

Optimisasi Model Deep Learning untuk Deteksi Penyakit Daun Tebu dengan Fine-Tuning MobileNetV2

Sarifah Agustiani¹, Riska Aryanti^{1,*}, Siti Khotimatul Wildah², Yoseph Tajul Arifin³, Siti Marlina⁴, Titik Misriati⁵

¹ Fakultas Teknik dan Informatika, Informatika, Universitas Bina Sarana Informatika, Jakarta, Indonesia

² Fakultas Teknik dan Informatika, Teknologi Komputer, Universitas Bina Sarana Informatika, Jakarta, Indonesia

³ Fakultas Teknik dan Informatika, Teknik Elektro, Universitas Bina Sarana Informatika, Jakarta, Indonesia

⁴ Fakultas Teknik dan Informatika, Sistem Informasi, Universitas Bina Sarana Informatika, Jakarta, Indonesia

⁵ Fakultas Teknik dan Informatika, Sistem Informasi Akuntansi, Universitas Bina Sarana Informatika, Jakarta, Indonesia

Email: ¹sarifah.sgu@bsi.ac.id, ²riska.rts@bsi.ac.id, ³siti.ska@bsi.ac.id, ⁴yoseph.ypa@bsi.ac.id, ⁵siti.smr@bsi.ac.id,

⁶titik.tmi@bsi.ac.id

Email Penulis Korespondensi: riska.rts@bsi.ac.id

Abstrak—Penyakit pada daun tebu menjadi ancaman serius dalam pertanian tebu karena dapat menurunkan produktivitas secara signifikan dan dapat menyebabkan kerugian besar dalam hasil panen jika tidak dideteksi secara dini. Untuk itu, dibutuhkan penanganan penyakit yang cepat dan akurat untuk mencegah kerugian lebih lanjut. Penelitian ini bertujuan untuk mengembangkan model deep learning berbasis MobileNetV2 dengan teknik fine-tuning untuk mendeteksi penyakit pada daun tebu secara efektif. Fine-tuning adalah metode yang digunakan untuk menyesuaikan parameter-model yang telah dilatih sebelumnya pada dataset target yang lebih spesifik. Dataset berisi gambar daun tebu yang telah diklasifikasikan per kelas berdasarkan jenis penyakitnya. Pada penelitian ini, dilakukan fine-tuning pada arsitektur MobileNetV2 yang telah dilatih sebelumnya dengan menggunakan dataset daun tebu. Proses fine-tuning dilakukan dengan mengatur ulang beberapa lapisan teratas dari MobileNetV2 dan menambahkan lapisan klasifikasi khusus untuk memprediksi kelas penyakit daun tebu. Model dilatih melalui dua tahap: pelatihan awal untuk mendapatkan baseline performa dan fine-tuning dengan membuka beberapa lapisan dari MobileNetV2. Pada evaluasi awal, model mencapai akurasi validasi sebesar 93,12%. Setelah dilakukan fine-tuning, akurasi meningkat menjadi 95,01%, menunjukkan bahwa teknik ini mampu meningkatkan kemampuan deteksi penyakit secara signifikan. Hasil penelitian ini memberikan kontribusi penting dalam bidang pertanian, khususnya dalam mendukung keberlanjutan produksi tebu melalui teknologi berbasis kecerdasan buatan. Implementasi model yang diusulkan diharapkan dapat membantu petani mendeteksi penyakit dengan lebih cepat dan mengambil tindakan pencegahan yang tepat waktu, sehingga mengurangi kerugian.

Kata Kunci: Deep Learning, Deteksi Dini, Fine-Tuning, MobileNetV2, Penyakit Daun Tebu

Abstract—Sugarcane leaf diseases are a serious threat in sugarcane farming because they can significantly reduce productivity and can cause major losses in yields if not detected early. Therefore, fast and accurate disease management is needed to prevent further losses. This study aims to develop a deep learning model based on MobileNetV2 with fine-tuning techniques to effectively detect sugarcane leaf diseases. Fine-tuning is a method used to adjust the parameters of a pre-trained model on a more specific target dataset. The dataset contains images of sugarcane leaves that have been classified per class based on the type of disease. In this study, fine-tuning was performed on the MobileNetV2 architecture that had been previously trained using the sugarcane leaf dataset. The fine-tuning process was carried out by rearranging the top few layers of MobileNetV2 and adding a special classification layer to predict the class of sugarcane leaf diseases. The model was trained through two stages: initial training to obtain a baseline performance and fine-tuning by opening several layers of MobileNetV2. In the initial evaluation, the model achieved a validation accuracy of 93.12%. After fine-tuning, the accuracy increased to 95.01%, indicating that this technique was able to significantly improve disease detection capabilities. The results of this study provide important contributions in the field of agriculture, especially in supporting the sustainability of sugarcane production through artificial intelligence-based technology. The implementation of the proposed model is expected to help farmers detect diseases more quickly and take timely preventive measures, thereby reducing losses.

Keywords: Deep Learning, Early Detection, Fine-Tuning, MobileNetV2, Sugarcane Leaf Disease

1. PENDAHULUAN

Indonesia dikenal sebagai negara agraris, dengan sektor pertanian menjadi salah satu tulang punggung perekonomian nasional [1]. Luasnya lahan pertanian, keberagaman sumber daya alam, dan mayoritas penduduk yang bergantung pada sektor ini menjadikan pertanian sebagai sektor strategis dalam mendukung ketahanan pangan, kesejahteraan masyarakat, dan pembangunan ekonomi [2]. Selain itu, Indonesia memiliki potensi besar dalam pengembangan energi terbarukan, salah satunya melalui energi biomassa, yang semakin relevan di tengah kebutuhan global akan sumber energi yang berkelanjutan dan ramah lingkungan [3].

