

DOI: doi.org/10.21009/03.1301.FA13

KLASIFIKASI KUALITAS CANGKANG TELUR AYAM MENGGUNAKAN EFFICIENTNET BERBASIS CITRA DIGITAL

Hernanda Khoiriyah Putri^{1, a)}, Bambang Heru Iswanto^{1, b)}, Haris Suhendar^{1, c)}

¹Program Studi Fisika, FMIPA, Universitas Negeri Jakarta, Jl. Rawamangun Muka, Jakarta 13220, Indonesia

Email: ^{a)}hernanda472@gmail.com

Abstrak

Keretakan telur sering terjadi selama proses distribusi, baik yang terlihat dengan jelas maupun yang tidak terlihat secara kasat mata. Retakan pada cangkang telur menjadi perhatian serius karena berpotensi menyebabkan kontaminasi dan risiko kesehatan bagi konsumen. Pada penelitian ini keretakan cangkang telur ayam diklasifikasi berdasarkan citra digital dengan menggunakan *Convolutional Neural Network* (CNN)-EfficientNet. Eksperimen dilakukan dengan sampel 300 gambar telur dalam tiga kondisi; bagus, retak, dan pecah, masing-masing kondisi terdiri dari 100 gambar. Pengambilan gambar dilakukan dengan menggunakan kamera DSLR yang telah terkalibrasi dan berlatar belakang stabil. Pra-pemrosesan data meliputi *cropping*, *resize*, dan *augmentasi*. *Splitting* data dilakukan dengan proporsi 80:20. *Hyperparameter* menggunakan *optimizer* Adam dengan 50 iterasi dan *batch* 32. Performa model dievaluasi menggunakan metrik *loss function* (*sparse categorical crossentropy*), akurasi, dan *confusion matrix*. Klasifikasi menggunakan EfficientNet-B0 hingga B3 menghasilkan akurasi, presisi, *recall*, dan *F1-Score* berturut-turut 94,52%, 95,75%, 95,71%, dan 95,73%; 94,05%, 94,09%, 94,05%, dan 94,02%; 94,52%, 94,56%, 94,52%, dan 94,54%; 97,14%, 97,19%, 97,14%, dan 97,15%. Berdasarkan hasil yang diperoleh, klasifikasi menggunakan EfficientNet menunjukkan peningkatan performa seiring dengan meningkatnya kompleksitas model. Hasil penelitian menunjukkan bahwa citra keretakan cangkang telur ayam dapat dimanfaatkan untuk identifikasi kualitas telur dan dikembangkan untuk klasifikasi kualitas telur ayam.

Kata-kata kunci: Klasifikasi, *Convolutional Neural Network (CNN)-EfficientNet*. Cangkang telur, Kualitas, Citra digital

Abstract

Cracks in eggshells often occur during the distribution process, both visible and invisible to the naked eye. Cracks in eggshells are a serious concern as they can lead to contamination and health risks for consumers. This study classifies cracks in chicken eggshells based on digital images using a Convolutional Neural Network (CNN)-EfficientNet. The experiment was conducted with a sample of 300 egg images in three conditions: good, cracked, and broken, with 100 images for each condition. The images were captured using a calibrated DSLR camera with a stable background. Data preprocessing included cropping, resizing, and augmentation. The data was split in an 80:20 ratio. Hyperparameters used the Adam optimizer with 50 iterations and a batch size of 32. Model performance was evaluated using loss function metrics (*sparse categorical crossentropy*), accuracy, and confusion matrix. Classification using EfficientNet-B0 to B3 resulted in accuracy, precision, recall, and F1-Score of 94.52%, 95.75%, 95.71%, and 95.73%; 94.05%, 94.09%, 94.05%, and 94.02%; 94.52%, 94.56%, 94.52%, and 94.54%; and 97.14%, 97.19%, 97.14%, and 97.15%, respectively. Based on the results, classification using EfficientNet shows improved performance as the model complexity increases. The findings suggest that images of eggshell cracks can be utilized for egg quality identification and can be developed for chicken egg quality classification.

Keywords: Classification, Convolutional Neural Network (CNN)-EfficientNet, Eggs, Quality, Digital Image.

