

Utilization of EfficientNet-B0 to Identify *Oncomelania Hupensis* *Lindoensis* as a Schistosomiasis Host

Moh. Raihan Dirga Putra Lamadjido ^{1*}, Rahmah Laila ^{2*}, Mohammad Yazdi Pusadan ^{3*}, Yuri Yudhaswana ^{4*},
Nouval Trezandy Lapatta ^{5*}, Hajra Rasmita Ngemba ^{6**}

* Teknik Informatika, Universitas Tadulako

** Sistem Informasi, Universitas Tadulako

raihandirga51@gmail.com ¹, rahmah.laila91@gmail.com ², yazdi.diyantara@gmail.com ³, yuri.yudhaswana@untad.ac.id ⁴,
nouval@untad.ac.id ⁵, hajra.rasmita@gmail.com ⁶

Article Info

Article history:

Received 2024-12-07

Revised 2025-05-20

Accepted 2025-05-26

Keyword:

Schistosomiasis,
Oncomelania hupensis lindoensis,
CNN,
EfficientNet-B0,
Snail identification

ABSTRACT

Schistosomiasis caused by the *Schistosoma japonicum* worm is a significant health problem in Indonesia, especially in endemic areas such as the Napu Plateau and Bada Plateau. The main problem in controlling this disease is the difficulty in rapid and accurate identification of *Oncomelania hupensis lindoensis* snails as intermediate hosts of the parasite. This research aims to develop an artificial intelligence-based system that can efficiently identify the snail species. The stages of this research include collecting snail image data from the Central Sulawesi Provincial Health Office, consisting of 2100 images covering seven snail species, then processed through preprocessing and augmentation stages. The model applied was EfficientNet-B0. The results showed that the EfficientNet-B0 model achieved 98.80% training accuracy and 98.33% validation accuracy. Confusion matrix testing showed good performance, with an accuracy of 98% and for the species *Oncomelania hupensis lindoensis* had a recall of 93%, precision of 100%, F1-score of 97%, and the resulting AUC value of 99.7%. This research successfully developed an efficient identification system, which is expected to help health surveillance personnel in accelerating the identification process of schistosomiasis intermediate hosts.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Hingga saat ini, Indonesia adalah salah satu negara endemik di Asia Tenggara yang menderita penyakit Schistosomiasis, atau demam keong. Penyakit ini disebabkan oleh cacing *Schistosoma japonicum* yang membutuhkan hewan perantara yang disebut *Oncomelania Hupensis Lindoensis* [1]. Jika cacing *Schistosoma japonicum* masuk melalui kulit dan menginfeksi inang mamalia, itu adalah titik dimana infeksi terjadi [2]. Penyakit ini secara global mempengaruhi lebih dari satu miliar orang, dengan lebih dari seperempat di antaranya terinfeksi di 78 negara, dan lebih dari 780 juta orang di dunia berisiko terkena infeksi. Meskipun angka kematian akibat penyakit ini tergolong rendah, yaitu sekitar 290.000 kematian per tahun, penyakit ini tetap menjadi penyebab morbiditas yang signifikan pada manusia [3]. Pada berbagai negara Asia, seperti Tiongkok, Jepang,

Filipina, Indonesia, Vietnam, Laos, Thailand, dan Kamboja, ditemukan cacing tersebut. Di Indonesia, penyakit ini hanya ditemukan di Dataran Tinggi Napu dan Dataran Tinggi Bada di Kabupaten Poso serta Dataran Tinggi Lindu di Kabupaten Sigi [2]. Identifikasi cepat dan akurat terhadap keong tersebut sangat penting untuk memetakan area yang berisiko dan merancang intervensi kesehatan yang tepat.

Dalam konteks identifikasi keong, pengenalan citra berbasis teknologi kecerdasan buatan (*Artificial Intelligence/AI*) semakin menjadi alternatif yang menjanjikan. Istilah kecerdasan buatan (AI) digunakan untuk menggambarkan perilaku dan pemikiran kritis yang mirip dengan manusia yang menggunakan teknologi dan komputer [4]. Pendekatan tradisional yang membutuhkan pengamatan manual seringkali memakan waktu dan rentan terhadap kesalahan manusia. Oleh karena itu, teknologi seperti

Convolutional Neural Networks (CNN), yang merupakan algoritma ini dibuat untuk mengolah data, termasuk gambar maupun suara [5]. CNN merupakan bentuk pengembangan dari *Multilayer Perceptron* (MLP) yang dirancang khusus untuk menangani data dua dimensi. CNN tergolong dalam kategori *Deep Neural Network* karena memiliki lapisan jaringan yang mendalam dan sering digunakan dalam pengolahan data gambar [6].

CNN telah menunjukkan keefektifan yang luar biasa dalam menangani tugas-tugas pengolahan gambar yang kompleks. Dengan kemampuannya untuk secara otomatis mengambil fitur-fitur penting dari data visual, CNN dapat mengenali pola-pola yang kompleks dan melakukan klasifikasi dengan akurasi yang sangat tinggi [7]. Metode ini cocok untuk diaplikasikan pada identifikasi spesies keong yang menjadi vektor schistosomiasis.

Namun, tantangan utama dalam penerapan CNN untuk identifikasi citra adalah efisiensi dan generalisasi model. Banyak model *deep learning* yang membutuhkan sumber daya komputasi besar dan cenderung rentan terhadap *overfitting*, terutama jika dataset yang digunakan relatif kecil. Untuk mengatasi masalah ini, dalam penelitian ini digunakan arsitektur EfficientNet, yang dikenal memiliki keunggulan dalam mencapai akurasi tinggi sekaligus mengurangi jumlah parameter dari FLOPS (*Floating Point Operations Per Second*), yang meningkatkan performa model. EfficientNet menarik perhatian karena mampu melakukan prediksi dengan memanfaatkan metode penskalaan yang menyelaraskan seluruh dimensi jaringan, yaitu lebar (*width*), kedalaman (*depth*), dan resolusi (*resolution*). Lebar jaringan didasarkan pada jumlah channel di setiap *layer*, kedalaman didasarkan pada jumlah layer dalam CNN, sedangkan resolusi didasarkan pada ukuran gambar. EfficientNet menggunakan skema pemutakhiran jaringan yang mengatur skala kedalaman, lebar, dan resolusi citra secara proporsional, sehingga menghasilkan model yang lebih efisien dalam penggunaan sumber daya komputasi sekaligus mempertahankan akurasi yang tinggi [8].

Penelitian oleh Fani Nurona Cahya tahun 2021 yang bertujuan untuk melakukan klasifikasi penyakit mata menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur Alexnet, yang telah diperbarui untuk menangani 4 kelas. Proses penelitian ini terdiri dari tiga tahap, yaitu tahap pre-processing yang mengubah ukuran citra menjadi 224x224 piksel. Tahap berikutnya adalah ekstraksi fitur menggunakan tiga *layer*, yaitu *Convolutional Layer*, *Pooling Layer*, dan *Fully Connected Layer*. Implementasi CNN dilakukan dengan 150 epoch, dan hasil akurasi klasifikasi penyakit mata menggunakan metode CNN mencapai 98,37% [6].