Energi biomassa merupakan salah satu solusi energi terbarukan yang dihasilkan dari bahan organik, seperti sisa tanaman, kayu, limbah pertanian, dan limbah organik lainnya [4]. Biomassa memiliki manfaat besar karena dapat diolah menjadi bahan bakar cair, gas, atau padat yang digunakan untuk menghasilkan listrik, panas, maupun biofuel [5]. Sumber biomassa di Indonesia sangat melimpah, mulai dari limbah sawit, sekam padi, tongkol jagung, hingga tanaman penghasil gula seperti tebu. Selain sebagai bahan baku produksi gula, tebu juga berperan penting dalam menghasilkan bioetanol, yang merupakan salah satu jenis biofuel utama dari biomassa [6].

Dalam konteks ini, tebu menjadi salah satu tanaman strategis, tidak hanya untuk memenuhi kebutuhan gula nasional tetapi juga sebagai bahan baku energi biomassa [7]. Namun, produktivitas sektor ini sering kali terganggu oleh penyakit tanaman, khususnya yang menyerang daun tebu. Penyakit daun tidak hanya menurunkan hasil panen tetapi juga dapat menyebabkan kehilangan tanaman secara keseluruhan jika tidak dikelola secara efektif [8]. Dampak negatif ini

menempatkan penyakit daun tebu sebagai salah satu tantangan utama yang harus diatasi dalam rangka memastikan keberlanjutan sektor pertanian tebu [9]. Selain itu, serangan penyakit ini turut meningkatkan biaya produksi karena memerlukan penggunaan pestisida dan fungisida yang tidak hanya berdampak buruk bagi lingkungan tetapi juga berpotensi membahayakan kesehatan manusia [10]. Dengan permintaan global terhadap gula dan energi biomassa yang terus meningkat, deteksi dan pengelolaan penyakit daun tebu menjadi kebutuhan mendesak untuk mendukung keberlanjutan produksi secara global.

Deteksi dini penyakit daun tebu memegang peranan penting dalam upaya meningkatkan hasil produksi. Serangan penyakit dan hama pada tanaman tebu diketahui dapat menyebabkan kerugian ekonomi yang besar, sehingga sistem otomatis berbasis teknologi mutakhir seperti pengolahan citra dan pembelajaran mesin (*machine learning*) diperlukan untuk mendeteksi penyakit dengan cepat dan akurat [11]. Metode identifikasi manual yang mengandalkan pengamatan mata telanjang sering kali tidak efektif karena rentan terhadap kesalahan manusia [12]. Oleh karena itu, diperlukan teknologi deteksi yang lebih canggih untuk memungkinkan tindakan pencegahan yang lebih cepat, tepat waktu, dan efektif.

Dalam upaya menjawab tantangan ini, penelitian ini bertujuan untuk mengembangkan model deep learning berbasis MobileNetV2 dengan teknik fine-tuning untuk mendeteksi penyakit daun tebu secara akurat. MobileNetV2 dipilih karena merupakan model yang ringan, efisien, dan cocok untuk implementasi pada perangkat mobile dengan keterbatasan perangkat keras. Dengan pendekatan ini, diharapkan mampu meningkatkan kemampuan deteksi dini penyakit, membantu petani dalam mengelola penyakit dengan lebih efektif, dan mengoptimalkan produktivitas pertanian tebu. Penelitian ini juga berkontribusi pada keberlanjutan pertanian melalui penerapan teknologi yang hemat sumber daya dan ramah lingkungan.

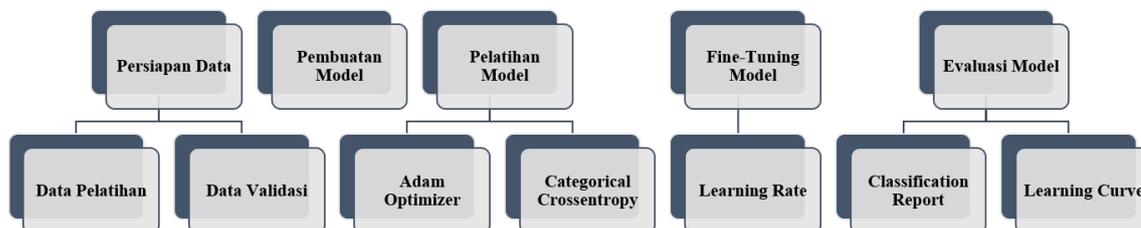
Berbagai penelitian sebelumnya [13]–[19] telah menunjukkan hasil yang menjanjikan dalam penerapan deep learning untuk deteksi penyakit tanaman. Sebagai contoh, penelitian sebelumnya berhasil mengembangkan model ensemble pada dataset berisi 2569 citra dengan lima kelas penyakit, yang mencapai akurasi hingga 86,53% dengan efisiensi parameter dan jumlah epoch yang optimal [20]. Penelitian lain menggunakan model YOLOv8 dengan menerapkan teknik data augmentation, seperti horizontal flipping, jittering scale, dan random brightness, yang meningkatkan akurasi model dari nilai mAP (*Mean Average Precision*) 40,3% menjadi 50,5% [18]. Selain itu, arsitektur seperti EfficientNet-b6 dan InceptionV4 juga telah menunjukkan akurasi yang sangat tinggi, masing-masing mencapai 93,39% dan 93,10%, dalam mendeteksi penyakit daun tebu [19]. Untuk deteksi hama tebu, model SSV2-YOLO (*Stem-ShuffleNet V2-YOLOv5s*) telah berhasil diterapkan untuk mendeteksi hama kecil pada lingkungan alami yang tidak terstruktur [21].