PENDAHULUAN

Konsumsi telur secara global telah meningkat, dengan perkiraan rata-rata mencapai 9 kilogram perkapita setiap tahunnya, meskipun angka ini bervariasi di berbagai wilayah. Manajemen yang efektif dalam produksi telur mempengaruhi komposisi, kualitas, dan keamanan pangan telur, memperkuat daya tariknya bagi konsumen [1]. Di Indonesia, telur ayam ras/kampung menjadi komoditas tertinggi keempat yang paling banyak dikonsumsi per orang selama sebulan sebanyak 9-10 butir telur. Pada tahun 2020, jumlah total produksi telur yaitu sebanyak 5,3 juta ton [2]. Untuk memenuhi permintaan telur yang tinggi, kualitas telur menjadi faktor utama. Kualitas telur dipengaruhi oleh keutuhan cangkangnya. Telur yang retak dapat mengakibatkan kontaminasi dan membahayakan konsumen. Faktor seperti genetika dan lingkungan mempengaruhi keretakan pada cangkang telur. Identifikasi manual keretakan telur cenderung memakan waktu serta rentan terhadap kesalahan pengamatan. Abnormalitas, bentuk telur, keutuhan kerabang, dan kebersihan kerabang tidak dipengaruhi oleh suhu tetapi lebih dipengaruhi oleh genetik dan sistem [3].

Kualitas gizi telur perlu dijaga selama proses produksi hingga konsumsi. Keretakan pada cangkang telur menjadi permasalahan utama yang mempengaruhi kualitas dan keselamatan konsumen. Pengetahuan pada tingkat keretakan telur dapat membantu dalam proses sortasi, pengemasan, dan distribusi yang lebih efisien. Identifikasi manual pada keretakan telur membutuhkan waktu dan rentan terhadap kesalahan pengamatan, menggarisbawahi pentingnya pengembangan metode otomatis dalam pemilahan tingkat keretakan telur. Proses pemilahan dengan teknologi dapat diterapkan untuk mempercepat proses pemilah telur. Studi sebelumnya telah melibatkan berbagai pendekatan dalam mendeteksi retakan pada telur menggunakan algoritma yang berbeda-beda. Algoritma *Support Vector Machine* (SVM) berhasil mencapai akurasi sekitar 98,75%. Namun, kelemahannya terletak pada keterbatasan klasifikasi yang hanya membedakan telur sebagai retak atau tidak retak tanpa memberikan detail tingkat keretakan yang lebih spesifik [4]. Sebagai alternatif, model algoritma RTMDet dan *random forest networks* juga menghasilkan akurasi klasifikasi tinggi, mencapai antara 94–96% [5]. EfficientNet menghasilkan akurasi pengenalan sebesar 99,5% dalam waktu pelatihan moderat. Metode ini menggunakan *transfer learning* untuk mempercepat pelatihan model, menandakan keunggulan dalam pengenalan retakan pada telur [6]. Namun, keterbatasan serupa ditemukan terkait keragaman kategori klasifikasi.

CNN memiliki kelebihan dalam mengidentifikasi fitur visual kompleks dan memiliki performa yang baik dalam klasifikasi gambar, menjadikannya pilihan yang tepat untuk mengembangkan klasifikasi yang lebih kompleks dalam mengklasifikasikan tingkat keretakan telur menjadi baik, retak, dan pecah. Berdasarkan hal tersebut, maka akan dilakukan sistem pengklasifikasian tingkat keretakan telur melalui teknologi pengolahan citra untuk mengklasifikasi kualitas cangkang telur ayam berdasarkan tingkat keretakannya menggunakan CNN-EfficientNet. Penelitian ini bertujuan untuk mengimplementasikan pengolahan citra digital menggunakan CNN untuk membuat sebuah sistem yang mampu mengklasifikasi kualitas cangkang telur ayam berdasarkan tingkat keretakannya. Pemanfaatan teknologi ini diharapkan dapat meningkatkan efektivitas pemilahan telur berdasarkan keretakannya, mendorong perkembangan dari penelitian sebelumnya, dan memberikan kontribusi signifikan terhadap industri telur ayam serta kesehatan konsumen secara keseluruhan.