Muh Alif Alghifari pada tahun 2024 [9] melakukan identifikasi keong *O.hupensis lindoensis*, tujuan dari penelitian ini yaitu membuat sebuah sistem yang dapat mengidentifikasi keong *O.hupensis lindoensis* diantara keong lainnya dalam habitat yang sama menggunakan algoritma *Convolutional Neural Network* (CNN) dengan arsitektur MobileNet. Dengan 4 kelas dan 1200 data citra, diperoleh

akurasi pelatihan 93% dan akurasi validasi 87%. *Loss function* pelatihan adalah 0.17 dan validasi 0.33. Pengujian *Black Box* menghasilkan 90% untuk fungsionalitas sistem, dan *Confusion matrix* menunjukkan *precision* sebesar 0.87. Penelitian ini mempercepat, mempermudah, dan mengurangi biaya survei keong bagi petugas serta membantu masyarakat mengenali keong penyebab schistosomiasis.

Penelitian dengan judul “Klasifikasi Jenis Kulit Wajah Menggunakan Metode *Convolutional Neural Network* (CNN) Efficientnet-B0” yang mana penelitian ini mengklasifikasikan jenis kulit, yaitu normal, kering, berminyak, dan kombinasi, menggunakan arsitektur EfficientNet-B0. EfficientNet-B0 menskalakan kedalaman, lebar, dan resolusi secara sederhana namun efektif. Dari 1550 data, 1240 digunakan untuk pelatihan dan 310 untuk pengujian. Hasil pengujian menunjukkan akurasi 100%, *loss* 0,001, *precision* 100%, *recall* 100%, dan *f1-score* 100%. Pengujian dilakukan dengan ukuran citra 64x64 piksel, *optimizer* Adam, *learning rate* 0,0001, 50 *epoch*, *dropout* 0,3, dan *batch size* 16 [10].

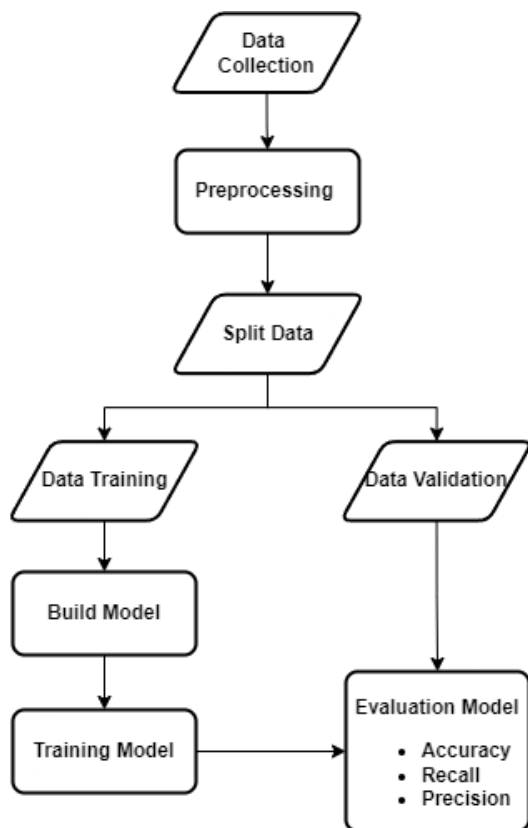
Berdasarkan penelitian-penelitian sebelumnya dan kompleksitas dari permasalahan Schistosomiasis, penelitian ini bertujuan untuk mengimplementasikan dan mengevaluasi model EfficientNet dalam klasifikasi citra keong yang terdiri dari tujuh spesies, yaitu *Sulawesidrobia sp.*, *Oncomelania Hupensis Lindoensis*, *Melanoides sp.*, *Thiara sp.*, *Brotia sp.*, *Lymnaea sp.*, dan *Physa sp.* Data yang digunakan dalam penelitian ini dikumpulkan dari lapangan di daerah endemik schistosomiasis, dengan jumlah total 350 citra yang terbagi rata pada setiap spesies. Untuk meningkatkan akurasi model, augmentasi data diterapkan pada dataset, seperti *random flip*, *brightness adjustment*, dan *contrast adjustment*, dengan tujuan untuk meningkatkan variasi data dan menghindari *overfitting*.

Efisiensi dari model EfficientNet-B0 akan dievaluasi berdasarkan beberapa metrik evaluasi, termasuk akurasi, *precision*, *recall*, dan *F1-score*. Selain itu, akan digunakan *confusion matrix* untuk memberikan gambaran lebih rinci mengenai performa klasifikasi model, terutama dalam mengidentifikasi spesies *Oncomelania Hupensis Lindoensis* yang menjadi inang utama schistosomiasis.

Penelitian ini akan berfokus pada evaluasi keefektifan arsitektur EfficientNet-B0 dalam mengidentifikasi keong berparasit *schistosoma japonicum*, yang nantinya diharapkan dapat memberikan wawasan baru atau kontribusi nyata dalam meningkatkan efisiensi proses identifikasi keong di lapangan, sehingga membantu tenaga surveilans kesehatan dalam mempercepat proses identifikasi inang perantara schistosomiasis. Meskipun demikian, terdapat tantangan dalam pengembangan sistem ini, terutama terkait dengan peningkatan variasi dataset yang diperlukan untuk meningkatkan akurasi model. Tantangan ini akan dibahas lebih lanjut dalam bagian evaluasi dan pengembangan sistem.

II. METODE

Tahapan atau alur kerja penelitian ini terdiri dari beberapa bagian, yaitu tahap pengumpulan dataset citra keong atau *data collection*, *preprocessing*, *split data*, *modeling*, dan *model evaluation*.



Gambar 1. Alur Penelitian

A. Data Collection

Data yang digunakan dalam penelitian ini merupakan data citra, yang diperoleh dari Dinas Kesehatan Provinsi Sulawesi Tengah dan Balai LITBANGKES Donggala. Dataset terdiri atas 7 jenis keong, yaitu *Sulawesidrobia sp*, *Oncomelania hupensis lindoensis*, *Thiara sp*, *Brotia sp*, *Lymnaea sp*, *Melanoides sp*, dan *Physa sp*. Data citra keong yang berhasil dikumpulkan pada penelitian ini terbagi dengan seimbang, yaitu masing-masing kelas berjumlah 50 data citra, sehingga total keseluruhan terdapat 350 data citra keong.

Proses pengambilan data citra dilakukan dengan menggunakan dua kamera *Smartphone* yang memiliki spesifikasi kamera yang tinggi yaitu Iphone 13 Pro dan Samsung S21 Ultra, dengan jarak yang diatur sekitar 5-15 cm dan diposisikan tegak lurus terhadap keong untuk menghindari terjadinya perubahan perspektif. Pengambilan citra dilakukan dari berbagai sisi agar dataset menjadi lebih variatif, dengan pencahayaan yang cukup dan objek penelitian yang digunakan berupa keong yang telah melalui sterilisasi. Untuk latar belakang dilakukan standarisasi menggunakan kertas putih guna memaksimalkan

pencahayaan alami sehingga dapat menangkap seluruh karakteristik morfologi dengan baik serta menghindari *noise* objek lain yang dapat mempengaruhi analisis citra. Tantangan terdapat pada pengambilan gambar keong dengan spesies *Sulawesidrobia sp* dan *Oncomelania hupensis lindonesis* karena memiliki bentuk yang serupa dan ukuran sangat kecil yang mengharuskan pengambilan gambar dilakukan dengan menggunakan lensa *macro* agar detail objek dapat tertangkap oleh kamera.



