

OPTIMASI DAN INTEGRASI *CONVOLUTIONAL NEURAL NETWORK* PADA APLIKASI *ANDROID* UNTUK DETEKSI PENYAKIT DAUN PADI

BAGUS MAULUDI KUSUMA¹, TEGUH IMAN HERMANTO², CANDRA DEWI LESTARI³

Sekolah Tinggi Teknologi Wastukencana

Jl. Cikopak No. 53, Kec. Babakan Cikao, Kab. Purwakarta, Jawa Barat 41151

Email: bagusmauludi11@wastukencana.ac.id¹, teguhiman@wastukencana.ac.id², candradewi@wastukencana.ac.id³

ABSTRAK

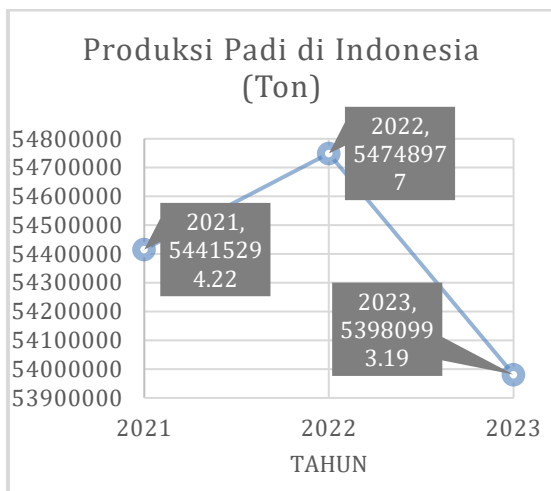
Padi adalah tanaman pangan utama di Indonesia dan memiliki peran vital dalam perekonomian serta kehidupan sehari-hari masyarakat. Namun, produksi padi saat ini mengalami penurunan akibat serangan hama dan penyakit. Deteksi dini dan klasifikasi penyakit padi yang akurat sangat penting untuk mengurangi dampak negatif ini. Penelitian ini membangun dan melatih model *Convolutional Neural Network* (CNN) menggunakan arsitektur *MobileNetV3 Large* untuk mengenali kondisi kesehatan tanaman padi. Model dilatih dengan dataset citra daun padi berlabel, melalui 30 *epoch*, *batch size* 45, dan *optimizer* Lion. Hasil pengujian menunjukkan akurasi 75% untuk data uji dengan *loss* 59%, dan akurasi 76% untuk data latih dengan *loss* 61%. Model ini juga berhasil diimplementasikan dalam aplikasi *mobile* berbasis *Android*. Penelitian ini diharapkan dapat berkontribusi pada sektor pertanian Indonesia dengan menyediakan alat deteksi penyakit padi yang lebih efisien dan efektif.

Kata kunci: *Convolutional Neural Network, Klasifikasi, Penyakit Padi*

I. PENDAHULUAN

Beras, yang dihasilkan dari tanaman padi (*Oryza sativa*), adalah makanan pokok utama bagi masyarakat Indonesia. Dengan konsumsi per kapita mencapai

sekitar 111,58 kg per tahun, sehingga tanaman padi dapat dikatakan memainkan peran penting dalam kehidupan sehari-hari masyarakat dan menjadi tulang punggung ketahanan pangan nasional (Herdiyanti & Sulistyono, 2021). Melihat pernyataan tersebut, dapat dikatakan bahwa tanaman padi adalah salah satu tumbuhan yang harus sangat diperhatikan.



