

Pemanfaatan Algoritma *Convolutional Neural Network* Dengan Untuk Mendeteksi Penyakit Pada Tumbuhan Jagung

*¹Alfin Kabir Rifai; ²Muhammad Rafi Muttaqin; ³Dede Irmayanti

*^{1,2,3}Sekolah Tinggi Teknologi Wastukencana, Jl Cikopak No 53, Mulyamekar, Babakancikao, Purwakarta, Jawa Barat

*¹Email : alfinkabir11@wastukencana.ac.id

*²Email : rafi@wastukencana.ac.id

*³Email : dedeirmayanti@wastukencana.ac.id

ABSTRACT

Corn is a crucial cereal crop that plays a significant role in food supply due to its high carbohydrate content. However, corn production in 2023 experienced a decline compared to 2022. One of the factors contributing to this decline is the attack of pests and diseases on corn plants. With the advancement of digital image processing and machine learning technologies, plant disease diagnosis can be performed more quickly and accurately. This study utilizes a dataset of corn leaf images containing various types of diseases. These images are processed and analyzed using a model with a convolutional neural network (CNN) algorithm that has undergone hyperparameter fine-tuning. The research demonstrates that the use of convolutional neural networks with hyperparameter fine-tuning yields satisfactory results in classifying types of diseases on corn plants. The study's findings indicate that this model achieves an accuracy of 0.92 and a loss value of 0.363. These results highlight the significant potential of using CNNs in detecting diseases in corn plants, which can aid farmers in improving their crop yield and quality.

Keywords: Convolutional Neural Network; Corn Leaves; Disease Classification; Digital Images; Machine Learning;

ABSTRAKS

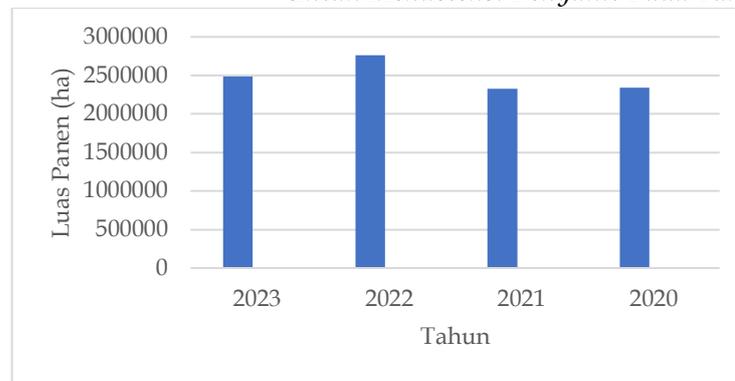
Jagung adalah salah satu jenis tanaman serealia yang memiliki peran yang sangat penting dalam penyediaan bahan pangan karena kandungannya yang kaya akan karbohidrat. Namun, jumlah produksi jagung pada tahun 2023 mengalami penurunan dibandingkan pada tahun 2022. Salah satu faktor yang menyebabkan menurunnya produksi jagung adalah serangan hama dan penyakit pada tanaman jagung. Dengan perkembangan teknologi pengolahan citra digital dan pembelajaran mesin, diagnosis penyakit tanaman dapat dilakukan dengan lebih cepat dan akurat. Penelitian ini menggunakan dataset citra daun jagung yang mengandung berbagai jenis penyakit. Citra-citra tersebut diproses dan diolah oleh sebuah model dengan algoritma convolutional neural network (CNN) yang telah melalui proses fine-tuning hyperparameter. Penelitian ini membuktikan bahwa penggunaan metode convolutional neural network dengan fine-tuning hyperparameter memberikan hasil yang memuaskan dalam mengklasifikasikan jenis penyakit pada tanaman jagung. Hasil penelitian menunjukkan bahwa model ini mampu mencapai nilai akurasi sebesar 0.92 dan nilai loss sebesar 0.363. Temuan ini menunjukkan potensi besar penggunaan CNN dalam mendeteksi penyakit pada tanaman jagung, yang dapat membantu petani dalam meningkatkan produksi dan kualitas hasil panen mereka.

Kata Kunci: Citra Digital; Convolutional Neural Network; Daun Jagung; Klasifikasi Penyakit; Pembelajaran Mesin.

