Journal of Information System and Application Development
Volume 2 Number 1 March 2024 page 01-11
P-ISSN: 2988-5698 | E-ISSN: 2988-4721
https://jurnal.unmer.ac.id/index.php/jisad

Fine tuning model *Convolutional Neural Network* EfficientNet-B4 dengan augmentasi data untuk klasifikasi penyakit kakao

Fine tuning Convolutional Neural Network model EfficientNet-B4 with data augmentation for cocoa disease classification

Akbar Ganang Pradana[1], De Rosal Ignatius Moses Setiadi[1], Ahmad Rofiqul Muslikh[2*]
[1]Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro, Indonesia
[2]Program Studi Sistem Informasi, Fakultas Teknologi Informasi, Universitas Merdeka Malang, Indonesia

E-mail: *rofickachmad@unmer.ac.id

Abstract. *Cocoa is an important agricultural commodity in Indonesia which contributes to the economy with a production share of 15.68%. Cocoa diseases, such as Black Pod Rot and Pod Borer, are very detrimental to farmers. So it is necessary to build a recognition model that can classify automatically with high performance. Unfortunately the collected dataset is very unbalanced, and this is an additional challenge as it can reduce recognition performance. This study proposes disease recognition in cocoa images using the EfficientNet-B4 Convolutional Neural Network (CNN) model with fine-tuning. In this study also used seven kinds of data augmentation. The result is that the proposed CNN model has a high accuracy of 97.3% which is an increase of about 7.4% compared to the original model, at relatively few epochs. In addition, the proposed model is compared with other CNN models such as Xception, InceptionV3, ResNet, DenseNet, and EfficientNet, using the same approach, namely fine-tuning and epoch. The result is that the proposed method is superior to other models. This confirms that the proposed CNN model can also work better on unbalanced data.*

Keywords: *Convolutional Neural Network, EfficientNet-B4, fine-tuning, image classification, image recognition*

Abstrak. Kakao adalah komoditas pertanian penting di Indonesia yang berkontribusi pada ekonomi dengan pangsa produksi 15,68%. Penyakit kakao, seperti Black Pod Rot dan Pod Borer, sangat merugikan petani. Maka perlu dibangun model rekognisi yang dapat mengklasifikasi secara otomatis dengan performa yang tinggi. Sayangnya *dataset* yang terkumpul sangat tidak seimbang, dan hal ini menjadi tantangan tambahan karena dapat mengurangi performa rekognisi. Penelitian mengusulkan rekognisi penyakit pada citra kakao dengan model *Convolutional Neural Network* (CNN) EfficientNet-B4 dengan *fine-tuning*. Pada penelitian ini juga digunakan tujuh macam augmentasi data. Hasilnya model CNN yang diusulkan memiliki akurasi tinggi yaitu 97,3% dimana terjadi peningkatan sekitar 7,4% dibandingkan model asli, pada *epoch* yang relatif sedikit. Selain itu model yang diusulkan dikomparasi dengan model-model CNN lain seperti Xception, InceptionV3, ResNet, DenseNet, dan EfficientNet, dengan pendekatan yang sama yaitu *fine-tuning* dan *epoch*. Hasilnya metode yang diusulkan lebih unggul dibandingkan model-model lain. Hal ini mengkonfirmasi bahwa model CNN yang diusulkan juga dapat bekerja lebih baik pada data yang tidak seimbang.

Kata kunci: *Convolutional Neural Network*, EfficientNet-B4, *fine-tuning*, klasifikasi citra, rekognisi citra

Submitted: 12-12-2023 | ***Accepted:*** 22-02-2024 | ***Published:*** 31-03-2024

How to Cite:
A. G. Pradana, D. R. I. M. Setiadi, and A. R. Muslikh, "Fine tuning model Convolutional Neural Network EfficientNet-B4 dengan augmentasi data untuk klasifikasi penyakit kakao," *Journal of Information System and Application Development*, vol.2, no.1, pp. 01-11, March 2024, doi: 10.26905/jisad.v2i1.11899.

DOI: 10.26905/jisad.v2i1.11899

PENDAHULUAN

Industri kakao dan cokelat secara global senilai 44 miliar USD pada tahun 2019. Penyakit Pod Borer yang disebabkan oleh *Conopomorpha cramerella* menjadi hama utama kakao di daerah Malaysia dan Indonesia. Penyakit ini telah terdeteksi sejak 1980-an. Sayangnya pengendalian saat ini tidak terlalu efisien [1]. Selain penyakit Pod borer, juga ada penyakit Black Pod Rot yang disebabkan oleh *Phytophthora megakarya*. Penyakit ini menjangkit tanaman kakao di Kamerun. *Phytophthora megakarya* adalah spesies jamur yang merupakan penyebab utama dari penyakit ini. Pada skala global, penyakit ini mengakibatkan kerugian sebesar 20-30% [2]. Penyakit Black Pod Rot dapat berkembang pesat dalam jangka waktu satu hingga dua minggu. Saat ini sudah banyak algoritma *machine learning* yang digunakan untuk klasifikasi dan berkembang menjadi algoritma *deep learning*. Selain itu, banyak model algoritma yang sudah dilatih sehingga siap digunakan seperti DenseNet, EfficientNet, InceptionV3, MobileNet, ResNet, dan Xception [3].