Gambar 2. Dataset

B. Data Preprocessing

Data preprocessing merupakan proses untuk mempersiapkan dan mengolah data sehingga siap digunakan oleh model. *Preprocessing* yang dilakukan dalam penelitian ini yaitu dengan melakukan augmentasi data yang bertujuan untuk meningkatkan keragaman dan variasi dari data pelatihan dengan memanipulasi transformasi dimensi citra [11].

Proses augmentasi dilakukan dengan menggunakan bantuan *library tensorflow* yang dilakukan dengan beberapa teknik seperti *random horizontal flipping*, *vertical flipping*, *random brightness adjustment*, dan *random contrast*. Pada augmentasi *random horizontal flipping* (*random_flip_left_right*) dan *vertical flipping* (*random_flip_up_down*) digunakan untuk mensimulasikan berbagai sudut pandang dalam pengambilan gambar dengan melakukan *flip* atau membalik citra baik secara horizontal maupun vertikal. Lalu *brightness adjustment* juga dilakukan (*random_brightness* dengan *max_delta=0.2*) untuk mengubah intensitas pencahayaan citra sebesar 20% untuk mencoba berbagai tingkat pencahayaan pada setiap gambar sehingga menambah variasi kondisi pencahayaan di lapangan,

serta menambahkan teknik augmentasi *contrast variation* (*random_contrast* rentang 0.8-1.2) untuk mencoba berbagai intensitas kontras citra yang akan meningkatkan ketahanan model dalam terhadap kontras latar belakang dalam citra keong.

Dari proses augmentasi yang diterapkan, jumlah data pada setiap kelas mengalami peningkatan hingga mencapai 300 data, sehingga total data dari keseluruhan keseluruhan kelas menjadi 2100 data citra keong. Kombinasi augmentasi yang dilakukan juga diharapkan dapat memberikan variasi atau keberagaman dalam data yang dapat merepresentasikan kompleksitas visual dari objek dan dapat dikenali dari berbagai *environment* sehingga dapat mencegah terjadinya *overfitting* dalam pelatihan model.

C. Split Data

Split data merupakan proses pembagian dataset. Dataset akan dipisah menjadi dua bagian, yaitu data latih dan data validasi. Data latih merupakan data yang akan digunakan oleh model untuk dapat mempelajari pola dan hubungan dari data yang ada. Sedangkan data validasi merupakan data yang akan digunakan untuk menguji atau mengevaluasi performa model selama pelatihan.

Pembagian dataset dapat dilakukan dengan menggunakan *library tensorflow* dengan memanfaatkan fungsi *image dataset from directory*. Rasio pembagian dataset yang digunakan yaitu data latih 80% dan data validasi 20%. Pembagian rasio yang ideal akan membuat model dapat belajar dan mengevaluasi performa model dengan baik.

D. Modeling

1) *Convolutional Neural Network (CNN)*: CNN merupakan salah satu metode *deep learning* yang kerap digunakan untuk melakukan ekstraksi atau pemrosesan pada data citra. CNN digunakan untuk mengeksplorasi pola visual dalam gambar dan mengubahnya menjadi fitur yang dapat dianalisa walaupun dengan pola yang sangat kompleks. Dalam membangun desain model CNN terdapat beberapa hal yang harus diperhatikan, yaitu seperti pengaturan lapisan konvolusi, jumlah filter, dan lapisan *pooling*. Dalam lapisan konvolusi melakukan proses operasi konvolusi yang dimana akan mengubah data masukan atau *input* menjadi *feature maps* dengan melakukan operasi *dot* matriks *input* dengan filter [12]. Seperti desain model CNN yang digunakan dalam penelitian ini terdiri dari beberapa lapisan untuk mengekstraksi fitur dari citra secara bertahap, yaitu menggunakan tiga lapisan konvolusi dengan ukuran masing-masing 32, filter berukuran 3x3, menggunakan ReLu (*rectified linear unit*) sebagai *activation function* atau fungsi aktivasi pada setiap lapisan konvolusi dan menggunakan lapisan *max pooling* setelah setiap blok konvolusi untuk mengurangi kompleksitas komputasi. Kemudian lapisan-lapisan tersebut akan disederhanakan menjadi vektor satu dimensi (*flatten*) sehingga dapat diproses dalam *fully connected layer*. Penyesuaian ini dilakukan untuk menghasilkan model yang lebih sederhana namun tetap

mampu menggeneralisasi data dengan baik dalam kasus klasifikasi citra yang digunakan.

2) *EfficientNet-B0*: EfficientNet merupakan arsitektur *deep convolutional neural network* yang dikembangkan oleh Google untuk menangani tugas yang berkaitan dengan *computer vision*. Arsitektur ini dirancang untuk memaksimalkan efisiensi dalam proses komputasi dengan menjaga akurasi tetap tinggi. Inovasi utama dari arsitektur ini yaitu penggunaan *compound scaling* sebagai pendekatan utamanya. *Compound scaling* dapat meningkatkan skala *baseline* ConvNet dengan efisien dan dapat ditingkatkan dengan sangat efektif serta dengan parameter dan FLOPS (*Floating Point Operations Per Second*) yang jauh lebih sedikit [13]. Metode ini memungkinkan untuk menyesuaikan dan meningkatkan dimensi utama model yaitu kedalaman (*depth*), lebar (*width*), dan resolusi (*resolution*) secara bersamaan dan proporsional [14]. Dalam konteks *transfer learning*, EfficientNet terdiri dari beberapa versi, dimulai dari EfficientNet-B0 hingga EfficientNet-B7. EfficientNet-B0 digunakan sebagai *base* model untuk pengembangan versi EfficientNet lainnya. Dalam penelitian ini, model EfficientNet yang digunakan adalah versi B0, memiliki jumlah parameter yang lebih sedikit dibandingkan dengan versi lainnya sehingga memungkinkan model untuk dilatih dengan komputasi yang rendah dan lebih cepat [13]. Pada penelitian yang dilakukan oleh [15] yang menguji EfficientNet-B0, MobileNetV2, ResNet-50, dan InceptionV3 untuk mengklasifikasikan karies gigi, menunjukkan performa yang seimbang, namun EfficientNet-B0 memiliki keunggulan efisiensi komputasi dibandingkan arsitektur lain dengan akurasi 98%.