1 Pendahuluan

Jagung adalah salah satu jenis tanaman serealia yang memiliki peran yang sangat penting dalam penyediaan bahan pangan karena kandungannya yang kaya akan karbohidrat. Jagung (*Zea mays L.*) merupakan salah satu komoditas pertanian yang digunakan sebagai bahan pangan dan strategis untuk ditanam di berbagai daerah. Keberadaan jagung di Indonesia memiliki dampak yang strategis dalam perekonomian nasional, dan memiliki fungsi dan peran yang sangat beragam.

Menurut data yang dipublikasikan oleh Badan Pusat Statistik Indonesia pada gambar 1, jumlah luas panen dalam satuan hektar untuk produksi tanaman jagung mengalami penurunan pada tahun 2023 yaitu sebanyak 2487191 Ha, dibandingkan dengan luas panen tanaman jagung pada tahun 2022 yang memiliki nilai sebesar 2764366 Ha.



Gambar 1. Grafik Luas Panen Jagung di Indonesia

Lalu pada gambar 2 dibawah terlihat bahwa produkis jagung pertahun juga mengalami penurunan yang signifikan, pada tahun 2022 jumlah produksi jagun mencapai angka 13414921 Ton sedangkan pada tahun 2023 mengalami penurunan menjadi 12928940 Ton.



Gambar 2. Grafik Produksi Jagung di Indonesia

Beberapa aspek yang mempengaruhi penurunan produksi jagung dan luas panen jagung seperti yang terlihat pada gambar 1 dan 2 meliputi proses pemilihan varietas benih, proses pengelolaan penanaman dan perawatan benih, pengendalian hama dan penyakit serta pengaruh iklim, cuaca dan kondisi tanah. Namun pada penelitian yang dilakukan oleh [1], penelitian tersebut mendapatkan hasil bahwa akibat meningkatnya serangan hama dan penyakit terhadap tanaman jagung, petani jagung mengalami kerugian beberapa tahun terakhir ini. Menurut Astari & Lestari (2024) juga, serangan hama dan penyakit-penyakit pada tanaman jagung sering menjadi penyebab utama rendahnya hasil produksi jagung di beberapa daerah di Indonesia. Tanda-tanda adanya penyakit pada tanaman jagung bisa dikenali melalui perubahan yang terjadi pada kondisi daunnya.

Penyakit yang terjadi pada daun jagung menunjukkan gejala yang beragam dan terkadang menimbulkan kesulitan dalam proses diagnosis bagi para petani. Oleh karena itu, diperlukan keahlian khusus untuk mengidentifikasi penyakit yang menyerang tanaman jagung serta mengetahui strategi penanggulangannya. Biasanya, keahlian semacam ini dimiliki oleh para ahli patologi tanaman yang telah berpengalaman dalam bidangnya.

Dengan berkembangnya teknologi saat ini, penggunaan teknologi *computer vision* dan *deep learning* dapat dijadikan solusi dan cara baru bagi petani mengidentifikasi penyakit pada tanaman jagung dengan lebih cepat dan efisien. Salah satu metode atau algoritma pada *deep learning* adalah *Convolutional Neural Network* (CNN). CNN memiliki kemampuan utama dapat mengenali informasi prediktif dari suatu objek seperti gambar, teks, suara dan video meskipun objek tersebut diposisikan dimana saja pada saat diinputkan (Putra, 2019). Penelitian dengan menggunakan algoritma CNN pernah dilakukan untuk mengklasifikasi penyakit daun jeruk dan mendapat akurasi 98% (R Riswandi et al., 2021). Penelitian lainnya yang dilakukan oleh [5] menggunakan arsitektur CNN untuk melakukan klasifikasi penyakit tanaman daun kentang dan mendapat hasil akurasi sebesar 97,90% dengan parameter *optimizer RMSprop*, *learning rate* 0,0001; *epochs* 100 dan *batch size* 32. Meskipun penelitian-penelitian tersebut menunjukkan keberhasilan dalam mengklasifikasikan penyakit pada daun jeruk dan daun kentang dengan tingkat akurasi yang tinggi, terdapat beberapa aspek yang belum dieksplorasi, yang menjadi

Pemanfaatan Algoritma Convolutional Neural Network Dengan Fine-Tuning Hyperparameter Untuk Mendeteksi Penyakit Pada Tumbuhan Jagung

fokus penelitian ini yaitu bagaimana efektifitas model CNN dalam mendeteksi penyakit pada daun jagung dan Pendekatan *Hyperparameter Fine-Tuning* yang tidak berfokus pada proses *compile* dan *training* model namun juga pada *layer* model.

