

Identifikasi Penyakit Daun Tomat dengan Menggunakan NASNet Mobile

^{1*}**Annisa' Nur Kamilah, ²Umi Mahdiyah, ³Resty Wulanningrum**

^{1,2,3} Teknik Informatika, Universitas Nusantara PGRI Kediri

E-mail: ¹nurkamilahannisa8@gmail.com, ²umimahdiyah@gmail.com, ³restyw@unpkdr.ac.id

Penulis Korespondens : Annisa' Nur Kamilah

Abstrak—Pertanian adalah sektor penting yang menyediakan pangan bagi masyarakat. Khususnya, pada tanaman tomat, sering kali terganggu oleh berbagai penyakit daun yang dapat menurunkan hasil panen dan menyebabkan kerugian bagi petani. Penelitian ini bertujuan mengembangkan model identifikasi citra daun tomat menggunakan arsitektur *NASNet Mobile* untuk mengidentifikasi penyakit secara otomatis. Dataset terdiri dari empat kelas, yaitu *Healty*, *Leaf Mold*, *Septoria Leaf Spot*, dan *Tomato Yellow Leaf Spot*. Model dilatih menggunakan model *NASNet Mobile* dan dievaluasi menggunakan metrik akurasi, presisi, *recall*, dan *f1-score*. Hasil menunjukkan bahwa model *NASNet Mobile* mencapai akurasi sebesar 69,97% dengan *macro average f1-score* sebesar 0,67%. Penelitian ini memberikan kontribusi awal dalam pemanfaatan *deep learning* untuk pertanian presisi, khususnya dalam mendukung pengambilan keputusan petani guna mengurangi risiko kerugian hasil panen akibat keterlambatan penanganan penyakit.

Kata Kunci—*Deep learning*, klasifikasi citra, *NASNet Mobile*, penyakit daun tomat, pertanian

Abstract—Agriculture is an essential sector that provides food for the community. Specifically, tomato plants are often affected by various leaf diseases that can reduce crop yields and cause losses for farmers.. This study aims to develop a tomato leaf image identification model using the *NASNet* architecture to automatically identify diseases. The dataset consists of four classes: healthy leaves, leaf mold, septoria leaf spot, and tomato yellow leaf spot. The model was trained using a *NASNet Mobile* model and evaluated using accuracy, precision, recall, and F1-score metrics. The results show that the *NASNet* model achieved an accuracy of 69.97% with a macro average F1-score of 0.67. Although it has not yet been implemented as an application, the model demonstrates potential in supporting early detection of plant diseases. This research provides an initial contribution to the application of deep learning in precision agriculture, particularly in assisting farmers with decision-making to reduce the risk of crop losses due to delayed disease management.

Keywords—Agriculture, deep learning, image classification, *NASNet Mobile*, Tomato leaf disease

This is an open access article under the CC BY-SA License.



I. PENDAHULUAN

Tomat (*Solanum lycopersicum L.*) merupakan salah satu komoditas hortikultura yang terpenting di Indonesia dan dunia karena kandungan nutrisinya yang tinggi serta kegunaannya yang luas sebagai bahan pangan[1]. Selain sebagai bahan pangan dalam berbagai masakan, tomat juga memiliki nilai ekonomi yang tinggi. Tomat termasuk dalam kategori buah karena bagian dari tanaman yang memiliki biji dan dapat langsung dimakan. Buah tomat juga dapat dikonsumsi

dalam berbagai macam olahan[2]. Permintaan akan tomat terus meningkat, baik untuk konsumsi langsung maupun sebagai bahan baku industri makanan. Oleh karena itu, pengembangan teknologi dalam budidaya dan pengolahan tomat sangat penting untuk meningkatkan produktivitas dan kualitasnya, sehingga dapat memenuhi kebutuhan pasar yang terus berkembang[3]. Budidaya tanaman tomat tidak terlalu sulit dan tidak memerlukan biaya yang mahal, namun terdapat beberapa faktor yang mempengaruhi kualitas dan kuantitas dalam produksi tanaman tomat[4].

