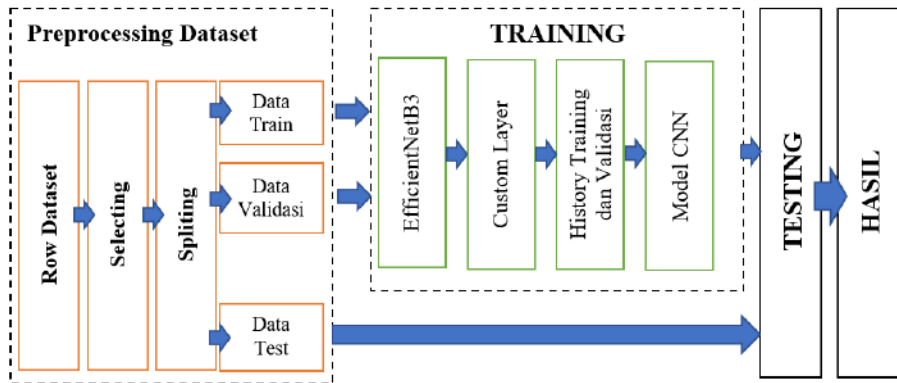
III. METODE PENELITIAN

Secara garis besar penelitian ini terdiri dari 4 tahap, yaitu: *preprocessing dataset*, *training*, *testing* dan hasil untuk dievaluasi. Tahap *preprocessing dataset* terdiri dari beberapa subproses yang bertujuan untuk mempersiapkan agar data dapat dipergunakan dengan format sesuai dengan arsitektur CNN dalam tahap *training*. *Training* adalah tahap dimana mesin akan melakukan proses pembelajaran dengan

menggunakan *data train* dan mengevaluasi hasil pembelajaran menggunakan data validasi untuk memperbaharui nilai bobot (bobot *update*) sebelumnya.

Nilai bobot *update* ini akan dipergunakan dalam proses iterasi selanjutnya, hingga tercapai nilai prosentase akurasi tinggi dan *loss* yang

rendah. Nilai bobot terakhir dengan nilai akurasi maksimum dan *loss* yang minimum disebut sebagai model hasil *training*. Selanjutnya model hasil *training* akan dipergunakan dalam proses *testing* dengan menggunakan *data test*, hingga diperoleh hasil akhir berupa *confussion matrix* (gambar 1).