Dengan adanya penerapan teknologi *deep learning* dengan algoritma CNN pada identifikasi penyakit pada daun tanaman jagung, harapannya produksi jagung/panen jagung di Indonesia dapat menjadi lebih baik dan meningkat dimasa yang akan datang.

2 Tinjauan Pustaka

2.1 Jagung

Jagung (*Zea mays L.*) adalah tanaman sereal tahunan yang memiliki peran penting dalam penyediaan bahan pangan. Tanaman ini ditanam secara luas untuk menghasilkan tongkol besar berisi biji-bijian bertepung yang dikenal sebagai biji jagung. Biji-bijian ini digunakan sebagai makanan bagi manusia dan hewan ternak serta sebagai bahan baku untuk produksi *biofuel* dan berbagai bahan kimia berguna lainnya. Jagung pertama kali didomestikasi di wilayah barat daya Meksiko sekitar 7.000 hingga 12.000 tahun yang lalu dan telah menjadi makanan pokok bagi penduduk asli Amerika sebelum menyebar ke seluruh dunia setelah penemuan benua Amerika [6]

Jagung sendiri memainkan peran penting dalam perekonomian Indonesia, khususnya sebagai bahan baku utama dalam industri pakan ternak. Meskipun produksi jagung meningkat pada tahun 2021-2022 dan menurun kembali pada tahun 2023. Namun, konsumsi dan kebutuhan akan jagung domestik terus meningkat, terutama didorong oleh peningkatan kegiatan ekonomi di negara Indonesia [7].

2.2 Convolutional Neural Network

Convolutional Neural Network (CNN) merupakan jenis jaringan saraf yang dirancang khusus untuk menangani data dengan struktur *grid*. CNN menggantikan penerapan matriks umum dengan operasi konvolusi, di mana setiap lapisan jaringan saraf ini setidaknya mengandung satu operasi konvolusi (Andika, 2019). *Convolutional Neural Network* (CNN) merupakan evolusi dari *Multilayer Perceptron* (MLP) yang tergolong dalam *neural network* tipe *feed forward* (bukan tipe berulang). CNN dirancang khusus untuk memproses data dua dimensi (Ramadhani, 2021).