Tomat menjadi salah satu komoditas unggulan yang banyak dibudidayakan oleh petani di Desa Kepung, Kabupaten Kediri. Daerah ini memiliki iklim yang cocok untuk pertanian tomat, dengan lahan yang subur dan sistem irigasi yang memadai. Namun, petani tomat sering menghadapi tantangan besar berupa serangan penyakit daun yang dapat merusak tanaman secara cepat[5]. Rata-rata tanaman tomat terserang penyakit busuk daun dan bercak daun, namun dalam membedakan kedua penyakit tersebut sangat sulit jika dilakukan secara kasat mata. Akibatnya, petani sering keliru dalam menggunakan obat pada saat mengendalikan penyakit sehingga mengakibatkan kerusakan tanaman tomat dan petani mengalami kerugian karena gagal panen[6]. Oleh karena itu, penting untuk menemukan solusi yang tepat untuk mendeteksi dan menangani penyakit daun pada tanaman tomat secara akurat dapat menggunakan metode *NasNet Mobile*.

Dalam penggunaan *NASNet Mobile* terdapat pendekatan yang digunakan untuk mendeteksi penyakit daun pada tanaman tomat. *NASNet (Neural Architecture Search Network)* yang dirancang untuk mengoptimalkan struktur jaringan saraf secara otomatis guna mencapai performa terbaik dalam klasifikasi citra. *NASNet Mobile* telah digunakan sebagai ekstraktor fitur dalam sistem identifikasi penyakit tanaman, memungkinkan integrasi dengan perangkat mobile untuk deteksi lapangan yang lebih praktis[7]. Dengan menggunakan metode *NASNet Mobile*, proses identifikasi penyakit daun tomat dapat dilakukan secara cepat dan akurat berdasarkan citra daun, sehingga membantu petani dan ahli pertanian dalam pengambilan keputusan yang tepat tanpa memerlukan keahlian khusus dalam mengenali gejala penyakit secara manual.

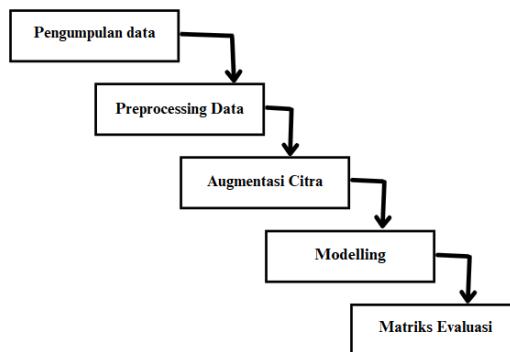
Berdasarkan penelitian Al-gaashani dkk, menggunakan arsitektur *NASNet Mobile* dan *MobileNetV2* untuk mengekstraksi fitur dari citra daun tomat yang terinfeksi penyakit, kemudian mereduksi dimensi fitur tersebut menggunakan teknik *Kernel Principal Component Analysis (KPCA)* sebelum diklasifikasikan dengan algoritma *machine learning* seperti SVM dan *Random Forest*[8]. Kemudian berdasarkan penelitian Najim dkk, mengembangkan sistem identifikasi penyakit daun tomat berbasis *Convolutional Neural Network (CNN)* yang dilatih menggunakan citra dari berbagai jenis penyakit daun, dengan tujuan agar sistem ini dapat diterapkan secara langsung di lingkungan pertanian untuk mendeteksi penyakit secara otomatis melalui pengolahan citra digital[9]. Dari kedua penelitian tersebut, tantangan ada dalam kebutuhan data yang besar, sumber daya komputasi, dan kemampuan generalisasi model terhadap kondisi lapangan yang beragam. Oleh karena itu, penelitian lebih lanjut diperlukan untuk mengembangkan solusi yang lebih efisien dan adaptif terhadap berbagai kondisi pertanian.

Solusi dalam permasalahan kerugian yang dialami petani akibat penyakit daun tomat. Dengan melalui pengembangan model klasifikasi berbasis *NASNet Mobile* yang mampu mengenali gejala penyakit secara otomatis dari citra daun. Dengan mengandalkan kemampuan ekstraksi fitur visual dari *NASNet Mobile*, sistem ini dapat digunakan untuk membangun alat bantu identifikasi penyakit yang lebih cepat dan objektif. Dengan solusi ini diharapkan menjadi dasar bagi pengembangan sistem lanjutan yang mendukung pengambilan keputusan dalam pengendalian penyakit tanaman, khususnya bagi petani yang belum memiliki akses terhadap tenaga ahli atau laboratorium pertanian.

