

# Model Deteksi Penyakit Karat Daun Pada Tanaman Kopi Menggunakan Metode Convolutional Neural Network (CNN) dan Recurrent Neural Networks (RNNs)

Rahmad Hidayat<sup>1\*</sup>, Hari Toha Hidayat, S.Si., M.Cs<sup>2</sup>, Ilham Safar, S.ST., M.Kom<sup>3</sup>, Riwanul Nasron, S.T.,M.T<sup>4</sup>

<sup>1,2,3,4</sup>Jurusan Teknologi Informasi dan Komputer Politeknik Negeri Lhokseumawe  
Jln. B.Aceh Medan Km.280 Buketrata 24301 INDONESIA

\*Penulis Korespondensi : rahmad\_hidayat@pnl.ac.id

**Abstrak**— Kopi merupakan komoditas tropis utama dalam subsektor perkebunan yang memiliki kontribusi signifikan bagi perekonomian Indonesia, baik di pasar domestik maupun internasional. Indonesia merupakan negara produsen kopi terbesar keempat di dunia dan mengalami peningkatan produksi dari tahun ke tahun jumlah produksi kopi Indonesia mencapai 774, 60 ribu ton pada 2021. Rata-rata produktivitas perkebunan kopi gayo adalah 750 kilogram per hektar per tahun, dimana jumlah ini lebih rendah dari pada potensi produksi sesungguhnya. Faktor-faktor yang mempengaruhi produktivitas perkebunan kopi Gayo antara lain faktor cuaca, kondisi tanah, perawatan yang belum optima, dan serangan hama yang cukup sering terjadi. Salah satu hama yang cukup dominan menyerang perkebunan kopi adalah hama *Hemileia vastatrix* atau hama karat daun. Karat daun kopi ditandai dengan perkembangan bercak berwarna kuning atau belang, tepung oranye atau bercak pada bagian bawah daun kopi, dengan klorotik mengelompok pada sisi atas daun. Diameter bercak awalnya 2-3mm namun sebagaimana penyakit berkembang, bercak meluas dan dapat menjadi beberapa sentimeter diameternya. Penyakit ini telah berkembang sejak abad 19, dan sampai saat ini menjadi salah satu penyakit yang paling merugikan petani. Penelitian ini mengembangkan model deep learning untuk membantu petani mendeteksi penyakit tersebut. Dataset diakuisisi pada perkebunan kopi Gayo yang terdiri dari citra daun yang sehat dan daun yang terserang hama karat daun. Penelitian ini menggabungkan beberapa klasifier yaitu Convolutional Neural Network (CNN) dan Recurrent Neural Networks (RNNs). Hasil klasifikasi masing-masing arsitektur digabungkan menggunakan metode ensemble voting untuk meningkatkan akurasi prediksi akhir yang didapat. Tujuan pemanfaatan metode ensemble adalah karena masing-masing arsitektur deep learning memiliki kelemahan dan kelebihan masing-masing.

**Kata kunci**— kopi gayo, produksi, hama, karat daun, deep learning

**Abstract**— Coffee is a major tropical commodity in the plantation subsector, contributing significantly to the Indonesian economy, both domestically and internationally. Indonesia is the world's fourth-largest coffee producer, with annual production increasing to 774,600,000 tons in 2021. The average productivity of Gayo coffee plantations is 750 kilograms per hectare per year, which is lower than the actual production potential. Factors affecting Gayo coffee plantation productivity include weather, soil conditions, suboptimal maintenance, and frequent pest attacks. One of the most dominant pests attacking coffee plantations is *Hemileia vastatrix*, also known as coffee leaf rust. Coffee leaf rust is characterized by the development of yellow or striped spots, orange powdery spots, or blotches on the undersides of coffee leaves, with chlorotic clusters on the upper side. The spots are initially 2-3 mm in diameter, but as the disease progresses, the spots expand and can reach several centimeters in diameter. This disease has been prevalent since the 19th century and remains one of the most detrimental to farmers. This research develops a deep learning model to assist farmers in detecting diseases. The dataset, acquired from a Gayo coffee plantation, consists of images of healthy leaves and leaves infected with leaf rust. This research combines several classifiers, namely Convolutional Neural Networks (CNNs) and Recurrent Neural Networks (RNNs). The classification results of each architecture are combined using an ensemble voting method to improve the accuracy of the final predictions. The purpose of utilizing the ensemble method is that each deep learning architecture has its own weaknesses and strengths.