Meskipun metode-metode tersebut menunjukkan performa yang sangat baik, model-model ini umumnya memiliki kompleksitas yang lebih tinggi, sehingga membutuhkan perangkat keras yang canggih untuk implementasi. Dalam penelitian ini, pendekatan menggunakan MobileNetV2 dengan fine-tuning memberikan keunggulan dalam hal efisiensi model tanpa mengorbankan akurasi. MobileNetV2 dirancang untuk bekerja optimal pada perangkat dengan keterbatasan komputasi, menjadikannya lebih sesuai untuk aplikasi dunia nyata, khususnya bagi petani yang membutuhkan solusi praktis dengan biaya terjangkau. Dengan fokus pada efisiensi parameter, penelitian ini menawarkan kebaruan dalam pengembangan teknologi deteksi penyakit daun tebu, memberikan alternatif yang lebih ringan namun tetap kompetitif dibandingkan model yang lebih kompleks seperti YOLOv8 atau EfficientNet.

Dengan pendekatan ini, penelitian diharapkan dapat memberikan kontribusi yang signifikan dalam bidang pertanian modern. Penerapan teknologi berbasis deep learning yang lebih ringan dan hemat sumber daya memungkinkan pengelolaan penyakit daun tebu yang lebih efektif, mengurangi kerugian akibat penyakit, dan memaksimalkan produktivitas. Selain itu, penelitian ini juga dapat menjadi landasan bagi pengembangan teknologi serupa di bidang pertanian lainnya, mendukung inovasi dalam pengelolaan penyakit tanaman secara luas, dan memastikan keberlanjutan produksi di tengah tantangan global yang semakin kompleks.

2. METODOLOGI PENELITIAN

Penelitian ini dilakukan melalui beberapa tahapan utama untuk mengembangkan dan mengoptimalkan model deep learning berbasis MobileNetV2 dalam mendeteksi penyakit pada daun tebu. Berikut adalah rangkaian metodologi yang diterapkan:



Gambar 1. Metodologi Penelitian

2.1 Persiapan Data

Dataset yang digunakan terdiri dari citra daun tebu yang telah diklasifikasikan berdasarkan jenis penyakitnya. Citra ini dimuat dan diproses menggunakan ImageDataGenerator, sebuah metode preprocessing untuk augmentasi data, seperti rotasi, flipping, dan normalisasi. Dataset kemudian dibagi menjadi dua subset yakni data pelatihan (*training data*) untuk melatih model dan data validasi (*validation data*) untuk mengevaluasi performa model. Berikut merupakan rincian dataset yang digunakan dalam penelitian ini:

Tabel 1. Dataset Penyakit Daun Tebu

Penyakit	Jumlah
<i>Banded Chlorosis</i>	471
<i>Brown Spot</i>	1722
<i>BrownRust</i>	314
<i>Grassy shoot</i>	346
<i>Pokkah Boeng</i>	297
<i>Sett Rot</i>	652
<i>Smut</i>	316
<i>Viral Disease</i>	663
<i>Yellow Leaf</i>	1194
<i>Total Dataset</i>	5975

Tabel 1 memberikan gambaran yang jelas mengenai jumlah kelas dan jumlah citra yang tersedia pada setiap kelas dalam dataset yang digunakan untuk pelatihan model pengenalan penyakit daun tebu. Setiap kelas mewakili jenis penyakit yang berbeda pada tanaman tebu, dan jumlah citra yang terdaftar mencerminkan berapa banyak contoh gambar yang ada untuk masing-masing penyakit, total dataset yang digunakan dalam penelitian ini sebanyak 5975 citra.

2.2 Pembuatan Model

Model klasifikasi dibangun dengan menggunakan arsitektur MobileNetV2 sebagai basis model. MobileNetV2 dipilih karena efisiensinya dalam menangani data citra pada perangkat dengan sumber daya terbatas. Di atas arsitektur dasar MobileNetV2, ditambahkan beberapa lapisan kustom, seperti: *GlobalAveragePooling2D* untuk mereduksi dimensi data. Dense layers untuk klasifikasi akhir sesuai jumlah kelas penyakit pada dataset. Model dikompilasi menggunakan *optimizer Adam* dan *loss function* menggunakan *categorical_crossentropy*, yang sesuai untuk masalah klasifikasi multi-kelas.

2.3 Pelatihan Model

Model dilatih menggunakan subset data pelatihan menggunakan 10 epoch untuk mendapatkan baseline performa awal. Selama pelatihan, metrik akurasi dipantau untuk mengukur seberapa baik model mempelajari data. Setelah pelatihan ini selesai, performa model dievaluasi menggunakan subset data validasi. Hasil akurasi dicatat sebagai baseline untuk dibandingkan dengan hasil setelah fine-tuning.

2.4 Fine-Tuning Model

Fine-tuning dilakukan dengan membuka beberapa lapisan dari model MobileNetV2 yang sebelumnya dibekukan selama pelatihan awal. Lapisan yang terbuka dilatih ulang menggunakan data pelatihan dengan learning rate yang lebih kecil untuk menghindari overfitting dan memastikan model dapat menyesuaikan parameter dengan data spesifik. Model dilatih kembali pada data pelatihan yang sama dengan lapisan yang terbuka untuk fine-tuning. Pelatihan dilakukan selama beberapa epoch, dengan metrik akurasi terus dipantau untuk memastikan peningkatan performa. Setelah proses fine-tuning selesai, model dievaluasi kembali menggunakan data validasi. Akurasi yang dicapai setelah fine-tuning dicatat untuk dibandingkan dengan baseline performa awal.