Model identifikasi berbasis *NASNet Mobile* dikembangkan untuk mendukung upaya menjaga kualitas hasil panen tomat dengan mengidentifikasi penyakit daun secara lebih akurat dan sistematis. Melalui analisis performa model menggunakan berbagai metrik evaluasi, pendekatan ini terbukti efektif dalam mengenali gejala penyakit berdasarkan citra daun. Meskipun belum diterapkan dalam sistem real-time atau aplikasi langsung di lapangan, hasil penelitian ini dapat menjadi langkah awal dalam membantu petani mengurangi risiko kerugian akibat keterlambatan diagnosis, sekaligus meningkatkan ketepatan pengendalian penyakit dalam budidaya tomat.

II. METODE

Pada penelitian ini digunakan pendekatan komprehensif untuk mengetahui penyakit daun tomat. Proses yang terlibat mencakup beberapa tahapan utama, mulai dari pengumpulan data, preprocessing data, augmentasi citra, hingga evaluasi hasil. Alur penelitian ini telah dicantumkan pada Gambar 1 :



Gambar 1 Alur Penelitian

2.1 Pengumpulan Data

Table 1 Dataset

Healty	Septoria Leaf Spot
Leaf Mold	Tomato Yellow Leaf Spot

Pengumpulan data adalah langkah awal dalam penelitian atau pengembangan, di mana data dikumpulkan dan dipersiapkan untuk dianalisis lebih lanjut. Proses pengumpulan data tidak hanya melalui pengumpulan data mentah, tetapi juga persiapan dan pemrosesan agar data siap

digunakan. Dalam pengumpulan data ini menghasilkan total 363 gambar, 117 kategori *Healty*, 82 kategori *Leaf Mold*, 86 kategori *Septoria Leaf Spot*, dan 78 kategori *Tomato Yellow Leaf Spot*.

2.2 Preprocessing Data

Sebelum melakukan analisis lebih lanjut, citra yang dikumpulkan menjalani proses pra pemrosesan yang meliputi, pada normalisasi dilakukan perskalaan kembali terhadap nilai-nilai yang tersimpan pada dataset yang membuat proses pengolahan menjadi lebih mudah[10], pada *Resize* adalah mengubah ukuran citra dalam satuan pixel[11].



Gambar 2 Daun awal

Tahap prapemrosesan data menunjukkan bahwa semua citra telah berhasil dinormalisasi dan diubah ukurannya menjadi 224x224 piksel. Proses normalisasi piksel dilakukan secara efektif dengan mengonversi nilai piksel dari rentang awal 0–255 ke rentang 0–1.



Gambar 3 Data setelah di normalisasi dan resize

Karena jumlah data yang dikumpulkan dalam penelitian ini masih tergolong sedikit, maka dilakukan proses normalisasi untuk meningkatkan variasi data yang ada seperti pada gambar 3. Proses pengubahan ukuran gambar memastikan bahwa seluruh citra memiliki dimensi yang seragam, meskipun ukuran aslinya berbeda-beda. Konsistensi ini sangat penting agar sesuai dengan kebutuhan arsitektur model, yang memerlukan input berukuran tetap yaitu 224x224 piksel. Penyamaan ukuran gambar memberikan keunggulan dalam tahap pelatihan model, karena data dapat diproses secara konsisten tanpa gangguan akibat perbedaan dimensi yang berpotensi menghambat kestabilan proses pelatihan.

2.3 Augmentasi Citra

Pada jumlah data yang dikumpulkan dalam penelitian ini masih sedikit, maka dilakukan proses normalisasi data untuk menambah jumlah variasi data yang ada. Augmentasi adalah proses penggandaan data sehingga dataset menjadi lebih banyak[12]. Teknik augmentasi yang digunakan dalam penelitian ini adalah *Rotation* (Rotasi), *Flipping Horizontal* (Pembalikan Horizontal), *Flipping Vertical* (Pembalikan Vertikal), *Zooming* (Pembesaran/Pengecilan), *Brightness Adjustment* (Penyesuaian Kecerahan), *Shearing* (Pemotongan), *Shifting* (Perpindahan Horizontal dan Vertikal), *Gaussian Noise*, *Blurring* (Pengaburan), dan *Contrast Adjustment* (Penyesuaian Kontras).