TABEL I
ARSITEKTUR EFFICIENTNET-B0

Operasi	Resolusi	Channel	Lapisan
Konv 3x3	224x224	32	1
MBKonv1 (k3x3)	112x112	16	1
MBKonv6 (k3x3)	112x112	24	2
MBKonv6 (k5x5)	56x56	40	2
MBKonv6 (k3x3)	28x28	80	3
MBKonv6 (k5x5)	14x14	112	3
MBKonv6 (k5x5)	14x14	192	4
MBKonv6 (k3x3)	7x7	320	1
Konv1x1&Pooling+FC	7x7	1280	1

E. Training Model

Training model merupakan tahap untuk melakukan dan mengatur jalannya proses pembelajaran. Dalam menjalankan proses pelatihan model, terdapat beberapa hal yang perlu disesuaikan dalam *hyperparameter*. *Hyperparameter* merupakan variabel yang perlu diatur untuk menjalankan pelatihan model atau disebut juga sebagai *controller*. Nilai *hyperparameter* diatur sesuai dengan kebutuhan pelatihan dan biasanya disesuaikan melalui percobaan untuk mendapatkan kombinasi nilai parameter yang optimal, yang dikenal dengan istilah *hyperparameter tuning*.

Hyperparameter yang perlu diatur yaitu seperti penentuan *epoch*, *batch size*, *learning rate*, dan *optimizer*.

Pengaturan *hyperparameter* merupakan hal yang penting untuk diperhatikan. Namun setidaknya terdapat dua *hyperparameter* yang cukup krusial, yaitu *learning rate* dan *optimizer*. *Optimizer* merupakan *hyperparameter* yang digunakan untuk mengurangi *loss* dengan melakukan penyesuaian terhadap parameter *weight* dan bias. Adam (*Adaptive Moment Estimation*) merupakan salah satu *optimizer* yang terbukti memiliki performa yang stabil karena dapat membuat *learning rate* beradaptasi sendiri dengan keseluruhan nilai *weight* yang ada [16]. *Learning rate* merupakan *hyperparameter* yang digunakan untuk mengatur besarnya langkah selama pelatihan model. Meskipun dengan menggunakan *optimizer* Adam *learning rate* dapat secara adaptif menyesuaikan ketika proses pelatihan, akan tetapi untuk memberikan *baseline* yang baik, *learning rate* awal ditentukan agar model dapat dengan mudah belajar dengan lebih efektif dan efisien. Pengaturan *learning rate* juga perlu untuk diperhatikan karena jika nilainya terlalu besar maka akan terjadi perpindahan gradien yang besar sehingga model tidak dapat belajar dengan baik dan mempengaruhi stabilitas pelatihan.

TABEL II
HYPERPARAMETER

Hyperparameter	Nilai
Epoch	100
Batch Size	32
Learning Rate	0.0001
Optimizer	Adam

F. Evaluation

Teknik yang kerap digunakan dalam mengevaluasi model klasifikasi yaitu *confusion matrix*. *Confusion matrix* digunakan untuk mengetahui dan mengevaluasi performa model yang telah dilatih serta menghitung nilai *error* dari hasil prediksi, yang berdasarkan hasil distribusi prediksi yang dilakukan model. Informasi yang dihasilkan oleh *confusion matrix* yaitu akurasi, *recall*, dan *precision* [17].

Akurasi merupakan metrik yang digunakan untuk menilai seberapa banyak model dapat memprediksi dengan tepat [18]. *Recall* atau sensitivitas data merupakan metrik yang mengukur tingkat keberhasilan dengan menilai seberapa banyak model memprediksi sampel positif dengan benar diantara seluruh sampel positif sebenarnya, dan *Precision* merupakan metrik yang mengukur seberapa sering model memprediksi suatu kelas positif dengan benar di antara seluruh prediksi positif yang dihasilkan model [14]. Sedangkan F1-Score merupakan informasi *retrieval* yang menggabungkan antara *recall* dan *precision* [10].

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

$$Recall = \frac{TP}{TP+FN} \quad (2)$$

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

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

Keterangan:


TP = True Positive

TN = True Negative

FN = False Negative

FP = False Positive

Dalam mengevaluasi performa model, metode *Receiver Operating Characteristic* (ROC) juga dapat digunakan sebagai alat ukur dalam visualisasi grafik untuk menilai kemampuan model yang telah dilatih. Kurva ROC didapatkan berdasarkan perhitungan antara *sensitivity* atau *true positive rate* (TPR) dengan *specificity* atau *false positive rate* (FPR). Dari perbandingan grafik tersebut akan didapatkan nilai *Area Under Curve* (AUC) dengan melakukan perhitungan luas area dibawah kurva, dengan nilai yang dihasilkan berada direntang 0 hingga 1, yang dimana performa model dikategorikan optimal jika nilainya mendekati 1 [19]. Dalam penelitian ini, ROC AUC digunakan sebagai metrik pendukung untuk melihat perspektif lebih terkait kinerja model yang dihasilkan.



Gambar 3. ROC AUC

III. HASIL DAN PEMBAHASAN

Pada penelitian ini model *computer vision* dibangun menggunakan arsitektur CNN *Scratch* dan arsitektur EfficientNet-B0 dengan *framework tensorflow*, tujuannya yaitu untuk melakukan identifikasi keong berparasit schistosomiasis. Tahap awal pelatihannya yang ditunjukkan pada Tabel III, dapat terlihat bahwa hasil dari pelatihan dengan menggunakan model *scratch* CNN yang mana model menunjukkan peningkatan bertahap dalam akurasi, namun laju pembelajaran yang tidak stabil terlihat dari fluktuasi nilai *loss* pada data validasi.

Selama 10 *epoch* pertama, akurasi pelatihan meningkat dengan cukup cepat dan mencapai 88%, sementara *loss* pada

data validasi mengalami penurunan kecil tetapi tetap tidak stabil dan akurasi validasi terus meningkat hingga 75%. Namun pada *epoch* ke-11 hingga ke-20, akurasi pelatihan terus meningkat hingga mencapai 100% dengan *loss* pelatihan 0.0083, sementara pada akurasi validasi stagnan dan *loss* validasi justru meningkat dengan konsisten dari 1.3587 ke 2.0626 pada *epoch* ke-100 dan *loss* pelatihan mendekati nol, yaitu 2.1996e-05. Hal ini menandakan bahwa model semakin kesulitan untuk memprediksi data validasi dengan baik, dan mengindikasikan *overfitting*. Meskipun model menunjukkan akurasi tinggi pada data pelatihan, hasil pada data validasi tetap tidak memuaskan, mengindikasikan bahwa model telah terlalu menghafal (*memorizing*) data pelatihan dan tidak mampu beradaptasi dengan data yang belum pernah dilihat sebelumnya.