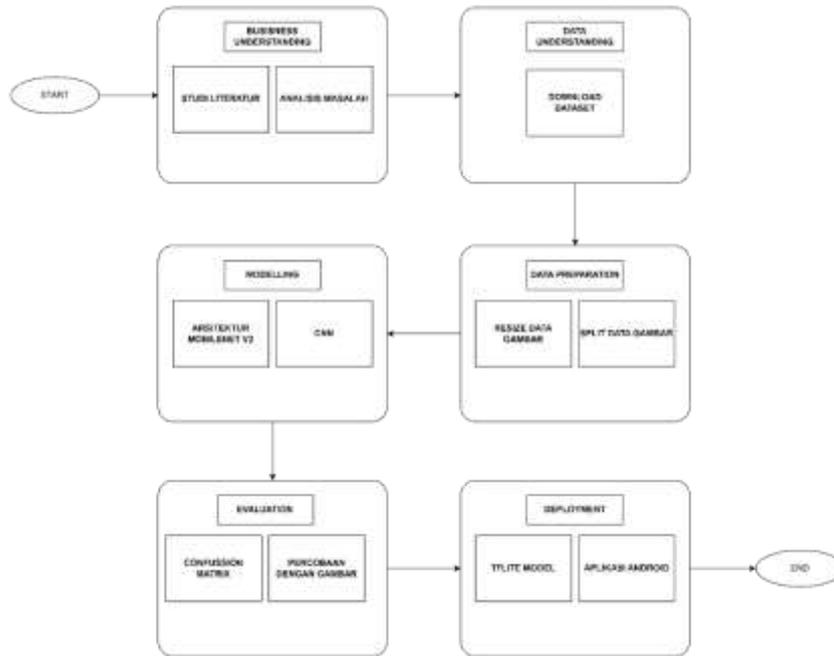
2.3 CRISP-DM

CRISP-DM adalah metode yang menggunakan model pengembangan data yang sering digunakan oleh para ahli untuk menyelesaikan masalah. Penelitian ini mengikuti enam tahap dari CRISP-DM, yaitu pemahaman bisnis, pemahaman data, persiapan data, pemodelan, evaluasi, dan implementasi [10]. *Cross Industry Standard Process for Data Mining* (CRISP-DM) adalah model proses industri independen yang lazim digunakan untuk keperluan *data mining* (Kurniawan, 2022). Metode CRISP-DM (*Cross-Industry Standard Process for Data Mining*) bertujuan untuk memberikan *blue print* berupa tahapan dalam proses pengumpulan data, Tahapan tersebut dibagi menjadi enam yaitu *business understanding*, *data understanding*, *data preparation*, *modeling*, *evaluation*, dan *deployment* (Navisa, 2021).

3 Metode Penelitian

Kerangka Penelitian merupakan garis besar penulis dalam melaksanakan penelitian yang mana menjadi gambaran apa saja yang telah maupun akan dilakukan penulis selama penelitian dari mulai studi literatur hingga *deployment* dengan mengikuti aturan dari metode CRISP-DM. Dengan kerangka penelitian, penulis dapat melakukan penelitian berdasarkan alur yang telah disusun secara sistematis dan terstruktur dalam mengembangkan solusi berbasis *machine learning* untuk deteksi penyakit pada tanaman jagung. Adapun kerangka penelitian yang penulis jalankan selama penelitian dapat dilihat pada gambar 3 dibawah.

Pemanfaatan Algoritma Convolutional Neural Network Dengan Fine-Tuning Hyperparameter Untuk Mendeteksi Penyakit Pada Tumbuhan Jagung



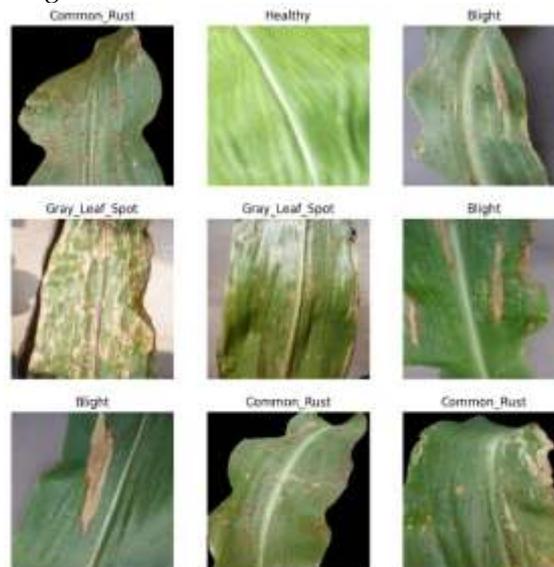
Gambar 3. Kerangka Penelitian

3.1 Business Understanding

Pada tahap ini, fokus utama adalah memahami konteks dari permasalahan yang ingin dipecahkan yaitu menurunnya produktivitas industri pertanian jagung di Indonesia. Studi literatur dilakukan untuk mengidentifikasi penelitian sebelumnya dan mengetahui teknik-teknik yang telah diterapkan dalam deteksi penyakit tanaman serta mengembangkan aspek-aspek yang belum dieksplorasi pada penelitian sebelumnya. Analisis masalah juga dilakukan untuk menentukan kebutuhan dan tujuan dari penelitian ini.

3.2 Data Understanding

Setelah merumuskan permasalahan dan solusi yang relevan, langkah berikutnya adalah memahami data yang akan digunakan. Data yang akan digunakan berupa dataset atau kumpulan yang berisi gambar daun jagung yang mengandung berbagai jenis penyakit yang diunduh melalui situs *Kaggle.com*. Dataset ini akan menjadi dasar dalam proses pengolahan data dan pemodelan. Data gambar yang diperoleh berjumlah 4.188 gambar dengan 4 kategori yaitu *Blight* sebanyak 1146 gambar, *Common_Rust* 1306 gambar, *Gray_Leaf_Spot* 574 gambar, dan *Healthy* 1162 gambar. Sample dari dataset yang telah diunduh dapat dilihat pada gambar 4 dibawah.



