

Identifikasi Penyakit Daun Jagung Menggunakan *NASNet Mobile*

Umi Roziqoh

Teknik Informatika, Fakultas Teknik dan Ilmu Komputer, Universitas Nusantara PGRI Kediri

E-mail: *umiroziqoh03@gmail.com

Abstrak – Jagung merupakan komoditas pangan penting yang rentan terhadap serangan penyakit daun, seperti *Common Rust*, *Gray Leaf Spot*, dan *Blight*, yang dapat menurunkan hasil panen secara signifikan. Identifikasi penyakit secara manual masih bergantung pada pengamatan visual sehingga berpotensi menimbulkan kesalahan diagnosis. Oleh karena itu, penelitian ini bertujuan mengembangkan sistem identifikasi penyakit daun jagung berbasis citra menggunakan metode *NASNet Mobile*. Data penelitian terdiri dari citra daun jagung dengan empat kelas, yaitu *Healthy*, *Common Rust*, *Gray Leaf Spot*, dan *Blight*. Tahapan penelitian meliputi *preprocessing* citra berupa *resize* dan *normalisasi*, *augmentasi* data untuk meningkatkan variasi citra, serta pelatihan model menggunakan arsitektur *NASNet Mobile* dengan pendekatan *transfer learning*. Evaluasi kinerja model dilakukan menggunakan *confusion matrix* serta metrik akurasi, *presisi*, *recall*, dan *F1-score*. Hasil pengujian menunjukkan bahwa model mampu mencapai akurasi sebesar 91%, dengan performa terbaik pada kelas *Healthy* dan *Common Rust*, sementara kelas *Gray Leaf Spot* masih menunjukkan nilai *recall* yang lebih rendah akibat kemiripan visual antar penyakit. Hasil ini menunjukkan bahwa *NASNet Mobile* efektif digunakan untuk identifikasi penyakit daun jagung dan berpotensi dikembangkan sebagai sistem pendukung keputusan bagi petani dalam pengendalian penyakit tanaman secara lebih akurat.

Kata Kunci — *augmentasi data, citra daun jagung, NASNet Mobile, penyakit daun, deep learning.*

1. PENDAHULUAN

Jagung (*Zea mays* L.) adalah salah satu jenis makanan pokok di Indonesia yang memiliki peran penting sebagai sumber karbohidrat untuk memenuhi kebutuhan makan sehari-hari masyarakat[1]. Selain dimanfaatkan sebagai bahan makanan, jagung juga memiliki nilai ekonomi yang besar[2]. Jagung termasuk ke dalam kelompok sereal karena bijinya bisa langsung dikonsumsi[3]. Selain itu, biji jagung juga bisa diubah menjadi berbagai jenis produk makanan atau pakan hewan[4]. Permintaan jagung terus naik, baik untuk dikonsumsi langsung maupun digunakan sebagai bahan baku industri makanan. Karena itu, pengembangan teknologi dalam pengolahan jagung sangat penting agar bisa meningkatkan produksi dan kualitasnya, sehingga mampu memenuhi kebutuhan pasar yang terus bertambah[5]. Namun ada beberapa hal yang memengaruhi jumlah dan kualitas hasil panen jagung[6].

Jagung menjadi salah satu komoditas unggulan yang banyak dibudidayakan oleh petani. Namun, petani jagung sering menghadapi tantangan besar berupa serangan penyakit daun yang dapat merusak tanaman secara cepat[7]. Tanaman jagung umumnya terkena penyakit seperti *Cercospora Leaf Spot* (*Gray Leaf Spot*), *Common Rust*, dan *Northern Leaf Blight*. Namun, membedakan ketiga penyakit cukup sulit hanya dilakukan secara kasat mata. Karena itu, para petani sering salah dalam memilih obat saat mengatasi penyakit, sehingga menyebabkan kerusakan pada tanaman jagung. Akibatnya, petani mengalami kerugian karena gagal panen[8]. Oleh karena itu, sangat penting untuk menemukan solusi yang tepat agar bisa mendeteksi penyakit daun pada tanaman jagung secara akurat, dan metode *NASNet Mobile* bisa digunakan untuk hal tersebut.