Teknik augmentasi yang diterapkan meliputi rotasi hingga 40° , *flipping horizontal* dan vertikal, *zooming* antara 80-120%, penyesuaian kecerahan (*brightness*) dari 0,5 hingga 1,5, shearing hingga 20° , *shifting* (perpindahan) horizontal dan vertikal hingga 20%, penambahan *derau Gaussian* untuk mensimulasikan noise lingkungan, blurring menggunakan *Gaussian Blur*, serta penyesuaian kontras antara 0,8 hingga 1,2. Setelah di augmentasi mendapatkan data baru dengan hasil :



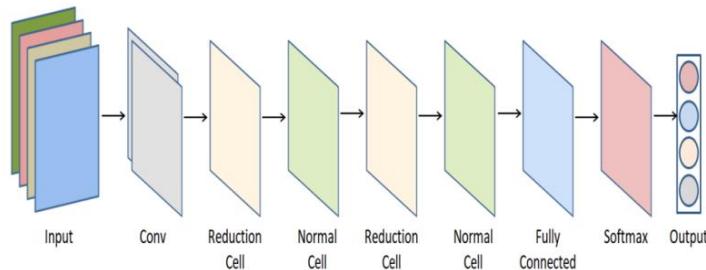
Gambar 4 Data setelah di augmentasi

Dari proses augmentasi, kumpulan data menjadi lebih beragam, membantu model medeteksi berbagai kondisi penyakit daun tomat. Akibat augmentasi ini, kumpulan data berfluktuasi, sehingga dapat membantu model dalam mendeteksi berbagai kondisi penyakit daun tomat. Dari hasil augmentasi ini menghasilkan total 3630 gambar. Dengan 1170 kategori *Healty*, 820 kategori *Leaf Mold*, 860 kategori *Septoria Leaf Spot*, dan 780 kategori *Tomato Yellow Leaf Spot*. Hal ini menunjukkan bahwa model dapat mengenali penyakit daun tomat, meskipun kondisi citra mengalami berbagai variasi seperti perubahan pencahayaan, orientasi, dan kualitas visual.

2.4 Modelling

Dalam penelitian ini menggunakan metode dalam bidang pembelajaran mesin, khususnya identifikasi citra menggunakan model *Deep Learning* berbasis *Convolutional Neural Network (CNN)*. *Convolutional Neural Network (CNN)* adalah metode pembelajaran mendalam yang dapat digunakan untuk mengklasifikasikan gambar, mengelompokkannya berdasarkan kesamaan, dan melakukan pengenalan gambar dan adegan[13].

Model yang digunakan adalah *NASNet Mobile (Neural Architecture Search Network)*. *NASNet Mobile* adalah CNN yang dilatih lebih dari satu juta gambar dari dataset *ImageNet*. Arsitektur CNN *NASNet* dapat diskalakan yang terdiri dari blok bangunan dasar (sel) yang dioptimalkan menggunakan *Reinforcement Learning*[14].



Gambar 5 Arsitektur *NASNet Mobile* [15]

Arsitektur *NASNet Mobile* dimulai dari input layer yang menerima citra berwarna dengan tiga saluran (RGB), kemudian dilanjutkan dengan lapisan konvolusi awal (Conv) yang bertugas

mengekstraksi fitur dasar dari gambar seperti tepi dan warna. Setelah itu, jaringan terdiri dari blok-blok utama yang disebut *Reduction Cell* dan *Normal Cell*. *Reduction Cell* digunakan untuk mengurangi dimensi spasial (tinggi dan lebar) dari fitur dengan tetap mempertahankan informasi penting, sehingga efisien dalam memperdalam jaringan tanpa kehilangan konteks visual.

Sedangkan *Normal Cell* berfungsi untuk memperkuat dan mengekstraksi fitur lebih lanjut tanpa mengubah ukuran dimensi spasial, dan biasanya diulang beberapa kali sepanjang jaringan. Setelah melalui beberapa lapisan ini, fitur yang telah diproses diteruskan ke *Fully Connected Layer* untuk dirangkum menjadi vektor satu dimensi. Lapisan ini diikuti oleh *Softmax Layer* yang mengubah vektor menjadi probabilitas kelas, menghasilkan output berupa prediksi kelas akhir. *NASNet Mobile* dikenal karena kemampuannya menyesuaikan kompleksitas model terhadap kebutuhan, baik untuk performa tinggi maupun efisiensi komputasi, menjadikannya sangat ideal digunakan dalam berbagai tugas klasifikasi citra, termasuk pada perangkat mobile melalui versi *NASNet Mobile*. [15].