Gambar 4. Sample Dataset

3.3 Data Preparation

Pada tahap persiapan data, gambar-gambar yang telah diunduh diresize menjadi 180 x 180 piksel untuk kebutuhan peningkatan kinerja model. Proses *resie data* membantu menstandarkan dimensi *input*, memastikan konsistensi dan kompatibilitas dengan lapisan *input* berukuran tetap pada model CNN. Proses ini dapat meningkatkan efisiensi komputasi dan mengurangi kompleksitas model [13].

Selain itu, dataset dibagi menjadi beberapa subset untuk keperluan pelatihan dan pengujian model, memastikan bahwa model dapat dievaluasi dengan data yang tidak pernah dilihat sebelumnya dengan rasio 80% untuk data latih dan 20% untuk data uji.

```
data_training = tf.keras.utils.image_dataset_from_directory(
    data_gambar_jagung,
    validation_split=0.2,
    subset='training',
    seed=123,
    image_size=(img_height, img_width),
    batch_size=batch_size)

Found 4188 files belonging to 4 classes,
using 3351 files for training.

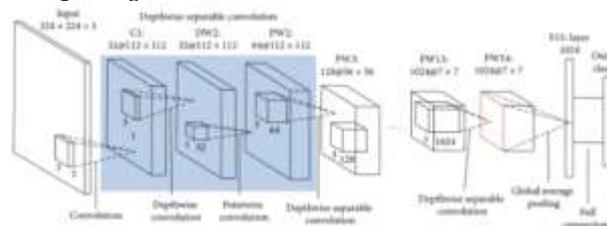
data_validation = tf.keras.utils.image_dataset_from_directory(
    data_gambar_jagung,
    validation_split=0.2,
    subset='validation',
    seed=123,
    image_size=(img_height, img_width),
    batch_size=batch_size)

Found 4188 files belonging to 4 classes,
using 837 files for validation.
```

Gambar 5. Baris kode dalam melakukan split dataset

3.4 Modelling

Setelah berhasil melakukan tahapan perapihan dataset sehingga mendapatkan dua variable *data_training* dan *data_validation*, tahapan selanjutnya yang akan dilakukan penulis adalah membangun model *convolutional neural network*. Dalam membangun model, penulis menggunakan arsitektur *MobileNetV2* yang akan di-*import* melalui library *tf.keras.applications* untuk membantu model meningkatkan akurasi dan menghindari terjadinya *overfitting* pada model. *MobileNet-V2* merupakan pembaruan dari versi-versi sebelumnya, dimana pada pembaruan kali ini menambahkan metode *depthwise separable convolution* (DSP) untuk mengefisiensi parameter dan menciptakan jaringan *neural* yang lebih ringan. Fitur yang hanya ada pada *MobileNet-V2* dan tidak ada pada versi sebelumnya adalah penambahan fitur *bottleneck* dan *shortcut connection* [14]. Ilustrasi dari arsitektur *MobileNet V2* dapat dilihat pada gambar 6 dibawah.



Gambar 6. Ilustrasi Arsitektur *MobileNet V2*
Sumber: Hastomo (2021)

4 Hasil dan Pembahasan

Setelah melakukan proses *import* arsitektur *MobileNetV2* dari library *tf.keras.application*, tahapan selanjutnya adalah proses pembangunan model. Dalam membangun model, penulis membangun empat model dengan parameter-parameter yang berbeda-beda guna untuk mencari model dengan parameter terbaik.

Pada model pertama seperti yang terlihat pada Tabel 1 dibawah, menggunakan arsitektur *mobilenetv2*, lalu dikonvolusi dengan jumlah *filter* sebanyak 32. Lalu untuk *padding* diisi dengan

Pemanfaatan Algoritma Convolutional Neural Network Dengan Fine-Tuning Hyperparameter Untuk Mendeteksi Penyakit Pada Tumbuhan Jagung

nilai *same* sehingga hasil *output* konvolusi berdimensi sama dengan *input*. Lalu dengan *kernel_size* atau jendela konvolusi 3x3, menggunakan *activation Relu*, dengan jumlah *strides* atau perpindahan jendela konvolusi sebanyak 1 dan jumlah *dropout* atau efisiensi *neuron* sebanyak 0.5, menghasilkan nilai akurasi 0,94 dan nilai *loss* 0,244.