Gambar 1. 1 Grafik Produksi Padi di Indonesia



Gambar 1. 2 Grafik Luas Panen Padi di Indonesia

Namun, menurut data yang dikeluarkan oleh Badan Pusat Statistik, jumlah produksi padi pada tahun 2023 mengalami penurunan dibandingkan dengan jumlah produksi padi pada tahun 2022. Data tersebut menunjukkan penurunan sebanyak 2,05% untuk jumlah produksi padi atau senilai dengan 1,12 juta Ton GKG (Gabah Kering Giling) dan penurunan sebanyak 2,45% untuk luas panen atau senilai dengan 0,26 juta hektar (Badan Pusat Statistik, 2023). Berkurangnya angka produksi dan jumlah luas panen padi ini dapat dipengaruhi oleh berbagai macam faktor, salah satu faktor yang mempengaruhi menurunnya angka tersebut adalah karena serangan hama dan penyakit pada tumbuhan padi.

Bagian daun sering menjadi tempat yang paling mudah dideteksi karena gejala penyakit biasanya tampak jelas di sana. Meskipun begitu, mengenali jenis penyakit memerlukan keahlian tertentu dan biasanya hanya dilakukan oleh para pakar dan para ahli (Saputra et al., 2023). Petani biasa yang tidak memiliki kompetensi yang mumpuni dalam bidang ilmu pengetahuan anatomi tumbuhan padi

kerap mengalami kesulitan dalam mendeteksi penyakit dan jenis penyakit pada tanaman padi.

Salah satu teknologi yang dapat dikembangkan untuk proses identifikasi atau klasifikasi kondisi kesehatan tumbuhan padi adalah dengan pengenalan citra daun padi menggunakan metode *Convolutional Neural Network* (CNN). CNN merupakan salah satu model algoritma pada bidang *deep learning* yang dapat digunakan untuk meng-klasifikasi suatu citra gambar (Khoiruddin et al., 2022). Pada algoritma CNN sendiri terdapat salah satu arsitektur bernama *MobilNetV3 Large* yang dapat mengklasifikasikan suatu citra gambar dengan akurat dan efisien (Howard et al., 2019).

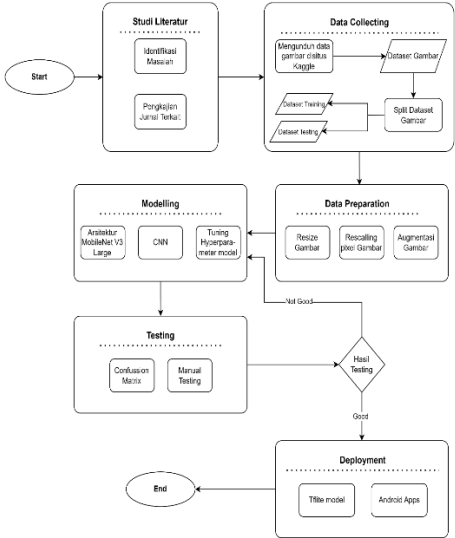
Meskipun berbagai penelitian sebelumnya, seperti yang dilakukan oleh (Khoiruddin et al., 2022) pada penelitiannya yang berjudul Klasifikasi Penyakit Daun Padi Menggunakan *Convolutional Neural Network* dan (Saputra et al., 2023) pada penelitiannya yang berjudul Klasifikasi Kesehatan Pada Tanaman Padi Menggunakan Citra *Unmanned Aerial Vehicle* (Uav) Dengan Metode *Convolutional Neural Networks* (CNN), telah berhasil mengembangkan model *Convolutional Neural Network* (CNN) untuk klasifikasi jenis penyakit pada daun padi, sebagian besar penelitian tersebut tidak melanjutkan hasilnya ke tahap integrasi pada *platform mobile* berbasis *Android*. Keterbatasan ini menimbulkan kebutuhan akan penelitian lebih lanjut yang tidak hanya fokus pada akurasi model, tetapi juga integrasi model ke dalam aplikasi *mobile*, sehingga teknologi ini dapat lebih mudah diakses dan dimanfaatkan oleh petani di lapangan.

Dengan adanya pengembangan penelitian ini, harapannya dapat meningkatkan angka produksi dan luas panen padi pada masa yang akan datang dan dapat membantu para petani padi untuk mencegah juga mendeteksi terjadinya serangan hama dan penyakit pada tumbuhan padi dengan lebih mudah dan efisien.

