

Analisis Kinerja ResNet-50 dalam Klasifikasi Penyakit pada Daun Kopi Robusta

Suprihanto¹, Iwan Awaludin², Muhammad Fadhil³, M. Andhika Zaini Zulfikor⁴

^{1,2,3,4} Politeknik Negeri Bandung
Jl. Gegerkalong Hilir, Ciwaruga, Kec. Parongpong, Kabupaten Bandung Barat, Jawa Barat 40559,
Indonesia

e-mail: ¹sprh@jtk.polban.ac.id, ²awaludin@jtk.polban.ac.id, ³muhammad.fadhil.tif418@polban.ac.id,
⁴m.andhika.tif418@polban.ac.id

Informasi Artikel Diterima: 17-06-2022 Direvisi: 31-08-2022 Disetujui: 05-09-2022

Abstrak

Indonesia merupakan negara agraris yang banyak ditanami tumbuhan salah satunya yaitu tanaman kopi. Dalam budidaya kopi terdapat halangan seperti hama dan cuaca ekstrim yang bisa membuat tanaman layu atau terkena penyakit. Dengan teknologi yang berkembang pesat pada masa kini banyak sistem yang membantu para petani untuk membantu mengidentifikasi penyakit pada daun. Sistem ini menggunakan teknologi Convolutional Neural Network untuk mengidentifikasi dan mengklasifikasi penyakit pada daun kopi. Dalam pembangunan Arsitektur CNN diperlukan proses data training, data validation, dan data testing. Banyak metode dan arsitektur CNN yang memperoleh kinerja yang tinggi, salah satu nya adalah ResNet-50. Performa dari model ini dihitung dengan menggunakan Confusion Matrix yang di dalamnya menghitung *accuracy*, *precision*, *recall*, *specificity*, dan F1-Score pada arsitektur ResNet-50 dimana berfokus pada nilai *accuracy* dan F1-Score pada model tersebut, penelitian dilakukan dengan dua kasus yaitu binary class classification dan multiclass classification dimana binary class untuk mengklasifikasi gambar daun kopi robusta sehat dengan yang tidak sehat dan multiclass untuk mengklasifikasikan gambar daun kopi robusta sehat dan daun sakit yang telah terbagi pada setiap jenis kategori yang ada. Hasil dari penelitian menunjukkan pada kasus binary class mencapai *accuracy* 92,68% dan F1-Score mencapai 92,88%, sedangkan pada kasus multiclass *accuracy* hanya mencapai 88,98% dan F1-Score mencapai 88,44%. Kedua kasus tersebut diukur menggunakan data testing dengan model ResNet-50 yang telah dilatih.

Kata Kunci: ResNet-50, Klasifikasi, Kinerja Model.

Abstract

Indonesia is an agricultural country that is widely planted with plants, one of which is coffee plants. In coffee cultivation, there are obstacles such as pests and extreme weather that can cause plants to wither or get diseased. With today's rapidly developing technology, there are many systems that help farmers to help identify leaf diseases. This system uses Convolutional Neural Network technology to identify and classify diseases in coffee leaves. In the construction of the CNN architecture, it is necessary to process data training, data validation, and data testing. Many CNN architectures and methods have achieved high performance, one of which is ResNet-50. The performance of this model will be calculated using the Confusion Matrix which includes calculating accuracy, precision, recall, specificity, and F1-Score on the ResNet-50 architecture which will focus on the accuracy and F1-Score values in the model, the study was conducted with two cases, namely binary class classification and multiclass classification, where binary class is used to classify images of healthy and unhealthy robusta coffee leaves and multiclass is used to classify images of healthy and diseased robusta coffee leaves which have been divided into each category. The results of the study show that in the case of binary class accuracy it reaches 92.68% and F1-Score reaches 92.88%, while in the case of multiclass accuracy it only reaches 88.98% and F1-Score reaches 88.44%. Both cases were measured using data testing with the trained ResNet-50 model.