METODOLOGI

1.1. Pengolahan Citra Digital

Citra dapat didefinisikan sebagai fungsi dua dimensi, $f(x, y)$, dimana x dan y adalah koordinat spasial (bidang), dan amplitudo f pada pasangan koordinat (x, y) disebut sebagai intensitas atau tingkat keabuan dari citra pada titik tersebut. Ketika x , y , dan nilai intensitas f semuanya adalah kuantitas diskrit yang terbatas, citra tersebut disebut sebagai citra digital [7]. Pengolahan citra

merupakan cabang ilmu dalam *Artificial Intelligence* (AI) yang menggunakan objek citra dalam bentuk digital untuk penyelesaian kasusnya. Metode dalam citra dapat digunakan baik perhitungan matematis pada objek secara piksel ataupun geometris. Masing-masing objek citra memiliki nilai perbedaan yang dapat diperhitungkan secara matematis, sehingga menunjukkan ciri yang berbeda antara objek satu dengan yang lain. Penciri dari perbedaan setiap objek dapat ditentukan dari warna, tekstur, ataupun bentuk [8].

Pada visi komputer, pengolahan citra berperan untuk mengenali bentuk-bentuk khusus yang dilihat oleh mesin sehingga mesin dapat mengenali atau mendapatkan informasi dari objek yang dilihatnya melalui kamera [9]. Pengolahan citra digital merujuk pada proses manipulasi dan analisis citra digital menggunakan algoritma komputer. Proses dalam pengolahan citra digital melibatkan berbagai teknik, seperti transformasi, filtrasi, segmentasi, dan analisis. Transformasi mencakup perubahan domain citra, sementara filtrasi digunakan untuk menghilangkan *noise* atau meningkatkan kualitas citra. Segmentasi membagi citra menjadi bagian-bagian yang lebih terdefinisi, sementara analisis citra melibatkan ekstraksi fitur dan informasi untuk tujuan identifikasi, klasifikasi, atau pengenalan [7].

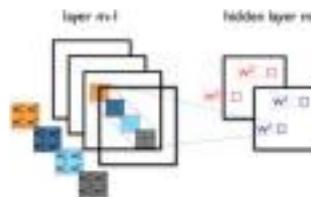
1.2. Convolutional Neural Networks (CNN)-EfficientNet

CNN terdiri dari banyak lapisan (*layer*). Lapisan-lapisan ini mirip dengan neuron dalam otak yang terhubung sepenuhnya. Neuron membantu mentransfer 'pesan' dari satu sel ke sel lainnya, dengan satu neuron dikelilingi oleh banyak neuron lainnya [10]. Pada CNN, data yang dipropagasikan pada jaringan adalah data dua dimensi, sehingga operasi linear dan parameter bobot pada CNN berbeda. Operasi linear CNN menggunakan operasi konvolusi, sedangkan bobot tidak lagi satu dimensi saja, namun berbentuk empat dimensi yang merupakan kumpulan kernel konvolusi seperti pada Gambar 1.

Dimensi bobot pada CNN adalah:

$$w = \text{neuron input} \times \text{neuron output} \times \text{tinggi} \times \text{lebar} \quad (1)$$

Karena sifat proses konvolusi, maka CNN hanya dapat digunakan pada data yang memiliki struktur dua dimensi seperti citra dan suara [11].

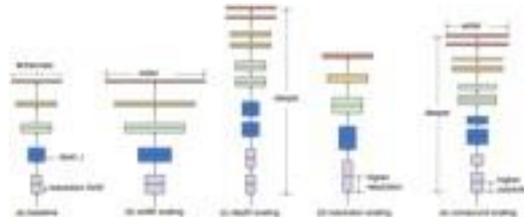


GAMBAR 1. Proses konvolusi pada CNN

CNN dapat digunakan untuk mendeteksi dan mengenali objek pada sebuah gambar. Pada dasarnya CNN sama dengan *neural network* yang biasanya yang terdiri dari neuron yang memiliki *weight*, *bias*, dan fungsi aktivasi. CNN memiliki kesamaan struktur dengan *Artificial Neural Network* (ANN). Pada kasus klasifikasi citra, CNN menerima citra *input* atau masukan kemudian diproses dan diklasifikasi ke dalam kategori tertentu. Perbedaan CNN dengan ANN adalah CNN memiliki arsitektur tambahan yang dioptimisasi untuk fitur yang ada pada citra masukan. Komponen-komponen utama yang ada di dalam CNN adalah lapisan *input* (*input layer*), lapisan konvolusi (*convolution layer*), fungsi aktivasi (*activation function*), lapisan *pooling* (*pooling layer*), dan lapisan terhubung penuh (*fully connected layer*) [12]. Lapisan *input* menerima sinyal dari luar, kemudian melewatkannya ke lapisan tersembunyi pertama yang akan diteruskan sehingga akhirnya mencapai lapisan *output* [13]. Filter konvolusi digunakan untuk menjelajahi gambar, mengekstraksi fitur dari

area kecil, dan membuat peta fitur yang menyoroti pola penting. Lebar, tinggi, dan kedalaman filter berpengaruh pada analisis yang dilakukan, sedangkan langkah dan *padding* memengaruhi cara filter bergerak dan ukuran *output*. Misalnya, filter 3x3x3 digunakan pada gambar RGB dengan variasi *padding*, memperlihatkan dampaknya pada hasil akhirnya [14].