**Keywords**— Gayo coffee, production, pests, leaf rust, deep learning;

## I. PENDAHULUAN

Kopi merupakan komoditas tropis utama dalam subsektor perkebunan yang memiliki kontribusi signifikan bagi perekonomian Indonesia, baik di pasar domestik maupun internasional [1-3]. Indonesia merupakan negara produsen kopi terbesar keempat di dunia dan mengalami peningkatan produksi dari tahun ke tahun jumlah produksi kopi Indonesia mencapai 774, 60 ribu ton pada 2021. Jumlah itu meningkat sekitar 1,62% dari tahun sebelumnya yang sebanyak 762,20 ribu ton dan akan diprediksi terus meningkat pada tahun-tahun berikutnya [4].

Salah satu daerah penghasil kopi yang berada di Provinsi Aceh yaitu Dataran Tinggi Gayo merupakan wilayah yang sangat terkenal akan tanaman kopinya yang sering dikenal dengan nama Kopi Gayo yang telah mendapatkan sertifikasi Indikasi Geografis. Banyak permintaan kopi arabika Indonesia dari berbagai daerah di Indonesia salah satunya di daerah Dataran Tinggi Gayo mempunyai karakteristik citarasa (acidity,

aroma, flavour) yang sangat diminati oleh pecinta kopi karena keunikan dan cita rasanya. Dari Total produksi kopi Indonesia, 550.000 ton (81,2%) berupa kopi robusta dan 125.000 ton (18,8%) berupa kopi arabika. Provinsi Aceh adalah produk kopi arabika terbesar di Indonesia .

Dari keseluruhan kopi arabika yang berasal dari daerah Provinsi Aceh hampir keseluruhannya berasal dari Dataran Tinggi gayo, yang meliputi Kabupaten Aceh Tengah, Kabupaten Bener Meriah, dan Kabupaten Gayo Lues. Berdasarkan data BPS tahun 2015 disebutkan bahwa total luas tanah tahun 2011 mencapai sekitar 95.00 ha, yang terdiri atas 48.500 ha total produksi 0,68 ton per hektar pertahun di Aceh Tengah, 39.000 ha total produksi 0,78 to per hektar pertahun di Bener Meriah, dan 7.000 ha total produksi 0,5 ton per hektar pertahun di Gayo Lues [5-7]. Jumlah petani kopi khususnya di daerah Kabupaten Aceh Tengah mencapai 34.476 keluarga dengan rata-rata memiliki lahan mencapai 1,4 ha [4]. Kalau seandainya diasumsikan bawah terdapat 4 orang di satu keluarga itu, maka 137.904 orang yang tinggal di

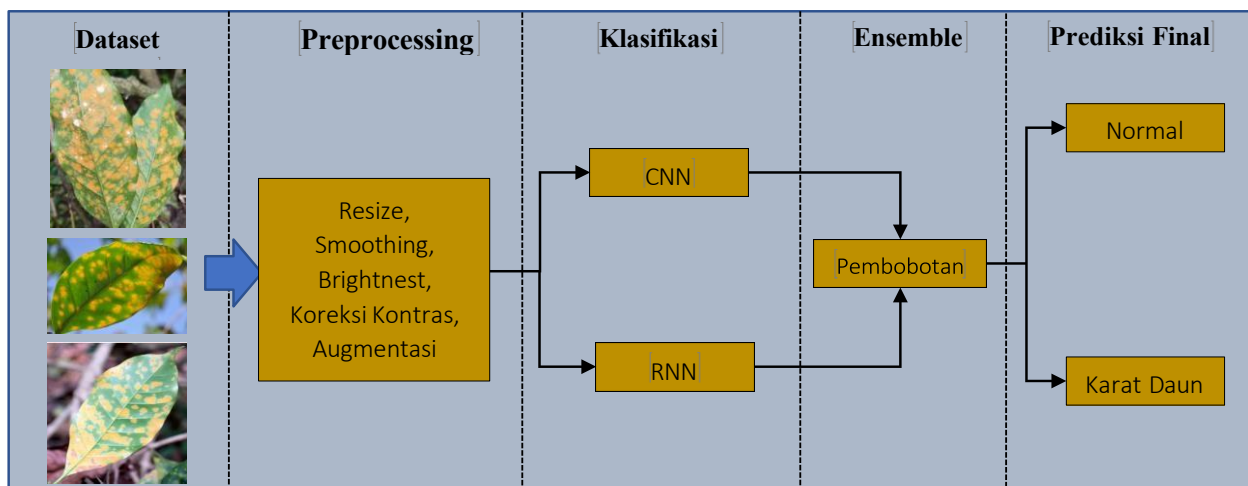
Kabupaten Aceh Tengah menggantungkan hidupnya pada kebun kopi. Jumlah itu setara dengan hampir 90% total penduduk Aceh Tengah yang mencapai 150.231 jiwa [8-10].