Keywords: ResNet-50, Classification, Model Performance.



1. Pendahuluan

Indonesia merupakan negara agraris dengan sebagian besar lahannya digunakan untuk pertanian atau perkebunan. Hasil dari pertanian atau perkebunan tersebut bisa dijadikan barang ekspor untuk meningkatkan ekonomi negara. Salah satu tanaman dengan nilai komoditas yang tinggi yaitu tanaman kopi. Negara Indonesia merupakan negara penghasil kopi terbesar keempat dengan nilai produksi 639.305 ton per tahun (Atlas Big, 2020). Kopi sudah menjadi suatu kebutuhan di kalangan masyarakat, tidak hanya orang tua saja yang menikmati kopi. Kopi juga sekarang banyak dinikmati oleh anak-anak muda. Sebelum kopi bisa dinikmati secara langsung kopi membutuhkan proses lagi setelah dipetik dari tanaman kopi.

Petani banyak menghadapi tantangan dalam proses pembudidayaan tanaman. Seperti halnya manusia kopi juga bisa terkena penyakit akibat perubahan cuaca atau hama yang menempel pada halaman tersebut. Tanaman kopi yang terkena penyakit bisa menyebabkan kerugian sekitar 50% (Syakir & Surmaini, 2017). Terdapat banyak penyakit yang bisa menyerang tanaman kopi diantaranya yaitu penyakit karat daun, penyakit jamur upas, penyakit rebah batang dan penyakit akar (Dinas Pertanian Pemerintah Kabupaten Buleleng, 2020).

Setiap bagian tanaman mempunyai peranya masing-masing terutama bagian daun. Fungsi daun yaitu sebagai menyimpan cadangan makanan, alat berkembang biak, alat pernapasan, alat penguapan dan media gutasi. (Al-Amin, 2021) Setelah mengetahui fungsi dari daun maka peran dari daun sangatlah penting bagi tumbuhan. Jika tidak ada daun maka tanaman tersebut layu dan mati. Oleh karena itu penyakit yang paling penting dan harus ditangani dengan benar adalah penyakit daun karat. Sudah beberapa negara yang mendapatkan kerugian akibat penyakit ini diantaranya yaitu negara Uganda mendapatkan kerugian sekitar 30% karena penyakit ini dan negara Kaledonia Baru dalam jangka dua tahun dapat merugikan produksi sekitar 50% (Dinas Perkebunan Provinsi Jawa Barat, 2020).

Penggunaan teknologi yang pesat dapat mempermudah mendeteksi penyakit pada daun tanaman kopi. Dengan menggunakan *dataset* gambar daun tanaman kopi yang berpenyakit maupun sehat, data tersebut dijadikan data *training* untuk *Machine Learning*, sehingga penyakit pada tanaman kopi tersebut dapat diatasi lebih tepat oleh para petani.

Artificial intelligence atau kecerdasan buatan merupakan suatu bidang di ilmu komputer yang berfokus pada proses mesin yang memiliki kemampuan untuk berpikir seperti manusia (Takdirillah, 2020). Namun berbeda dengan manusia, kecerdasan buatan dapat belajar dan menemukan pola dan memproses pola tersebut dengan jauh lebih cepat dan efisien. Di dalam kecerdasan buatan, terdapat sub bidang kecerdasan buatan yang biasa digunakan untuk memprediksi suatu pola dari *dataset* yang diberikan, yaitu *Deep Learning*. *Deep Learning* merupakan salah satu perkembangan dari *machine learning* yang memanfaatkan banyak *layer* untuk pemrosesan *feature extraction* dan *transformation* secara *supervised* atau *unsupervised* yang lebih dalam. Pengamatan yang dilakukan oleh *deep learning* bisa berupa analisis dan klasifikasi suatu pola pada gambar atau menyatakan pernyataan dari suatu gambar misalnya bisa mendeteksi wajah seseorang atau tidak (Deng & Yu, 2013).