Penelitian yang dilakukan oleh [4] yaitu mengusulkan jaringan neural yang merupakan gabungan dari jaringan Xception dan ResNet50V2. Pada *dataset* yang terbagi menjadi tiga kelas pada penyakit Covid-19, penyakit Pneumonia, dan Sehat didapatkan hasil akurasi rata-rata keseluruhan kelas terbilang baik yaitu 91,4%. Pada penelitian serupa juga dilakukan oleh [5] yaitu mengusulkan sistem deteksi otomatis untuk mencegah penyebaran Covid-19 secara cepat. Studi menggunakan tiga model yang berbeda yaitu DenseNet, InceptionV3, dan Inception-ResNetV4 yang akan digunakan untuk menganalisis pasien yang terinfeksi. Pada penelitian ini DenseNet mendapatkan hasil akurasi terbaik yaitu 92%, disusul model Inception-ResNetV4 dengan akurasi sebesar 85,57% dan terakhir yaitu InceptionV3 dengan akurasi sebesar 83,47%. Penelitian yang dilakukan oleh [6] menggunakan model InceptionV3 untuk mengklasifikasikan enam kategori olahraga. Model InceptionV3 berhasil mengklasifikasikan dengan rata-rata akurasi sebesar 96,64%. Identifikasi dan klasifikasi penyakit tanaman rumah kaca oleh [7] menggunakan model EfficientNet-B4 dengan *optimizer Ranger*. Hasil dari mengklasifikasikan empat jenis penyakit daun mentimun, dimana akurasi model EfficientNet-B4 dengan *optimizer Ranger* yaitu sebesar 96%. Penelitian menggunakan model EfficientNet juga dilakukan oleh [8] untuk mengklasifikasikan kanker kulit. Penelitian ini membandingkan semua model EfficientNet dari EfficientNet-B0 sampai EfficientNet-B7. Hasil tertinggi pada penelitian ini yaitu model EfficientNet-B4 dengan akurasi sebesar 87,91% dimana performa terbaik diraih oleh EfficientNet-B4 dan EfficienNet-B5.

Dari beberapa penelitian yang telah dilakukan didapatkan kesimpulan bahwa model *pre-trained* seperti DenseNet, ResNet, Xception, Inception, dan EfficientNet sangat baik digunakan untuk klasifikasi dan memiliki akurasi yang tinggi. Dari beberapa penelitian diatas, model EfficientNet-B4 merupakan salah satu algoritma terbaik untuk klasifikasi meskipun hasil akurasinya sebesar 87,91%, sehingga peneliti berharap bahwa model EfficientNet-B4 masih dapat ditingkatkan lagi. Banyak hal yang menyebabkan akurasi dapat menurun seperti objek yang memiliki kemiripan tinggi. Untuk meningkatkan nilai akurasinya, dapat dilakukan *fine-tuning* dan penambahan objek secara semu menggunakan augmentasi data. Menurut [9] augmentasi digunakan supaya data yang ada meningkat secara artifisial. Penelitian yang dilakukan oleh [10] pada model EfficientNet-B4 secara konsisten mengurangi FLOPs dan parameter berdasarkan urutan besarnya daripada ConvNet. Hasil akurasi pada klasifikasi ImageNet dengan model EfficientNet-B4 mencapai 82,9% dengan parameter 19M dan FLOPs 4,2B. Hal yang dapat mempengaruhi tinggi rendahnya akurasi yaitu *dataset* yang digunakan, *fine-tuning* yang tidak tepat, dan penggunaan *layer* tambahan. Dari literatur-literatur di atas maka penelitian ini mengusulkan model CNN EfficientNet-B4 untuk mengklasifikasi penyakit kakao dan *fine-tuning* untuk meningkatkan performanya.

LITERATURE REVIEW

Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu kategori dari jaringan saraf yang paling populer terutama untuk data berupa gambar dan video. Perbedaan utama dari CNN dengan jaringan saraf standar yaitu terdapat pada setiap unit lapisan CNN adalah filter dua dimensi atau lebih tinggi yang digabungkan dengan lapisan *input* [11]. Arsitektur *neural network* CNN terinspirasi dari sistem visual manusia, khususnya cara manusia memproses dan memahami gambar. Pengembangan arsitektur CNN terus berlanjut, dan teknik terbaru seperti *transfer learning* juga digunakan untuk meningkatkan kinerja [12]. *Transfer learning* yaitu sebuah metode dimana model akan diberikan masalah baru tetapi menerapkan pengalaman dari pelatihan sebelumnya yang telah dilakukan [13]. Jadi dapat didefinisikan bahwa *transfer learning* merupakan sebuah metode pada *machine learning* dengan menggunakan domain asal untuk meningkatkan kualitas model pada *domain* target. Dengan demikian metode *transfer learning* yaitu memanfaatkan pengetahuan pada model yang telah dilatih sebelumnya pada data yang besar dan dapat digunakan kembali pada data yang lebih kecil supaya lebih efisien [14]. Model *transfer learning* yang telah dilatih biasa disebut *pre-trained model*. Model ini telah dilatih pada *dataset* besar seperti ImageNet, sehingga hasil dari metode ini sudah sangat baik [15].

EfficientNet-B4

Algoritma EfficientNet diperkenalkan oleh [10], memiliki beberapa model dari B0 hingga B7 dan dianggap sebagai salah satu model *deep learning* yang paling efisien secara komputasi yang dilatih dengan ImageNet [16]. EfficientNet didasarkan pada penskalaan majemuk yang cepat memperluas ukuran model jaringan dasar untuk menargetkan ukuran model dengan cara efisien dan memperoleh akurasi model teratas. Penskalaan majemuk memungkinkan jaringan untuk diskalakan secara seragam di seluruh lebar, kedalaman, dan resolusi. Model EfficientNet terdiri dari berbagai jenis *mobile inverted bottleneck convolution* blok MBConv dengan berbagai ukuran *kernel* 3×3 dan 5×5 [17]. Metode penskalaan gabungan yang menggunakan koefisien gabungan untuk menskalakan lebar, kedalaman, dan resolusi jaringan secara seragam dengan Formula (1) [18].

$$\begin{aligned} d &= \alpha^{\emptyset} \\ w &= \beta^{\emptyset} \\ r &= \gamma^{\emptyset} \\ \text{Sehingga } \alpha \,.\, \beta^{\emptyset} \,.\, \gamma^{\emptyset} &\approx 2,\ \alpha \geq 1, \beta \geq 1, \gamma \geq 1 \end{aligned} \tag{1}$$

Dimana d untuk kedalaman, w untuk lebar, dan r untuk resolusi. Model EfficientNet-B0 dibangun dengan menggunakan nilai $\emptyset = 0, w = 1, d = 1, r = 1$, yang mewakili model *baseline*. EfficientNet-B0 terdiri dari lapisan MBconv1 dan MBcon6. Demikian juga, model EfficientNet-B4 dibangun dengan menggunakan nilai $\emptyset = 4, w = \alpha 4, d = \beta 4, r = \gamma 4$, yang menunjukkan bahwa lebih banyak sumber daya tersedia untuk memperoleh kinerja superlatif. Model EfficientNet-B4 terdiri dari jaringan yang lebih dalam dibandingkan dengan model dasar, yang memahami fitur yang rumit dan lebih kaya serta menggeneralisasi dengan baik pada tugas baru. EfficientNet-B4 terdiri dari jaringan yang lebih luas yang dapat mengekstraksi fitur dan pola optimal yang bermanfaat untuk tugas klasifikasi. Seiring dengan peningkatan akurasi, model EfficientNetB3 juga meningkatkan efisiensi dengan menurunkan FLOPS (*Floating Point Operations per Second*) dan parameter.