Tabel 1. Arsitektur Model 1

Nama Model	Arsitektur	Filter	Padding	Kernel_size
Model 1	<i>Mobilenet V2</i>	32	Same	3
Activation	Strides	Dropout	Akurasi	Loss
<i>Relu</i>	1	0.5	0.94	0.244

Selanjutnya pada model kedua seperti yang terlihat pada Tabel 2 dibawah, parameter *strides* atau perpindahan jendela konvolusi dirubah menjadi 2 piksel. Menghasilkan nilai akurasi yang kurang baik daripada model 1 pada Tabel 1 yaitu 0.92 dengan nilai *loss* 0.250. Dapat disimpulkan bahwa jumlah perpindahan jendela konvolusi yang lebih banyak berpotensi adanya piksel yang terlewat sehingga performa model menurun. Karena model 2 pada Tabel 2 memiliki performa yang kurang baik, maka struktur model kembali pada model 1.

Tabel 2. Arsitektur Model 2

Nama Model	Arsitektur	Filter	Padding	Kernel_size
Model 2	<i>Mobilenet V2</i>	32	Same	3
Activation	Strides	Dropout	Akurasi	Loss
<i>Relu</i>	2	0.5	0.92	0.250

Selanjutnya pada model 3 seperti yang terlihat pada Tabel 3 dibawah, aktivasi yang semula *Relu* dirubah menjadi *Sigmoid*. Aktivasi *sigmoid* menghasilkan *range output* 0-1, sedangkan aktivasi *Relu* menghasilkan *output* 0-tak hingga sesuai dengan *input layer* [15]. Model 3 pada Tabel 3 dengan aktivasi *Sigmoid* menghasilkan performa yang kurang baik daripada model 1 pada Tabel 1, dapat disimpulkan bahwa aktivasi *Sigmoid* tidak cocok untuk studi kasus ini dikarenakan studi kasus ini memiliki kategori *output* atau *output class* lebih dari 2.

Tabel 3. Arsitektur Model 3

Nama Model	Arsitektur	Filter	Padding	Kernel_size
Model 3	<i>Mobilenet V2</i>	32	Same	3
Activation	Strides	Dropout	Akurasi	Loss
<i>Sigmoid</i>	1	0.5	0.92	0.206

Karena model 3 ada Tabel 3 memiliki performa yang kurang baik, maka struktur model kembali pada model 1 pada Tabel 1. Pada model 4 seperti yang terlihat pada Tabel 4, jumlah efisiensi *dropout* dirubah yang semula 0.50 atau 50% efisiensi pada model 1 menjadi 0.20 atau 20% pada model 4. Model 4 pada Tabel 4 menghasilkan nilai akurasi dan *loss* yang kurang baik daripada model 1 sehingga dapat disimpulkan bahwa semakin kecil nilai efisiensi pada layer *neuron* maka mempengaruhi nilai akurasi dan *loss* pada model. Detail dari arsitektur model keempat dapat dilihat pada Tabel 4 dibawah.

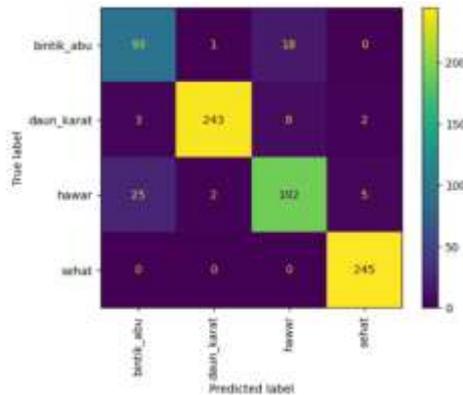
Tabel 4. Arsitektur Model 4

Nama Model	Arsitektur	Filter	Padding	Kernel_size
Model 4	<i>Mobilenet V2</i>	32	Same	3
Activation	Strides	Dropout	Akurasi	Loss
<i>Relu</i>	1	0.2	0.92	0.363

Dengan begitu dapat disimpulkan bahwa model yang terbaik diantara keempat model diatas adalah model 1 dengan nilai akurasi 0,94 dan nilai *loss* 0,244. Tahapan selanjutnya adalah pengujian model yang sudah melalui proses *fine-tuning hyperparameter*. Proses pengujian ini menggunakan metode *Confussion matrix*. *Confussion matrix* adalah alat yang digunakan untuk

Pemanfaatan Algoritma Convolutional Neural Network Dengan Fine-Tuning Hyperparameter Untuk Mendeteksi Penyakit Pada Tumbuhan Jagung