Convolutional Neural Network (CNN) merupakan salah satu metode dari *Supervised Deep Learning* yang biasa digunakan pada data *image*. CNN bisa digunakan untuk mendeteksi dan mengenali objek pada sebuah *image* karena cara kerjanya yang terinspirasi dari cara kerja visual manusia dan hewan. CNN memiliki hasil yang sangat signifikan dalam pengenalan citra karena CNN memiliki implementasi menyerupai sistem pengenalan citra pada visual cortex manusia dan hewan. Dengan menggunakan CNN, maka diharapkan model tersebut dapat mengenali gambar penyakit pada daun kopi secara akurat (Lina, 2019).

CNN memiliki beberapa arsitektur di dalamnya seperti LeNet 5, AlexNet, GoogLeNet (*Inception*), dan Resnet. Setiap arsitektur tersebut memiliki kelebihan dan kekurangan masing-masing sehingga perlu diperhatikan pemilihan arsitektur CNN yang digunakan tergantung kegunaannya. ResNet merupakan salah satu arsitektur CNN yang cukup baik dalam segi *accuracy* karena menggunakan metode yang berbeda dibandingkan dengan CNN sebelumnya, yaitu *residual blocks* dan *skip connection* (Great Learning, 2020).

2. Metode Penelitian

Metode penelitian yang dilakukan terdiri dari beberapa tahap yaitu identifikasi masalah, Studi pustaka, Pengumpulan data, Preprocessing data, Pembentukan model, perhitungan hasil kinerja model dengan *confusion matrix*. Pada penelitian ini model ResNet-50 memprediksi penyakit daun kopi robusta pada kasus *binary class* dan *multiclass*.

Pengukuran kinerja model dilakukan juga pada penelitian identifikasi daun kopi menggunakan VGG16 (Windiawan & Aries, 2021).

A. Identifikasi Masalah

Peneliti mengidentifikasi masalah berdasarkan penelitian serupa yang dilakukan yaitu tentang identifikasi penyakit daun kopi menggunakan machine learning VGG16 (Windiawan & Aries, 2021). Hasil dari penelitian tersebut menyatakan bahwa pengklasifikasian dengan VGG16 mencapai akurasi 89% Pada perbandingan *dataset* 60:40 antara data *train* dan data *validation*. Pada penelitian ini akan mengklasifikasikan penyakit daun kopi robusta menggunakan model ResNet-50 dan menghitung hasil kinerja model tersebut menggunakan *confusion matrix*. Kasus yang ditentukan pada penelitian ini yaitu kasus *binary class* dan *multiclass*. Penilaian performa akurasi dan F1-Score akan dihitung menggunakan hasil dari *confusion matrix* yang didalamnya menghitung nilai akurasi, nilai presisi, nilai *recall*, nilai *spesifisitas*, dan nilai F1-Score untuk kasus *binary class*. Sedangkan untuk kasus *multiclass*, kinerja model yang dihitung adalah akurasi model, nilai rata-rata *makro* presisi, nilai rata-rata *makro recall*, dan nilai rata-rata *makro* F1-Score.

B. Studi Pustaka

Pada tahapan ini, peneliti mempelajari teori-teori dasar mengenai *machine learning*, CNN, ResNet-50, Tanaman kopi secara umum, Kopi robusta, jenis-jenis penyakit kopi, dan *confusion matrix* yang berkaitan dengan masalah yang sedang dibahas. Referensi yang didapatkan untuk penelitian ini diperoleh dari berbagai macam laporan penelitian sebelumnya, *website* dan *e-book*.