EfficientNet-B4 bisa dikatakan cukup bagus karena memiliki nilai akurasi yang tinggi dengan ukuran model 36% lebih kecil dari EfficientNet-B5. Model ini juga sudah dievaluasi pada *dataset transfer learning* yang umum digunakan. Hasil dari evaluasi tersebut menunjukkan bahwa akurasi yang didapatkan lebih baik dengan pengurangan parameter rata-rata 7,4x. EfficientNet konsisten mendapatkan akurasi yang lebih baik dengan urutan parameter yang lebih sedikit daripada model lainnya seperti RestNet, DenseNet, Inception, dan NASNet [10].

Augmentasi Data

Pelatihan jaringan saraf dengan jumlah data yang sedikit menghasilkan akurasi model klasifikasi yang cukup buruk, sehingga banyaknya data yang digunakan sangat mempengaruhi tingkat akurasi jaringan saraf. Meskipun model *pre-trained* sudah dilatih pada kumpulan data yang besar seperti

ImageNet dan memiliki akurasi yang cukup baik, akurasi tersebut masih dapat ditingkatkan lagi. Terdapat salah satu teknik yang dapat membantu untuk meningkatkan akurasi jaringan saraf dengan cara menambah data menjadi lebih banyak yang disebut augmentasi. Augmentasi adalah pendekatan untuk meningkatkan jumlah salinan data dengan sedikit modifikasi tanpa mengumpulkan data baru. Teknik ini adalah salah satu teknik yang paling umum digunakan untuk meningkatkan kinerja model jaringan saraf [19].

Augmentasi pada data dapat diartikan meningkatnya jumlah atau ukuran data secara artifisial/semu. Dengan menggunakan augmentasi data yang ada akan diperbanyak seperti dipotong, diputar/rotasi, dibalik/flip, memainkan warna, dan masih banyak lagi. Augmentasi dilakukan dengan cepat pada saat gambar dimuat. Pada setiap penelitian, augmentasi digunakan untuk memperbanyak data untuk pelatihan [9]. Teknik augmentasi data gambar secara kasar dapat dibagi menjadi tiga kategori, termasuk metode pemrosesan gambar dasar, metode pembelajaran mendalam, dan metode optik. Metode pemrosesan gambar dasar meliputi augmentasi data geometris, transformasi warna, injeksi derau, filter *kernel*, pencampuran gambar, dan penghapusan acak. Tipe augmentasi yang sering digunakan yaitu augmentasi data geometris dimana tipe ini menggunakan transformasi geometris dari gambar *input*, termasuk *flipping*, *cropping*, rotasi, translasi, deformasi, dan penskalaan [20].

Fine Tuning

Fine tuning adalah teknik yang digunakan dalam *machine learning* untuk memperbaiki kinerja model. *Fine tuning* memperbaiki kinerja model dengan cara menyesuaikan kembali bobot dan bias dari model yang telah dilatih sebelumnya pada tugas baru. Teknik ini biasanya digunakan pada model yang dilatih pada *dataset* besar untuk kemudian digunakan pada tugas pengenalan citra atau teks yang lebih kecil [21].

Cara kerja *fine-tuning* dimulai dengan mengambil model yang sudah dilatih pada *dataset* besar sebagai model dasar atau *pre-trained* model. Kemudian perubahan dilakukan dengan mengganti lapisan terakhir dari model tersebut untuk diadaptasi pada tugas yang baru. Lapisan terakhir ini disebut lapisan kelas atau lapisan keluaran. Proses *fine-tuning* dilakukan dengan melatih ulang lapisan terakhir sambil menjaga agar lapisan lain tetap menggunakan bobot dan bias yang sudah diatur sebelumnya. Dalam proses *fine-tuning* ini, bobot dan bias pada lapisan terakhir disesuaikan dengan *dataset* target. Selain itu, *fine-tuning* juga dapat dilakukan pada beberapa lapisan terakhir atau seluruh lapisan terakhir dari model dasar tergantung pada kompleksitas *dataset* target dan model yang digunakan [21].

Dense layer adalah jenis lapisan *neural network* yang terhubung secara padat dengan operasi yang dilakukan oleh *dense layer* adalah *output = activation (dot (input, kernel) + bias)* [22]. Pada jenis *dense layer* tertentu, digunakan fungsi aktivasi ReLU. Properti ReLU adalah membuang semua nilai negatif dan memberikan nol. Namun, parameter *default* dapat dimodifikasi selain nol [23]. *Fine-tuning* dengan menambahkan *dense layer* di lapisan akhir dapat mengatasi masalah gradien yang hilang, selain itu *dense* berpengaruh dalam kecepatan dan kemudahan pada pelatihan model.

Selain menambahkan *dense* juga terdapat *pooling layer*. *Pooling layer* memiliki fungsi untuk mengurangi ukuran agar biaya komputasi yang dibutuhkan lebih sedikit untuk pemrosesan data dengan cara *downsampling* dimana *layer* yang digunakan yaitu *Global Average Pooling* [24]. *Global Average Pooling* sama halnya seperti *pooling layer* biasanya, perbedaanya terdapat pada penyatuan yang ditetapkan ke semua nilai saluran fitur dan digabungkan menjadi satu nilai [25]. *Layer* ini akan digunakan sebagai representasi akhir dari model pengenalan gambar karena hanya menghasilkan satu nilai per kanal fitur. Hal ini memungkinkan mengurangi dimensi sehingga meningkatkan kinerja model dengan mengurangi masalah *over-fitting* [19], [26].