II. METODE PENELITIAN

Penelitian ini dilakukan untuk membuat model yang dapat mengenali jenis penyakit pada tumbuhan padi menggunakan metode *Convolutional Neural Network* (CNN) serta melakukan integrasi model yang sudah dibuat kedalam aplikasi *mobile* berbasis *Android*. Aktivitas yang dilakukan pada penelitian mengacu pada kerangka

penelitian yang telah penulis susun berdasarkan metode CRISP-DM. Adapun kerangka penelitian tersebut dapat dilihat pada Gambar 2.1 dibawah



Gambar 2. 1 Kerangka Penelitian

2.1 Data Collecting

Data yang digunakan berupa citra daun tumbuhan padi yang dimana citra gambar tersebut berasal dari dataset yang telah diunduh melalui situs *Kaggle.com*. Format data yang terdapat pada dataset yang telah diunduh adalah file data citra ber-ekstensi *.jpg* dengan ukuran keseluruhan dari dataset ini adalah sebesar 798MB, berjumlah total data citra sebanyak 53.300 data citra. Masing-masing data citra pada dataset memiliki 3 *channel* yaitu *red, green, dan blue*. Kualitas data citra pada dataset tergolong cukup baik. Sampel dari data citra pada dataset dapat dilihat pada gambar 2.2 dibawah.



Gambar 2. 2 Sample Data

Dataset yang sudah didapatkan selanjutnya akan dipisah menjadi dua kelompok yaitu data *training* yang akan digunakan untuk melatih model dalam proses mengklasifikasi citra sebanyak 2419 data atau 80% dari keseluruhan dataset, dan data *testing* yang akan digunakan untuk menguji model dalam mengklasifikasikan citra sebanyak 603 atau 20% dari keseluruhan dataset.

2.2 Data Preparation

Dataset yang telah diunduh, akan memasuki tahapan *data preparation* yang bertujuan untuk merapihkan dataset agar nantinya model dapat memproses dataset dengan efisien dan optimal.

Proses pertama pada tahapan *data preparation* adalah *resize data*. *Resize data* adalah proses penyesuaian ukuran seluruh data pada dataset. Dataset yang didapatkan memiliki data-data citra dengan ukuran yang berbeda-beda. Jika tidak ada penyesuaian ukuran data-data tersebut, maka model nantinya akan melakukan proses pengenalan fitur citra dengan tidak konsisten yang menyebabkan menurunnya tingkat akurasi model. Oleh karena itu proses *resize data* wajib dilakukan. Pada penelitian ini, penulis menyesuaikan ukuran seluruh data pada dataset menjadi 224×224 pixel.

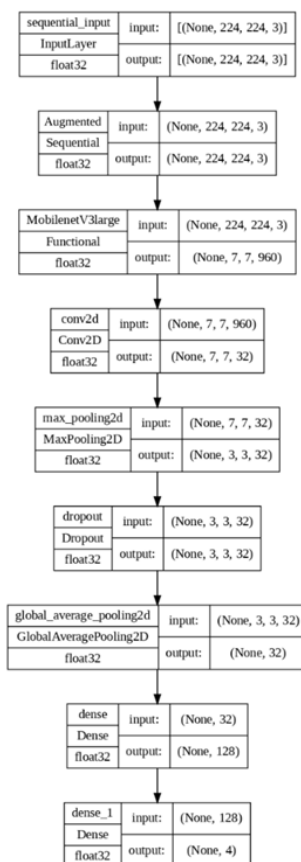
Proses *data preparation* selanjutnya adalah augmentasi data. Augmentasi data adalah proses memperbanyak jumlah dataset dengan cara menduplikasi setiap data pada dataset namun dengan sudut pandang atau *angle* yang berbeda-beda. Tujuan dari proses ini adalah untuk menghindari *overfitting* pada model juga agar model dapat mengenali citra dengan berbagai sudut pandang. Proses augmentasi dilakukan dengan menggunakan *library keras* dengan beberapa parameter, parameter-parameter tersebut adalah sebagai berikut:

1. *RandomFlip*, digunakan sebagai lapisan augmentasi yang akan membalik gambar secara acak dalam arah horizontal.
2. *RandomRotation*, digunakan sebagai lapisan augmentasi yang akan memutar gambar secara acak sebesar $\pm 10\%$ dari sudut aslinya.
3. *RandomZoom*, lapisan augmentasi yang akan memperbesar atau memperkecil gambar secara acak hingga 50% dari ukuran aslinya.

Proses *data preparation* yang terakhir adalah *rescalling pixel*. Proses *rescalling pixel* pada dataset dilakukan untuk memastikan bahwa semua nilai *pixel* berada dalam rentang 0 hingga 1. Hal ini penting karena nilai piksel asli berada dalam rentang 0 hingga 255. Tujuan dari proses ini adalah untuk meringankan beban komputasi pada model serta agar model dapat bekerja dengan lebih efisien dan lebih stabil. Dalam melakukan proses *rescalling pixel*, penulis menggunakan *library keras* untuk membagi setiap nilai *pixel* dengan nilai 255. Dengan demikian, nilai *pixel* yang semula berada dalam rentang 0 hingga 255 akan diubah menjadi rentang 0 hingga 1.

2.3 Modelling

Model yang dibangun akan menggunakan arsitektur *MobileNetV3 Large* untuk membantu meningkatkan efisiensi model dan untuk menghindari *overfitting* pada model. Diagram alur model yang akan dibangun dapat dilihat pada Gambar 2.3.



Gambar 2. 3 Diagram Alur Model

III. HASIL DAN PEMBAHASAN

Setelah melakukan pembangunan model sesuai dengan diagram alur model pada gambar 2.3 diatas, proses selanjutnya adalah optimasi parameter model. Proses optimasi parameter model dilakukan untuk meningkatkan performa model yang telah dibangun sebelumnya. Parameter-parameter yang akan dioptimasi meliputi jumlah *epoch*, jumlah *batch size*, dan jenis *optimizer*. Selanjutnya model yang telah dioptimasi akan di-integrasikan kedalam suatu aplikasi *mobile* berbasis *Android* untuk memudahkan para petani dalam menggunakan model.

3.1 Optimasi Model

Eksperimen pertama yang akan dilakukan adalah dengan melatih model dengan tiga macam jumlah *epoch* dan *batch size*. *Epoch* sendiri merupakan suatu istilah yang merujuk pada proses dimana model mengolah seluruh dataset dalam satu siklus. Sedangkan *batch size* adalah jumlah kelompok data yang akan diproses oleh model (Suwitono & Kaunang, 2022). Hasil dari eksperimen ini dapat dilihat pada table 3.1 dibawah.

Tabel 3. 1 Hasil Eksperimen Jumlah Epoch dan Batch Size

<i>Batch</i> <i>Epoch</i>	15		30		45	
	<i>Training</i>	<i>Validasi</i>	<i>Training</i>	<i>Validasi</i>	<i>Training</i>	<i>Validasi</i>
10	Acc:70% Los:70%	Acc:70% Los:70%	Acc:69% Los:77%	Acc:71% Los:71%	Acc:67% Los:81%	Acc:69% Los:73%
20	Acc:71% Los:73%	Acc:76% Los:62%	Acc:71% Los:70%	Acc:73% Los:67%	Acc:72% Los:69%	Acc:71% Los:69%
30	Acc:73% Los:68%	Acc:71% Los:67%	Acc:73% Los:68%	Acc:74% Los:63%	Acc:74% Los:66%	Acc:76% Los:59%

Setelah melakukan eksperimen pertama, penulis mendapatkan nilai akurasi terbaik yaitu pada jumlah *batch size* sebesar 45 dan jumlah *epoch* sebesar 30 baik untuk data *training* maupun data *testing*. Dengan begitu dapat disimpulkan bahwa semakin besar jumlah *epoch* dan *batch size* maka semakin baik pula nilai akurasi yang dihasilkan oleh model untuk studi kasus ini.