TABEL III
PELATIHAN MODEL CNN SCRATCH

Epoch	Loss (Train)	Accuracy (Train)	Loss (Val)	Accuracy (Val)
1	0.1932	2.1626	0.3238	1.6165
2	0.3453	1.5426	0.4476	1.3772
3	0.5297	1.2189	0.5381	1.2300
4	0.6039	1.0112	0.4976	1.2682
5	0.6717	0.8223	0.5929	1.1183
6	0.6642	0.8879	0.6452	1.0322
7	0.8014	0.5437	0.7000	0.9856
8	0.8650	0.3711	0.6929	1.0477
9	0.8982	0.3031	0.7571	0.8748
10	0.8870	0.3012	0.7524	0.9258
⋮	⋮	⋮	⋮	⋮
91	1.0000	3.0043e-05	0.8262	2.0116
92	1.0000	2.9570e-05	0.8262	2.0229
93	1.0000	2.7802e-05	0.8262	2.0333
94	1.0000	2.9218e-05	0.8262	2.0394
95	1.0000	2.6817e-05	0.8262	2.0442
96	1.0000	2.6609e-05	0.8262	2.0498
97	1.0000	2.4106e-05	0.8262	2.0515
98	1.0000	2.4174e-05	0.8262	2.0608
99	1.0000	2.3612e-05	0.8238	2.0596
100	1.0000	2.1996e-05	0.8262	2.0626

Sebaliknya, pada Tabel IV dijelaskan bahwa, model yang dilatih dengan EfficientNet-B0 menunjukkan perkembangan positif dalam meningkatkan akurasi baik pada data pelatihan maupun validasi. Pada awal pelatihan, akurasi model dimulai dari 20.79% yang meningkat secara bertahap dengan *loss* 2.0516, sementara akurasi validasi sebesar 57.14% dan *loss* 1.5379. Setelah 10 *epoch*, akurasi latih mencapai 82.78% dengan *loss* 0.5714, dan akurasi validasi 88.33% *loss* 0.4571, yang menunjukkan kemampuan model mulai stabil.

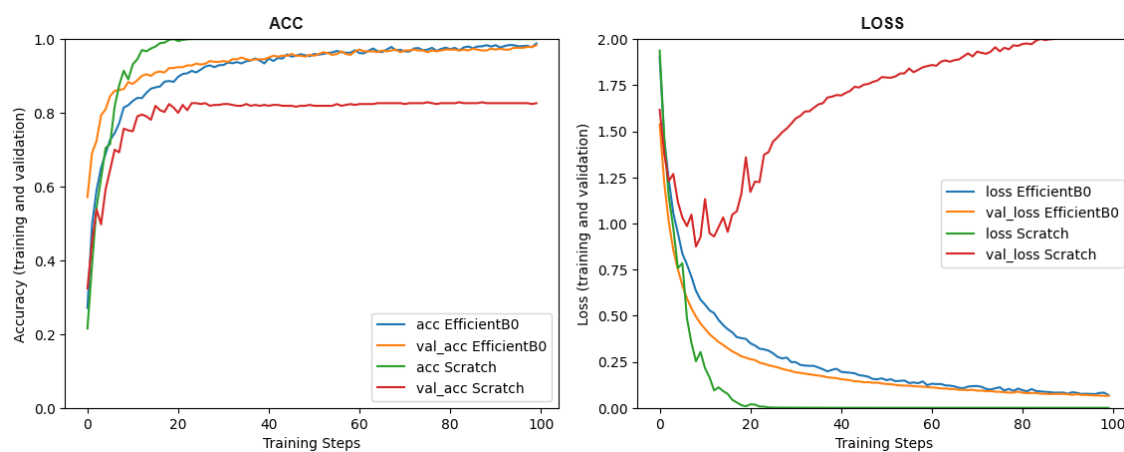
Hingga *epoch* ke-50, model menunjukkan peningkatan kinerja yang stabil, dimana akurasi validasi terus meningkat

dan konsisten berada di atas 95%. Pada akhir pelatihan *epoch* 90 akurasi pelatihan mencapai 98.8% dengan *loss* 0.0667, sedangkan akurasi validasi sebesar 98.33% dengan *loss* 0.0652. Proses ini menunjukkan bahwa model mengalami peningkatan yang konsisten dalam hal akurasi, sambil menjaga nilai *loss* tetap rendah, yang mengindikasikan bahwa model mampu belajar dengan baik dari data pelatihan dan juga mampu melakukan generalisasi yang memadai pada data validasi.

TABEL IV
PELATIHAN MODEL EFFICIENTNET-B0

Epoch	Loss (Train)	Accuracy (Train)	Loss (Val)	Accuracy (Val)
1	0.2079	2.0516	0.5714	1.5379
2	0.4526	1.5273	0.6905	1.2206
3	0.5812	1.2641	0.7238	1.0103
4	0.6409	1.0895	0.7929	0.8563
5	0.6898	0.9622	0.8095	0.7527
6	0.7235	0.8583	0.8452	0.6640
7	0.7442	0.7846	0.8595	0.5940
8	0.7700	0.6982	0.8619	0.5400
9	0.8173	0.6353	0.8643	0.4948
10	0.8278	0.5714	0.8833	0.4571
⋮	⋮	⋮	⋮	⋮
91	0.9842	0.0760	0.9714	0.0739
92	0.9813	0.0838	0.9738	0.0704
93	0.9848	0.0716	0.9714	0.0742
94	0.9827	0.0751	0.9714	0.0702
95	0.9807	0.0770	0.9762	0.0700
96	0.9805	0.0749	0.9762	0.0687
97	0.9795	0.0732	0.9762	0.0673
98	0.9819	0.0770	0.9786	0.0663
99	0.9794	0.0773	0.9786	0.0650
100	0.9880	0.0667	0.9833	0.0652

Hasil perbandingan antara model EfficientNet-B0 dan model yang dibangun dari awal (*scratch*) menunjukkan perbedaan yang signifikan dalam hal stabilitas dan kemampuan generalisasi. Berdasarkan grafik *loss*, model EfficientNet-B0 menunjukkan penurunan *loss* yang lebih stabil baik pada data pelatihan maupun validasi, dengan *loss* validasi yang cenderung menurun tanpa fluktuasi yang besar. Hal ini menunjukkan bahwa model EfficientNet-B0 mampu mempelajari pola data secara efektif dan menghindari *overfitting* secara lebih optimal. Sebaliknya, model CNN *Scratch* memperlihatkan penurunan *loss* yang lebih cepat pada data pelatihan, namun mengalami fluktuasi yang tinggi pada data validasi, mengindikasikan kesulitan dalam melakukan generalisasi terhadap data yang tidak terlihat sebelumnya.