C. Pengumpulan Data

Dataset yang digunakan dalam penelitian ini adalah dataset *A robusta coffee leaf images dataset* yang tersedia pada *repository dataset Mendeley Data* yang merupakan salah satu situs penyedia dataset yang lebih dari 25.7 juta dataset dari seluruh dunia. Total gambar yang ada pada dataset ini yaitu 1560 data gambar yang masih tercampur antara daun sehat dan daun sakit pada kopi robusta, selain data gambar didalam dataset juga terdapat file *excel* yang didalamnya sudah ada klasifikasi atau kategori daun berdasarkan data gambar yang ada pada dataset ini. Jenis-jenis atau kategori daun yang ada pada dataset ini adalah:

1. Daun sehat
2. Daun berpenyakit *Red Spider Mite*
3. Daun berpenyakit *Rust Level 1*
4. Daun berpenyakit *Rust Level 2*

5. Daun berpenyakit *Rust Level 3*
6. Daun berpenyakit *Rust Level 4*

D. Preprocessing Data

Preprocessing Data merupakan proses pengubahan data mentah menjadi data yang bisa digunakan untuk pelatihan dan pengujian model ResNet-50. Dalam melakukan *preprocessing data* terdiri dari beberapa bagian, yaitu *Data labeling*, *Segmentation Data*, *Data Augmentation*, dan *Data Resize*.

1. Tahap *preprocessing* yang pertama adalah *Data Labeling* dimana setiap gambar pada dataset dipisahkan ke masing-masing folder sesuai klasifikasi atau kategori yang tertulis pada *excel* di dataset yang telah didapatkan.
2. Tahap kedua yaitu *Data Segmentation* dimana gambar daun pada data akan dihilangkan sekitarnya sehingga model akan fokus dan tertuju pada 1 daun yang akan diklasifikasi pada setiap gambar pada dataset.
3. Tahap ketiga yaitu *Data Augmentation* dimana data akan di duplikasi jumlahnya dengan cara merotasi, mencerminkan dan memperbesar gambar, tujuan dari augmentasi data ini agar data seimbang, data augmentasi ini hanya dilakukan pada kasus *multiclass* saja.
4. Tahap keempat yaitu *Data Resize* dimana semua data akan di ubah ukurannya sesuai dengan input model pada ResNet-50.

E. Pembentukan Model

Pada bagian pembentukan data, dataset yang telah melalui *preprocessing* data akan dibagi menjadi 3 jenis data yaitu data *training*, data *validation*, dan data *testing* dimana persentase pembagian data yang dilakukan yaitu 70% untuk data train, 10% untuk data validation, dan 20% untuk data testing. Sumber pembagian data mengikuti penelitian klasifikasi daun apel dengan pembagian data 80% untuk data training dan data testing 20% (Guntur Wicaksono, 2020). Untuk Jumlah data validation penelitian ini mengambil 10% dari data train.

F. Perhitungan Hasil dengan Confusion Matrix

Setelah dilakukan *training* dan *testing* pada model tahap selanjutnya adalah perhitungan *confusion matrix*. *Confusion Matrix* adalah pengukuran performa dari model klasifikasi *machine learning* dimana keluaran dapat berupa dua class atau lebih (Anggraeany, 2020). Terdapat empat istilah yang merupakan representasi kinerja proses klasifikasi pada *confusion matrix* yaitu *true positive*, *true*

negative, false positive, dan false negative. Setelah ditemukan representasi kinerja proses langkah selanjutnya yaitu menghitung kinerja model seperti akurasi, presisi, recall, specificity, dan F1-Score untuk kasus *binary class* (Arthana, 2019). Sedangkan untuk kasus *multiclass* akan dihitung metrics akurasi, rata-rata makro presisi, rata-rata makro recall, dan rata-rata makro F1-Score (Leung, 2022).

$$Accuracy = \frac{TP + TN}{TP + TN + FN + FP} * 100\% \quad (1)$$

$$Precision = \frac{TP}{TP + FP} * 100\% \quad (2)$$

$$Recall = \frac{TP}{TP + FN} * 100\% \quad (3)$$

$$Specificity = \frac{TN}{TN + FP} * 100\% \quad (4)$$

$$F1\ Score = \frac{2 * (Recall * Precision)}{(Recall + Precision)} * 100\% \quad (5)$$