2.5 Evaluasi Model

Pada pelatihan awal, model MobileNetV2 mencapai akurasi validasi sebesar 93.12%. Setelah fine-tuning diterapkan, akurasi validasi meningkat menjadi 95.01%, menunjukkan peningkatan signifikan dalam kemampuan deteksi penyakit. Metodologi ini memberikan pendekatan terstruktur untuk memaksimalkan performa model deep learning dalam klasifikasi gambar daun tebu berdasarkan jenis penyakitnya.

3. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan arsitektur MobileNetV2 yang telah dilatih sebelumnya untuk melakukan klasifikasi pada dataset penyakit daun tebu dengan 9 kelas. Berikut adalah hasil dan pembahasan berdasarkan eksperimen yang dilakukan:

3.1 Pelatihan Model Sebelum Fine-Tuning

Model dilatih selama 10 epoch menggunakan data augmentasi untuk meningkatkan kemampuan generalisasi. Pada tahap ini, lapisan-lapisan pada MobileNetV2 dibekukan untuk memanfaatkan fitur yang telah dilatih sebelumnya. Akurasi validasi awal meningkat secara bertahap dari 71.87% pada epoch pertama menjadi 93.12% pada epoch terakhir. Berikut adalah tabel yang merangkum hasil pelatihan dan validasi untuk 10 epoch pada model sebelum fine-tuning:

Tabel 2. Hasil Pelatihan Model Sebelum Fine-Tuning

Epoch	Loss Pelatihan	Akurasi Pelatihan	Loss Validasi	Akurasi Validasi
1	0.8050	71.87%	0.4346	83.53%
2	0.4552	82.44%	0.3581	86.74%
3	0.3731	85.87%	0.2911	88.42%
4	0.3080	87.98%	0.2176	91.38%
5	0.2877	88.40%	0.2220	91.01%
6	0.2633	89.66%	0.2189	91.40%
7	0.2354	90.43%	0.2031	91.65%
8	0.2274	90.76%	0.1809	92.20%
9	0.2041	91.53%	0.1612	92.79%
10	0.2003	91.46%	0.1609	93.12%

Tabel 2 menunjukkan bahwa proses pelatihan berlangsung selama 10 epoch. Pada awal pelatihan, nilai loss pelatihan cukup tinggi, yaitu 0.8050 pada epoch pertama, dengan akurasi pelatihan sebesar 71,87%. Namun, seiring dengan meningkatnya jumlah epoch, nilai loss secara bertahap menurun hingga mencapai 0.2003 pada epoch ke-10, dengan akurasi pelatihan yang meningkat menjadi 91,46%.

Pada data validasi, performa model juga mengalami peningkatan. Loss validasi yang awalnya berada pada angka 0.4346 pada epoch pertama terus menurun hingga 0.1609 pada epoch terakhir. Hal ini sejalan dengan peningkatan akurasi validasi, yang meningkat dari 83,53% di awal pelatihan menjadi 93,12% pada epoch ke-10.

Peningkatan performa pada data validasi menunjukkan bahwa model mampu menggeneralisasi dengan baik terhadap data baru. Selain itu, selisih yang kecil antara nilai loss pada data pelatihan dan validasi mengindikasikan bahwa model tidak mengalami overfitting. Dengan akurasi validasi akhir yang mencapai 93,12%, model ini dapat dianggap memiliki performa yang baik dalam menyelesaikan tugas klasifikasi.

3.2 Pelatihan Model Setelah Fine-Tuning

Fine-tuning dilakukan dengan membuka semua lapisan pada MobileNetV2 dan melatih model kembali dengan learning rate yang lebih kecil. Langkah ini bertujuan untuk menyelaraskan fitur pre-trained dengan dataset yang digunakan. Akurasi validasi setelah fine-tuning meningkat menjadi 95.01%, menunjukkan sedikit perbaikan. Berikut adalah tabel yang merangkum hasil pelatihan dan validasi untuk 10 epoch pada model setelah fine-tuning:

Tabel 3. Hasil Pelatihan Model Setelah Fine-Tuning

Epoch	Loss Pelatihan	Akurasi Pelatihan	Loss Validasi	Akurasi Validasi
1	0.2226	0.9172	0.1532	0.9386
2	0.1712	0.9300	0.1148	0.9439
3	0.1483	0.9386	0.1114	0.9488
4	0.1375	0.9386	0.1753	0.9284
5	0.1279	0.9389	0.0980	0.9479
6	0.1157	0.9416	0.0867	0.9510
7	0.1144	0.9423	0.0964	0.9476
8	0.1095	0.9392	0.1039	0.9454
9	0.1110	0.9428	0.0934	0.9506
10	0.1056	0.9411	0.0899	0.9501

Tabel 3 menunjukkan hasil pelatihan dan validasi dari model pada setiap epoch, nilai loss pelatihan dan validasi, serta akurasi pelatihan dan validasi. Dalam pelatihan ini, nilai loss pelatihan dan validasi menunjukkan tren menurun, sementara akurasi pelatihan dan validasi menunjukkan peningkatan yang konsisten. Epoch 6 dan seterusnya memperlihatkan performa model yang stabil dengan sedikit fluktuasi, mencerminkan bahwa model mengalami peningkatan yang signifikan dalam akurasi dan performa secara keseluruhan.

3.3 Evaluasi Model

3.3.1 Laporan Klasifikasi Model

Laporan klasifikasi memiliki manfaat penting dalam evaluasi performa model dalam penelitian. Dengan menyediakan metrik seperti precision, recall, dan f1-score untuk setiap kelas, laporan ini memungkinkan peneliti untuk menganalisis kinerja model secara rinci, termasuk kemampuan model dalam mendeteksi kelas minoritas pada dataset yang tidak seimbang. Selain itu, metrik rata-rata seperti macro average dan weighted average memberikan gambaran umum tentang kinerja model secara keseluruhan. Informasi ini tidak hanya membantu dalam mengidentifikasi kelemahan model, tetapi juga berfungsi sebagai dasar untuk menentukan langkah-langkah perbaikan yang diperlukan guna meningkatkan akurasi prediksi dan efisiensi model dalam konteks penelitian.