Dalam penggunaan *NASNet Mobile*, terdapat pendekatan yang digunakan untuk mendeteksi penyakit daun pada tanaman jagung. *NASNet* (*Neural Architecture Search Network*) dirancang untuk mengoptimalkan struktur jaringan saraf secara otomatis agar mencapai performa terbaik dalam klasifikasi citra. *NASNet Mobile* telah digunakan sebagai ekstraktor fitur dalam sistem identifikasi penyakit tanaman, sehingga memungkinkan integrasi dengan perangkat mobile untuk deteksi di lapangan yang lebih praktis[9]. Dengan menggunakan *NASNet Mobile*, proses mengenali penyakit pada daun jagung bisa dilakukan dengan cepat dan tepat berdasarkan citra daun, sehingga membantu petani dan para ahli pertanian dalam membuat keputusan yang benar tanpa perlu kemampuan khusus untuk mengenali tanda-tanda penyakit secara manual.

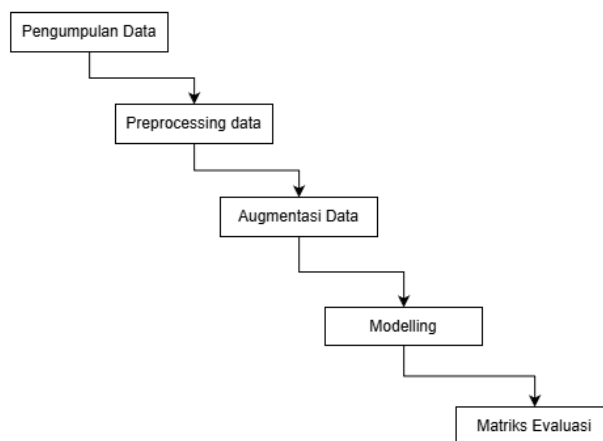
Penggunaan model *NASNet Mobile* sebagai pengekstraksi menunjukkan peningkatan tingkat keakuratan klasifikasi ketika digabungkan dengan teknik *transfer learning*. Model ini lebih efektif dalam mengenali pola visual pada daun yang terkena penyakit seperti *Cercospora Leaf Spot* (*Gray Leaf Spot*), *Common Rust*, dan *Northern Leaf Blight* dibandingkan dengan metode yang biasa digunakan[10]. Selanjutnya, dikembangkan sistem untuk mendeteksi penyakit pada daun jagung menggunakan teknologi *Convolutional Neural Network* (*CNN*).

Sistem ini dilatih dengan data gambar penyakit daun yang berasal dari berbagai kondisi lingkungan. Tujuannya adalah agar sistem bisa digunakan di lapangan untuk membantu proses identifikasi penyakit secara otomatis melalui analisis gambar digital[11].

Solusi untuk mengatasi kerugian petani akibat penyakit daun jagung dikembangkan melalui model klasifikasi berbasis *NASNet Mobile* yang secara otomatis dapat mengenali gejala penyakit dari citra daun. Dengan memanfaatkan kemampuan ekstraksi fitur visualnya, model ini dirancang untuk mempercepat dan membuat objektif proses identifikasi penyakit daun, yang dapat digunakan sebagai dasar sistem lanjutan bagi petani yang tak memiliki akses ke tenaga ahli. Meskipun belum diterapkan secara real-time, pendekatan ini terbukti efektif melalui evaluasi kinerja model, dan dapat membantu petani mengurangi risiko kerugian akibat diagnosis yang terlambat serta meningkatkan ketepatan pengendalian penyakit, mendukung kualitas panen secara lebih akurat dan sistematis.