Keterangan:

TP: True Positive

TN: True Negative

FP: False Positive

FN: False Negative

Untuk menghitung kinerja kasus *multiclass*, pengukuran *specificity* tidak diperlukan. Namun untuk menghitung nilai *precision*, *recall*, dan *f1-score* perlu dihitung juga nilai rata-rata *macro average*, dengan menghitung total setiap *metrics* dari setiap kelas kemudian dibagi jumlah kelas yang ada, untuk rumus perhitungan akurasi dan rata-rata *metrics* kinerja lainnya dapat dilihat pada rumus berikut.

$$Accuracy = \frac{Jumlah\ Prediksi\ yang\ benar}{Jumlah\ seluruh\ prediksi} \quad (6)$$

$$MAP = \frac{\sum_{k=1}^K Precision_k}{K} * 100\% \quad (7)$$

$$MAR = \frac{\sum_{k=1}^K Recall_k}{K} * 100\% \quad (8)$$

$$MAF = \frac{\sum_{k=1}^K F1Score_k}{K} * 100\% \quad (9)$$

Keterangan:

MAP: Macro Average Precision

MAR: Macro Average Recall

MAF: Macro Average F1-Score

K: Jumlah kelas pada sistem klasifikasi *multiclass*

3. Hasil dan Pembahasan

Tahap ini merupakan hasil dari training yang telah dilakukan yang dibagi menjadi 2 hasil, yaitu hasil kinerja dari kasus *binary class* dan hasil kasus pada *multiclass*. Pada Tabel 1 merupakan skenario yang akan dilakukan pada penelitian ini.

Tabel 1. Skenario Penelitian

Skenario	Learning rate	Batch size
(B/M).1	10 ⁻³	16
(B/M).2	10 ⁻³	32
(B/M).3	10 ⁻³	64
(B/M).4	10 ⁻⁴	16
(B/M).5	10 ⁻⁴	32
(B/M).6	10 ⁻⁴	64

Sumber : Penelitian (2022)

Berdasarkan Tabel 1. *Learning rate* yang digunakan pada penelitian ini yaitu 10⁻³ dan 10⁻⁴ seperti penelitian yang dilakukan (Windiawan & Aries, 2021). Nilai *Batch Size* yang digunakan yaitu 16,32,dan 64 seperti penelitian yang dilakukan (Masters & Carlo, 2018). Epoch yang digunakan penelitian ini yaitu 200 epoch karena jika menggunakan epoch dibawah 200, nilai dari validasi akurasi skenarionya masih naik dan untuk validasi nya masih turun sehingga belum terjadi *overfit*. Oleh karena itu ditetapkan epoch 200 untuk penelitian ini agar sesuai untuk skenario dengan learning rate 10⁻³ dan 10⁻⁴. Skenario ini berlaku pada kedua kasus yaitu kasus *binary class* dan *multiclass*.

A. Kasus Binary Class

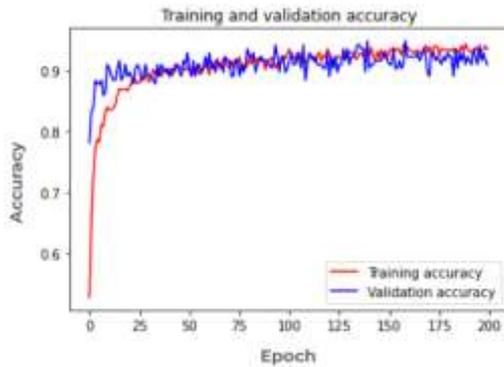
Sub bab ini akan menjelaskan hasil penelitian dan kinerja pada kasus *binary class*. Data yang digunakan sebanyak 1560 data gambar daun sakit dan sehat tanpa adanya proses augmentasi, Tabel 2 menunjukkan hasil kinerja model pada kasus *binary class*.