Tabel 4. Laporan Klasifikasi Model Sebelum Fine-Tuning

class	precision	recall	f1-score	support
<i>Banded Chlorosis</i>	0.09	0.08	0.09	471
<i>Brown Spot</i>	0.28	0.28	0.28	1722
<i>BrownRust</i>	0.06	0.06	0.06	314
<i>Grassy shoot</i>	0.06	0.05	0.06	346
<i>Pokkah Boeng</i>	0.03	0.03	0.03	297
<i>Sett Rot</i>	0.10	0.10	0.10	652
<i>Smut</i>	0.04	0.03	0.03	316
<i>Viral Disease</i>	0.10	0.10	0.10	663
<i>Yellow Leaf</i>	0.21	0.21	0.21	1194
<i>accuracy</i>			0.16	5975
<i>macro avg</i>	0.11	0.11	0.11	5975
<i>weighted avg</i>	0.16	0.16	0.16	5975

Pada model sebelum dilakukan fine-tuning, hasil klasifikasi memperlihatkan ketidaksetaraan dalam performa antar kelas. Kelas dengan jumlah data yang lebih besar, seperti kelas *Brown Spot* dengan 1722 citra, cenderung memiliki nilai precision dan recall yang lebih tinggi. Hal ini menunjukkan bahwa model lebih efektif dalam mengenali kelas yang memiliki representasi lebih besar dalam dataset. Sebaliknya, kelas-kelas dengan jumlah data yang lebih kecil cenderung memiliki nilai precision dan recall yang lebih rendah. Akurasi keseluruhan pada model ini tercatat sekitar 17%, yang mengindikasikan bahwa model kesulitan dalam memprediksi beberapa kelas, khususnya kelas dengan jumlah data terbatas. Nilai akurasi yang rendah ini mencerminkan ketidakmampuan model untuk secara efektif menangani ketidakseimbangan kelas, di mana beberapa kelas minoritas tidak dapat terdeteksi dengan baik.

Tabel 5. Laporan Klasifikasi Model Setelah Fine-Tuning

class	precision	recall	f1-score	support
<i>Banded Chlorosis</i>	0.08	0.08	0.08	471
<i>Brown Spot</i>	0.30	0.30	0.30	1722
<i>BrownRust</i>	0.05	0.06	0.05	314
<i>Grassy shoot</i>	0.05	0.05	0.05	346
<i>Pokkah Boeng</i>	0.06	0.07	0.07	297
<i>Sett Rot</i>	0.12	0.12	0.12	652
<i>Smut</i>	0.06	0.04	0.05	316
<i>Viral Disease</i>	0.12	0.12	0.12	663
<i>Yellow Leaf</i>	0.21	0.21	0.21	1194
<i>accuracy</i>			0.17	5975
<i>macro avg</i>	0.12	0.12	0.12	5975
<i>weighted avg</i>	0.17	0.17	0.17	5975

Tabel 5 menunjukkan hasil evaluasi klasifikasi untuk model yang diterapkan pada dataset penyakit daun tebu. Model ini menggunakan tiga metrik utama: precision, recall, dan f1-score untuk menilai kinerjanya dalam mengklasifikasikan setiap kelas. Precision mengukur ketepatan prediksi positif, dan recall mengukur kemampuan model untuk mendeteksi semua sampel yang benar-benar ada dalam kelas tersebut. Sementara itu, f1-score adalah rata-rata harmonis dari precision dan recall, memberikan gambaran keseimbangan antara keduanya.

Dari hasil yang ditampilkan, dapat disimpulkan bahwa model menunjukkan performa yang rendah, dengan nilai precision, recall, dan f1-score yang umumnya berada di bawah 0.30 untuk sebagian besar kelas. Misalnya, kelas *Banded Chlorosis* memiliki precision dan recall yang sangat rendah, masing-masing 0.08, yang berarti model hanya berhasil memprediksi dengan benar sebagian kecil dari kelas ini. Kelas dengan jumlah data lebih banyak, seperti *Brown Spot* (1722 citra), sedikit lebih baik dengan precision dan recall masing-masing 0.30, namun tetap jauh dari tingkat performa yang optimal. Secara keseluruhan, nilai f1-score untuk kelas-kelas ini rendah, mencerminkan bahwa model kesulitan mencapai keseimbangan yang baik antara precision dan recall.

Support, yang menunjukkan jumlah sampel untuk tiap kelas, sangat bervariasi antara kelas satu dengan yang lainnya. Kelas-kelas dengan jumlah data lebih sedikit, seperti BrownRust (314 citra) atau Grassy shoot (346 citra), lebih sulit diprediksi dengan akurat, yang tercermin dalam nilai precision, recall, dan f1-score yang lebih rendah. Akurasi keseluruhan model adalah 0.17, yang menunjukkan bahwa model hanya berhasil memprediksi 17% dari semua data dengan benar, sebuah hasil yang sangat rendah. Ini mengindikasikan bahwa model kesulitan dalam mendeteksi kelas-kelas minoritas, yang kemungkinan disebabkan oleh ketidakseimbangan jumlah data antara kelas mayoritas dan minoritas.