Untuk melatih jaringan saraf agar lebih cepat dan mencegah terjadinya *over-fitting* maka perlu ditambahkan *dropout*. Dengan menggunakan *dropout layer*, menjadi lebih mudah bagi model selama tahap pengujian untuk memperkirakan hasil rata-rata dari semua prediksi jaringan yang ditipiskan ini dengan memanfaatkan jaringan yang tidak ditipiskan yang memiliki bobot lebih kecil [19]. Dengan memilih 0,2 nilai probabilitas p *dropout* dalam model yang diusulkan diharapkan mencapai akurasi yang lebih tinggi dan mengurangi masalah *over-fitting* dari jaringan saraf yang diusulkan.

Tahap terakhir yaitu menggabungkan semua vektor fitur yang telah dibentuk dari tahap sebelumnya. Dari vektor fitur yang telah diterima dari lapisan *dropout* diteruskan lebih jauh ke dalam jaringan untuk klasifikasi sebagai lapisan keluaran menggunakan *fully connected layer*. Dengan lapisan Softmax sebagai lapisan keluaran untuk pengklasifikasi model berdasarkan jumlah kelas pada *dataset* yang dibangun menggunakan *dense layer* dan menggabungkan *input* dengan *output* model [19]. Pada pelatihan model peneliti juga menambahkan *optimizer* yang berfungsi untuk mengatasi kelemahan dari penurunan gradien. *Optimizer* yang digunakan yaitu Adam [27].

METODE YANG DIUSULKAN

Penelitian ini mengusulkan augmentasi data dan model EfficientNet-B4 serta *fine-tuning* dengan penambahan beberapa lapisan *layer* terakhir. Model augmentasi data yang diusulkan adalah rotasi, pergeseran lebar, pergeseran tinggi, *shear*, *zoom*, *flip horizontal*, dan *vertical*. Sedangkan model CNN yang diusulkan dipresentasikan pada Tabel 1.

Tabel 1. Model CNN yang diusulkan

Layer	Output Shape
input_1 (InputLayer)	(380, 380, 3)
rescaling (Rescaling)	(380, 380, 3)
normalization (Normalization)	(380, 380, 3)
tf.math.truediv (TFOpLambda)	(380, 380, 3)
stem_conv_pad (ZeroPadding2D)	(381, 381, 3)
stem_conv (Conv2D)	(190, 190, 48)
stem_bn (BatchNormalization)	(190, 190, 48)
stem_activation (Activation)	(190, 190, 48)
block1a_dwconv (DepthwiseConv2D)	(190, 190, 48)
block1a_bn (BatchNormalization)	(190, 190, 48)
…	…
block7b_se_reduce (Conv2D)	(1, 1, 112)
block7b_se_expand (Conv2D)	(1, 1, 2688)
block7b_se_excite (Multiply)	(12, 12, 2688)
block7b_project_conv (Conv2D)	(12, 12, 448)
block7b_project_bn (BatchNormalization)	(12, 12, 448)
block7b_drop (Dropout)	(12, 12, 448)
block7b_add (Add)	(12, 12, 448)
top_conv (Conv2D)	(12, 12, 1792)
top_bn (BatchNormalization)	(12, 12, 1792)
top_activation (Activation)	(12, 12, 1792)
global_average_pooling2d (GlobalAveragePooling2D)	(1792)
dropout (Dropout)	(1792)
dense (Dense)	(32)
dense_1 (Dense)	(3)
Total params: 17,731,298	
Trainable params: 16,200,223	
Non-trainable params: 1,531,075	
Non-trainable params: 1,531,075	

Secara *default*, EfficientNet-B4 memiliki 478 *layer*, dimana tiga *layer* terakhir adalah *classifier*. Tetapi karena ketiga *layer* ini merupakan *classifier* yang dapat digunakan untuk mengklasifikasikan 1.000 kelas, maka tentunya akan mengurangi akurasi jika difokuskan untuk klasifikasi tiga kelas saja. Jumlah *layer* pada model yang diusulkan yaitu 479 *layer* termasuk empat *layer* tambahkan. *Layer* tambahan ditandai dengan warna merah pada tabel tersebut. *Layer* tambahan yaitu tiga *layer* model dan satu *layer fully connected*. Tiga *layer* tambahan yang diberikan yaitu GlobalAveragePooling2D, Dropout, dan Dense *layer*, serta *layer fully connected* menggunakan Dense. Alasan dari menambahkan beberapa *layer* tersebut karena setiap *layer* yang ditambahkan memiliki keunggulan yang cukup mempengaruhi

pelatihan model. *Layer* GlobalAveragePooling2D digunakan untuk mengambil nilai rata-rata dari citra, Dense dengan *activation* ReLU untuk membuat pembatas pada bilangan nol sehingga dapat mempercepat proses yang dilakukan, dan Dropout untuk mencegah terjadinya *overfitting*. Lalu *fully connected layer* yang ditambahkan yaitu Dense dengan *activation* Softmax untuk mengubah jumlah kelas awal menjadi jumlah kelas yang sesuai dengan *dataset*. Selain itu, pada model ini hanya sebagian dari *layer* yang dilakukan *training*, dimana *layer* ke-1 hingga ke-238 *trainable=False* dan *layer* ke-239 hingga terakhir *trainable=True*. Sehingga parameter yang dilatih berjumlah 16.200.223 dari total parameter 17.731.298.

HASIL DAN PEMBAHASAN

Dataset

Jenis data bersifat kualitatif dengan tipe gambar adalah JPG. Sumber didapatkan dari *dataset* umum Kaggle (https://www.kaggle.com/datasets/zaldyjr/cacao-diseases). Pada *dataset* terdapat tiga kelas, dimana kelas *black pod rot* terdapat 943 gambar, *pod borer* 103 gambar, dan *healthy* 3.344 gambar, sehingga keseluruhan berjumlah 4.390 gambar yang diperlihatkan pada Gambar 1. Tiap kelas akan diambil 5% gambar untuk digunakan pada pengujian.

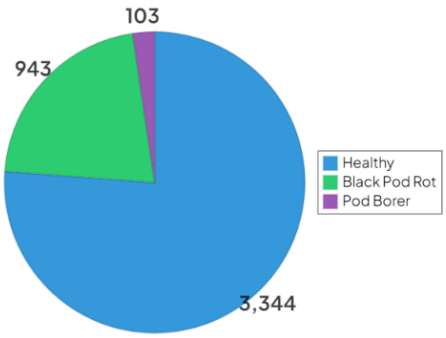

Gambar 1. Grafik jumlah kelas dan baris pada *dataset*

Augmentasi Data

Augmentasi data pada klasifikasi citra bertujuan untuk meningkatkan kinerja model dengan menciptakan variasi baru dari *dataset*, memperluas jumlah sampel pelatihan, mengatasi variasi *domain*, dan mengurangi risiko *overfitting*. Hal ini membantu model mengenali objek dengan lebih baik, meningkatkan keandalan pada data baru, dan mengoptimalkan hasil klasifikasi citra [28], [29]. Contoh hasil augmentasi disajikan pada Gambar 2.