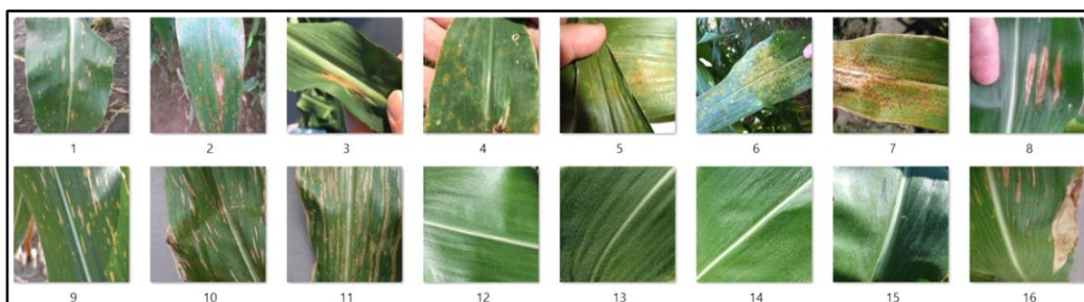
2. METODE PENELITIAN

Dalam penelitian ini, dilakukan pendekatan yang menyeluruh untuk mengenali penyakit pada daun jagung. Proses yang dilakukan melibatkan beberapa tahapan utama, yaitu mulai dari pengumpulan data, preprocessing data, augmentasi citra, hingga mengevaluasi hasil. Alur penelitian ini telah disajikan pada Gambar 1.



Gambar 1. Alur Penelitian

2.1 Pengumpulan Data



Gambar 2. Pengumpulan Data Daun Jagung Sehat dan Terserang Penyakit

Pengumpulan data dalam penelitian ini sebagian ditunjukkan pada gambar 2, data dikumpulkan melalui kaggle, dengan total 300 gambar untuk kategori 100 *Healthy*, 100 *Cercospora Leaf Spot (Gray Leaf Spot)*, 100 *Common Rust*, dan 100 untuk kategori *Northern Leaf Blight*.

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[12]. Pada *Resize* adalah mengubah ukuran citra dalam satuan pixel[13]. Gambar 3 menunjukkan aktivitas *resize*.



Gambar 3. sebelum dan sesudah *Resize* dan Normalisasi

Tahap pra-pemrosesan data dilakukan untuk menormalisasi dan diubah ukurannya menjadi 224x224 piksel[14]. Proses normalisasi nilai piksel dilakukan dengan baik, yaitu dengan mengubah nilai dari rentang awal 0 sampai 255 menjadi rentang 0 sampai 1[15].

Karena jumlah data yang dikumpulkan dalam penelitian ini masih terbilang sedikit, maka dilakukan proses normalisasi untuk meningkatkan variasi data. Proses mengubah ukuran gambar bertujuan agar semua citra memiliki dimensi yang sama, meskipun ukuran aslinya berbeda[16]. Konsistensi ini sangat penting agar sesuai dengan kebutuhan arsitektur model, yang memerlukan input berukuran tetap yaitu 224x224 piksel[17]. Penyesuaian ukuran gambar memberikan keuntungan dalam tahap pelatihan model, karena data dapat diproses secara konsisten tanpa adanya gangguan akibat perbedaan dimensi yang bisa menghambat kestabilan proses pelatihan.

2.3 Augmentasi Data

Karena data yang terkumpul dalam studi ini masih terbatas, normalisasi data dilakukan untuk meningkatkan variasi data. Augmentasi data merupakan proses penggandaan data untuk memperbesar ukuran dataset[18]. Beberapa teknik augmentasi diterapkan, meliputi rotasi, pembalikan horizontal dan vertikal, pembesaran atau pengecilan (*zooming*), penyesuaian kecerahan, pemotongan (*shearing*), perpindahan horizontal dan vertikal (*shifting*), penambahan *Gaussian noise*, pengaburan (*blurring*), serta penyesuaian kontras.

Teknik augmentasi yang digunakan melibatkan rotasi gambar hingga 40°, pembalikan horizontal dan vertikal, serta *zooming* antara 80% sampai 120%. Selain itu, dilakukan perubahan kecerahan dari 0,5 sampai 1,5, distorsi *shearing* sampai 20°, pergeseran horizontal dan vertikal hingga 20%, penambahan *noise Gaussian* untuk meniru gangguan lingkungan, *blurring* memakai *Gaussian Blur*, dan perubahan kontras antara 0,8 sampai 1,2.