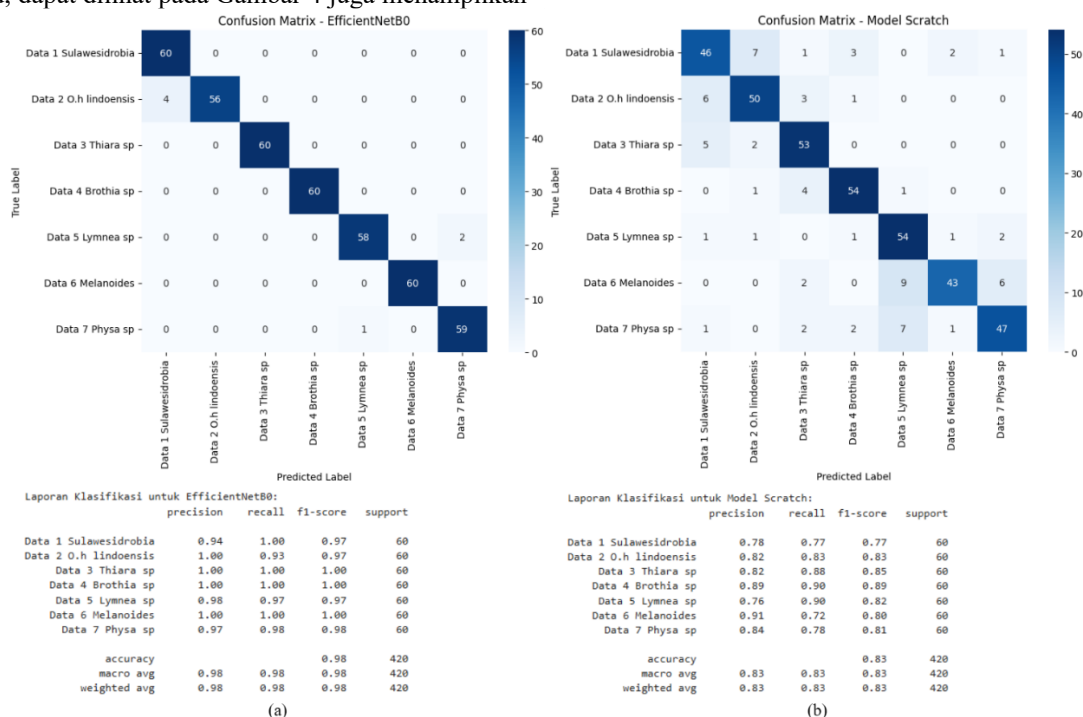


Gambar 4. Visualisasi Hasil Pelatihan EfficientNet-B0 dan CNN Scratch

Pada grafik akurasi, seperti yang ditunjukkan pada Gambar 4, model EfficientNet-B0 berhasil mencapai akurasi pelatihan sebesar 98.81% dan akurasi validasi sebesar 98.33%. Arsitektur EfficientNet-B0 menunjukkan tren yang konsisten pada akurasi data pelatihan dan validasi, yang menunjukkan kapasitas model untuk menangkap pola pada kedua data tersebut. Sebaliknya, model dari *scratch* mengalami peningkatan akurasi yang cepat pada data pelatihan yakni sebesar 100%, namun memiliki selisih sekitar 17% dengan akurasi validasi yakni sebesar 82.86% serta *loss* validasi sebesar 2.0626, yang artinya model CNN *Scratch* terindikasi adanya *overfitting*.

Selain itu, dapat dilihat pada Gambar 4 juga menampilkan

nilai *loss* dimana model EfficientNet-B0 yaitu pada pelatihan 0.0667 dan validasi sebesar 0.0652, yang menunjukkan nilai *loss* validasi yang lebih rendah secara konsisten dibandingkan dengan model dari CNN *Scratch*. Hal ini menunjukkan bahwa model EfficientNet-B0 tidak hanya belajar dengan cepat, tetapi juga mampu mempertahankan performanya ketika dihadapkan pada data validasi, sehingga lebih mampu untuk meminimalisasi kesalahan prediksi pada data yang baru. Secara keseluruhan, model EfficientNet-B0 menunjukkan kinerja yang lebih unggul dibandingkan model yang dibangun dari awal, menjadikannya pilihan yang lebih efektif dalam hal stabilitas dan kemampuan untuk mengakomodasi data baru.



Gambar 5. Confusion Matrix dan Classification Report, (a) EfficientNet-B0, (b) CNN Scratch

Model yang telah dilatih akan dievaluasi untuk melihat kinerja dari model EfficientNet-B0 dan CNN *Scratch* dengan menggunakan *confusion matrix* dan *classification report* Gambar 5. yang digunakan untuk mengklasifikasikan tujuh spesies, yakni *Sulawesidrobia sp*, *O.h lindoensis*, *Thiara sp*, *Brothia sp*, *Lymnaea sp*, *Melanoides sp*, dan *Physa sp*. Nilai diagonal pada matriks menunjukkan jumlah prediksi yang benar untuk masing-masing kelas, sementara nilai di luar diagonal menunjukkan kesalahan klasifikasi.

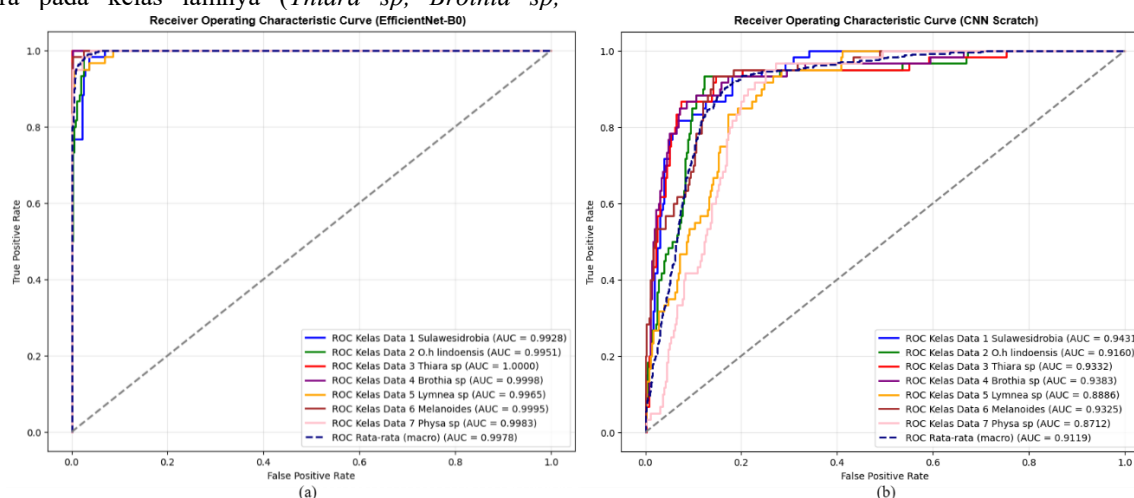
Berdasarkan hasil *confusion matrix* EfficientNet-B0 Gambar 5 (a), spesies *O.h lindoensis* diprediksi dengan benar sebanyak 56 kali, namun salah diklasifikasikan sebagai *Sulawesidrobia sp*. Demikian pula, terdapat misprediksi pada *Physa sp*, yang salah diklasifikasikan sebagai *Lymnaea sp* sebanyak 1 kali, sedangkan pada *Lymnaea sp* salah prediksi sebagai *Physa sp* sebanyak 2 kali. Kesalahan prediksi tersebut yang mempengaruhi skor pada *classification report* sebagai metrik evaluasi untuk menilai akurasi, *precision*, *recall*, dan *f1-score*. Terdapat setidaknya empat kelas yang memiliki kemiripan fitur, yaitu pasangan pertama (*Sulawesidrobia sp* dan *O.h lindoensis*), lalu pasangan kedua (*Lymnaea sp* dan *Physa sp*). Keempat kelas tersebut memiliki karakteristik yang serupa, terutama pada struktur cangkang, warna, dan ukurannya. Tingginya keserupaan antarpasangan tersebut dapat meningkatkan potensi terjadinya kesalahan dalam melakukan identifikasi, terutama jika foto yang diprediksi memiliki *noise* berlebih tanpa distandarisasi terlebih dahulu dengan menggunakan latar kertas putih.