Kopi Gayo merupakan jenis tanaman yang di olah biji yang sudah di haluskan untuk dijadikan sebuah minuman yang banyak diminati oleh masyarakat. Ada beberapa jenis kopi diantaranya Arabica, Robusta, Luwak, Tubruk dan masih banyak lagi, namun kopi mengandung sedikit nutrisi tetapi mengandung lebih dari ribuan bahan kimia alami seperti karbohidrat, senyawa nitrogen, lipid, mineral, vitamin, senyawa fenolik, dan alkaloid. Dataran Tinggi Gayo yang terletak diperbukitan tidak menutup kemungkinana bahwa tanaman kopi yang berkualitas ini tidak mempunyai kendala seperti salah satunya adalah bahwa tanaman-tanaman kopi gayo yang di tanam di Dataran Tinggi Gayo sebagian besar pasti akan terserang penyakit-penyakit yang akan mempengaruhi produktifitas dan kualitas dari Kopi Gayo itu, ketika tanaman kopi gayo diserang hama maka akan menurunkan mutu pada kopi tersebut dan mengakibatkan produktivitas dari tahun ke tahun mulai turun [11].

Data Badan Pusat Statistik Aceh menyebutkan, produksi kopi yang berada di daerah di Kabupaten Bener Meriah secara keceluruhan naik.

Daun, maupun daun yang sehat sehingga petani kopi gayo dapat dengan lugas mengantisipasi akan penyakit tersebut. Informasi mengenai penyakit daun pada tanaman kopi sebenarnya telah tersedia, namun tantangan utama adalah bagaimana menyediakan alat atau metode yang cepat, akurat, dan mudah digunakan untuk membantu petani dalam mendeteksi penyakit tersebut, Maka dari itu dibutuhkanna sebuah sistem pendeteksi penyakit daun pada tanaman kopi gayo .

Penelitian ini mengembangkan model deep learning untuk membantu petani mendeteksi penyakit karat daun tersebut. Dataset diakuisisi pada perkebunan kopi Gayo yang terdiri dari citra daun yang sehat dan daun yang terserang hama karat daun. Penelitian ini menggabungkan beberapa klasifier yaitu Convolutional Neural Network (CNN). Keunggulan utama CNN terletak pada kemampuannya untuk mengklasifikasikan citra dengan tingkat akurasi tinggi. Hal ini disebabkan oleh kemampuannya untuk mengurangi jumlah parameter bebas dan menangani deformasi gambar input, seperti translasi, rotasi, dan skala. Selain itu, CNN juga bekerja lebih baik dengan dataset gambar yang besar dan memberikan akurasi yang lebih tinggi dalam banyak kasus.



Gambar 2. Tahapan dalam Model Deteksi Penyakit Karat Daun Pada Tanaman Kopi Menggunakan Metode Ensemble Deep Learning

Namun, kenaikan itu tidak sesuai dengan kenaikan luas lahan pada tahun 2010 mencapai 87.533 hektar, sedangkan pada tahun 2014 seluas 97.796 ha. Adapun produksi kopi gayo pada 2010 sebanyak 41.027 ton, sedangkan pada 2014 meningkat sedikit menjadi 42.079 ton. Dapat disimpulkan bawah kejadian-kejadian tersebut diakibatkan oleh penurunan produktivitas tanaman kopi yang disebabkan oleh tanaman yang terjangkit oleh penyakit atau hama kopi gayo [12-14].

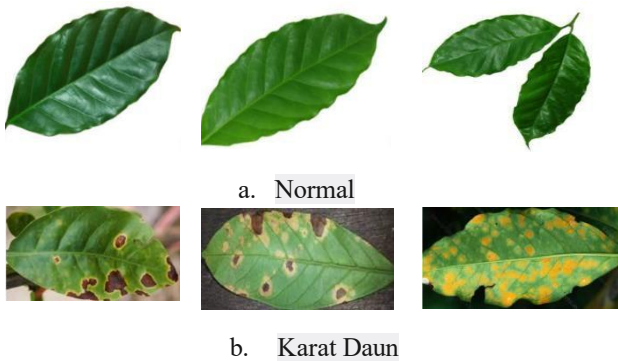
Hama tersebut dapat menyerang dari daun, batang, ataupun akar. Dalam dunia biologi, daun sering digunakan untuk menandakan kesehatan pada daun dengan melihat warna karena daun berkaitan terhadap kandungan klorofil dan sebagai pigmen yang dibutuhkan untuk proses kehidupan pada tumbuhan [15]. sehingga sejumlah besar petani kopi gayo perlu menentukan beberapa kriteria untuk menunjang berbagai tanaman kopi. Untuk menentukan tumbuhan kopi gayo mana yang sehat dan mana yang terjaring penyakit melalui daun kopi, maka harus diciptakan kriteria dan pengenalan dari penyakit daun kopi. Semisal Nematoda, karat Daun, Bercak