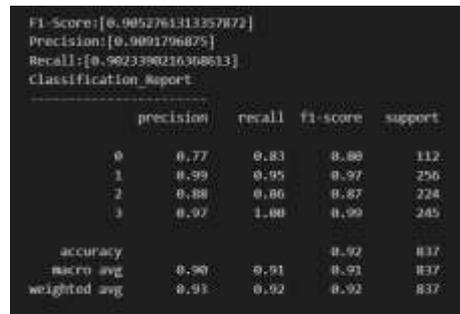
mengevaluasi kinerja model klasifikasi dengan memberikan gambaran yang jelas tentang prediksi yang benar dan salah untuk masing-masing kelas dalam dataset. *Confussion matrix* dari model 1 dapat dilihat pada gambar 4.8 dibawah ini.



Gambar 7. *Confussion Matrix* Model 1

Dari hasil *confussion matrix* diatas terlihat bahwa model memprediksi dengan benar jauh lebih banyak daripada memprediksi dengan salah pada setiap kelas. Sehingga dapat disimpulkan bahwa model yang dibangun dapat bekerja dengan baik atau dapat mengklasifikasikan jenis penyakit dengan baik.

Untuk melakukan pengujian lebih lanjut. Model 1 akan diuji berdasarkan nilai *f1-score*, *recall*, dan *precision* untuk masing-masing kelas juga berdasarkan nilai *macro average f1-score* dan *weighted average f1-score* untuk menilai keseimbangan antara *recall* dan *precision* dari seluruh kelas. Pengujian ini menggunakan *library scikit-learn* dalam melakukannya, hasil dari pengujian ini dapat dilihat pada gambar 8 dibawah.



Gambar 8. Hasil pengujian

Dari gambar 8 diatas, dapat disimpulkan bahwa model telah memiliki kinerja yang sangat baik dan seimbang berdasarkan nilai *f1-score* pada setiap kelas dan nilai *macro average* dan *weighted average fi-score* yang berada pada angka 80% - 99%. Nilai *precision* pada setiap kelas juga menunjukkan angka yang sangat bagus, sehingga akurasi atau ketepatan prediksi pada model ini sangat bagus.

Setelah meng-evaluasi model dan model telah dinyatakan layak, tahapan selanjutnya adalah implementasi model keladam suatu aplikasi *mobile* berbasis *Android*. Tujuan dari implementasi ini adalah agar model dapat digunakan oleh pengguna secara *portable* dan tanpa harus memerlukan spesifikasi komputasi yang tinggi. Dalam melakukan implementasi, model yang telah dibangun harus disimpan terlebih dahulu pada format *Tflite*. Dengan format ini, memungkinkan aplikasi *Android* untuk mengenali dan menjalankan model tanpa memerlukan spesifikasi yang tinggi. Hasil dari implementasi model keladam suatu aplikasi *mobile* berbasis *Android* dapat dilihat pada gambar 9 dibawah ini.



Gambar 9. Hasil Implementasi Model

Kesimpulan

Simpulan Berdasarkan hasil penelitian yang telah dilakukan, dapat disimpulkan bahwa Model CNN yang telah melalui proses *fine-tuning hyperparameter* pada penelitian ini menunjukkan kinerja yang baik dalam mengklasifikasikan jenis-jenis penyakit pada daun jagung dengan nilai akurasi 0,94 dan nilai *loss* 0,244. Dalam membangun model dapat disimpulkan bahwa jumlah *strides*, jumlah efisiensi nilai *dropout*, dan pemilihan jenis aktivasi cukup berpengaruh pada tingkat akurasi dan *loss* model.

Model yang telah dibangun juga dapat disimpan dan diimplementasikan kedalam aplikasi *mobile* berbasis *Android* untuk memudahkan penggunaannya. Harapannya dengan adanya penelitian ini, dapat membantu meningkatkan kualitas dan produksi tanaman jagung khususnya pada pertanian Indonesia.