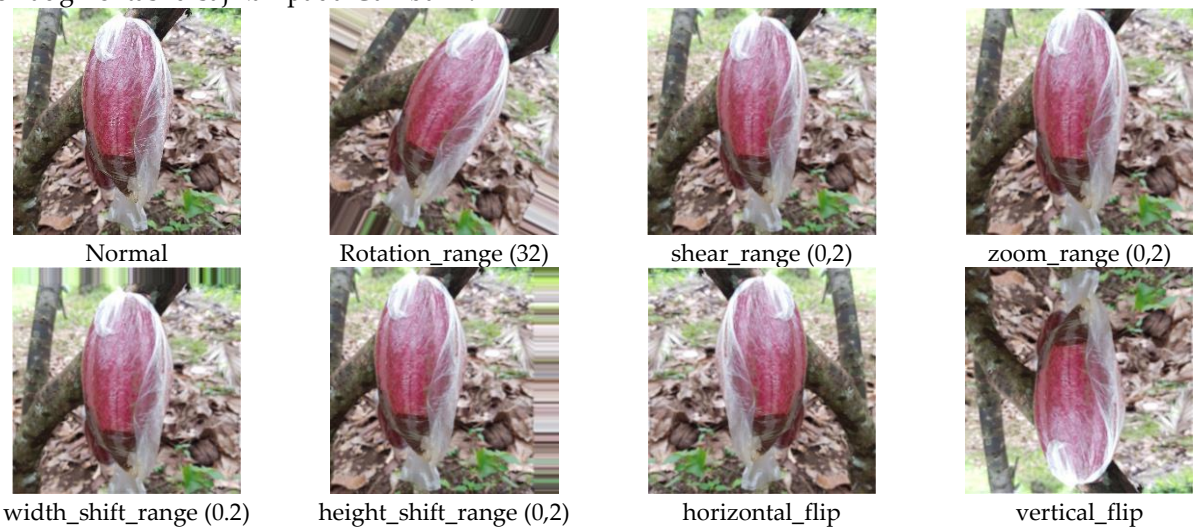

Gambar 2. Contoh hasil augmentasi data

Tes Pelatihan

Sebelum melakukan pelatihan model, peneliti menetapkan *callback* sebesar 0,98 atau 98% yang artinya proses pelatihan akan berhenti jika akurasi *training* dan *validation* keduanya sama di angka 98%. Sehingga pada proses pelatihan model didapatkan data sebagai berikut.

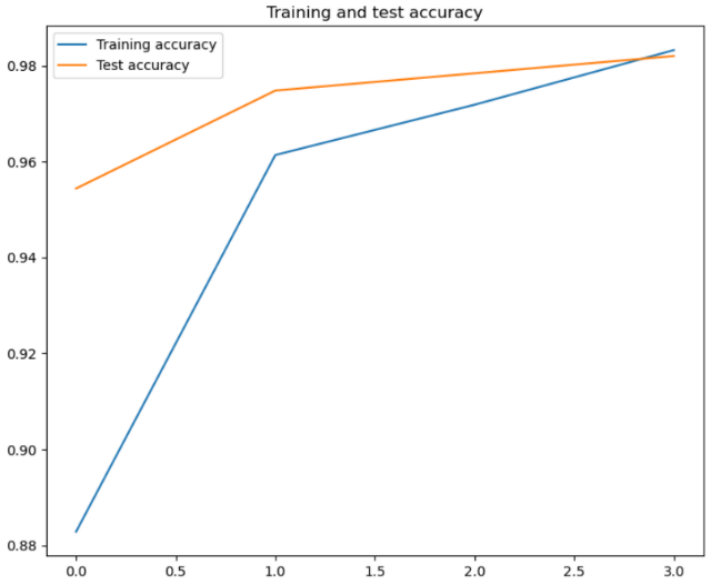

Gambar 3. Grafik akurasi dari model yang diusulkan pada minimal *epoch*

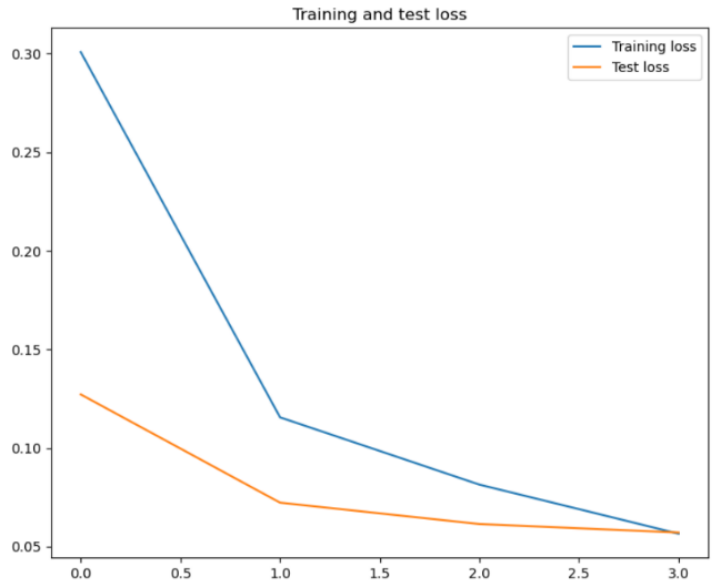

Gambar 4. Grafik *loss* dari model yang diusulkan pada minimal *epoch*

Melihat dari grafik pada Gambar 3 dan Gambar 4, diketahui bahwa akurasi pada *epoch* pertama memiliki selisih yang cukup jauh yaitu hampir 7%. Tetapi pada *epoch* kedua meningkat drastis, hingga pada *epoch* keempat antara *training* dan *validation* memiliki nilai di atas 98% sehingga pelatihan model secara otomatis berhenti. Pada grafik *loss* juga mirip dengan grafik akurasi dimana *epoch* pertama terdapat selisih *loss* yang cukup tinggi. Tetapi pada *epoch* kedua nilai *loss* pada *training* dapat turun secara drastis mendekati nilai *loss validation* pada *epoch* pertama. Hingga pada *epoch* keempat nilainya