Gambar 1. Tahap penelitian

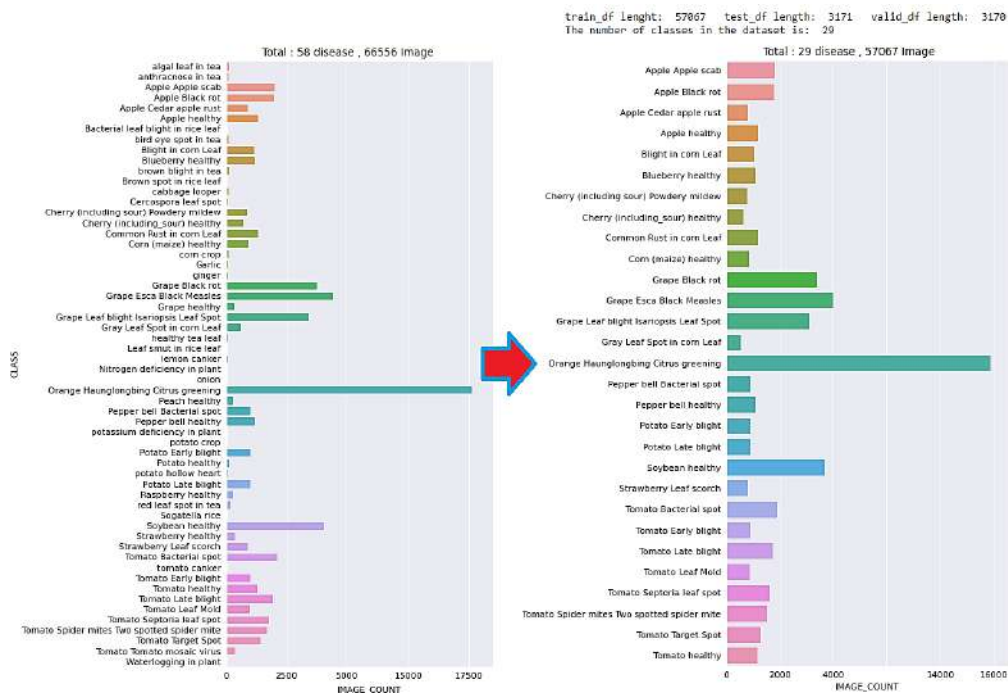
A. Pre-processing Dataset

Dataset berisi *image* daun dari berbagai tanaman (gambar 2) yang dikelompokkan dalam *folder* sesuai dengan jenis penyakit tanaman. *Preprocessing dataset* merupakan proses awal untuk mempersiapkan data agar dapat dipergunakan dengan baik dan sesuai untuk tahap selanjutnya (tahap *training* dan *testing*). *Dataset* mentah (*raw dataset*) penelitian ini diperoleh dari Kaggle [22], terdiri dari 66.556 *image* yang berada dalam 58 *folder* jenis penyakit tanaman (gambar 3). *Dataset* mentah ini terlihat memiliki jumlah *image* yang tidak seimbang di setiap *foldernya*. Untuk mengatasi ketidakimbangan data dilakukan proses *selecting folder* [23], hanya *folder* yang memiliki jumlah lebih dari 500 *image*. Data mentah yang semula 66.556 *image* dalam 58 *folder* karena proses *selecting* berkurang menjadi

63.408 *image* dalam 29 *folder* jenis penyakit. Kemudian data 63.408 *image* dilakukan proses *splitting* (pemisahan) menjadi *data training* 57.067 (90%), *data validasi* 3.170 (5%) dan *data testing* 3171 (5%) (gambar 3).



Gambar 2. Image dataset [22]



Gambar 3. Row dataset (kiri) dan hasil pre-processing untuk data training (kanan)


B. Training dan Testing

Dalam tahap *training* dilakukan proses pelatihan dengan menggunakan data *train* dan proses validasi menggunakan data validasi. Dalam tiap *epoch* proses validasi dilakukan setelah proses pelatihan, membandingkan dengan nilai target untuk memperoleh nilai deviasi sebagai dasar ukuran untuk melakukan *update* bobot matrik. Matrik bobot terbaru (setelah *update*) akan dipergunakan untuk proses pelatihan untuk *epoch* selanjutnya. Proses ini dilakukan terus berulang hingga mencapai nilai *epoch* yang diinginkan. Proses pelatihan dan validasi ini menggunakan base model arsitektur *EfficientNetB3* yang ada pada *library tensorflow-keras* dan arsitektur lapisan *custom*.

Selama proses iterasi berlangsung akan direkam nilai akurasi dan *loss* dalam bentuk *history*. Proses ini berjalan dalam *epoch* yang diinginkan dan mencapai nilai akurasi yang tinggi dan *loss* yang rendah. Hasil dalam bentuk matrik bobot ini dinyatakan sebagai model hasil *training*. Model ini dipergunakan untuk proses selanjutnya yaitu proses pengujian atau *testing* dengan menggunakan *data test*.

Banyak arsitektur CNN dirancang untuk menaikkan skor akurasi tinggi dengan penambahan lapisan tebal yang memerlukan kebutuhan komputasi yang semakin tinggi pula. Dengan


mempertimbangkan kemampuan komputer yang ada maka dalam penelitian ini dipilih *EfficientNet-B3*. Selain itu *EfficientNet-B3* telah menunjukkan kemampuan kuat dalam klasifikasi *image* untuk *remote sensing* [24]. Dalam *study* yang telah dilakukan oleh Mingxing Tan [21], *EfficientNet-B3* dengan menggunakan data latih *ImageNet* mampu mencapai akurasi 81.7% dengan jumlah parameter komputasi 12 juta (Gambar 4)



Gambar 4. Model Size vs ImageNet Accuracy [21]

Dengan melihat arsitektur *EfficientNet-B3* dapat diketahui bahwa arsitektur ini merupakan tumpukan tebal lapisan modul *MobileNet* (gambar 5). Data *train* dan data validasi akan diumpankan


Dalam dimensi lebih kecil 4x4 menjadi dimensi 2x2, *max pooling* dapat diilustrasikan dalam gambar 6.