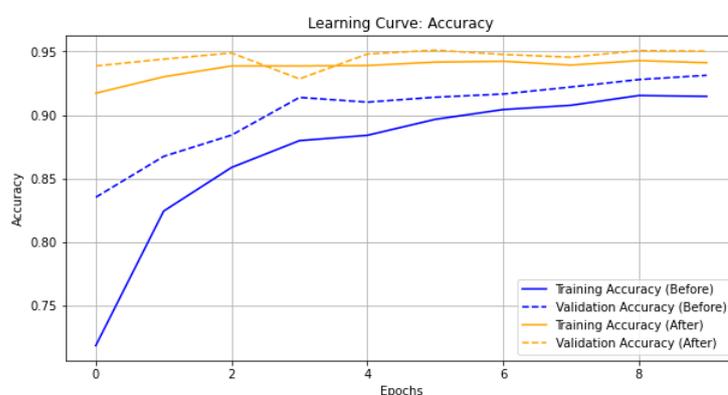
Rata-rata makro dan rata-rata tertimbang dari precision, recall, dan f1-score lebih rendah dari yang diharapkan, dengan nilai sekitar 0.12 untuk rata-rata makro dan 0.17 untuk rata-rata tertimbang. Rata-rata tertimbang sedikit lebih tinggi karena memberi bobot lebih besar pada kelas dengan jumlah data yang lebih besar, seperti Brown Spot. Namun, secara keseluruhan, hasil ini menunjukkan bahwa model belum cukup baik dalam mengklasifikasikan penyakit daun tebu, terutama kelas-kelas minoritas. Ketidakseimbangan data menjadi salah satu faktor utama yang mempengaruhi performa model ini.

Dengan demikian, dapat disimpulkan bahwa meskipun ada beberapa penyesuaian pada bobot model untuk meningkatkan kemampuannya dalam mengenali fitur-fitur spesifik dari dataset, hasilnya tidak menunjukkan perubahan signifikan pada metrik evaluasi seperti precision, recall, maupun F1-score untuk sebagian besar kelas. Hal ini mengindikasikan bahwa fine-tuning belum sepenuhnya meningkatkan kemampuan model dalam mendeteksi kelas-kelas minoritas, yang mungkin disebabkan oleh ketidakseimbangan data yang masih ada. Dalam beberapa kasus, model mungkin belum sepenuhnya belajar untuk mengatasi masalah kelas minoritas, meskipun telah dilakukan penyesuaian pada parameter model. Ini menunjukkan bahwa meskipun fine-tuning dapat memberikan peningkatan pada beberapa aspek performa, masalah ketidakseimbangan kelas masih menjadi tantangan utama dalam meningkatkan akurasi keseluruhan model.

Secara keseluruhan, meskipun fine-tuning dapat membantu dalam beberapa situasi, masalah ketidakseimbangan kelas tetap menjadi faktor utama yang mempengaruhi kinerja model. Peningkatan akurasi untuk kelas minoritas mungkin memerlukan teknik tambahan seperti oversampling, undersampling, atau penggunaan metrik evaluasi yang lebih sensitif terhadap ketidakseimbangan data, seperti area under the curve (AUC) atau menggunakan model yang lebih canggih dalam menangani kelas minoritas.

3.3.2 Kurva Pembelajaran Akurasi Model

Kurva pembelajaran yang menggambarkan loss dan akurasi ini digunakan untuk analisis performa model selama proses pelatihan. Melalui visualisasi ini, dapat dilakukan evaluasi pembelajaran model, termasuk mendeteksi indikasi overfitting atau underfitting dengan mengamati kesenjangan antara training dan validation curves. Selain itu, kurva ini memungkinkan identifikasi epoch optimal untuk menghentikan pelatihan guna mencegah degradasi performa akibat pelatihan berlebih. Dalam konteks pengembangan model, kurva ini juga menjadi alat evaluasi efektif untuk membandingkan hasil sebelum dan setelah fine-tuning, serta memastikan stabilitas model dalam mempelajari pola data secara generalis. Visualisasi kurva pembelajaran akurasi dapat dilihat pada gambar 2, sedangkan untuk kurva pembelajaran loss dapat dilihat pada gambar 3.



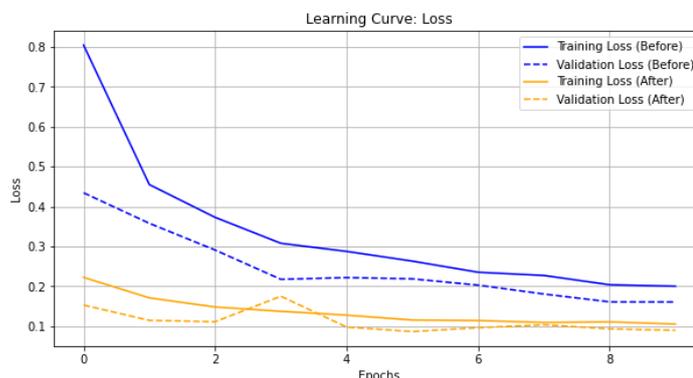
Gambar 2. Kurva Pembelajaran Akurasi Model

Gambar 2 menunjukkan grafik akurasi pelatihan (training accuracy) dan validasi (validation accuracy) sebelum dan sesudah proses fine-tuning. Sumbu horizontal (x-axis) merepresentasikan jumlah epoch, sedangkan sumbu vertikal (y-axis) menunjukkan tingkat akurasi.

- Grafik garis penuh biru menunjukkan akurasi pelatihan, yang terus meningkat seiring dengan bertambahnya epoch.
- Garis putus-putus biru menunjukkan akurasi validasi, yang lebih rendah dibandingkan akurasi pelatihan dan mengalami fluktuasi kecil. Hal ini menunjukkan model belum optimal dalam menangani data validasi, mungkin karena underfitting atau kurang maksimalnya pelatihan pada kelas tertentu.
- Grafik garis penuh oranye menunjukkan peningkatan akurasi pelatihan yang lebih signifikan dan stabil dibandingkan sebelumnya.