EfficientNet adalah suatu arsitektur CNN yang ditemukan dengan melakukan *scaling* secara teratur pada tiga komponen, yaitu lebar mengacu pada jumlah *channel* pada lapisan manapun, kedalaman mengacu pada lapisan di CNN, dan resolusi mengacu pada ukuran resolusi gambar yang digunakan [15]. Arsitektur dari EfficientNet dapat dilihat pada Gambar 2.



GAMBAR 2. Arsitektur EfficientNet

Penelitian yang diterapkan oleh Tan dan Le [16] adalah membuat pengembangan baru tentang *neural network*. Penelitian tersebut menjabarkan tentang suatu model *scaling* dan cara untuk identifikasi hubungan antara kedalaman jaringan, lebar, dan resolusi untuk mencapai performa yang lebih baik dari arsitektur CNN lainnya. EfficientNet adalah salah satu arsitektur model CNN yang mencapai akurasi dan efisiensi yang lebih baik daripada model sebelumnya dengan memperhatikan keseimbangan kedalaman jaringan, lebar, dan resolusi. Model-model ini diskalakan menggunakan metode penskalaan gabungan yang secara merata mengubah semua dimensi kedalaman, lebar, dan resolusi dengan menggunakan koefisien gabungan yang sederhana namun sangat efektif. Efektivitas penskalaan model sangat bergantung pada jaringan dasar dan EfficientNet terbukti secara signifikan mengungguli arsitektur CNN lainnya dalam hal akurasi dan efisiensi. Kelebihan dari arsitektur ini yaitu mampu memberikan akurasi yang tinggi dan mampu memperbaiki efektivitas model, dengan melakukan pengurangan parameter dan *Floating Point Operations Per Second* (FLOPS). Penambahan ketiga komponen lebar, kedalaman, dan resolusi, dilakukan dengan teratur sehingga mendapatkan jumlah parameter yang lebih sedikit dan membuat waktu proses menjadi lebih cepat namun bisa mendapatkan akurasi yang baik dari model-model sebelumnya [15].

Saat ini ada 8 model EfficientNet, yaitu EfficientNet-B0 hingga EfficientNet-B7. Pada penelitian ini akan menggunakan model EfficientNet-B0 hingga EfficientNet-B3. Model-model ini memiliki jumlah parameter yang lebih besar, yang diikuti dengan nilai akurasi yang lebih tinggi. Untuk setiap model, resolusi citra yang diinput itu berbeda-beda, berikut adalah resolusi citra yang cocok untuk setiap model.

TABEL 1. Resolusi citra yang cocok untuk model EfficientNet

| Model Dasar | Resolusi |
|-------------|------------|
| B0 | 224 piksel |
| B1 | 240 piksel |
| B2 | 260 piksel |
| B3 | 300 piksel |
| B4 | 380 piksel |
| B5 | 456 piksel |
| B6 | 528 piksel |
| B7 | 600 piksel |

EKSPERIMEN

1.3. Dataset

Tahap pengumpulan data dilakukan dengan mengambil citra telur dengan tiga kondisi keretakan yang berbeda, yakni baik, retak, dan pecah (Gambar 3). Data citra yang digunakan pada penelitian ini adalah citra yang didapat secara mandiri. Citra setiap kondisi keretakan telur diambil secara langsung menggunakan Kamera DSLR Nikon D3200 dengan resolusi 24,2 MP. Data yang dikumpulkan berjumlah 100 untuk setiap kondisi, sehingga totalnya adalah 300 citra telur. Proses pengambilan gambar dilakukan dengan telur ayam diletakkan pada latar belakang berwarna putih, bertujuan untuk menjaga konsistensi lingkungan.