Pelatihan model menggunakan *NASNet Mobile* yang dilatih sebelumnya dilakukan dengan memanfaatkan dataset yang disimpan di *Google Drive*. Model *NASNet Mobile* dilatih menggunakan dataset yang dibagi menjadi dua bagian, yaitu data pelatihan dan validasi, dengan proses pelatihan berlangsung selama 10 epoch. Model menggunakan optimizer Adam dengan learning rate 0,0001 dan fungsi kehilangan *Categorical Crossentropy*. Hasil pelatihan menunjukkan akurasi pelatihan mencapai 99,92%, sementara akurasi validasi meningkat dari 45,45% menjadi 69,97%, menunjukkan potensi *Overfitting* karena kesenjangan performa antara data pelatihan dan validasi. Proses pelatihan berjalan efisien dengan waktu 12-14 detik per epoch, namun peningkatan performa dapat dicapai melalui regularisasi, augmentasi data, atau penyesuaian arsitektur model.

2.5 Matriks Evaluasi Model

Menentukan tingkat keberhasilan dari kinerja sistem menggunakan model yang telah dilatih untuk mendeteksi objek digunakan matriks evaluasi diantaranya adalah akurasi, *precision*, *recall*, *F1-score*, dan *confusion matrix*. *Confusion Matrix* adalah tabel yang menyatakan klasifikasi jumlah data uji yang benar dan jumlah data uji yang salah. Contoh *confusion matrix* untuk klasifikasi biner ditunjukkan pada Tabel 1[16].

Table 2 Confusion Matrix

Class	Kelas Positif	Kelas Negatif
Positif	TP (True Positive)	TN (True Negative)
Negatif	FP (False Positive)	FN (False Negative)

$$\text{Akurasi} = \frac{(TP+TN)}{(TP+FP+FN+TN)} \quad (1)$$

$$\text{Precision} = \frac{TP}{(TP+FP)} \quad (2)$$

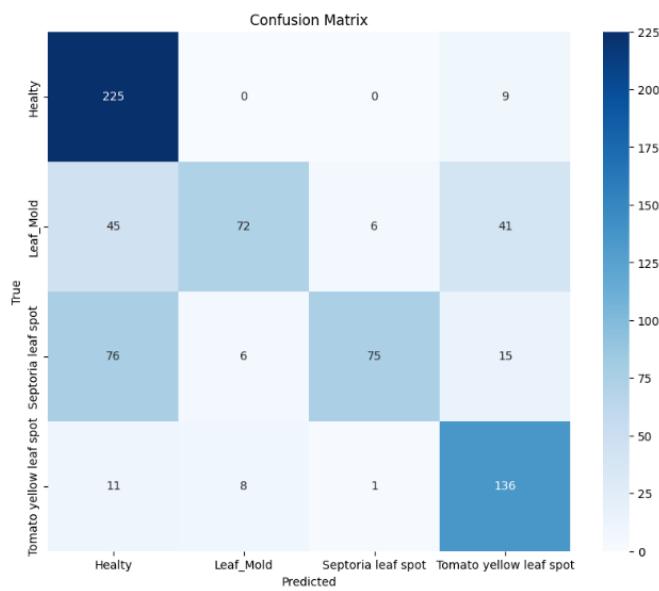
$$\text{Recall} = \frac{(TP)}{(TP+FN)} \quad (3)$$

$$\text{F1-score} = 2 * \frac{(Recall*Precision)}{(Recall+Precision)} \quad (4)$$

III. HASIL DAN PEMBAHASAN

3.1 Confusion Matrix

Mengevaluasi kinerja model *NASNet Mobile* yang telah dikembangkan melalui serangkaian pengujian. Pada tahap awal, menerapkan *Confusion Matrix* untuk menilai kemampuan model dalam membedakan jenis penyakit. Nilai persentase dalam *Confusion Matrix* yang dinormalisasi memberikan gambaran yang jelas tentang seberapa baik model dalam mengklasifikasikan objek dengan benar. Nilai-nilai dalam *Confusion Matrix*, seperti *Precision*, *Recall*, dan *F1-score*, dapat dihitung untuk menilai akurasi model dalam membedakan jenis penyakit daun tomat.