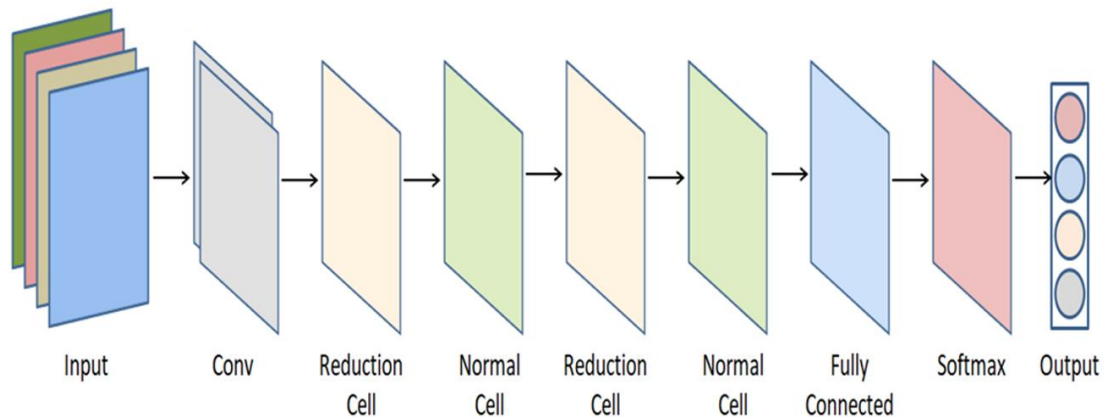
Gambar 4. Hasil Augmentasi

Melalui proses augmentasi ditunjukkan gambar 4, data yang lebih beragam diperoleh, yang membantu model dalam mengenali berbagai kondisi penyakit pada daun jagung. Augmentasi ini menghasilkan total 3.975 gambar yang terdiri dari 1.162 gambar kategori sehat, 557 gambar kategori *Cercospora Leaf Spot* (*Gray Leaf Spot*), 1.189 gambar kategori *Common Rust*, dan 1.067 gambar kategori *Northern Leaf Blight*. Hasil ini menunjukkan bahwa model mampu mengenali penyakit daun jagung meskipun terdapat variasi kondisi gambar seperti perubahan pencahayaan, orientasi, dan kualitas visual.

2.4 Modelling

Penelitian ini menerapkan metode *machine learning*, terutama identifikasi citra, memakai model *Deep Learning* berbasis *Convolutional Neural Network* (CNN). CNN adalah metode *deep learning* yang bisa dipakai untuk klasifikasi gambar, pengelompokan berdasarkan kemiripan, serta pengenalan gambar dan adegan[19].

Model yang dipakai adalah *NASNet Mobile* (*Neural Architecture Search Network*). *NASNet Mobile* adalah CNN yang dilatih memakai lebih dari satu juta gambar dari dataset *ImageNet*. Arsitektur CNN *NASNet* bisa diskalakan; arsitektur ini tersusun dari blok bangunan dasar (sel) yang diatur memakai *Reinforcement Learning*[20].



Gambar 5. Arsitektur *NASNet Mobile*[21]

Arsitektur *NASNet Mobile* tampak pada gambar 5 dimulai dengan lapisan masukan yang menerima citra berwarna tiga kanal (RGB). Setelah itu, terdapat lapisan konvolusi awal (Conv) yang berfungsi mengekstraksi fitur dasar seperti tepi dan warna dari citra. Jaringan ini tersusun dari blok utama bernama *Reduction Cell* dan *Normal Cell*. *Reduction Cell* berfungsi untuk mengurangi dimensi spasial fitur (tinggi dan lebar) sambil menjaga informasi penting. Hal ini membuat pendalaman jaringan menjadi efisien tanpa menghilangkan konteks visual.

Cell Normal berperan untuk memperkuat serta mengekstraksi fitur lebih lanjut tanpa mengubah ukuran dimensi spasial dan umumnya diulang beberapa kali dalam jaringan. Setelah melewati beberapa lapisan ini, fitur yang telah diproses diteruskan ke *Fully Connected Layer* untuk diringkas menjadi vektor satu dimensi. Lapisan ini diikuti oleh *Softmax Layer* yang mengubah vektor menjadi probabilitas kelas sehingga menghasilkan prediksi kelas akhir. *NASNetMobile* dikenal karena kemampuannya menyesuaikan kompleksitas model dengan kebutuhan, baik untuk performa tinggi maupun efisiensi komputasi. Hal ini membuatnya sangat ideal untuk dipakai dalam berbagai tugas klasifikasi citra, termasuk pada perangkat *mobile* melalui versi *NASNetMobile*[20].