- d. Garis putus-putus oranye menunjukkan akurasi validasi yang juga meningkat secara keseluruhan, dengan tren yang lebih stabil. Hal ini menunjukkan bahwa fine-tuning berhasil meningkatkan performa model dalam memprediksi data yang tidak terlihat (validasi).

Dengan demikian, proses fine-tuning memberikan dampak positif terhadap kinerja model, terlihat dari peningkatan akurasi pada pelatihan dan validasi, serta kesenjangan yang lebih kecil antara keduanya, yang mengindikasikan model semakin generalisasi dengan baik.



Gambar 3. Kurva Pembelajaran Loss Model

Gambar 3 menggambarkan perubahan nilai loss selama proses pelatihan (training) dan validasi, baik sebelum maupun setelah proses fine-tuning. Berikut adalah penjelasan rinci:

- a. Loss Pelatihan sebelum fine-tuning (ditunjukkan oleh garis penuh biru):

Nilai loss pelatihan dimulai dengan angka yang tinggi pada epoch pertama, menunjukkan bahwa model awal memiliki kesalahan yang signifikan dalam memprediksi kelas. Namun, nilai ini menurun secara konsisten hingga mencapai nilai yang lebih kecil mendekati akhir pelatihan. Hal ini menunjukkan bahwa model belajar dari data dan mampu meminimalkan kesalahan prediksi pada data pelatihan.

- b. Loss Validasi sebelum fine-tuning (ditunjukkan oleh garis putus-putus biru):

Nilai loss validasi lebih tinggi daripada loss pelatihan di seluruh epoch, yang menandakan adanya kesenjangan antara performa model pada data pelatihan dan data validasi. Walaupun loss validasi juga menunjukkan tren penurunan, namun tidak serendah loss pelatihan, yang mungkin disebabkan oleh overfitting atau kurangnya kemampuan model untuk menggeneralisasi data baru.

- c. Loss Pelatihan setelah fine-tuning (ditunjukkan oleh garis penuh oranye):

Nilai loss pelatihan dimulai dari angka yang lebih rendah dibandingkan training loss sebelum fine-tuning, menunjukkan bahwa model memiliki performa awal yang lebih baik setelah fine-tuning. Selama pelatihan, nilai loss ini terus menurun, namun laju penurunannya lebih lambat dibandingkan sebelum fine-tuning. Hal ini menunjukkan bahwa model sudah mencapai fine-tuning dari parameter yang lebih optimal.

- d. Loss Validasi setelah fine-tuning (ditunjukkan oleh garis putus-putus oranye):

Validation loss menunjukkan stabilitas yang lebih baik, dengan nilai yang lebih rendah dibandingkan validation loss sebelum fine-tuning. Hal ini menunjukkan bahwa model lebih mampu menggeneralisasi pola data baru. Tren loss validasi juga lebih mendekati loss pelatihan, yang mengindikasikan bahwa model sudah mengurangi kemungkinan overfitting.

Berdasarkan gambar 3 dapat disimpulkan bahwa sebelum fine-tuning, terdapat kesenjangan yang cukup besar antara training loss dan validation loss, yang menandakan bahwa model belum mampu menggeneralisasi pola data dengan baik. Sedangkan setelah fine-tuning, nilai loss secara keseluruhan menjadi lebih kecil dan stabil. Kesenjangan antara training loss dan validation loss juga berkurang secara signifikan, menunjukkan bahwa model sudah lebih optimal dalam mempelajari pola data pelatihan sekaligus mengurangi kesalahan pada data validasi. Kurva pembelajaran menunjukkan tren yang konsisten, di mana nilai loss pada data pelatihan dan validasi terus menurun seiring bertambahnya jumlah epoch. Selisih yang kecil antara loss pelatihan dan validasi mengindikasikan bahwa model mampu belajar secara efektif tanpa kehilangan kemampuan generalisasi terhadap data baru. Hal ini menunjukkan bahwa model tidak hanya unggul pada data pelatihan, tetapi juga menunjukkan performa yang baik pada data validasi, sehingga risiko overfitting dapat diminimalkan. Konsistensi ini mencerminkan bahwa model telah dirancang dan dilatih dengan pendekatan yang tepat untuk menyelesaikan tugas klasifikasi secara andal.

4. KESIMPULAN

Penelitian ini berhasil mengembangkan model deep learning berbasis MobileNetV2 untuk mendeteksi penyakit pada daun tebu dengan tingkat akurasi yang tinggi. Proses pelatihan awal model menghasilkan akurasi validasi sebesar 93.12%, yang menunjukkan bahwa arsitektur MobileNetV2 mampu menangani klasifikasi penyakit daun tebu dengan baik. Penerapan teknik fine-tuning pada beberapa lapisan MobileNetV2 berhasil meningkatkan performa model, dengan

akurasi validasi akhir mencapai 95.01%. Hasil ini menunjukkan bahwa fine-tuning merupakan langkah penting dalam mengoptimalkan performa model deep learning, terutama untuk dataset spesifik seperti gambar daun tebu. Dengan akurasi yang lebih tinggi setelah fine-tuning, model ini memberikan solusi yang andal untuk mendeteksi berbagai jenis penyakit daun tebu secara cepat dan akurat. Kontribusi utama penelitian ini adalah penerapan teknologi berbasis kecerdasan buatan yang dapat membantu petani dalam mendeteksi penyakit daun tebu secara dini. Dengan demikian, model ini dapat menjadi alat yang efektif dalam mengurangi kerugian hasil panen dan mendukung keberlanjutan produksi tebu. Untuk penelitian mendatang, model ini dapat dikembangkan lebih lanjut dengan menggunakan dataset yang lebih besar dan beragam untuk meningkatkan generalisasi. Selain itu, integrasi model ini ke dalam aplikasi berbasis perangkat seluler dapat meningkatkan aksesibilitasnya bagi petani di lapangan.