GAMBAR 3. Tiga kondisi keretakan telur a) Data gambar telur kondisi baik, b) Data gambar telur kondisi retak, c) Data gambar telur kondisi pecah

1.4. Pra-Pemrosesan Data

Sebelum melakukan langkah utama klasifikasi, data gambar yang digunakan dalam penelitian ini harus melewati serangkaian tahap pra-pemrosesan yang bertujuan untuk memastikan konsistensi, kualitas, dan keberagaman data. Tahap ini tidak hanya penting untuk mempersiapkan data secara teknis, tetapi juga untuk mengoptimalkan performa model yang akan dikembangkan. Teknik-teknik yang dilakukan pada tahap ini adalah *crop*, dan *resize*, dan augmentasi.

1.4.1. Crop

Crop citra dilakukan untuk menghilangkan bagian yang tidak dibutuhkan pada tepi citra yang tidak memberikan informasi pola dari telur. Dengan menghilangkan bagian tersebut melalui proses *cropping*, citra dapat lebih fokus pada fitur atau objek yang relevan. Dalam penelitian ini, gambar yang sebelumnya beresolusi 6016x4000 piksel dipotong menjadi bentuk persegi dengan resolusi 4000x4000 piksel.

1.4.2. Resize

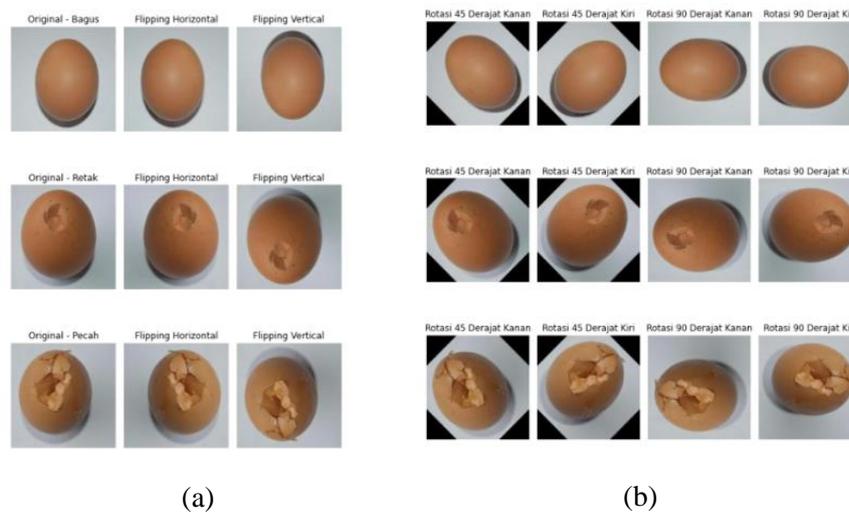
Resize dilakukan untuk menyesuaikan ukuran gambar agar sesuai dengan spesifikasi ukuran masukan yang diperlukan oleh masing-masing arsitektur CNN. Ukuran citra dalam dataset diubah menjadi beberapa resolusi yang berbeda, yaitu 224x224, 240x240, 260x260, dan 300x300 piksel. Hal ini dilakukan untuk menyesuaikan ukuran citra masukan yang optimal yang dapat diolah oleh model EfficientNet yang berbeda. Jumlah yang dihasilkan dari tahap *resize* untuk tiap citra adalah 100 citra *resize* pada tiap-tiap resolusinya, sehingga total seluruh citra *resize* adalah 400 citra untuk masing-masing kondisi telur. Dengan demikian, proses *resize* ini mempersiapkan data masukan dengan ukuran yang sesuai untuk pengolahan lebih lanjut.

1.4.3. Augmentasi

Augmentasi dilakukan untuk menambah variasi data dengan menerapkan modifikasi pada setiap gambar dalam dataset. Pada penelitian ini teknik augmentasi yang dilakukan adalah horizontal *flip*, vertikal *flip*, dan rotasi 45° ke kanan, rotasi 45° ke kiri, rotasi 90° ke kanan, dan rotasi 90° ke kiri.

Dengan menerapkan teknik-teknik ini, dataset menjadi lebih beragam dan merepresentasikan kondisi yang mungkin terjadi dalam dunia nyata. Jumlah yang dihasilkan dari tahap augmentasi untuk tiap citra adalah 6 citra augmentasi, sehingga total seluruh citra augmentasi adalah 600 citra

untuk masing-masing kondisi telur. Kemudian, total citra asli dan augmentasi adalah 700 citra untuk masing-masing kondisi telur.