2.5 Matriks Evaluasi

Menentukan tingkat keberhasilan performa sistem menggunakan model yang telah dilatih untuk mendeteksi objek dilakukan dengan matriks evaluasi, diantaranya adalah akurasi, presisi, recall, F1 score, dan confusion matrix. Confusion Matrix adalah tabel yang menunjukkan jumlah data uji yang diklasifikasikan secara benar dan salah [22].

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

$$Precision = \frac{(True\ Positive)}{(True\ Positive+False\ Positive)} \quad (2)$$

$$Recall = \frac{(True\ Positive)}{(True\ Positive+False\ Negative)} \quad (3)$$

$$F1 - Score = \frac{(2 \times recall \times presisi)}{(recall + presisi)} \quad (4)$$


Tabel 1. *Confusion Matrix*

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

3. HASIL DAN PEMBAHASAN

3.1 *Confusion Matrix*

Mengevaluasi kinerja model *NASNet Mobile* yang 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 jagung.



Gambar 6. Hasil *Confusion Matrix*

Confusion Matrix yang disajikan pada gambar 6. menggambarkan kemampuan model dalam mengelompokkan empat jenis penyakit daun jagung. Untuk kategori *Healthy*, model menunjukkan akurasi tinggi dengan 113 gambar berhasil diklasifikasikan dengan benar dan tidak ditemukan kesalahan identifikasi ke kelas lain. Sebaliknya, pada kategori *Blight*, performa model cukup baik, dengan hanya 100 gambar terklasifikasi tepat, sementara 1 gambar salah dikenali sebagai *Common Rust*, 7 sebagai *Gray Leaf Spot*, dan 1 sebagai *Healthy*. Kategori *Gray Leaf Spot* juga menurun, di mana hanya 36 gambar diklasifikasi dengan benar, sedangkan 17 gambar dikenali sebagai *Blight*, dan 4 sebagai *Common Rust*. Kesalahan klasifikasi ini umumnya terjadi akibat kemiripan visual antar jenis penyakit, khususnya antara *Gray Leaf Spot* dan *Blight*. Temuan ini menegaskan perlunya peningkatan pada data pelatihan, strategi augmentasi, serta teknik regularisasi agar performa model menjadi lebih optimal.

3.2 Performa Model

Tabel 2. Peforma Model (*Precision, Recall, F1-Score*)

Kelas	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	Support
<i>Blight</i>	0,83	0,92	0,87	109
<i>Common Rust</i>	0,96	0,96	0,96	118
<i>Gray Leaf Spot</i>	0,80	0,63	0,71	57
<i>Healthy</i>	0,99	1,00	1,00	113
<i>accuracy</i>			0,91	397
<i>macro avg</i>	0,90	0,88	0,88	397
<i>weighted avg</i>	0,91	0,91	0,91	397

Pada tabel 2, matriks evaluasi memberikan gambaran tentang peforma model dalam mengklasifikasi penyakit daun jagung berdasarkan matrik presisi, *recall*, *F1-Score*, dan akurasi. Secara keseluruhan, model mencatatkan akurasi sebesar 91%, yang menunjukkan bahwa model telah mampu melakukan klasifikasi dengan tingkat ketepatan yang tinggi. Meskipun demikian, masih terdapat perbedaan performa antar kelas yang menunjukkan adanya ketimpangan hasil klasifikasi. Perbedaan hasil itu bisa jadi karena setiap kelas punya tampilan yang berbeda-beda dan jumlah datasetnya tidak sama. Kelas *Healthy* paling bagus dengan hasil *recall*-nya 100%. Artinya semua gambar daun *Healthy* bisa dikenali dengan tepat. Selain itu, juga *precision* juga tinggi 99%, menunjukkan terdapat sedikit citra dari kelas lain yang salah diklasifikasikan sebagai *Healthy*.