Model yang dihasilkan oleh arsitektur EfficientNet-B0 memiliki performa yang optimal, terlihat pada kelas *Sulawesidrobia sp* memiliki skor *recall* 100%, *precision* 94% dan *f1-score* 97%. Lalu pada kelas *O.h lindoensis* memiliki skor *recall* 93%, *precision* 100%, dan *f1-score* 97%, yang dipengaruhi oleh kesalahan prediksi pada beberapa sampel dikelas tersebut. Tidak hanya itu, kelas *Lymnaea sp* dan *Physa sp* juga mendekati sempurna dengan *f1-score* di atas 97%. Sementara pada kelas lainnya (*Thiara sp*, *Brothia sp*,

Melanoides, dan *Physa sp*) model EfficientNet-B0 menunjukkan performa sempurna dengan semua prediksi benar (*precision*, *recall*, dan *f1-score* = 100%). Hasil ini menunjukkan bahwa model mampu mengklasifikasikan mayoritas spesies dengan akurasi tinggi, meskipun terdapat sedikit kesalahan pada beberapa kelas tertentu.

Pada Gambar 5 (b) ditampilkan *output confusion matrix* CNN *Scratch*, memperlihatkan distribusi prediksi model *Scratch* terhadap label sebenarnya. Dapat terlihat prediksi yang dihasilkan oleh model CNN *Scratch* memiliki persebaran yang tidak merata dengan kesalahan identifikasi yang signifikan pada setiap kelas. Kesalahan tersebut dapat diakibatkan oleh model yang tidak bisa menggeneralisasi setiap data baru. Akurasi yang dihasilkan oleh model *Scratch* yang dikembangkan mencapai 83%. Namun jika dilihat pada kelas *Lymnaea sp* dan *Melanoides sp* memiliki pola kesalahan yang saling tertukar pada 7-9 sampel. Jika dilihat dari segi morfologi, baik bentuk cangkang, warna, ataupun ukurannya, kedua spesies tersebut tidak memiliki kemiripan yang signifikan, sehingga model seharusnya dapat membedakan kedua kelas tersebut dengan mudah. Hal ini mencerminkan kelemahan model CNN *Scratch* dalam membedakan fitur morfologis atau mengekstrak ciri khas setiap kelas yang ada.

Jika dibandingkan dengan EfficientNet-B0 yang mencapai akurasi 98%, model *scratch* jauh tertinggal dalam hal konsistensi prediksi. Pada EfficientNet-B0, empat kelas (*Thiara sp*, *Brothia sp*, *Melanoides*, *Physa sp*) mencapai *precision* dan *recall* sempurna (100%), sementara model *scratch* hanya mampu mencapai *precision* tertinggi 91% pada kelas *Melanoides sp* dengan *recall* yang tidak seimbang. Kesalahan prediksi pada model *scratch* juga lebih tinggi, seperti terlihat dari kesalahan model memprediksi antara *Sulawesidrobia sp* dan *O.h lindoensis* (13 sampel salah total) dibandingkan EfficientNet-B0 yang hanya memiliki selisih akurasi 0.5% antarkelas.



Gambar 6. ROC Curve, (a) EfficientNet-B0, (b) CNN Scratch

Selanjutnya digunakan juga metode *Receiver Operating Characteristic* (ROC) untuk menilai performa model berdasarkan visualisasi grafik. Kurva ROC model EfficientNet-B0 yang ditunjukkan pada Gambar 6 (a), memiliki nilai rata-rata *Area Under Curve* (AUC) sebesar 0.997. Nilai tersebut menunjukkan bahwa model EfficientNet-B0 memiliki kemampuan yang sangat baik dalam mengklasifikasikan ketujuh spesies keong, Nilai AUC yang mendekati 1.0 pada sebagian besar kelas mengindikasikan kemampuan model dalam membedakan fitur-fitur diskriminatif antar kelas dengan presisi tinggi. Sementara pada kurva ROC model CNN *Scratch* yang ditunjukkan pada Gambar 6 (b), tren kurva yang dihasilkan memiliki persebaran nilai AUC yang sangat beragam antar kelas, yang mengindikasikan ketidakstabilan model dalam mengklasifikasi kelas spesies yang ada, dengan nilai AUC rata-rata sebesar 0.911.

Dari penelitian yang telah dilakukan, penelitian ini memberikan performa yang baik dan memiliki keunggulan dibandingkan dengan penelitian sebelumnya. Penelitian terdahulu telah mempresentasikan hasil kinerja dari model MobileNet untuk mengidentifikasi keong sebagai inang perantara parasit schistosomiasis [9]. Data yang digunakan terdiri dari empat kelas, yaitu *Sulawesidrobia sp*, *Oncomelania hupensis lindoensis*, *Thiara sp*, dan *Brotia sp*, dengan total keseluruhan data 1200 citra keong, yang dibagi dengan rasio pelatihan 60:40 validasi. Penelitian tersebut dilatih dengan 100 *epoch* menunjukkan hasil akurasi yang cukup tinggi, dengan akurasi pelatihan sebesar 93% dan akurasi validasi sebesar 87%. Evaluasi model juga dilakukan dengan menggunakan *confusion matrix* menghasilkan akurasi sebesar 87% dan *recall* untuk kelas *O.h lindoensis* sebesar 87%.

Pada penelitian ini, terdapat dua model yang digunakan untuk mengidentifikasi keong berparasit schistosomiasis, yaitu CNN *Scratch* dan EfficientNet-B0, yang dimana data yang digunakan dalam penelitian ini terdapat penambahan 3 kelas baru dari penelitian sebelumnya, sehingga total terdiri atas tujuh kelas atau jenis keong, yaitu *Sulawesidrobia sp*, *Oncomelania hupensis lindoensis*, *Thiara sp*, *Brotia sp*, *Lymnaea sp*, *Melanoides sp*, dan *Physa sp*. Kedua model tersebut dapat mencapai akurasi pelatihan yang tinggi dengan 100 *epoch*, namun hanya model EfficientNet-B0 yang mampu memberikan performa terbaik, sedangkan model CNN *Scratch* memberikan hasil *overfitting* yang ditandai dengan nilai *loss* validasi yang stagnan dan sangat tinggi, yaitu sebesar 2.0626. Arsitektur EfficientNet-B0 yang digunakan dalam penelitian ini dapat menghasilkan performa yang baik dengan akurasi pelatihan 98.80% dan akurasi validasi sebesar 98.33%. Evaluasi menggunakan *confusion matrix* juga memberikan hasil yang baik, dengan nilai akurasi sebesar 96% dan nilai *recall* untuk spesies *O.h lindoensis* sebesar 100%. ROC AUC sebagai metrik pendukung juga memberikan hasil nilai yang tinggi yakni sebesar 0.997, menunjukkan bahwa model EfficientNet-B0 memiliki kemampuan diskriminasi yang sangat baik dalam

mengelompokkan setiap kelas spesies dan disetiap *threshold* mempertahankan performa yang stabil. Hal tersebut juga dapat disebabkan oleh kemampuan model EfficientNet-B0 yang memiliki pendekatan *scaling*, sehingga memiliki lebih banyak parameter yang digunakan untuk mempelajari fitur-fitur yang lebih kompleks pada data citra.