Gambar 6 Hasil Confusion Matrix

Confusion Matrix yang disajikan pada gambar 6 menggambarkan kemampuan model dalam mengelompokkan empat jenis penyakit daun tomat. Untuk kategori *Healthy*, model menunjukkan akurasi tinggi dengan 225 gambar berhasil diklasifikasikan dengan benar dan hanya sembilan gambar yang salah identifikasi. Sebaliknya, pada kategori *Leaf Mold*, performa model menurun, dengan hanya 72 gambar terkласifikasi tepat, sementara 45 gambar salah dikenali sebagai *Healthy*, enam sebagai *Septoria Leaf Spot*, dan 41 sebagai *Tomato Yellow Leaf Spot*. Kategori *Septoria Leaf Spot* juga menunjukkan kelemahan serupa, di mana hanya 75 gambar diklasifikasikan dengan benar, sedangkan sisanya tersebar salah ke tiga kategori lainnya, terutama ke *Healthy*. Pada kategori *Tomato Yellow Leaf Spot*, model cukup akurat dengan 136 klasifikasi benar, meskipun masih terdapat beberapa kesalahan ke kelas lain. Kesalahan klasifikasi ini umumnya terjadi akibat kemiripan visual antar kategori penyakit, khususnya antara *Leaf Mold* dan *Septoria Leaf Spot*. Temuan ini menegaskan perlunya peningkatan pada data pelatihan, strategi augmentasi, serta teknik regularisasi agar performa model menjadi lebih optimal.

3.2 Performa Model

Table 3 Performa Model (Precision, Recall, dan F1-score)

Kelas	Precision	Recall	F1-score	Akurasi
<i>Healty</i>	0,63	0,96	0,76	
<i>Leaf Mold</i>	0,84	0,44	0,58	
<i>Septoria Leaf Mold</i>	0,91	0,44	0,59	0,70
<i>Tomato Yellow Leaf Spot</i>	0,68	0,87	0,76	
<i>Macro avg</i>	0,76	0,68	0,67	
<i>Weighted avg</i>	0,75	0,70	0,68	

Pada tabel 3, matriks evaluasi memberikan gambaran tentang performa model dalam mengklasifikasikan penyakit daun tomat berdasarkan metrik presisi, *recall*, *F1-score*, dan akurasi. Secara keseluruhan, model mencatatkan akurasi sebesar 69,97%, meskipun terdapat ketimpangan hasil klasifikasi antar kelas. Salah satu penyebab utamanya adalah distribusi data yang tidak merata, di mana kelas *Healthy* memiliki jumlah data yang jauh lebih besar dibandingkan kelas lainnya. Hal ini membuat model cenderung lebih mudah mengenali kelas tersebut, sebagaimana terlihat dari nilai *recall* yang tinggi (96%), meskipun presisinya rendah (63%) karena banyak citra dari kelas lain salah diklasifikasikan sebagai *Healthy*. Di sisi lain, kelas seperti *Leaf Mold* dan *Septoria Leaf Spot* memiliki nilai *recall* yang rendah (44%), yang menunjukkan bahwa model mengalami kesulitan dalam mengidentifikasi citra dari kelas tersebut secara akurat. Kemiripan visual antar jenis penyakit daun turut mempersulit proses klasifikasi.

Perbandingan antara *Macro avg* dan *Weighted avg* mencerminkan perbedaan cara perhitungan evaluasi model. *Macro avg* menghitung rata-rata dari setiap kelas secara merata tanpa mempertimbangkan jumlah data per kelas, dengan hasil *precision* 0,76, *recall* 0,68, dan *f1-score* 0,67. Sebaliknya, *Weighted avg* memperhitungkan jumlah sampel di setiap kelas, sehingga kelas dengan data lebih banyak memiliki pengaruh lebih besar terhadap hasil akhir. Nilai *Weighted avg* menunjukkan *precision* 0,75, *recall* 0,70, dan *f1-score* 0,68. Perbedaan ini mengindikasikan bahwa distribusi data yang tidak merata memengaruhi nilai evaluasi, terutama meningkatkan *Weighted avg* pada metrik *recall* dan *f1-score*.