Tabel 2. Hasil dari Kinerja Model Kasus Binary Class

Skenario	Akurasi	Presisi	Recall	Specificity	F1-Score
B.1	0.9236	0.9245	0.9245	0.9226	0.9245
B.2	0.9268	0.9198	0.9371	0.9161	0.9283
B.3	0.9236	0.9141	0.9371	0.9097	0.9255
B.4	0.9204	0.8988	0.9497	0.8903	0.9235
B.5	0.9268	0.9146	0.9434	0.9097	0.9288
B.6	0.9204	0.9187	0.9245	0.9161	0.9216

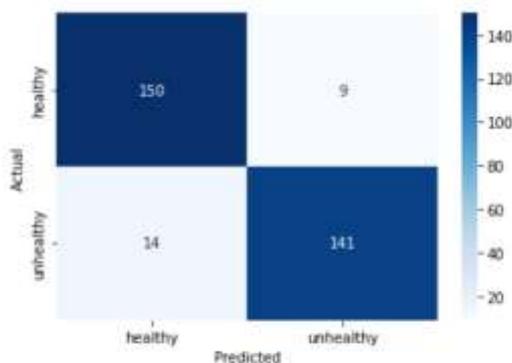
Pada Tabel 2. ditunjukkan hasil dari *testing* dari model yang sudah di *training*, dapat dilihat bahwa skenario B.5 mempunyai nilai

akurasi dan F1-Score paling tinggi diantara semua skenario dengan 92,68% dan F1-Score mencapai 92,88% pada *learning rate* 10^{-4} dan *batch size* 32. Gambar 1 merupakan hasil dari akurasi dari *training* yang dilakukan pada skenario terbaik dalam kasus *binary class*.



Gambar 1. Hasil Akurasi dari *Training* Skenario B.5

Hasil dari training bisa dilihat pada Gambar 1 selama epoch 200 nilai akurasi pada *validasi* tidak menurun yang tandanya bahwa model ini tidak mengalami *underfit* atau *overfit*. Kemudian pada Gambar 2 merupakan tabel *confusion matrix* dari hasil *testing* pada skenario B.5.



test accuracy : 92.67515923566879

Gambar 2. Hasil *Confusion Matrix* pada Skenario B.5

Dari Gambar 2 untuk nilai *true positive* berjumlah 150 gambar daun sehat yang diklasifikasi benar dan *true negative* berjumlah 9 gambar yang diklasifikasikan salah, nilai *false positive* berjumlah 14 gambar daun sakit yang diklasifikasikan salah, dan yang terakhir nilai *false negative* dengan jumlah 141 gambar daun yang sakit dan diklasifikasikan benar.

B. Kasus Multiclass

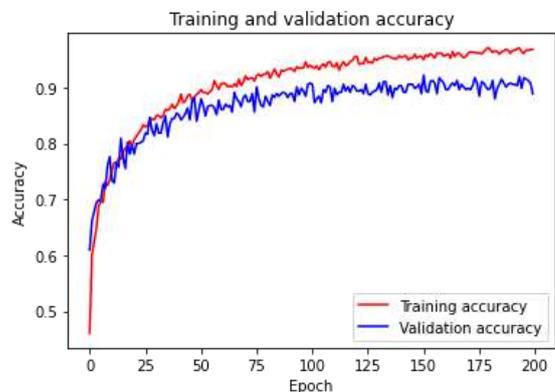
Sub bab ini akan menjelaskan hasil penelitian dan kinerja pada kasus *multiclass*. Data yang digunakan sebanyak 4275 setelah

melakukan data *augmentasi*. Tabel 3 menunjukkan hasil kinerja model pada kasus *multiclass*.