cukup kecil yaitu 0,0565 untuk *loss training* dan 0,0571 untuk *loss validation*. Hasil ini sebenarnya telah menunjukan bahwa performa model CNN yang dihasilkan sangat memuaskan bahkan dengan jumlah *epoch* yang sangat minim, yaitu empat. Tetapi ketika dibandingkan model-model pembanding lain, tampak adanya *gap* yang sangat tinggi ketika dibandingkan dengan jumlah *epoch* yang sama. Maka dicoba pengujian menggunakan 10 *epoch* tanpa pembatasan, dan ternyata hasilnya juga sudah relatif stabil, seperti yang ditunjukan pada Gambar 5 dan Gambar 6.

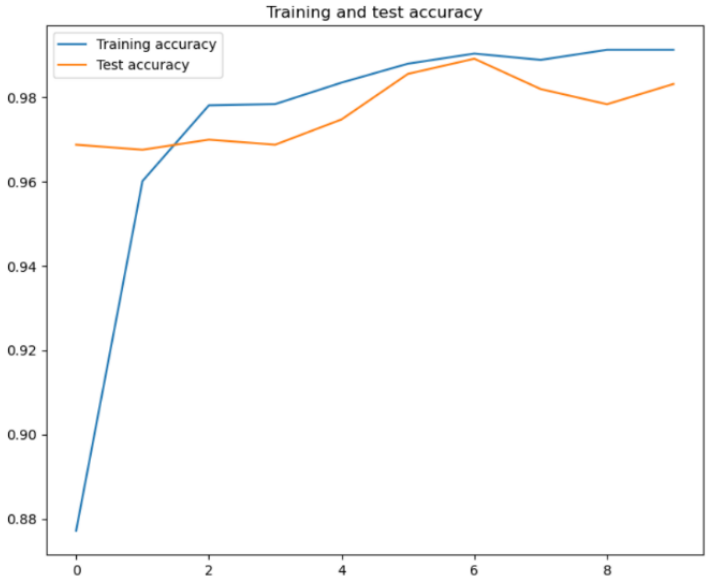

Gambar 5. Grafik akurasi dari model yang diusulkan dengan 10 *epoch*

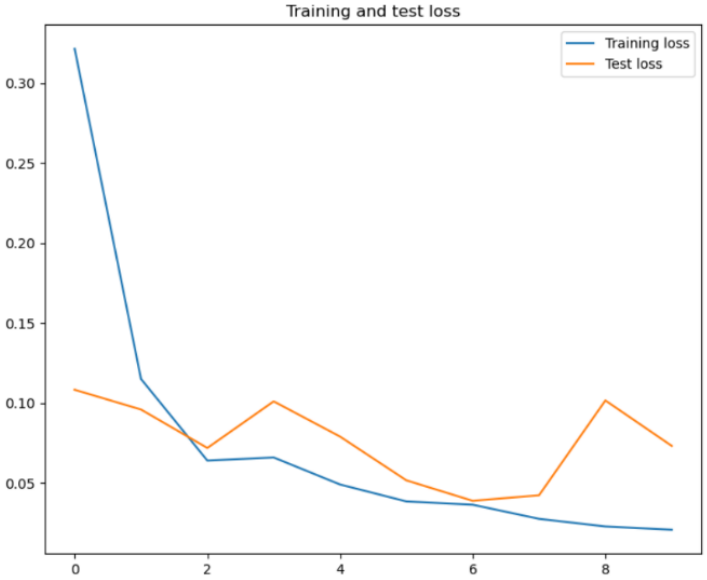

Gambar 6. Grafik loss dari model yang diusulkan dengan 10 *epoch*

Confusion Matrix

Metode *Confusion Matrix* juga digunakan untuk menghitung akurasi pada konsep *data mining*. *Confusion Matrix* didefinisikan melalui tabel yang menunjukkan jumlah data uji yang diklasifikasikan dengan benar dan jumlah data uji yang diklasifikasikan dengan salah. Model yang diusulkan akan dihitung berdasarkan *recall*, *F1-score*, *precision*, dan *accuracy*. Metrik dihitung pada kasus *True Positive*

(TP), *False Positive* (FP), *True Negative* (TN), dan *False Negative* (FN) [18], [30].

1. *True Positive* (TP) label benar positif dan label diprediksi positif.
2. *False Positive* (FP) label benar negatif dan label diprediksi positif.
3. *True Negative* (TN) label benar negatif dan label diprediksi negatif.
4. *False Negative* (FN) label benar positif dan label diprediksi negatif.

Akurasi merupakan metrik evaluasi yang menemukan kinerja model di semua kelas. Ini adalah sebagian kecil dari jumlah prediksi yang benar dengan jumlah total prediksi yang dapat dihitung dengan Formula (2). Presisi adalah metrik evaluasi yang menghitung fraksi dari total sampel positif terhadap jumlah total sampel positif baik yang diklasifikasikan secara tepat maupun tidak tepat, yang dapat dihitung dengan Formula (3).

$$Accuracy = \frac{(TN + TP)}{(TN + TP + FN + FP)} \times 100\% \quad (2)$$

$$Precision = \frac{TP}{(TP + FP)} \times 100\% \quad (3)$$

Recall adalah metrik evaluasi yang menghitung fraksi dari total sampel positif terhadap jumlah total sampel input positif yang diklasifikasikan dengan benar, yang dapat dihitung dengan Formula (4). Sedangkan *F1-score* yaitu metrik evaluasi yang menemukan akurasi mode dengan menggabungkan presisi dan daya ingat dengan memberi lebih banyak bobot pada positif palsu dan negatif palsu, yang dapat dihitung dengan Formula (5).

$$Recall = \frac{TP}{(TP + FN)} \times 100\% \quad (4)$$

$$F1\ Score = \frac{2 \times (Recall\ \times Precission)}{(Recall\ + Precission)} \quad (5)$$

Testing

Pada tahap ini model akan diuji dengan 5% gambar yang telah dipisahkan di awal. Sebanyak 5% data tersebut meliputi *pod borer* (5), *black pod rot* (47), dan *healthy* (167). Hasil pengujian dinyatakan dalam bentuk tabel *confusion matrix*. Setelah hasil pengujian sudah dalam bentuk tabel *confusion matrix*, kemudian akan dilakukan pengukuran dengan rumus *Accuracy*, *Precission*, *Recall*, dan *F1-Score* untuk dijadikan sebuah evaluasi. Gambar 7 adalah hasil pengujian dari model *fine-tuning* EfficientNet-B4.