GAMBAR 4. Augmentasi teknik (a) rotasi gambar *flipping* horizontal dan vertikal (b) rotasi gambar 45° dan 90° ke kanan dan kiri

1.5. Klasifikasi Citra

Dataset yang digunakan untuk klasifikasi adalah data gabungan antara dataset asli dan dataset hasil augmentasi. Hal ini bertujuan untuk menciptakan variasi baru dan meningkatkan keberagaman dataset serta memungkinkan model untuk mempelajari fitur-fitur yang lebih umum dari berbagai sudut pandang. Dengan menggabungkan keduanya, maka akan dapat meningkatkan jumlah dan keragaman data yang tersedia untuk pelatihan model, yang dapat meningkatkan kinerja dan generalisasi model dalam melakukan klasifikasi citra. Dataset yang digunakan untuk klasifikasi akan dibagi menjadi dua bagian, yaitu data latih (*training data*) dan data uji (*testing data*) dengan proporsi 80:20. Selanjutnya adalah melakukan eksperimen menggunakan beberapa arsitektur model EfficientNet yang berbeda untuk menguji kinerja model pada tugas klasifikasi citra. Arsitektur yang akan diujikan meliputi EfficientNet B0, EfficientNet-B1, EfficientNet-B2, dan EfficientNet-B3.

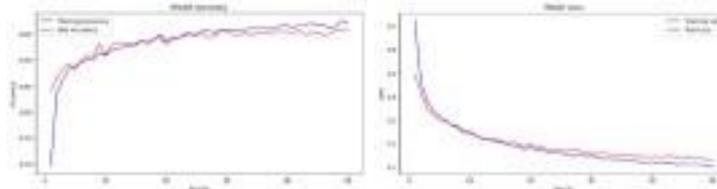
1.5.1. Pelatihan Data

Pada eksperimen ini dilakukan iterasi (*epoch*) sebanyak 50 kali. Setiap arsitektur CNN diuji dengan menggunakan Adam sebagai *optimizer* dan pengaturan *learning rate* sebesar 0,001. Tahap pelatihan dari berbagai arsitektur CNN menghasilkan nilai akurasi model, *loss function*, dan waktu *training* (Tabel 2).

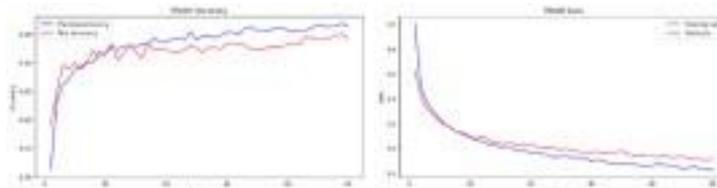
TABEL 2. Resolusi citra yang cocok untuk model EfficientNet

| <u>Arsitektur Model</u> | <u>Waktu Training</u> | <u>Training Accuracy (%)</u> | <u>Training Loss (%)</u> | <u>Validation Accuracy (%)</u> | <u>Validation Loss (%)</u> |
|-------------------------|-----------------------|------------------------------|--------------------------|--------------------------------|----------------------------|
| <u>EfficientNet-B0</u> | <u>2j 16m 56d</u> | <u>99,17</u> | <u>3,96</u> | <u>97,38</u> | <u>8,41</u> |
| <u>EfficientNet-B1</u> | <u>3j 0m 35d</u> | <u>96,43</u> | <u>11,26</u> | <u>94,05</u> | <u>15,68</u> |
| <u>EfficientNet-B2</u> | <u>3j 37m 37d</u> | <u>95,77</u> | <u>14,69</u> | <u>94,52</u> | <u>14,69</u> |
| <u>EfficientNet-B3</u> | <u>8j 27m 37d</u> | <u>97,56</u> | <u>9,25</u> | <u>97,14</u> | <u>9,72</u> |

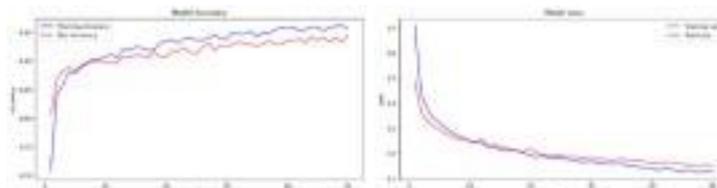
Semakin tinggi kompleksitas model, maka semakin lama waktu yang dibutuhkan untuk melatihnya. Hal ini terlihat dari waktu pelatihan yang terus bertambah dari EfficientNet-B0 hingga EfficientNet-B3. Meskipun demikian, peningkatan waktu pelatihan tidak selalu diikuti dengan peningkatan kinerja model secara signifikan. Dapat disimpulkan bahwa efisiensi dan kinerja model tidak selalu sebanding dengan tingkat kompleksitasnya.