Tabel 3. Hasil Kinerja Model Kasus *Multiclass*

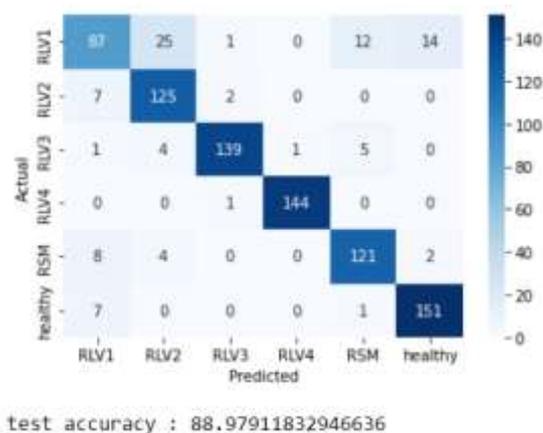
Skenario	Akurasi	Macro Avg Precision	Macro Avg Recall	Macro Avg F1-Score
M.1	0.8898	0.8870	0.8874	0.8844
M.2	0.8735	0.8722	0.8684	0.8689
M.3	0.8596	0.8561	0.8564	0.8529
M.4	0.8237	0.8169	0.8182	0.8167
M.5	0.7610	0.7578	0.7551	0.7547
M.6	0.7390	0.7303	0.7317	0.7286

Berdasarkan Tabel 3, dapat dilihat bahwa skenario M.1 mempunyai akurasi dan *f1-score* paling tinggi diantara semua skenario dengan akurasi 88,98% dan *f1-score* mencapai 88,44% pada *learning rate* 10^{-3} dan *batch size* 16. Gambar 3 merupakan hasil akurasi dari *training* yang dilakukan pada skenario tersebut.



Gambar 3. Hasil Akurasi dari Training Skenario M.1

Hasil dari training bisa dilihat pada Gambar 3 selama epoch 200 nilai akurasi pada *validasi* tidak menurun namun berada dibawah akurasi dari training. Untuk model tersebut hampir mengalami *overfit* akibat kurang seimbangnnya data yang digunakan pada setiap kategori. Kemudian pada Gambar 4 merupakan tabel *confusion matrix* dari hasil *testing* pada skenario M.1.



Gambar 4. Hasil *Confusion Matrix* pada Skenario M.1

Dari Gambar 4, diagonal dari gambar tersebut menunjukkan setiap kategori gambar yang diklasifikasikan benar untuk data yang mendatar dari kategori yang diprediksi benar merupakan nilai setiap kategori yang *false negative*, dan data yang tegak lurus dengan kategori yang diklasifikasikan benar merupakan *false positive*.

4. Kesimpulan

Hasil dari penelitian yang telah dilakukan yaitu model ResNet-50 pada kasus *binary class* dan *multiclass* dengan pembagian data *training* 70%, data *validation* 10%, dan data *testing* 20% dengan jumlah data pada kasus *binary class* sebanyak 1560 data gambar daun sehat, dan daun sakit, sedangkan data gambar *multiclass* sebanyak 4275 data gambar daun untuk semua kategori dapat disimpulkan bahwa memiliki performa paling baik pada kasus *binary class* dengan akurasi sebesar 92,68% dan nilai *f1-score* sebesar 92,88%, sedangkan pada kasus *multiclass* performa paling baik hanya mendapat akurasi sampai 88,98% dan nilai *f1-score* mencapai 88,44%. Nilai kinerja yang dihasilkan untuk klasifikasi kasus *multiclass* tidak sebaik nilai kinerja yang dihasilkan oleh klasifikasi kasus *binary class*. Peneliti lain dapat menggunakan kualitas dataset yang baik atau memodifikasi model ResNet-50 dengan metode lain agar mendapatkan hasil akurasi dan *f1-score* yang lebih baik.