## II. METODOLOGI PENELITIAN

Secara umum terdapat 5 tahapan pada usulan penelitian ini yaitu: Dataset, Preprocessing, Klasifikasi, Ensemble dan Prediksi Akhir. Tahap pertama adalah mengumpulkan dan menelaah dataset Dataset Karat Daun Kopi Gayo (KDKG) yang akan digunakan. Pada tahapan Peprocessing, kualitas citra yang terdapat dalam dataset KDKG ditingkatkan , baik dengan melakukan perbaikan kontras, brightnest, mengatur (menyeragamkan) ukuran, dan augmentasi. Tahapan selanjutnya adalah klasifikasi, dimana dua arsitektur deep learning CNN dengan data yang diambil secara acak dari dataset. Selanjutnya, hasil prediksi dari masing-masing arsitektur kemudian digabungkan (ensemble) dengan menggunakan metode Voting untuk mendapatkan hasil akurasi yang lebih baik. Hasil akurasi akhir didapatkan setelah proses Voting selesai dilakukan. Gambar 2 menunjukkan tahapan yang dilakukan pada usulan penelitian ini.

- Dataset

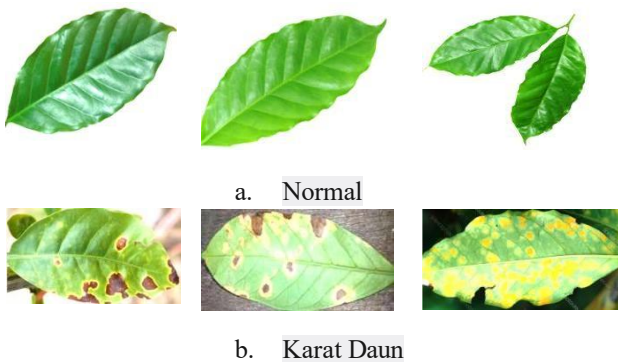
Dataset Karat Daun Kopi Gayo (KDKG) merupakan himpunan citra daun normal dan daun yang terserang karat daun yang peneliti akusisi dari perkebunan kopi di daerah Gayo. Sampai saat jumlah citra yang terkumpul sebanyak 300 citra daun normal dan 300 citra daun yang terserang karat daun. Citra dalam dataset KDKG memiliki ukuran rata-rata 500x500 piksel dan memiliki format PNG. Gambar 3 menampilkan contoh citra yang terdapat pada masing-masing kelas pada dataset KDKG.



Gambar 3. Contoh citra untuk masing-masing kelas pada dataset KDKG

- Preprocessing

Salah satu langkah yang sering digunakan untuk meningkatkan kualitas citra adalah dengan melakukan perbaikan kontras. Kontras yang tidak seragam dapat dalam citra dapat mengaburkan bahkan membuat fitur-fitur penting tersembunyi sehingga akurasi klasifikasi dapat menurun. Metode Histogram Equalization menggunakan komputasi yang sederhana dalam meningkatkan nilai kontras pada citra secara global, terutama jika nilai kontras pada citra terletak pada jarak yang berdekatan. Melalui penyesuaian ini, intensitas kontras dapat terdistribusi dengan lebih baik. Hasil citra sebelum dan setelah dilakukan preprocessing ditampilkan pada Gambar 4.



Gambar 4. Hasil preprocessing pada citra yang terdapat pada dataset KDKG

Untuk meningkatkan akurasi dan mencegah terjadinya overfitting (dimana model memasukan noise dan fitur-fitur yang tidak relevan sebagai bahan pembelajaran) maka dilakukan pendekatan dengan menggunakan data augmentasi. Karakteristik augmentasi yang digunakan pada usulan penelitian ini ditampilkan pada Tabel 2.

Tabel 2. Karakteristik Augmentasi

Proses	Nilai
Rescale	1./255
Rotation	45
Horizontal Flip	TRUE
Zoom	0.2

Data augmentasi membangkitkan data training tambahan dari data yang sudah ada dengan melakukan berbagai transformasi. Berikut implementasi augmentasi dalam kode python:

```
train_datagen = ImageDataGenerator(
    rescale=1./255,
    brightness_range=(0.8, 1.2),
    rotation_range=20,
    width_shift_range=0.1,
    height_shift_range=0.1,
    zoom_range=0.2,
    horizontal_flip=True,
    fill_mode='nearest'
)
```

Citra hasil operasi augmentasi ditampilkan pada Gambar 5.