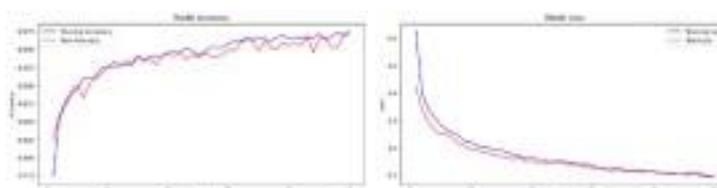
GAMBAR 6. Grafik akurasi dan *loss* model EfficientNet-B0



GAMBAR 7. Grafik akurasi dan *loss* model EfficientNet-B1



GAMBAR 8. Grafik akurasi dan *loss* model EfficientNet-B2



GAMBAR 9. Grafik akurasi dan *loss* model EfficientNet-B3

1.5.2. Pengujian Data

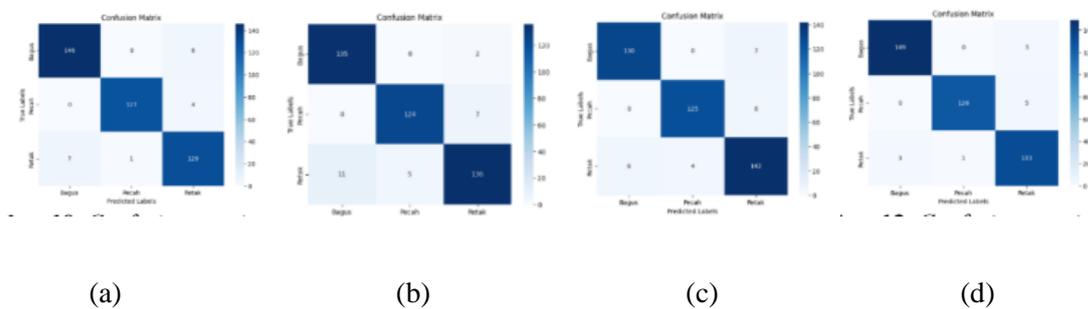
Setelah menyelesaikan tahap pelatihan menggunakan data latih, langkah selanjutnya adalah melakukan pengujian terhadap model menggunakan data uji. Pengujian data bertujuan untuk menguji kemampuan klasifikasi model yang telah dilatih. Tahap ini dilakukan menggunakan data uji dengan rasio pembagian 80:20.

HASIL DAN PEMBAHASAN

Untuk mengevaluasi kinerja model, dilakukan analisis menggunakan *confusion matrix* dengan memperhatikan nilai akurasi, presisi, *recall*, dan *F1-Score* (Tabel 3).

TABEL 3. Evaluasi Model

| <u>Arsitektur Model</u> | <u>Akurasi (%)</u> | <u>Presisi (%)</u> | <u>Recall (%)</u> | <u>F-1 Score (%)</u> |
|-------------------------|--------------------|--------------------|-------------------|----------------------|
| <u>EfficientNet-B0</u> | 97,38 | 95,75 | 95,71 | 95,73 |
| <u>EfficientNet-B1</u> | 94,05 | 94,09 | <u>94,05</u> | 94,02 |
| <u>EfficientNet-B2</u> | 94,52 | 94,56 | <u>94,52</u> | 94,54 |
| <u>EfficientNet-B3</u> | <u>97,14</u> | <u>97,19</u> | <u>97,14</u> | <u>97,15</u> |



GAMBAR 10. Confusion matrix model (a) EfficientNet-B0 (b) EfficientNet-B1 (c) EfficientNet-B2 (d) EfficientNet-B3