Tabel 2. *Confusion Matrix* hasil *testing*

Class	BPR	Healthy	Pod Borer
BPR	**44**	1	0
Healthy	3	**166**	1
Pod Borer	0	0	**4**

Jika hasil *testing* di atas dilakukan pengukuran dengan rumus, didapatkan hasil akurasi 97,72 dan presisi 98,47. Sedangkan nilai *recall* 91% dan nilai *F1-skor* 94,59%.

Komparasi

Sebagai bahan perbandingan, peneliti juga melatih model EfficientNet-B4 *original* untuk dibandingkan. Selain itu peneliti juga melatih beberapa model yang sering digunakan dengan pengaturan *fine-tuning* yang sama untuk model Xception, InceptionV3, DenseNet, dan RestNet dengan jumlah *epoch* yang sama, yaitu sepuluh *epoch*. Hasil komparasi disajikan pada Tabel 2.

Tabel 3. Komparasi model CNN yang diusulkan dibandingkan dengan model *original* dan model-model lain berdasarkan *Confusion Matrix*

Model	Acc	Prec	Rec
EfficientNet-B4 (Original)	89,9%	77,1%	61,6%
Xception	76,3%	25,4%	33%
InceptionV3	76,3%	25,4%	33%
DenseNet201	76,3%	25,4%	33%
ResNet50V2	76,3%	25,4%	33%
EfficientNet-B4 (Fine-tuning)	97,3%	97,3%	97,3%

SIMPULAN DAN SARAN

Dengan melihat dari hasil penelitian yang telah dilakukan, maka dapat ditarik kesimpulan yaitu akurasi untuk *training* dan *validation* untuk model EfficientNet-B4 yang sudah dilakukan *fine-tuning* dapat mencapai 98%, sedangkan untuk model *original* hanya dapat mencapai 87% untuk *training* dan *validation*. Melakukan *fine-tuning* dapat meningkatkan akurasi pelatihan hingga 10%. Model EfficientNet-B4 dengan *fine-tuning* dapat berhasil untuk mengklasifikasikan dengan baik. Melakukan *fine-tuning* dan menambah *dataset* dengan augmentasi pada model lain tidak dapat mengklasifikasikan dengan baik. Memperbanyak data dengan cara augmentasi tidak membuat data menjadi seimbang, tetapi model EfficientNet-B4 dapat berjalan dengan baik pada data tersebut. Memberikan tambahan *layer* untuk model EfficientNet-B4 memiliki peran yang cukup penting. Dense ReLU ditambahkan untuk mempercepat proses sehingga proses pelatihan tidak terlalu lama. Lalu ada *layer dropout* untuk mencegah terjadinya *overfitting*. Selain itu penggunaan *pooling layer* digunakan untuk mereduksi data dimana ukuran dari data akan dikecilkan (*downsampling*). GlobalAveragePooling2D akan mengambil nilai rata-rata dari semua matriks datanya. Selain itu dapat terkonfirmasi dan terbukti bahwa model CNN yang diusulkan mampu bekerja pada data tidak seimbang.

DAFTAR PUSTAKA

[1] N. A. N. Muhammad *et al.*, "Data on RNA-seq analysis of the cocoa pod borer pest Conopomorpha cramerella (Snellen) (Lepidoptera: Gracillariidae)," *Data Br.*, vol. 34, p. 106638, Feb. 2021, doi: 10.1016/j.dib.2020.106638.

[2] J. B. Mbarga *et al.*, "Field testing an oil-based Trichoderma asperellum formulation for the biological control of cacao black pod disease, caused by Phytophthora megakarya," *Crop Prot.*, vol. 132, p. 105134, Jun. 2020, doi: 10.1016/j.cropro.2020.105134.

[3] S. B. Imanulloh, A. R. Muslikh, and D. R. I. M. Setiadi, "Plant Diseases Classification based Leaves Image using Convolutional Neural Network," *J. Comput. Theor. Ap pl.*, vol. 1, no. 1, pp. 1–10, Aug. 2023, doi: 10.33633/jcta.v1i1.8877.

[4] M. Rahimzadeh and A. Attar, "A modified deep convolutional neural network for detecting COVID-19 and pneumonia from chest X-ray images based on the concatenation of Xception and ResNet50V2," *Informatics Med. Unlocked*, vol. 19, p. 100360, 2020, doi: 10.1016/j.imu.2020.100360.

[5] S. Albahli, N. Ayub, and M. Shiraz, "Coronavirus disease (COVID-19) detection using X-ray images and enhanced DenseNet," *Appl. Soft Comput.*, vol. 110, p. 107645, Oct. 2021, doi: 10.1016/j.asoc.2021.107645.

[6] K. Joshi, V. Tripathi, C. Bose, and C. Bhardwaj, "Robust Sports Image Classification Using InceptionV3 and Neural Networks," *Procedia Comput. Sci.*, vol. 167, pp. 2374–2381, Jan. 2020, doi: 10.1016/j.procs.2020.03.290.

[7] P. Zhang, L. Yang, and D. Li, "EfficientNet-B4-Ranger: A novel method for greenhouse cucumber disease recognition under natural complex environment," *Comput. Electron. Agric.*, vol. 176, p. 105652, Sep. 2020, doi: 10.1016/j.compag.2020.105652.

[8] K. Ali, Z. A. Shaikh, A. A. Khan, and A. A. Laghari, "Multiclass skin cancer classification using EfficientNets – a first step towards preventing skin cancer," *Neurosci. Informatics*, vol. 2, no. 4, p. 100034, Dec. 2022, doi: 10.1016/j.neuri.2021.100034.