Selain itu, kualitas dan keberagaman visual dalam tiap kelas juga memengaruhi performa model. Kelas dengan variasi gambar yang minim dari segi pencahayaan, sudut, dan latar belakang mempermudah proses pembelajaran, sedangkan kelas dengan tingkat variasi tinggi menyulitkan model mengenali pola yang konsisten. Keterbatasan *NASNet Mobile* dalam menangani keragaman visual juga menjadi salah satu faktor yang berkontribusi terhadap hasil klasifikasi yang kurang merata. Temuan ini menegaskan perlunya perbaikan pada aspek kualitas data serta optimasi model untuk memperoleh hasil klasifikasi yang lebih seimbang.

IV. KESIMPULAN

Dengan mempertimbangkan hasil evaluasi yang dilakukan, bahwa dapat disimpulkan yang menunjukkan bahwa penggunaan arsitektur *NASNet Mobile* dalam identifikasi penyakit daun tomat memberikan kontribusi yang relevan dalam pengembangan sistem klasifikasi citra berbasis deep learning untuk mendukung efisiensi pertanian. Model yang dibangun mampu mencapai akurasi sebesar 69,97%, dengan nilai presisi dan *F1-score* yang menggambarkan kinerja cukup stabil dalam mengenali beberapa jenis penyakit. Pendekatan ini berpotensi menjadi solusi awal dalam mendeteksi penyakit daun tomat secara otomatis guna mengurangi kerugian hasil panen akibat keterlambatan penanganan. Secara umum, pencapaian ini memperkuat pemanfaatan teknologi kecerdasan buatan di bidang sains terapan dan teknik industri berbasis pertanian, serta membuka peluang pengembangan sistem pendukung keputusan di sektor agrikultur.

DAFTAR PUSTAKA

- [1] D. H. Saputry, A. Daryanto, M. R. A. Istiqlal, and S. Widiyanto, “Potensi Hasil dan Penampilan Hortikultura Tomat Generasi F6 di Dataran Rendah,” *J. Hortik. Indones.*, vol. 13, no. 1, pp. 14–22, 2022, doi: 10.29244/jhi.13.1.14-22.
- [2] N. Fadhilah, Irmawanty, Nurdyanti, M. Wajdi, and R. Thahir, “Pemanfaatan Sumberdaya Lokal Berupa Pengolahan Tomat Menjadi Saos Tomat di Desa Tompobulu Kecamatan Rumbia,” *PATIKALA J. Pengabdi. Kpd. Masy.*, vol. 1, no. 4, pp. 272–276, 2022, doi: <https://doi.org/10.51574/patikala.v1i4.434>.
- [3] R. Erwinson, Lusmaniar, and S. Jali, “Pengaruh Pemberian Pupuk Abu Boiler Tandan Kelapa Sawit terhadap Komponen Hasil Tanaman Tomat (*Lycopersicum esculentum* Mill.),” *J. Ilmu Pertan. Agronitas*, vol. 5, no. 2, pp. 1–7, 2023, doi: <https://doi.org/10.51517/ags.v5i2.274>
- [4] M. J. Zebua, T. K. Suharsi, and M. Syukur, “Studi Karakter Fisik dan Fisiologi Buah dan Benih Tomat (*Solanum lycopersicum* L.) Tora IPB,” *Bul. Agrohorti*, vol. 7, no. 1, pp. 69–75, 2019, doi: 10.29244/agrob.v7i1.24418.
- [5] P. Tanaman, R. Pada, B. Kedelai, M. Serangga, B. Di, and L. Terdampak, “Jurnal Agrotek Tropika,” *PERTUMBUHAN DAN PRODUKSI PADI Var. MAPAN 05 (Oryza sativa L.) PADA BEBERAPA TARAF KADAR AIR YANG DIKONTROL OLEH MIKRO-KONTROLER ARDUINO UNO*, vol. 12, no. 1, pp. 29–34, 2024, doi: <http://dx.doi.org/10.23960/jat.v12i1.8685> .
- [6] A. W. Putri, “Implementasi Artificial Neural Network (ANN) Backpropagation Untuk Klasifikasi Jenis Penyakit Pada Daun Tanaman Tomat,” *MATHunesa J. Ilm. Mat.*, vol. 9, no. 2, pp. 344–350, 2021, doi: 10.26740/mathunesa.v9n2.p344-350.
- [7] M. S. A. M. Al-gaashani, F. Shang, M. S. A. Muthanna, M. Khayyat, and A. A. Abd El-Latif, “Tomato leaf disease classification by exploiting transfer learning and feature concatenation,” *IET Image Process.*, vol. 16, no. 3, pp. 913–925, 2022, doi: 10.1049/ipr2.12397.
- [8] M. S. A. M. Al-gaashani, F. Shang, M. S. A. Muthanna, M. Khayyat, and A. A. Abd El-Latif, “Tomato leaf disease classification by exploiting transfer learning and feature concatenation,” *IET Image Process.*, vol. 16, no. 3, pp. 913–925, 2022, doi: 10.1049/ipr2.12397.
- [9] M. H. Najim, S. K. Abdulateef, and A. H. Alasadi, “Early detection of tomato leaf diseases based on deep learning techniques,” *IAES Int. J. Artif. Intell.*, vol. 13, no. 1, pp. 509–515, 2024, doi: 10.11591/ijai.v13.i1.pp509-515.
- [10] A. KHOTIBUL UMAM, "Perbandingan Metode ARIMA dan LSTM pada Prediksi Jumlah Pengunjung Perpustakaan," *MIND (Multimedia Artificial Intelligent Networking)*