Model lebih mudah mengenali kelas *Healthy* dibandingkan kelas penyakit lainnya. Sebaliknya, untuk kelas *Gray Leaf Spot*, *recall* lebih rendah, cuma 63%. Ini artinya modelnya masih agak kesulitan buat mengenali semua gambar dari kelas ini dengan tepat. Walaupun tingkat ketepatannya *precision* lumayan, 80%, karena *recall* rendah, berarti lumayan banyak gambar *Gray Leaf Spot* yang tertukar dengan kelas lain. Salah satu penyebabnya, *Gray Leaf Spot* ini nampakannya mirip dengan penyakit daun lain, contohnya *Blight*, jadi klasifikasinya lebih susah. Kelas *Blight* dan *Common Rust* hasilnya relatif baik dan seimbang. *Blight* punya tingkat ketepatan 83% dan kemampuan mengingat 92%. *Common Rust* menunjukkan performa sangat tinggi, *precision* dan *recall* masing masing sebesar 96%. Ini menunjukkan model cukup untuk ngenalin ciri-ciri visual dari dua penyakit ini.

Perbedaan antara *macro average* dan *weighted average* ada dicara menghitung hasil evaluasi model. *Macro average* menghitung nilai rata-rata yang sama untuk setiap kelas, tidak mempertimbangkan ada berapa banyak data di kelas. *Precision* dengan nilai 0,90, *recall* 0,88, dan *F1-score* 0,88. Sebaliknya, *weighted average* mempertimbangkan berapa banyak sampel di tiap kelas. Jadi, kelas dengan data lebih banyak jadi lebih berpengaruh ke hasil akhir. Nilai *weighted average* untuk *precision*, *recall*, dan *F1-score* adalah 0,91. Ini menunjukkan sebaran data membantu meningkatkan performa model secara keseluruhan.

Kualitas gambar beda-beda tampilan tiap kelas juga mempengaruhi hasil klasifikasi. Kelas yang visualnya mirip dan mudah dibedakan, seperti *Healthy* dan *Common Rust*, biasanya lebih gampang dipelajari. Kelas dengan tingkat kemiripan visual yang tinggi dan variasi citra yang kompleks, seperti *Gray Leaf Spot*, model jadi susah ngenalin polanya. Selain itu menegaskan perlunya peningkatan kualitas dan keberagaman data pelatihan serta optimasi model agar performa klasifikasi menjadi lebih seimbang di seluruh kelas.

4. SIMPULAN

Setelah melakukan penelitian dan pembahasan tentang cara mengenali penyakit daun jagung pakai metode *NASNet Mobile*, inilah beberapa kesimpulan yang bisa diambil:

1. Penelitian ini berhasil mengembangkan model klasifikasi penyakit daun jagung pakai *NASNet Mobile*. Model ini bisa mengenali empat jenis penyakit, yaitu daun *Healthy*, *Common Rust*, *Gray Leaf Spot*, dan *Blight*, berdasarkan dari citra daun jagung. Hasilnya, model menunjukkan kalau metode *deep learning* itu efektif dipakai di bidang pertanian, terutama untuk mengenali penyakit tanaman secara otomatis.
2. Hasil evaluasi model peforma model dengan akurasi 91%. Artinya, model ini mampu mengenali citra daun jagung. Kelas *Healthy* dan *Common Rust* memiliki peforma baik, dengan nilai *precision* dan *recall* yang tinggi, kemampuan untuk mengenali dua kelas perbedaan visual antara keduanya dengan jelas.
3. Model ini masih kurang untuk mendeteksi *Gray Leaf Spot*, terutama dalam hal *recall*. Ini menjunkkan modelnya belum bisa membedakan penyakit yang mirip-mirip, khususnya *Gray Leaf Spot* sama *Blight*.

4. Augmentasi ternyata membantu meningkatkan dataset dan berbagai kondisi citra, seperti pencahayaan, orientasi, dan kualitas gambar. Namun, tidak seimbang jumlah data dan kemiripan kelas menjadi tantangan dalam proses klasifikasi.
5. Model *NASNet Mobile* dapat dikembangkan jadi alat bantu untuk petani mendeteksi penyakit daun jagung.
6. Untuk pengembangan selanjutnya, perbanyak dan variasi data latihnya. Mencoba Teknik regularisasi, mengoptimasi parameter dan arsitektur modelnya agar performa klasifikasi lebih merata di semua kelas.