Gambar 5. Citra hasil Augmentasi

- Klasifikasi Klasifikasi

Penelitian ini menggunakan 2 arsitektur deep learning yang sangat populer yaitu : Convolutional Neural Network (CNN) dan Recurrent Neural Networks (RNNs). Convolutional Neural Network (CNN) termasuk dalam jenis Deep Neural Network karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. CNN terdiri dari satu atau lebih convolutional layer dan subsampling layer serta diikuti oleh layer yang menghubungkan secara keseluruhan seperti dalam standar jaringan syaraf [14]. CNN terbentuk oleh berlapis-lapis neuron memperoleh masukan dari layer input, melakukan dotproduct pada layer-layer berikutnya dan menghasilkan keluaran pada layer output. Pada umumnya semakin banyak jumlah layer, semakin tinggi akurasi dan semakin kompleks kemampuan dari jaringan, namun pada suatu titik akan menjadi kompleks return, dimana peningkatan jumlah layer tidak meningkatkan kinerja dari jaringan. Network ini dilatih untuk mengambil data mentah dan membuat korelasi antara data tersebut terhadap skor yang diperoleh diakhir. Semakin tinggi skor,

semakin bias jaringan terhadap konfigurasi tertentu yang menghasilkan skor tersebut. Gambar yang dimasukkan kedalam CNN sebaiknya di-downscale terlebih dahulu. Gambar yang berukuran besar akan menghasilkan jumlah piksel sebanyak hasil perkalian dari panjang piksel, lebar piksel, dan color channel dari gambar. Dengan melakukan downscaling akan mempersingkat waktu yang diperlukan untuk melatih jaringan nantinya. Berikut arsitektur CNN yang digunakan dalam penelitian ini :

```
model = tf.keras.Sequential([
    base_model,
    tf.keras.layers.Conv2D(32,
        kernel_size=3, padding='same',
        activation='relu'),
    tf.keras.layers.MaxPool2D(pool_size=2,
        strides=2),
    tf.keras.layers.Dropout(rate=0.5),
    tf.keras.layers.Flatten(),
    tf.keras.layers.Dense(3,
        activation='softmax')
])
```

Recurrent neural network (RNN) adalah sistem algoritma tertua yang telah dikembangkan sejak tahun 1980-an. Sistem ini dinilai penting karena menjadi satu-satunya sistem yang memiliki memori internal pada masa itu. Kemudian, pada 1990-an, banyak modifikasi yang menyempurnakan RNN, salah satunya adalah long short term memory (LSTM). Sebagai sebuah sistem algoritma, Recurrent neural network dapat mengingat input dan selanjutnya memberikan output sesuai dengan yang diinginkan. Memori internal menjadi poin penting dalam Recurrent neural network karena dapat memprediksi hal berikutnya. Sehingga, Recurrent neural network sangat cocok untuk diaplikasikan pada deret waktu, mesin pencarian, teks, audio, video, bahkan mesin keuangan [15]. Strategi pelatihan pada masing-masing arsitektur adalah pelatihan dilakukan dengan menggunakan data yang diambil dari dataset secara acak. Arsitektur-arsitektur tersebut kemudian dilatih secara paralel dan kemudian hasil klasifikasinya digabungkan dengan metode ensemble dengan menggunakan bobot. Citra yang digunakan pada proses pelatihan dan pengujian memiliki tiga dimensi yaitu Lebar (L), Tinggi (T), dan Kedalaman (K). Citra yang digunakan dinormalisasi kedalam ukuran 227x227x3, dimana K menunjukkan jumlah channel warna yang digunakan. Berikut arsitektur RNN dalam penelitian ini :

```
model = Sequential()
model.add(LSTM(128, input_shape=(None,
    len(chars))))
model.add(Dense(len(chars),
    activation='softmax'))
# compile the model
model.compile(loss='categorical_crossentropy',
    optimizer='adam')
# train the model
model.fit(x, y, batch_size=128, epochs=20)
```

- Metode Ensemble (Pembobotan)

Metode Ensemble dengan menggunakan pembobotan melakukan operasi sederhana dimana hasil prediksi masing-masing arsitektur dikumpulkan, dan klasifier dengan akurasi terbaik akan diberi bobot lebih tinggi sedahkan klasifier yang lebih rendah selanjutnya diberi bobot yang lebih rendah.