[9] F. Pérez-García, R. Sparks, and S. Ourselin, "TorchIO: A Python library for efficient loading, preprocessing, augmentation and patch-based sampling of medical images in deep learning," *Comput. Methods Programs*

Biomed., vol. 208, p. 106236, Sep. 2021, doi: 10.1016/j.cmpb.2021.106236.

[10] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," May 2019, [Online]. Available: http://arxiv.org/abs/1905.11946

[11] A. P. Wibowo and D. R. I. M. Setiadi, "Performance Analysis of Deep Learning Models for Sweet Potato Image Recognition," in *2022 International Seminar on Application for Technology of Information and Communication (iSemantic)*, Sep. 2022, pp. 101–106. doi: 10.1109/iSemantic55962.2022.9920423.

[12] S. Khan, H. Rahmani, S. A. A. Shah, and M. Bennamoun, "A Guide to Convolutional Neural Networks for Computer Vision," *Synth. Lect. Comput. Vis.*, vol. 8, no. 1, pp. 1–207, Feb. 2018, doi: 10.2200/S00822ED1V01Y201712COV015.

[13] V. R. Kamath, V. S. Rao, and V. Manjunath, "Transferred Fusion Learning using Skipped Networks," Nov. 2020, [Online]. Available: http://arxiv.org/abs/2011.05895

[14] Y. Li, K. He, D. Xu, and D. Luo, "A transfer learning method using speech data as the source domain for micro-Doppler classification tasks," *Knowledge-Based Syst.*, vol. 209, p. 106449, Dec. 2020, doi: 10.1016/j.knosys.2020.106449.

[15] J. Yang, Y. Xu, H. Cao, H. Zou, and L. Xie, "Deep learning and transfer learning for device-free human activity recognition: A survey," *J. Autom. Intell.*, vol. 1, no. 1, p. 100007, 2022, doi: 10.1016/j.jai.2022.100007.

[16] M. Canayaz, "C+EffxNet: A novel hybrid approach for COVID-19 diagnosis on CT images based on CBAM and EfficientNet," *Chaos, Solitons & Fractals*, vol. 151, p. 111310, Oct. 2021, doi: 10.1016/j.chaos.2021.111310.

[17] A. S. Ebenezer, S. D. Kanmani, M. Sivakumar, and S. J. Priya, "Effect of image transformation on EfficientNet model for COVID-19 CT image classification," *Mater. Today Proc.*, vol. 51, pp. 2512–2519, 2022, doi: 10.1016/j.matpr.2021.12.121.

[18] L. Yang *et al.*, "A dual attention network based on efficientNet-B2 for short-term fish school feeding behavior analysis in aquaculture," *Comput. Electron. Agric.*, vol. 187, p. 106316, Aug. 2021, doi: 10.1016/j.compag.2021.106316.

[19] S. Salian and D. Sawarkar, "Melanoma Skin Lesion Classification using Improved EfficientNetB3," *Jordanian J. Comput. Inf. Technol.*, vol. 08, no. 01, p. 1, 2022, doi: 10.5455/jjcit.71-1636005929.

[20] B. Li, O. K. Ersoy, C. Ma, Z. Pan, W. Wen, and Z. Song, "A 4F optical diffuser system with spatial light modulators for image data augmentation," *Opt. Commun.*, vol. 488, p. 126859, Jun. 2021, doi: 10.1016/j.optcom.2021.126859.

[21] G. Jang, J. Lee, J.-G. Lee, and Y. Liu, "Distributed fine-tuning of CNNs for image retrieval on multiple mobile devices," *Pervasive Mob. Comput.*, vol. 64, p. 101134, Apr. 2020, doi: 10.1016/j.pmcj.2020.101134.

[22] "Dense layer." https://keras.io/api/layers/core_layers/dense/ (accessed Dec. 12, 2023).

[23] M. Agarwal, S. Gupta, and K. K. Biswas, "A new Conv2D model with modified ReLU activation function for identification of disease type and severity in cucumber plant," *Sustain. Comput. Informatics Syst.*, vol. 30, p. 100473, Jun. 2021, doi: 10.1016/j.suscom.2020.100473.

[24] P. Singh, P. Raj, and V. P. Namboodiri, "EDS pooling layer," *Image Vis. Comput.*, vol. 98, p. 103923, Jun. 2020, doi: 10.1016/j.imavis.2020.103923.

[25] I. Rodriguez-Martinez, J. Lafuente, R. H. N. Santiago, G. P. Dimuro, F. Herrera, and H. Bustince, "Replacing pooling functions in Convolutional Neural Networks by linear combinations of increasing functions," *Neural Networks*, vol. 152, pp. 380–393, Aug. 2022, doi: 10.1016/j.neunet.2022.04.028.

[26] M. S. Sunarjo and H. Gan, "High-Performance Convolutional Neural Network Model to Identify COVID-19 in Medical Images," *J. Comput. Theor. Appl.*, vol. 1, no. 1, pp. 19–30, Aug. 2023, doi: 10.33633/jcta.v1i1.8936.

[27] K. R. Prilianti, T. H. P. Brotosudarmo, S. Anam, and A. Suryanto, "Performance comparison of the convolutional neural network optimizer for photosynthetic pigments prediction on plant digital image," 2019, p. 020020. doi: 10.1063/1.5094284.

[28] A. Susanto, I. U. W. Mulyono, C. A. Sari, E. H. Rachmawanto, D. R. I. M. Setiadi, and M. K. Sarker, "Handwritten Javanese script recognition method based 12-layers deep convolutional neural network and data augmentation," *IAES Int. J. Artif. Intell.*, vol. 12, no. 3, p. 1448, Sep. 2023, doi: 10.11591/ijai.v12.i3.pp1448-1458.

[29] H. T. Adityawan, O. Farroq, S. Santosa, H. M. M. Islam, M. K. Sarker, and D. R. I. M. Setiadi, "Butterflies Recognition using Enhanced Transfer Learning and Data Augmentation," *J. Comput. Theor. Appl.*, vol. 1, no. 2, pp. 115–128, Nov. 2023, doi: 10.33633/jcta.v1i2.9443.

[30] F. Mustofa, A. N. Safriandono, and A. R. Muslikh, "Dataset and Feature Analysis for Diabetes Mellitus Classification using Random Forest," *J. Comput. Theor. Appl.*, vol. 1, no. 1, pp. 41–48, Sep. 2023, doi: 10.33633/jcta.v1i1.9190.