Gambar 6. *Max pooling* [21]

C. Flatten

Lapisan *flatten* ini umumnya diletakkan setelah lapisan *pooling* dalam CNN. Lapisan ini adalah proses merubah matrik menjadi bentuk *vector* tunggal. Dengan terbentuknya *vector* tunggal ini berguna sebagai input proses selanjutnya yaitu *classification (dense)*.




Gambar 7. *Flattening*

D. Dense

Dense atau *fully connected* merupakan bagian dari proses *classification*, lapisan *dense* diletakkan setelah *flattening* dengan format *output vector*

Gambar 9. *History training* (Lampiran)

menjadi mungkin untuk dilakukan proses *neural network* biasa dengan sejumlah *node* di setiap *hidden layer*nya.



Gambar 8. *Dense* [21]

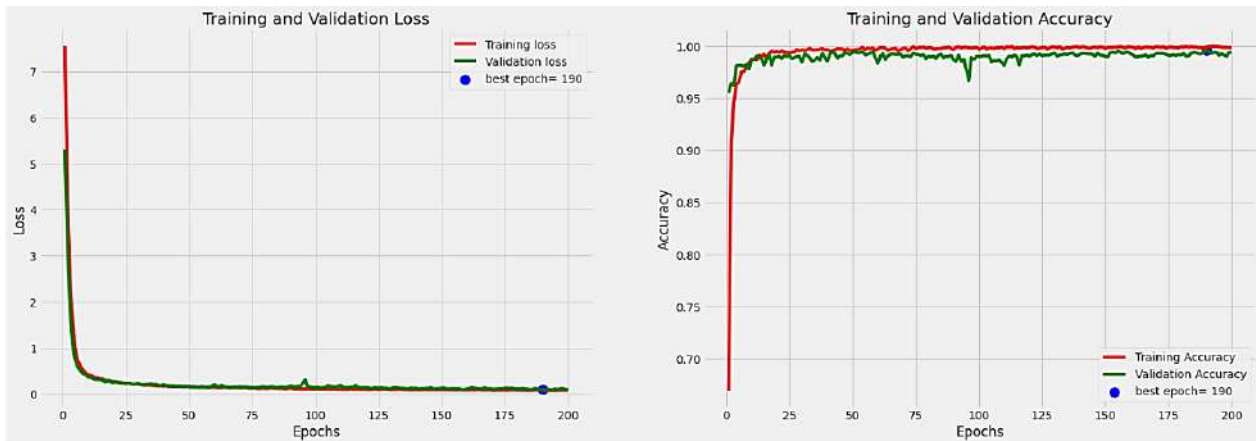
IV. HASIL DAN PEMBAHASAN

Pada bagian ini, kami menyajikan hasil klasifikasi yang diikuti dengan diskusi singkat tentang hasil yang diberikan oleh model. Akurasi diperoleh dengan menggunakan *tensorflow library* dengan *python* dan simulasi telah dilakukan menggunakan editor *Jupyter Notebook*.

Lingkungan operasi yang digunakan dalam eksperimen ini yaitu; (a) Intel Core i5 12400 6Core 12Thread 2.5Ghz, (b) Graphics processing unit (GPU) Gtx 1650 4GB DDR6, (c) Ram 8GB DDR4 3200Mhz Team.

A. Accuracy and Loss

Dari model yang telah terbentuk dilakukan *training* dengan *epoch* 200, diperoleh hasil nilai *loss*: 0.1144, *accuracy*: 0.9917, *val_loss*: 0.7196, *val_accuracy*: 0.8375. Nilai *val_loss* terendah: 0.4589 terjadi pada *epoch* 100 (*best epoch* untuk *val_loss*). Nilai *val_accuracy* tertinggi: 0.9967 terjadi di *epoch* 155 (*best epoch* untuk *val_accuracy*) (gambar 9). Untuk pembacaan *history* secara keseluruhan dapat ditampilkan dalam bentuk grafik (gambar 10).