Tabel 3. Simulasi Pembobotan menggunakan 2 Klasifier

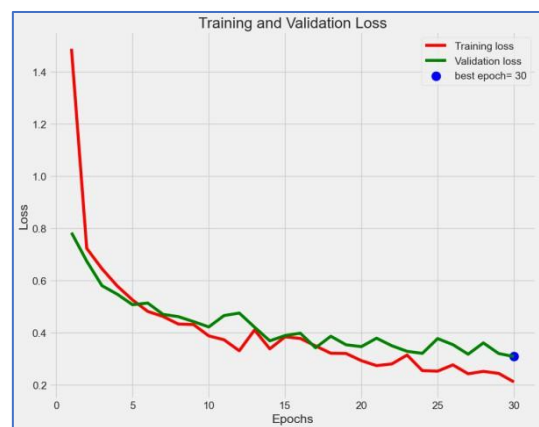
No	Data	Klasifier 1	Klasifier 2	Prediksi Akhir
1	Citra 1	Normal	Normal	Normal
2	Citra 2	Normal	Karat Daun	Normal
3	Citra 3	Karat Daun	Karat Daun	Karat Daun
4	Citra 4	Karat Daun	Normal	Karat Daun

Pada penelitian ini, terdapat dua kelas yang menjadi output yaitu kelas normal dan kelas karat daun. Tabel 3 menampilkan simulasi pembobotan dengan menggunakan 2 klasifier. Berdasarkan tabel diatas, Citra 1 mendapat hasil prediksi normal pada Klasifier 1, sementara pada Klasifier 2 mendapatkan hasil prediksi juga normal sehingga prediksi akhir menjadi normal. Hal ini disebabkan Klasifier 1 memiliki bobot yang lebih tinggi dari Klasifier 2. Begitu juga proses pengambilan hasil prediksi akhir untuk Citra 2 sampai dengan Citra 4.

III. HASIL DAN PEMBAHASAN

3.1 Hasil Evaluasi Akurasi dan Loss

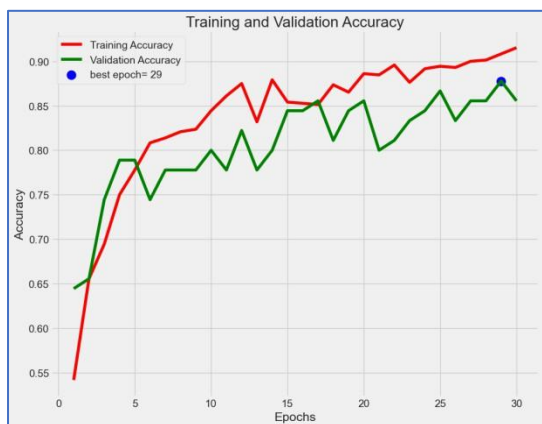
Selama proses pelatihan, nilai akurasi dan loss untuk data pelatihan dan validasi dipantau untuk mengidentifikasi tren performa model. Hasil menunjukkan peningkatan akurasi yang stabil dan penurunan nilai loss seiring bertambahnya jumlah epoch, tanpa indikasi overfitting yang signifikan. Berdasarkan evaluasi akhir pada data uji, diperoleh nilai loss sebesar 0,2165 dan akurasi sebesar 91,11%. Nilai loss yang rendah mengindikasikan bahwa model mampu meminimalkan kesalahan prediksi, sedangkan akurasi yang tinggi menunjukkan kemampuan model dalam mengklasifikasikan citra daun kopi Gayo ke dalam kelas yang sesuai secara konsisten.



Gambar 6. Grafik Loss

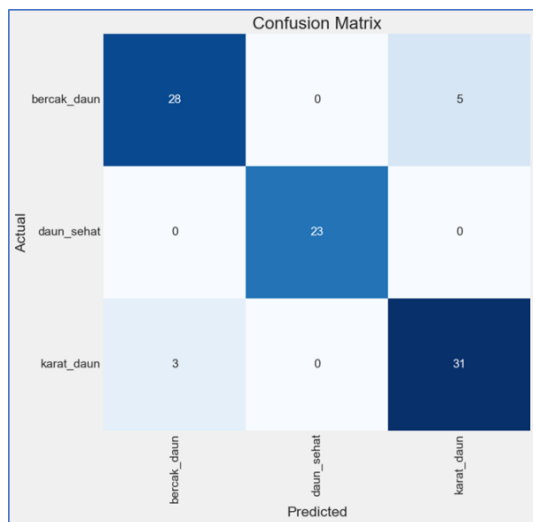
Dengan mempertimbangkan kompleksitas visual pada dataset dan jumlah kelas (tiga kelas: karat daun, bercak daun, dan daun sehat), hasil ini membuktikan bahwa pendekatan CNN berbasis transfer learning dengan arsitektur

NASNetMobile memberikan performa yang baik dan dapat diandalkan. Gambar hasil akurasi grafik model loss dan akurasi dapat dilihat pada Gambar 6 dan Gambar 7.