5. SARAN

1. Untuk peneliti selanjutnya, bisa menambahkan lagi jumlah dan jenis data gambar daun jagungnya. Terutama untuk penyakit yang sering salah klasifikasi seperti *Gray Leaf Spot*. Data yang ditambahkan dari berbagai kondisi Cahaya, sudut untuk pengambilan foto, dan pertumbuhan tanaman diharapkan bisa meningkatkan model.
2. Perlu dilakukan evaluasi terhadap teknik augmentasi data yang digunakan dengan mengombinasikan atau membatasi jenis augmentasi tertentu, sehingga variasi data yang dihasilkan tetap relevan dengan karakteristik visual penyakit daun jagung dan tidak menimbulkan distorsi yang berlebihan.
3. Penelitian berikutnya dapat mengkaji optimasi arsitektur *NASNet Mobile* melalui penyesuaian hyperparameter, seperti learning rate, jumlah epoch, dan ukuran batch, guna memperoleh performa klasifikasi yang lebih optimal dan stabil pada seluruh kelas penyakit.
4. Untuk mengurangi kesalahan klasifikasi akibat kemiripan visual antar penyakit, penelitian selanjutnya dapat menerapkan teknik fine-tuning yang lebih mendalam pada lapisan tertentu atau mengombinasikan *NASNet Mobile* dengan metode ekstraksi fitur tambahan.
5. Evaluasi model dengan skenario pembagian data yang berbeda, seperti cross-validation, disarankan untuk memperoleh gambaran performa model yang lebih konsisten dan mengurangi bias akibat distribusi data yang tidak seimbang.
6. Penelitian lanjutan juga dapat membandingkan performa *NASNet Mobile* dengan arsitektur *deep learning* lain yang sejenis, sehingga dapat diketahui kelebihan dan kekurangan masing-masing model dalam mengklasifikasikan penyakit daun jagung secara lebih komprehensif.

DAFTAR PUSTAKA

- [1] B. Nurwenda, Saediman, and Yusria, “8550-8565,” *Innov. J. Soc. Sci. Res.*, vol. 4, no. Analisis Dampak Perubahan Iklim Terhadap Ketahanan Pangan Petani Jagung Lokal Di Kecamatan Kabawo Kabupaten Muna, pp. 8550–8566, 2024.
- [2] V. A. Puspita, U. A. Hamakonda, and P. Oba, “LOKAL DI KABUPATEN NGADA Program Studi Agroteknologi Sekolah Tinggi Pertanian Flores Bajawa , Ngada NTT * Email : ayupuspitav@gmail.com Abstrak INCREASING THE ECONOMIC VALUE OF CORN WITH FOOD DIVERSIFICATION OF LOCAL WISDOM-BASED PROCESSING IN NGADA DISTR”.
- [3] M. Fiqriansyah *et al.*, *TEKNOLOGI BUDIDAYA TANAMAN JAGUNG (Zea mays) DAN SORGUM (Sorghum bicolor (L.) Moench)*. 2021.
- [4] N. U. M. H. Lapui Ardiansyah, “Tepung Jagung 2,” *J. Agropet*, vol. 18, pp. 43–46, 2021, [Online]. Available: <https://ojs.unsimar.ac.id/index.php/AgroPet/article/view/359>
- [5] F. Melia, F. M. Aldian, M. S. F. Pahlevi, R. N. I. Risqullah, and S. Oktaffiani, “Peran Pemerintah Dalam Meningkatkan Volume Ekspor Jagung,” *J. Econ.*, vol. 2, no. 1, pp. 1305–1320, 2023, doi: 10.55681/economina.v2i1.287.
- [6] H. Halimah, N. Hendri, and Syukrial, “Pengaruh Biaya Produksi dan Harga Jual Terhadap Pendapatan Petani Jagung Pada Petani Jagung Nagari Aie Tajun Kecamatan Lubuk Alung,” *J. Point Equilib. Manaj. dan Akunt.*, vol. 6, no. 2, pp. 75–88, 2024, doi: 10.59963/jpema.v6i2.357.
- [7] E. Ginting, T. S. Alasi, R. Alamsyah, M. Halim, and I. J. Tarigan, “Sistem Pakar Diagnosa Penyakit Tanaman Jagung Menggunakan Metode Forward Chaining Pada Kabupaten Langkat,” *J. Armada Inform.*, vol. 8, no. 2, pp. 36–47, 2024, doi: 10.36520/jai.v8i2.130.
- [8] A. Pfordt and S. Paulus, “A review on detection and differentiation of maize diseases and pests by imaging sensors,” *J. Plant Dis. Prot.*, vol. 132, no. 1, pp. 1–21, 2025, doi: 10.1007/s41348-024-01019-4.