Gambar 10. Grafik *accuracy* dan *loss*


B. Confusion Matrix dan Classification Report

Untuk menghitung nilai *accuracy* dari proses *training deep learning* dalam mengklasifikasikan data kedalam label yang diinginkan, maka di buat

program menggunakan *library seaborn heatmap* di *python* dari hasil nilai prediksi dan nilai sebenarnya, sehingga menghasilkan *confusion matrix* (gambar 11).

Gambar 11. *Confusion matrix* (Lampiran)

Dari *confusion matrix* dapat dilakukan komputasi untuk menentukan nilai *precision*, *recall*, *f1-score* dan *accuracy*, dengan menggunakan formula berikut:



Gambar 12. Komputasi untuk *classification report*

$$Precision = \frac{TP}{TP + FP} \tag{1}$$

$$Recall = \frac{TP}{TP + FN} \tag{2}$$

$$F1 - Score = 2 * \frac{Precision * Recall}{Precision + Recall} \tag{3}$$

$$Accuracy = \frac{TN + TP}{TN + FP + TP + FN} \tag{4}$$

Hasil pemrograman yang telah dilakukan untuk menentukan nilai *precision*, *recall*, *f1-score* dan *accuracy*, dirangkum dalam bentuk *classification report* untuk untuk 29 penyakit tanaman (gambar 13)

Classification Report:

	precision	recall	f1-score	support
Apple Apple scab	1.0000	1.0000	1.0000	101
Apple Black rot	1.0000	1.0000	1.0000	100
Apple Cedar apple rust	1.0000	1.0000	1.0000	44
Apple healthy	0.9851	1.0000	0.9925	66
Blight in corn Leaf	0.9623	0.8947	0.9273	57
Blueberry healthy	1.0000	0.9500	0.9744	60
Cherry (including sour) Powdery mildew	1.0000	1.0000	1.0000	42
Cherry (including_sour) healthy	1.0000	1.0000	1.0000	34
Common Rust in corn Leaf	1.0000	0.9697	0.9846	66
Corn (maize) healthy	1.0000	1.0000	1.0000	46
Grape Black rot	0.9947	1.0000	0.9974	189
Grape Esca Black Measles	1.0000	1.0000	1.0000	222
Grape Leaf blight Isariopsis Leaf Spot	1.0000	1.0000	1.0000	172
Gray Leaf Spot in corn Leaf	0.7941	0.9643	0.8710	28
Orange Haunglongbing Citrus greening	1.0000	1.0000	1.0000	881
Pepper bell Bacterial spot	1.0000	1.0000	1.0000	50
Pepper bell healthy	1.0000	1.0000	1.0000	59
Potato Early blight	1.0000	1.0000	1.0000	50
Potato Late blight	0.9412	0.9600	0.9505	50
Soybean healthy	1.0000	1.0000	1.0000	204
Strawberry Leaf scorch	1.0000	1.0000	1.0000	44
Tomato Bacterial spot	0.9813	0.9813	0.9813	107
Tomato Early blight	0.9796	0.9600	0.9697	50
Tomato Late blight	0.9307	0.9792	0.9543	96
Tomato Leaf Mold	1.0000	0.9787	0.9892	47
Tomato Septoria leaf spot	0.9884	0.9551	0.9714	89
Tomato Spider mites Two spotted spider mite	0.9877	0.9524	0.9697	84
Tomato Target Spot	0.9452	0.9857	0.9650	70
Tomato healthy	1.0000	1.0000	1.0000	63
accuracy			0.9905	3171
macro avg	0.9824	0.9838	0.9827	3171
weighted avg	0.9910	0.9905	0.9906	3171

Gambar 13. Classification report

V. KESIMPULAN

Berdasarkan *Confusion Matrix* dan *Classification Report*, diperoleh informasi sebagai berikut:

1. Hasil *testing* menggunakan *data test* menghasilkan prediksi paling banyak salah yaitu pada jenis penyakit tanaman "*Blight in corn leaf*". Total dari 57 *image* "*Blight in corn leaf*", dengan prediksi benar tertinggi adalah 51 dan salah terbanyak adalah 6 dengan prediksi jenis penyakit "*Gray leaf Spot in corn Leaf*".
2. Prediksi paling banyak selanjutnya adalah pada jenis penyakit tanaman "*Tomato Spider mites Two spotted spider mite*". Total dari 84 *image* "*Tomato Spider mites Two spotted spider mite*", dengan prediksi benar tertinggi adalah 80 dan salah terbanyak adalah 4 dengan prediksi jenis penyakit "*Tomato Target Spot*".
3. Setelah melakukan *testing* dengan 3.171 *image data test*, menggunakan model matrik hasil dari proses *training* dengan 57.067 *image data train* dan 3.170 *image data validasi*, secara keseluruhan menghasilkan *score* akurasi dan *f1-score* yang sangat baik yaitu 0.99%.
4. Kesalahan prediksi yang terjadi dikarenakan terdapat 2 *image* daun dengan jenis penyakit tertentu yang memiliki kemiripan bentuk atau warna hampir serupa ("*Blight in corn leaf*" mirip dengan "*Gray leaf Spot in corn Leaf*" dan "*Tomato Spider mites Two spotted spider mite*" mirip dengan "*Tomato Target Spot*").

Penelitian selanjutnya dapat menggunakan kombinasi algoritme CNN yang lain untuk membandingkan hasil agar lebih optimal.

UCAPAN TERIMA KASIH

Ucapan terimakasih ditujukan kepada [22] yang telah menyediakan *dataset* dalam mendukung eksperimen ini.