Gambar 7. Grafik Akurasi

Confusion matrix digunakan untuk mengevaluasi performa model CNN dalam mengklasifikasikan citra daun kopi Gayo ke dalam tiga kelas, yaitu: bercak daun, daun sehat, dan karat daun. Matriks ini menunjukkan hubungan antara label sebenarnya (actual) dan hasil prediksi model (predicted). Gambar 3.3 berikut ini menunjukkan confusion matrix hasil pengujian model terhadap data uji.



Gambar 3.3 Confusion matrix hasil pengujian model terhadap data uji

Interpretasi Confusion Matrix berupa Kelas "bercak\_daun": dari 33 citra, sebanyak 28 gambar diklasifikasikan dengan benar, sementara 5 gambar salah diklasifikasikan sebagai "karat\_daun", kelas "daun\_sehat": seluruh 23 gambar diklasifikasikan dengan benar, tanpa kesalahan klasifikasi dan kelas "karat daun": dari 34 gambar, sebanyak 31 gambar diklasifikasikan dengan benar, dan 3 gambar salah diklasifikasikan sebagai "bercak\_daun". Dari confusion matrix ini, terlihat bahwa kelas "daun\_sehat" memiliki tingkat akurasi sempurna (100%), kesalahan terbesar terjadi antara kelas "bercak\_daun" dan "karat\_daun", yang kemungkinan disebabkan oleh kemiripan visual antara gejala penyakit pada daun.

Classification report digunakan untuk mengevaluasi performa klasifikasi model CNN berdasarkan tiga metrik utama, yaitu precision, recall, dan F1-score. Metrik ini dihitung untuk masing-masing kelas target: bercak daun, daun sehat, dan karat daun. Selain itu, disediakan pula nilai accuracy secara keseluruhan, serta rata-rata makro dan tertimbang dari seluruh kelas.

Tabel 3. 1 Classification Report

Classification Report	Precision	Recall	F1-Score	Support
bercak_daun	0.90	0.85	0.88	33
daun_sehat	1.00	1.00	1.00	23
karat_daun	0.86	0.91	0.89	34
accuracy			0.91	90
macro avg	0.92	0.92	0.92	90
weihited avg	0.91	0.91	0.91	90

Model CNN berhasil mengklasifikasikan kelas "daun sehat" dengan sempurna, dengan precision, recall, dan F1-score sebesar 1.00, pada kelas "bercak daun", recall sedikit lebih rendah (0.85), menunjukkan bahwa beberapa gambar dengan bercak daun diklasifikasikan sebagai kelas lain, kelas "karat daun" menunjukkan performa yang seimbang antara precision (0.86) dan recall (0.91), menandakan kemampuan model yang cukup baik dalam mendeteksi jenis penyakit ini, akurasi total dari model adalah 91%, yang mencerminkan kinerja klasifikasi yang sangat baik secara keseluruhan.

IV. KESIMPULAN

Berdasarkan perancangan dan penelitian yang telah dilakukan untuk mengimpelementasikan sistem deteksi penyakit daun pada tanaman kopi gayo maka didapat kesimpulan sebagai berikut: Sistem deteksi penyakit daun pada tanaman kopi gayo ini berhasil mendeteksi daun daun yang telah diambil langsung oleh penulis ke kebun warga yang berada di daerah dataran tinggi gayo, dengan jumlah data uji sebanyak 900 gambar. Model pertama yang dilatih menggunakan dataset lokal menunjukkan akurasi sebesar 91,11%. Untuk meningkatkan kinerja dan pemanfaatan sistem deteksi ini, penelitian selanjutnya disarankan menambahkan jumlah dan variasi dataset agar model memiliki kemampuan generalisasi yang lebih baik. Optimasi hyperparameter seperti learning rate, batch size, dan jumlah epoch juga perlu dilakukan untuk mencapai performa maksimal. Selain itu, penggunaan arsitektur CNN lain seperti MobileNetV2, EfficientNet, atau ResNet dapat dibandingkan guna menentukan model yang paling efisien. Pengembangan sistem juga dapat diarahkan pada integrasi ke dalam aplikasi berbasis Android atau IoT sehingga memungkinkan deteksi penyakit daun secara real-time di lapangan. Terakhir, validasi lapangan dengan citra yang diambil dalam kondisi nyata sangat dianjurkan untuk memastikan akurasi model dan kegunaannya secara praktis.