Referensi

Al-Amin, M. I. (2021, Desember 9). *Mengenal Fungsi Daun dan Struktur pada Tumbuhan*. (Katadata.co.id) Dipetik April 17, 2022, dari <https://katadata.co.id/intan/berita/61b0e4dc2036a/mengenal-fungsi-daun-dan-struktur-pada-tumbuhan>

- Angraeany, M. S. (2020, November 1). *Confusion Matrix*. (School of Computer Science Binus University) Dipetik Januari 3, 2022, dari <https://socs.binus.ac.id/2020/11/01/confusion-matrix/>.
- Arthana, R. (2019, April 5). *Mengenal Accuracy, Precision, Recall, dan Specificity Serta yang Diprioritaskan Dalam Machine Learning*. Diambil kembali dari Medium: <https://rey1024.medium.com/mengenal-accuracy-precision-recall-dan-specificity-serta-yang-diprioritaskan-b79ff4d77de8>
- Atlas Big. (2020). *Produksi Kopi Dunia Menurut Negara*. (Atlas Big) Dipetik February 20, 2022, dari <https://www.atlasbig.com/id/negara-dengan-produksi-kopi>
- Deng, L., & Yu, D. (2013). Deep Learning: Methods and Applications. *Foundations and Trends, 3-4*, 197-387. Dipetik July 05, 2022
- Dinas Perkebunan Provinsi Jawa Barat. (2020, Oktober 4). *Ancaman Penyakit Karat Daun Pada Tanaman Kopi*. (Dinas Perkebunan Provinsi Jawa Barat) Dipetik February 20, 2022, dari <https://disbun.jabarprov.go.id/post/view/618-id-ancaman-penyakit-karat-daun-pada-tanaman-kopi>
- Dinas Pertanian Pemerintah Kabupaten Buleleng. (2020, Juli 7). *Pengenalan Dan Pengendalian Penyakit Tanaman Kopi*. (Dinas Pertanian Pemerintah Kabupaten Buleleng) Dipetik April 16, 2022, dari <https://distan.bulelengkab.go.id/informasi/detail/artikel/pengenalan-dan-pengendalian-penyakit-tanaman-kopi-66>
- Great Learning. (2020, September 28). *Introduction to Resnet or Residual Network*. (Great Learning) Dipetik April 5, 2022, dari <https://www.mygreatlearning.com/blog/resnet/#:~:text=ResNet%2C%20short%20for%20Residual%20Network,Residual%20Learning%20or%20Image%20Recognition%E2%80%9D>
- Guntur Wicaksono, S. A. (2020). Aplikasi Pendeteksi Penyakit Pada Daun Tanaman Apel Dengan Metode Convolutional Neural Network. *JOINTECS, 5*(1), 09-16.
- Leung, K. (2022, January 4). *Micro, Macro & Weighted Averages of F1 Score, Clearly Explained*. Diambil kembali dari Towards Data Science: <https://towardsdatascience.com/micro-macro-weighted-averages-of-f1-score-clearly-explained-b603420b292f>
- Lina, Q. (2019, Januari 2). *Apa itu Convolutional Neural Network?* (Medium) Dipetik Februari 8, 2022, dari <https://medium.com/@16611110/apa-itu-convolutional-neural-network-836f70b193a4>

- Masters, D., & Carlo, L. (2018). Revisiting Small Batch Training For Deep Neural Networks. *Graphcore Research*.
- Syakir, M., & Surmaini, E. (2017). Perubahan Iklim Dalam Konteks Sistem Produksi Dan Pengembangan Kopi Di Indonesia. *Jurnal Litbang Pertanian*, 36(2), 77-90.
- Takdirillah, R. (2020, Juli 15). *Apa Itu Kecerdasan Buatan? Berikut Pengertian dan Contohnya*. (Dicoding) Dipetik April 4, 2022, dari <https://www.dicoding.com/blog/kecerdasan-buatan-adalah/>
- Windiawan, R., & Aries, S. (2021). Identifikasi Penyakit pada Daun Kopi Menggunakan Metode Deep Learning VGG16. *Journal Keilmuan dan Aplikasi Teknik Informatika*, 13(2), 43-50.