REFERENCES

- [1] M. Patiung, "Strategi Industrialisasi Pertanian dalam Bentuk Pembangunan Agribisnis Merupakan Solusi Mensejahterakan Rakyat," *Prosiding*, pp. 201–205, 2018.
- [2] R. Elizabeth and I. S. Anugrah, "Pertanian bioindustri meningkatkan daya saing produk agroindustri dan pembangunan pertanian berkelanjutan," *Mimb. Agribisnis J. Pemikir. Masy. Ilm. Berwawasan Agribisnis*, vol. 6, no. 2, p. 871, 2020.
- [3] K. Mudhoffar and L. Magriasti, "Ekonomi Politik Energi Terbarukan: Peluang dan Tantangan di Indonesia," *Multiverse Open Multidiscip. J.*, vol. 3, no. 1, pp. 47–52, 2024.
- [4] N. Nurdiansyah *et al.*, "Inovasi Teknologi Briket Solusi Cerdas Untuk Pengelolaan Limbah Dan Energi Berkelanjutan," *J. Pengabd. Masy. Bangsa*, vol. 2, no. 7, pp. 2774–2780, 2024.
- [5] S. Ikhbar, C. Rusmina, and others, "Optimalisasi Energi Biomassa: Solusi Energi Terbarukan untuk Ekonomi Hijau dengan Tinjauan Finansial dan Lingkungan," *J. Serambi Eng.*, vol. 9, no. 3, 2024.
- [6] M. D. Wijayanti, *Energi Biomassa*. Bumi Aksara, 2023.
- [7] M. N. IDHAM KHOLID, "Prarancangan Pabrik γ -Valerolactone (Gvl) dari Ampas Tebu dengan Kapasitas 15.244 Ton/Tahun."
- [8] M. Malado *et al.*, *Pengendalian Hama dan Penyakit Tanaman Pertanian*. CV. Gita Lentera, 2024.
- [9] B. Wardiman, E. Fitriyani, S. Herlyani, J. R. Ashar, N. J. Panga, and others, *Pertanian Keberlanjutan*. TOHAR MEDIA, 2024.
- [10] D. Sitompul, P. Lumbantobing, S. Manik, and M. S. Harefa, "Optimasi Penggunaan Bio-Pestisida sebagai Pengganti Pestisida Kimia pada Pertanian di Kec. Percut Sei Tuan, Kab. Deli Serdang," *El-Mujtama J. Pengabd. Masy.*, vol. 4, no. 2, pp. 670–681, 2024.
- [11] A. M. Amarullah, M. Adiwena, and F. R. Arifin, *Teknologi Budidaya dan Produksi Tanaman*. Syiah Kuala University Press, 2023.
- [12] S. Agustiani, Y. T. Arifin, A. Junaidi, S. K. Wildah, and A. Mustopa, "Klasifikasi Penyakit Daun Padi menggunakan Random Forest dan Color Histogram," vol. 10, no. 1, 2022.
- [13] K. Thilagavathi, "Detection of Diseases in Sugarcane Using Image Processing Techniques," *Biosci. Biotechnol. Res. Commun.*, vol. 13, no. 11, pp. 109–115, 2020, doi: 10.21786/bbrc/13.11/24.
- [14] R. Manavalan, "Efficient Detection of Sugarcane Diseases through Intelligent Approaches: A Review," *Asian J. Res. Rev. Agric.*, vol. 3, no. 1, pp. 174–184, 2021.
- [15] T. Huang, R. Yang, W. Huang, Y. Huang, and X. Qiao, "Detecting sugarcane borer diseases using support vector machine," *Inf. Process. Agric.*, vol. 5, no. 1, pp. 74–82, 2018, doi: 10.1016/j.inpa.2017.11.001.
- [16] S. Strachan, S. A. Bhuiyan, N. Thompson, N. T. Nguyen, R. Ford, and M. J. A. Shiddiky, "Latent potential of current plant diagnostics for detection of sugarcane diseases," *Curr. Res. Biotechnol.*, vol. 4, no. May, pp. 475–492, 2022, doi: 10.1016/j.crbiot.2022.10.002.
- [17] A. D. Syathori and L. Verona, "Faktor-faktor yang mempengaruhi produksi usahatani tanaman tebu di Desa Majangtengah Kecamatan Dampit Kabupaten Malang," *J. Agriekstensi*, vol. 19, no. 2, pp. 95–103, 2020.
- [18] I. Topan Adib Amrulloh, B. Nurina Sari, and T. Nur Padilah, "Evaluasi Augmentasi Data Pada Deteksi Penyakit Daun Tebu Dengan Yolov8," *JATI (Jurnal Mhs. Tek. Inform.)*, vol. 8, no. 4, pp. 7547–7552, 2024, doi: 10.36040/jati.v8i4.10267.
- [19] İ. Kunduracioğlu and İ. Paçal, "Deep Learning-Based Disease Detection in Sugarcane Leaves: Evaluating EfficientNet Models," *J. Oper. Intell.*, vol. 2, no. 1, pp. 321–235, 2024, doi: 10.31181/jopi21202423.
- [20] S. Hossain *et al.*, "Automated breast tumor ultrasound image segmentation with hybrid UNet and classification using fine-tuned CNN model," *Heliyon*, vol. 9, no. 11, p. e21369, 2023, doi: <https://doi.org/10.1016/j.heliyon.2023.e21369>.
- [21] W. Xu *et al.*, "A lightweight SSV2-YOLO based model for detection of sugarcane aphids in unstructured natural environments," *Comput. Electron. Agric.*, vol. 211, p. 107961, 2023, doi: <https://doi.org/10.1016/j.compag.2023.107961>.