- Database)* Journal, vol. 8, no. 2, pp. 119-129, 2023, doi: <https://doi.org/10.26760/mindjournal.v8i2.119-129>.
- [11] A. A. RAHMAN, S. D. AGUSTIN, N. IBRAHIM, and N. C. KUMALASARI, “Perbandingan Algoritma YOLOv4 dan Scaled YOLOv4 untuk Deteksi Objek pada Citra Termal,” *MIND J.*, vol. 7, no. 1, pp. 61–71, 2022, doi: 10.26760/mindjournal.v7i1.61-71.
 - [12] R. M. Taufiq, Sunanto, Y. Rizki, and M. R. A. Pratama, “Simulasi Deteksi Golongan Kendaraan pada Gerbang Tol Menggunakan YOLOv4,” *J. CoSciTech (Computer Sci. Inf. Technol.)*, vol. 3, no. 2, pp. 199–206, 2022, doi: 10.37859/coscitech.v3i2.3928.
 - [13] F. Ilham and N. Rochmawati, “Transliterasi Aksara Jawa Tulisan Tangan ke Tulisan Latin Menggunakan CNN,” *J. Informatics Comput. Sci.*, vol. 1, no. 04, pp. 200–208, 2020, doi: 10.26740/jinacs.v1n04.p200-208.
 - [14] O. V. Putra, M. Z. Mustaqim, and D. Muriatmoko, “Transfer Learning untuk Klasifikasi Penyakit dan Hama Padi Menggunakan MobileNetV2,” *Techno.Com*, vol. 22, no. 3, pp. 562–575, 2023, doi: 10.33633/tc.v22i3.8516.
 - [15] S. E. Nassar, I. Yasser, H. M. Amer, and M. A. Mohamed, “A robust MRI-based brain tumor classification via a hybrid deep learning technique,” *J. Supercomput.*, vol. 80, no. 2, pp. 2403–2427, 2024, doi: 10.1007/s11227-023-05549-w.
 - [16] D. Normawati and S. A. Prayogi, “Implementasi Naïve Bayes Classifier Dan Confusion Matrix Pada Analisis Sentimen Berbasis Teks Pada Twitter,” *J. Sains Komput. Inform. (J-SAKTI)*, vol. 5, no. 2, pp. 697–711, 2021, doi: <http://dx.doi.org/10.30645/j-sakti.v5i2.369>.
 - [17] R. G. Lopes, D. Yin, B. Poole, J. Gilmer, and E. D. Cubuk, “Improving Robustness Without Sacrificing Accuracy with Patch Gaussian Augmentation,” pp. 1–18, 2019, doi: <https://doi.org/10.48550/arXiv.1906.02611>
 - [18] S. K. Venu and S. Ravula, “Evaluation of deep convolutional generative adversarial networks for data augmentation of chest x-ray images,” *Futur. Internet*, vol. 13, no. 1, pp. 1–13, 2021, doi: 10.3390/fi13010008.
 - [19] L. Nanni, M. Paci, S. Brahnam, and A. Lumini, “Feature transforms for image data augmentation,” *Neural Comput. Appl.*, vol. 34, no. 24, pp. 22345–22356, 2022, doi: 10.1007/s00521-022-07645-z.