Eksperimen yang akan dilakukan selanjutnya adalah melakukan *compile* model dengan berbagai macam *optimizer*. *Optimizer* adalah algoritma atau metode yang digunakan untuk mengubah atribut *neural networks*, seperti *weights* dan *learning rate*, untuk mengurangi nilai *loss*. *Optimizer* bertujuan untuk meminimalkan (atau,

dalam beberapa kasus, memaksimalkan) fungsi *loss*, yang merupakan ukuran seberapa jauh perbedaan prediksi dari hasil sebenarnya (Everton Gomedé, 2024). Pada eksperimen ini, penulis akan menggunakan *optimizer variant* Adam, RMSprop, dan Lion untuk mengetahui *optimizer* terbaik untuk model yang telah dibangun. Eksperimen ini dilakukan dengan menggunakan jumlah *epoch* dan jumlah *batch size* terbaik yang sudah didapatkan pada eksperimen sebelumnya. Hasil dari eksperimen ini dapat dilihat pada tabel 3.2 dibawah.

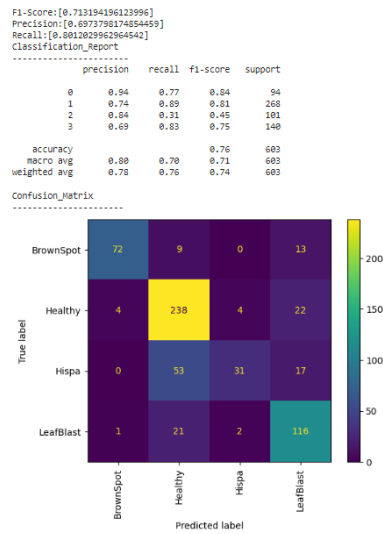
Tabel 3. 2 Hasil Eksperimen Jenis Optimier

<i>Optimizer</i> →	Adam		RMSprop		Lion	
Epoch, Batch Size ↓	<i>Training</i>	<i>Validasi</i>	<i>Training</i>	<i>Validasi</i>	<i>Training</i>	<i>Validasi</i>
(30,45)	Acc:74% Los:66%	Acc:76% Los:59%	Acc:73% Los:69%	Acc:74% Los:62%	Acc:76% Los:61%	Acc:75% Los:59%

Pada tabel 3.2 dapat dilihat bahwa *optimizer* Lion memiliki kinerja yang lebih baik dibaningkan *optimizer* Adam dan *optimizer* RMSprop. Sehingga dapat disimpulkan bahwa algoritma milik *optimizer* Lion yang akan mengalami peningkatan kinerja seiring dengan jumlah *batch size* yang sudah ditentukan sebelumnya (Chen et al., 2024).

3.2 Testing

Tahap ini dilakukan untuk mengevaluasi performa dari model yang telah berhasil dibangun dan dioptimasi. Proses evaluasi menggunakan metode *Matriks Confussion* untuk mengetahui bagaimana model bekerja pada seluruh dataset. Serta dilakukan perhitungan nilai *recall*, *precissions*, dan *f1 score* dari hasil *Matriks Confussion* menggunakan *library scikit learn* untuk memahami kualitas model dengan lebih mendalam dan objektif. Hasil dari *Matriks Confussion* dapat dilihat pada gambar 3. dibawah.



Gambar 3. 1 *Matriks Confusion Model*

Secara keseluruhan, model menunjukkan performa yang cukup baik. Model selanjutnya dapat diintegrasikan kedalam aplikasi *mobile* berbasis *Android*.