REFERENSI

- [1] M. P. Dario Caldara, Sarah Conlisk, Matteo Iacoviello, "The Effect of the War in Ukraine on Global Activity and Inflation," <https://www.federalreserve.gov/>, 2022. <https://www.federalreserve.gov/econres/notes/feds-notes/the-effect-of-the-war-in-ukraine-on-global-activity-and-inflation-20220527.htm>
- [2] John Ciempa, "The benefits of sustainable agriculture and how we get there," <https://www.ibm.com/>, 2021. <https://www.ibm.com/blogs/internet-of-things/the-benefits-of-sustainable-agriculture-and-how-we-get-there/>
- [3] M. R. Timaeus, J., Ruigrok, T., Siegmeier, T., & Finckh, "Adoption of Food Species Mixtures from Farmers' Perspectives in Germany: Managing Complexity and Harnessing Advantages.," *Agric. Ecosyst. Environ.*, vol. 12, no. 5, p. 697, 2022.
- [4] H. Y. PAN, S. Q., QIAO, J. F., Rui, W. A. N. G., YU, H. L., Cheng, W. A. N. G., TAYLOR, K., & PAN, "Intelligent diagnosis of northern corn leaf blight with deep learning model," *J. Integr. Agric.*, vol. 21, no. 4, pp. 1094–1105, 2022.
- [5] S. Nagpal, P., Chaudhary, S., & Kumar, "Detection of Disease in Plants with Android Integration Using Machine Learning," *Int. Conf. Comput. Eng. Technol. Springer, Singapore.*, pp. 144–151, 2022.
- [6] S. Collinge, D. B., & Sarrocco, "Transgenic approaches for plant disease control: Status and prospects 2021," *Plant Pathol.*, vol. 71, no. 1, pp. 207–225, 2022.
- [7] T. Hasanaliyeva, G., Si Ammour, M., Yaseen, T., Rossi, V., & Caffi, "Innovations in Disease Detection and Forecasting: A Digital Roadmap for Sustainable Management of Fruit and Foliar Disease," *Agronomy*, vol. 12, no. 7, p. 1707, 2022.
- [8] D. Couliably, S., Kamsu-Foguem, B., Kamissoko, D., & Traore, "Deep learning for precision agriculture: a bibliometric analysis," *Intell. Syst. with Appl.*, 2022.
- [9] W. Hastomo, "Klasifikasi Covid-19 Chest X-Ray Dengan Tiga Arsitektur Cnn (Resnet-152, Inceptionresnet-V2, Mobilenet-V2)," vol. 5, no. D1, 2021.
- [10] W. Hastomo, "Convolution Neural Network Arsitektur Mobilenet-V2 Untuk Mendeteksi Tumor Otak," vol. 5, no. Gambar 1, 2021.
- [11] W. Hastomo and S. Bayangkari, "Diagnosa Covid-19 Chest X-Ray Dengan Convolution Neural Network Arsitektur Resnet-152," vol. 2, no. 1, pp. 26–33, 2021.
- [12] A. Satyo, B. Karno, W. Hastomo, Y. Efendi, and R. Irawati, "Arsitektur Alexnet Convolution Neural Network (CNN) Untuk Mendeteksi Covid-19 Image Chest-Xray," pp. 482–485, 2021.
- [13] W. Hastomo, N. Aini, A. Satyo, B. Karno, and L. M. R. Rere, "Metode Pembelajaran Mesin untuk Memprediksi Emisi Manure Management," vol. 11, no. 2, pp. 131–139, 2022.
- [14] R. Razfar, N., True, J., Bassiouny, R., Venkatesh, V., & Kashef, "Weed detection in soybean crops using custom lightweight deep learning models," *J. Agric. Food Res.*, vol. 8, 2022.
- [15] H. Peng, Y., Dallas, M. M., Ascencio-Ibáñez, J. T., Hoyer, J. S., Legg, J., Hanley-Bowdoin, L., ... & Yin, "Early detection of plant virus infection using multispectral imaging and spatial-spectral machine learning," *Sci. Reports Nat.*, vol. 12, no. 1, pp. 1–14, 2022.
- [16] V. B. Paymode, A. S., & Malode, "Transfer Learning for Multi-Crop Leaf Disease Image Classification using Convolutional Neural Network VGG," *Artif. Intell. Agric.*, vol. 6, pp. 23–33, 2022.
- [17] L. M. Tassis and R. A. Krohling, "Few-shot learning for biotic stress classification of coffee leaves," *Artif. Intell. Agric.*, vol. 6, pp. 55–67, 2022, doi: <https://doi.org/10.1016/j.aiaa.2022.04.001>.
- [18] D. Wang, J. Wang, W. Li, and P. Guan, "T-CNN: Trilinear convolutional neural networks model for visual detection of plant diseases," *Comput. Electron. Agric.*, vol. 190, p. 106468, 2021, doi: <https://doi.org/10.1016/j.compag.2021.106468>.
- [19] X. Tang *et al.*, "Deep6mAPred: A CNN and Bi-LSTM-based deep learning method for predicting DNA N6-methyladenosine sites across plant species," *Methods*, vol. 204, pp. 142–150, 2022, doi: <https://doi.org/10.1016/j.ymeth.2022.04.011>.
- [20] B. Ahmad, A., Saraswat, D., Aggarwal, V., Etienne, A., & Hancock, "Performance of deep learning models for classifying and detecting common weeds in corn and soybean production systems," *Comput. Electron. Agric.*, vol. 184, p. 106081, 2021.
- [21] Q. Tan, M., & Le, "Efficientnet: Rethinking model scaling for convolutional neural networks," *Int. Conf. Mach. Learn.*, pp. 6105–6114, 2019.
- [22] S. M. Sakib, "Plant Disease Expert," *kaggle.com*, 2022. <https://www.kaggle.com/datasets/sadmansakibmah/plant-disease-expert>
- [23] W. Hastomo, A. S. Karno, S. Sutarno, D. Arif, & Moreta, E., and S. Sudjiran, "Mengatasi Ketimpangan Data Deep Neural Network dengan Pelipatan Fitur Data

Klasifikasi Spektroskopi Darah,” *J. Ilm.*, vol. 8, no. 2, pp. 579–591, 2022, doi: <https://doi.org/10.35326/pencerah.v8i2.2251>.

- [24] N. A. Alhichri, H., Alswayed, A. S., Bazi, Y., Ammour, N., & Alajlan, “Classification of remote sensing images using EfficientNet-B3 CNN model with attention,” *IEEE Access*, vol. 9, pp. 14078–14094, 2021.
- [25] Vardan Agarwal, “Complete Architectural Details of all EfficientNet Models,” *Medium Toward Data Science*, 2020. <https://medium.com/towards-data-science/complete-architectural-details-of-all-efficientnet-models-5fd5b736142>
- [26] C. O. Lee, Y., Park, J., & Lee, “Two-level group convolution,” *Neural Networks*, 2022.