REFERENSI

[1] D. M. Rahmah, D. Purnomo, F. Filianty, I. Ardiansah, R. Pramulya, and R. Noguchi, "Social Life Cycle Assessment of a Coffee Production Management System in a Rural Area : A Regional Evaluation of the Coffee Industry in West Java , Indonesia," 2023.

[2] H. U. E. Thi, M. Tran, S. Nathan, A. Ilmma, and M. Burkiewicz, "Identifying limiting factors for feasible productivity improvement for smallholder farmers in coffee sector in Indonesia," vol. 5, no. 2, pp. 53–60, 2021, doi: 10.13057/asianjagric/g050202.

- [3] M. F. Nainggolan, "Sustainable Arabica coffee development strategies in Aceh, Indonesia," 2nd Int. Conf. Agric. Bio-industry, 2021, doi: 10.1088/1755-1315/667/1/012106.
- [4] J. Jauharlina, T. Chamzurni, J. P. Tanaman, F. Pertanian, and U. S. Kuala, "PENGARUH KERAPATAN NAUNGAN TERHADAP INFEKSI KARAT DAUN (*Hemileia vastatrix*) PADA TANAMAN KOPI ARABIKA," J. Ilm. Mhs. Pertan., vol. 9, no. 1, pp. 727–738, 2024.
- [5] M. Siregar, "MANAJEMEN AGRIBISNIS KOPI GAYO DI TAKENGON," IHSAN J. Pengabd. Masy., vol. 3, no. 1, 2021.
- [6] J. Ilmiah and M. Pertanian, "Jurnal Ilmiah Mahasiswa Pertanian, Volume 4, Nomor 4, November 2019 353," vol. 4, no. November, pp. 353–361, 2019.
- [7] A. Humaira, H. P. Widayat, and Y. Abubakar, "Analisis Kualitas Organoleptik Kopi Arabika Gayo dan Arabika Lintong yang Diperoleh dari Pasar Online," J. Ilm. Mhs. Pertan., vol. 9, no. 1, pp. 409–415, 2024.
- [8] D. Hemileia and K. Sigi, "KETAHANAN BEBERAPA VARIETAS KOPI (*Coffea* sp) TERHADAP PENYAKIT KARAT DAUN (*Hemileia vastatrix*) DI KABUPATEN SIGI," J. Pertan. Agroteknologi, vol. 11, no. 5, pp. 357–363, 2023.
- [9] A. Fatchurrachman, D. Udjulawa, and Multi, "Identifikasi Penyakit Pada Tanaman Kopi Berdasarkan Citra Daun Menggunakan Metode Convolution Neural Network," J. Algoritm., vol. 3, no. 2, pp. 151–159, 2023.
- [10] A. Yhurinda, P. Putri, and A. Sodik, "Identifikasi Penyakit Tanaman Kopi Arabika dengan Metode K-Nearest Neighbor (K-NN)," Semin. Nas. Sains dan Teknol. Terap. VII 2019 Inst. Teknol. Adhi Tama Surabaya, pp. 759–764, 2019.
- [11] A. I. Saputra, I. Weni, and U. Khaira, "Implementasi Metode Convolutional Neural Network Untuk Deteksi Penyakit Pada Tanaman Kopi Arabika Melalui Citra Daun Berbasis Android," vol. 4, no. 1, pp. 41–51, 2024.
- [12] A. Sabrina, "Klasifikasi Penyakit pada Tanaman Kopi Robusta Berdasarkan Citra Daun Menggunakan Convolutional Neural Network," vol. 9, no. 3, pp. 1919–1927, 2022.
- [13] M. Ramadhan, B. Anwar, R. Gunawan, and R. Kustini, "SISTEM PAKAR UNTUK MENDIAGNOSA PENYAKIT PADA TANAMAN KOPI MENGGUNAKAN METODE TEOREMA BAYES," J. Sci. Soc. Res., vol. 4307, no. June, pp. 115–121, 2021.
- [14] X. Yang et al., "CNN with spatio-temporal information for fast suspicious object detection and recognition in THz security images," Signal Processing, vol. 160, pp. 202–214, 2019, doi: 10.1016/j.sigpro.2019.02.029.
- [15] C. N. Rao et al., "Intelligent Deep Learning Framework for Breast Cancer Prediction using Feature Ensemble Learning," 2023 4th IEEE Glob. Conf. Adv. Technol., pp. 1–5, 2023, doi: 10.1109/GCAT59970.2023.10353262.