3.3 Deployment

Setelah mendapatkan model dengan performa yang cukup baik, tahapan selanjutnya adalah meng-integrasikan model kedalam suatu aplikasi *mobile* berbasis *Android*. Untuk dapat meng-integrasikannya, model yang telah dibangun perlu dikonversi terlebih dahulu kedalam format *.tflite*. *TensorFlow Lite* (TFLite) adalah sebuah *framework* yang dikembangkan oleh *Google* untuk meng-integrasikan dan mengoptimalkan model *machine learning* pada perangkat *mobile* dan *embedded*. TFLite dirancang untuk memberikan inferensi yang cepat dan efisien, sehingga memungkinkan aplikasi berbasis AI berjalan secara efektif di perangkat dengan sumber daya terbatas seperti *smartphone* dan perangkat IoT. Hasil integrasi model dapat dilihat pada gambar 3.2 dibawah.



Gambar 3. 2 Hasil Integrasi Model Kedalam Aplikasi *Android*

IV. KESIMPULAN

Berdasarkan penelitian yang dilakukan dapat disimpulkan bahwa model yang telah berhasil juga telah dioptimasi dengan parameter jumlah *epoch* terbaik yaitu 30, jumlah *batch size* terbaik yaitu 45, dan *optimizer* terbaik yaitu Lion menghasilkan nilai akurasi 75% untuk data testing dengan nilai loss sebesar 59%, sedangkan untuk data training menghasilkan nilai akurasi sebesar 76% dan nilai *loss* sebesar 61%. Model yang telah dibangun juga telah berhasil di-integrasikan ke dalam aplikasi berbasis *mobile* dengan sistem operasi Android dan dapat bekerja dengan baik tanpa adanya hambatan.

DAFTAR PUSTAKA

- Badan Pusat Statistik. (2023, October 16). Luas Panen dan Produksi Padi di Indonesia 2023 (Angka Sementara). *Berita Resmi Statistik*.
- Chen, X., Liang, C., Huang, D., Real, E., Wang, K., Pham, H., Dong, X., Luong, T., Hsieh, C.-J., & Lu, Y. (2024). Symbolic discovery of optimization algorithms. *Advances in Neural Information Processing Systems*, 36.
- Everton Gomedé, P. (2024, January 5). *Exploring the Landscape of Optimizers in Keras*. Diakses Pada 8 Maret 2024, <https://Medium.Com/Aimonks/Exploring-the-Landscape-of-Optimizers-in-Keras-C7f1b13ddb63>.

- Herdiyanti, H., & Sulistyono, E. (2021). Pertumbuhan dan Produksi Beberapa Varietas Padi (*Oryza sativa* L.) pada Berbagai Interval Irigasi. *Indonesian Journal of Agronomy*, 49(2), 129–135.
- Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., & Vasudevan, V. (2019). Searching for mobilenetv3. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 1314–1324.
- Khoiruddin, M., Junaidi, A., & Saputra, W. A. (2022). Klasifikasi Penyakit Daun Padi Menggunakan Convolutional Neural Network. *Journal of Dinda: Data Science, Information Technology, and Data Analytics*, 2(1), 37–45.
- Saputra, D. M., Hermawan, E., & Agustian, S. (2023). KLASIFIKASI KESEHATAN PADA TANAMAN PADI MENGGUNAKAN CITRA UNMANED AERIAL VEHICLE (UAV) DENGAN METODE CONVOLUTIONAL NEURAL NETWORKS (CNN). *Jurnal Ilmiah Teknologi Infomasi Terapan (JITTER)*, 9(3).
- Suwitono, Y. A., & Kaunang, F. J. (2022). Implementasi Algoritma Convolutional Neural Network (CNN) Untuk Klasifikasi Daun Dengan Metode Data Mining SEMMA Menggunakan Keras. *Jurnal Komtika (Komputasi Dan Informatika)*, 6(2), 109–121.