KESIMPULAN

Penelitian ini membahas penggunaan CNN pada penerapan pengolahan citra digital untuk mengidentifikasi dan mengklasifikasi kualitas cangkang telur berbasis citra digital. Sebelum membangun model klasifikasi, dilakukan pra-pemrosesan data yang meliputi *cropping*, *resize*, dan augmentasi data. Klasifikasi menggunakan EfficientNet-B0 hingga B3 menghasilkan akurasi, presisi, *recall*, dan *F1-Score* berturut-turut 97,38%, 95,75%, 95,71%, dan 95,73%; 94,05%, 94,09%, 94,05%, dan 94,02%; 94,52%, 94,56%, 94,52%, dan 94,54%; 97,14%, 97,19%, 97,14%, dan 97,15%. Berdasarkan hasil yang diperoleh, klasifikasi menggunakan EfficientNet menunjukkan peningkatan performa seiring dengan meningkatnya kompleksitas model. Hasil penelitian menunjukkan bahwa citra keretakan cangkang telur ayam dapat dimanfaatkan untuk identifikasi kualitas telur dan dikembangkan untuk klasifikasi kualitas telur ayam. Namun, penelitian ini perlu dikembangkan lebih lanjut dengan menggunakan arsitektur CNN yang berbeda untuk membandingkan kinerja masing-masing model pada kasus penelitian ini.

REFERENSI

- [3] Zaheer K 2015 An updated review on chicken eggs: production, consumption, management aspects and nutritional benefits to human health. *Food and Nutrition Sciences* (6): 1208 [2] Badan Pusat Statistik 2021 *Konsumsi dan Produksi Telur di Indonesia* (Jakarta: Badan Pusat Statistik).
- [4] Setiawati T, Afnan R, dan Ulupi N. 2016. Performa produksi dan kualitas telur ayam petelur pada sistem litter dan cage dengan suhu kandang berbeda. *Jurnal Ilmu Produksi dan Teknologi Hasil Peternakan* (4): 197.
- [5] Haoran C, Chuchu H E, Minlan J, dan Xiaoxiao L 2020 Egg crack detection based on Support Vector Machine *IEEE 2020 International Conference on Intelligent Computing and Human Computer Interaction (ICHCI)* 80
- [6] Yang X, Bist R B, Subedi S, dan Chai L 2023 A computer vision-based automatic system for egg grading and defect detection *Animals* **13** 2354
- [7] Liu C, Wen H, Yin G, Ling X, dan Ibrahim S M. 2023. Research on intelligent recognition method of egg cracks based on EfficientNet network model. In *Journal of Physics: Conference Series* **2560** 012015.
- [8] Dhruv P dan Naskar S. 2020. Image classification using Convolutional Neural Network (CNN) and Recurrent Neural Network (RNN): A Review. In: Swain, D., Pattnaik, P., & Gupta, P (eds.) *Machine learning and information processing: Advances in intelligent systems and computing: Proceedings of ICMLIP 2019 (Singapore: Springer)* p 1101.
- [9] Gonzales R C dan Woods R E. 2018. *Digital image processing* (New York: Pearson)
- [10] Widyaningsih M. 2016. Identifikasi kematangan buah apel dengan gray level *co-occurrence* matrix (GLCM) *Jurnal saintekom* 6 71
- [11] Kaswar A B, Risal A A N, dan Adiba F. 2020. Klasifikasi tingkat kematangan buah markisa menggunakan jaringan syaraf tiruan berbasis pengolahan citra digital. *Journal of Embedded Systems, Security and Intelligent Systems* 1 1.
- [12] Putra W S E, Wijaya A Y, dan Soelaiman R. 2016. Klasifikasi citra menggunakan Convolutional Neural Network (CNN) pada caltech 101 *Jurnal Teknik ITS* **5**.
- [13] Awangga R M dan Batubara N A. 2020. *Tutorial object detection plate number with convolution neural network (CNN)* (Bandung: Kreatif Industri Nusantara).
- [14] Irfan M, Sumbodo B A A, dan Candradewi I. 2017. Sistem klasifikasi kendaraan berbasis pengolahan citra digital dengan metode multilayer perceptron Indonesian. *Journal of Electronics and Instrumentation System (IJEIS)* 7:139.
- [15] Dey S. 2018. *Hands-on image processing with python* (Mumbai: Packt Publishing Ltd)
- [16] Stanley J, Lubis C, dan Handhayani T. 2022. Sistem pengenalan Covid-19 berdasarkan foto x-ray paru dengan metode EfficientNet-B0. *Jurnal Ilmu Komputer dan Sistem Informasi*: 10.
- [17] Tan M dan Le Q. 2019. Efficientnet: Rethinking model scaling for convolutional neural networks. *Proceedings of the 36th International Conference on Machine Learning in Proceedings of Machine Learning Research* 97 6105.