Daftar Pustaka

- [1] S. A. Salelua and S. Maryam, "Potensi Dan Prospek Pengembangan Produksi Jagung (Zea Mays L.) Di Kota Samarinda (Potency and Prospect of Corn Production Development (Zea mays L.) in Samarinda City)," *Jurnal Agribisnis Dan Komunikasi Pertanian (Journal of Agribusiness and Agricultural Communication)*, vol. 1, no. 1, p. 47, 2018.
- [2] A. Astari and E. Lestari, "KORELASI KERAPATAN STOMATA DAUN TERHADAP TINGKAT KEJADIAN PENYAKIT BULAI (*Peronosclerospora philippinensis*) PADA TANAMAN JAGUNG," *Journal Agroecotech Indonesia (JAI)*, vol. 3, no. 01, pp. 32–44, 2024.
- [3] J. W. G. Putra, "Pengenalan konsep pembelajaran mesin dan deep learning," *Tokyo, Jepang*, 2019.
- [4] R Riswandi, R Jamiah, N Mardhatillah, and H hamid, "Klasifikasi Penyakit Pada Citra Daun Jeruk Menggunakan Arsitektur MobileNet berbasis Mobile Platform," *J. Fokus Elektroda Energi List. Telekomun. Komputer, Elektron. dan Kendali*, vol. 6, no. 4, p. 212, 2021.
- [5] P. T. Ompusunggu, "Klasifikasi Penyakit Tanaman Pada Daun Kentang Dengan Metode Convolutional Neural Network Arsitektur Mobilenet," *Jurnal Syntax Fusion*, vol. 2, no. 09, pp. 740–751, 2022.
- [6] F. N. Kushanov, O. S. Turaev, O. A. Muhammadiyev, R. F. Umarov, N. M. Rakhimova, and N. N. Mamadaliyeva, "Maize (*Zea mays L.*) as a Model System for Plant Genetic, Genomic, and Applied Research," *Model Organisms in Plant Genetics*, p. 49, 2022.
- [7] F. A. Diannastiti, S. N. H. Utami, and J. Widada, "The role of indigenous mycorrhizae of corn plants in various soil types in Gunung Kidul, Indonesia," *PLANTA TROPIKA*, vol. 10, no. 1, pp. 69–83, 2022.

Pemanfaatan Algoritma Convolutional Neural Network Dengan Fine-Tuning Hyperparameter Untuk Mendeteksi Penyakit Pada Tumbuhan Jagung

- [8] L. A. Andika, H. Pratiwi, and S. S. Handajani, "Klasifikasi penyakit pneumonia menggunakan metode convolutional neural network dengan optimasi adaptive momentum," *Indonesian Journal of Statistics and Its Applications*, vol. 3, no. 3, pp. 331–340, 2019.
- [9] R. D. Ramadhani, A. N. A. Thohari, C. Kartiko, A. Junaidi, T. G. Laksana, and N. A. S. Nugraha, "Optimasi Akurasi Metode Convolutional Neural Network untuk Identifikasi Jenis Sampah," *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, vol. 5, no. 2, pp. 312–318, 2021.
- [10] D. Astuti, "Penentuan Strategi Promosi Usaha Mikro Kecil Dan Menengah (UMKM) Menggunakan Metode CRISP-DM dengan Algoritma K-Means Clustering," *INISTA (Journal of Informatics Information System Software Engineering and Applications)*, vol. 1, no. 2, pp. 60–72, 2019.
- [11] D. Kurniawan and M. Yasir, "Optimization Sentimen Analysis using CRISP-DM and Naive Bayes Methods Implemented on Social Media," *Cyberspace: Jurnal Pendidikan Teknologi Informasi*, vol. 6, no. 2, pp. 74–85, 2022.
- [12] S. Navisa, L. Hakim, and A. Nabilah, "Komparasi Algoritma Klasifikasi Genre Musik pada Spotify Menggunakan CRISP-DM," *Jurnal Sistem Cerdas*, vol. 4, no. 2, pp. 114–125, 2021.
- [13] F. Marra, D. Gragnaniello, L. Verdoliva, and G. Poggi, "A full-image full-resolution end-to-end-trainable CNN framework for image forgery detection," *IEEE Access*, vol. 8, pp. 133488–133502, 2020.
- [14] W. Hastomo, "Convolution Neural Network Arsitektur Mobilenet-V2 Untuk Mendeteksi Tumor Otak," in *Prosiding Seminar SeNTIK*, 2021, pp. 17–21.
- [15] S. Elfwing, E. Uchibe, and K. Doya, "Sigmoid-weighted linear units for neural network function approximation in reinforcement learning," *Neural networks*, vol. 107, pp. 3–11, 2018.