-
- [9] G. T. Askale, A. B. Yibel, B. M. Taye, and G. D. Wubneh, “Mobile based deep CNN model for maize leaf disease detection and classification,” *Plant Methods*, vol. 21, no. 1, 2025, doi: 10.1186/s13007-025-01386-5.
- [10] S. Kumar *et al.*, “Spatial attention-guided pre-trained networks for accurate identification of crop diseases,” *Sci. Rep.*, vol. 15, no. 1, pp. 1–29, 2025, doi: 10.1038/s41598-025-08004-3.
- [11] H. Paul, H. Udayangani, K. Umesha, N. Lankasena, C. Liyanage, and K. Thambugala, “Maize leaf disease detection using convolutional neural network: a mobile application based on pre-trained VGG16 architecture,” *New Zeal. J. Crop Hortic. Sci.*, vol. 53, no. 2, pp. 367–383, 2025.
- [12] B. Widiyanto, E. Utami, and D. Ariatmanto, “Identifikasi Penyakit Tanaman Jagung Berdasarkan Citra Daun Menggunakan Convolutional Neural Network,” *Techno.Com*, vol. 22, no. 3, pp. 599–608, 2023, doi: 10.33633/tc.v22i3.8425.
- [13] P. A. Azli, M. Minarni, A. Syahrani, G. Y. Swara, and A. Anisya, “Segmentasi Citra Daun Tomat untuk Klasifikasi Penyakit Tanaman Menggunakan Support Vector Machine (SVM),” *J. Inform. J. Pengemb. IT*, vol. 10, no. 4, pp. 997–1008, 2025, doi: 10.30591/jpit.v10i4.9404.
- [14] Audy and Zaini, “Analisis Kualitas Jagung Berbasis IoT dengan Penerapan Model SSD Mobilenet dan Histogram,” *J. Nas. Tek. Elektro dan Teknol. Inf.*, vol. 11, no. 2, pp. 79–87, 2022, doi: 10.22146/jnteti.v11i2.3434.
- [15] D. Hindarto, “Comparison of Detection With Transfer Learning Architecture Restnet18, Restnet50, Restnet101 on Corn Leaf Disease,” *J. Teknol. Inf. Univ. Lambung Mangkurat*, vol. 8, no. 2, pp. 41–48, 2023, doi: 10.20527/jtiulm.v8i2.174.
- [16] Z. Ma *et al.*, “Maize leaf disease identification using deep transfer convolutional neural networks,” *Int. J. Agric. Biol. Eng.*, vol. 15, no. 5, pp. 187–195, 2022, doi: 10.25165/j.ijabe.20221505.6658.
- [17] W. Maximilliano and N. Rachmat, “Comparative Analysis of MobileNetV3-Large and Small for Corn Leaf Disease Classification,” *Brill. Res. Artif. Intell.*, vol. 5, no. 1, pp. 325–332, 2025, doi: 10.47709/brilliance.v5i1.6259.
- [18] U. Vignesh and R. Elakya, “Identification of Unhealthy Leaves in Paddy by using Computer Vision based Deep Learning Model,” *Int. J. Electr. Electron. Res.*, vol. 10, no. 4, pp. 796–800, 2022, doi: 10.37391/IJEER.100405.
- [19] D. Iswantoro and D. Handayani UN, “Klasifikasi Penyakit Tanaman Jagung Menggunakan Metode Convolutional Neural Network (CNN),” *J. Ilm. Univ. Batanghari Jambi*, vol. 22, no. 2, p. 900, 2022, doi: 10.33087/jiubj.v22i2.2065.
- [20] 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.
- [21] 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.
- [22] 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.