IV. KESIMPULAN

Penelitian ini mengkaji efektivitas model EfficientNet-B0 dalam mengidentifikasi keong sebagai inang perantara penyakit schistosomiasis, yang terdiri dari tujuh spesies, yaitu *Sulawesidrobia sp*, *Oncomelania hupensis lindoensis*, *Thiara sp*, *Brotia sp*, *Lymnaea sp*, *Melanoides sp*, dan *Physa sp* dengan total 2100 data citra. Terdapat dua model yang uji dalam penelitian ini, yaitu model CNN *Scratch* dan EfficientNet-B0. Model CNN *Scratch* menghasilkan akurasi pelatihan sebesar 100%, akurasi validasi sebesar 82.62%, sedangkan pada model EfficientNet-B0 menghasilkan akurasi pelatihan sebesar 98.80% dan akurasi validasi 98.33%. Hal ini menunjukkan bahwa model CNN *Scratch* memberikan hasil yang tidak stabil dan sangat jauh antara pelatihan dan validasi, sehingga model tersebut memberikan hasil yang *overfitting*. Kedua model tersebut dilatih dengan menggunakan *hyperparameter* yang sama, namun hanya model EfficientNet-B0 yang memberikan performa terbaik dengan nilai *loss* yang tetap terkendali. Hal ini juga didukung oleh hasil evaluasi dengan menggunakan *confusion matrix*, yang menghasilkan akurasi sebesar 98% dan *recall* untuk spesies *O.h lindoensis* sebesar 93%, *precision* 100%, serta *F1-score* 97%. Lalu untuk nilai rata-rata AUC pada EfficientNet-B0 juga memberikan hasil yang optimal, yaitu sebesar 0.997, sementara CNN *Scratch* memiliki nilai AUC sebesar 0.911. Tinggi skor pada model EfficientNet-B0 menandakan bahwa model yang dibangun dengan menggunakan tersebut dapat mengidentifikasi keong sebagai inang perantara cacing parasit *schistosoma japonicum* yang menyebabkan penyakit schistosomiasis dengan baik.

Secara keseluruhan, penelitian ini menunjukkan bahwa model EfficientNet-B0 menunjukkan performa yang sangat baik dalam mengklasifikasikan citra keong. Model ini menunjukkan akurasi dan keefektifan yang sangat baik dalam mengekstraksi fitur citra keong sehingga meningkatkan hasil dalam klasifikasi. Oleh karena model EfficientNet-B0 menjadi salah satu model yang efektif dan dapat digunakan dalam mengklasifikasi spesies keong berdasarkan morfologinya. Namun untuk menangani variasi spesies dengan karakteristik yang berbeda, disarankan untuk menambahkan dataset baru yang merepresentasikan spesies tersebut, sehingga akan meningkatkan akurasi dalam proses identifikasi.

Fokus utama dari penelitian ini yaitu identifikasi terhadap spesies *O.h lindoensis* sebagai perantara penyakit schistosomiasis. Meskipun Model ini Untuk adaptasi ke wilayah lain dengan variasi spesies atau karakteristik morfologi berbeda, model dapat dioptimalkan melalui fine-tuning menggunakan dataset baru yang merepresentasikan

keragaman lokal, dilengkapi augmentasi yang mensimulasi variasi lingkungan (misalnya tekstur latar belakang habitat atau pencahayaan).

DAFTAR PUSTAKA

- [1] N. B. Rasiman and L. S. Sampali, "Pengetahuan dan Sikap Masyarakat Dalam Upaya Pencegahan Penyakit Schistosomiasis di Puskesmas Wuasa Kabupaten Poso," *Husada Mahakam J. Kesehat.*, vol. 4, no. 7, p. 404, Jan. 2019, doi: 10.35963/hmjk.v4i7.142.
- [2] A. Nurwidayati, P. P. Frederika, and M. Sudomo, "Fluktuasi Schistosomiasis di Daerah Endemis Provinsi Sulawesi Tengah Tahun 2011-2018," *Bul. Penelit. Kesehat.*, vol. 47, no. 3, pp. 199–206, Dec. 2019, doi: 10.22435/bpk.v47i3.1276.
- [3] Vera Diana Towidjojo, Alya Shafira Nurhafizhah, and Sutrisnawati Mardin, "Faktor-Faktor yang Berhubungan dengan Perilaku Pencegahan Schistosomiasis pada Masyarakat Desa Kaduwaa Napu Kabupaten Poso," *Promot. J. Kesehat. Masy.*, vol. 13, no. 1, pp. 22–27, Jun. 2023, doi: 10.56338/promotif.v13i1.3719.
- [4] W. Halim and P. Mudjihartono, "Keceerdasan Buatan dalam Teknologi Kedokteran: Survey Paper," vol. 2, no. 1, 2022.
- [5] U. S. Rahmadhani and N. L. Marpaung, "Klasifikasi Jamur Berdasarkan Genus Dengan Menggunakan Metode CNN," *J. Inform. J. Pengemb. IT*, vol. 8, no. 2, pp. 169–173, May 2023, doi: 10.30591/jpit.v8i2.5229.
- [6] F. N. Cahya, N. Hardi, D. Riana, and S. Hadiyanti, "Klasifikasi Penyakit Mata Menggunakan Convolutional Neural Network (CNN)," *SISTEMASI*, vol. 10, no. 3, p. 618, Sep. 2021, doi: 10.32520/stmsi.v10i3.1248.
- [7] A. Kanaya Putri and A. Silvia Handayani, "Penerapan Arsitektur EfficientNet Untuk Pembuatan Model Algoritma Convolutional Neural Network Pada Klasifikasi Bahasa Isyarat," *Technol. Sci.*, vol. 6, no. 2, 2024, doi: 10.47065/bits.v6i2.5592.
- [8] R. Andre, B. Wahyu, and R. Purbaningtyas, "Klasifikasi Tumor Otak Menggunakan Convolutional Neural Network Dengan Arsitektur Efficientnet-B3," *J. IT*, vol. 11, no. 3, pp. 55–59, 2021, doi: 10.24853/justit.12.3.55-59.
- [9] M. A. Alghifari, H. R. Ngemba, J. Widjaja, S. Hendra, M. Y. Pusadan, and Y. Y. Joefrie, "Identification of the Snail *Oncomelania hupensis* *Lindoensis* as *Schistosomiasis* Host Using CNN," *Adv. Sustain. Sci. Eng. Technol.*, vol. 5, no. 3, Aug. 2023, doi: 10.26877/asset.v5i3.17195.
- [10] N. A. Sundari, R. Magdalena, and S. Saidah, "Klasifikasi Jenis Kulit Wajah Menggunakan Metode Covolutional Neural Network (CNN) Efficientnet-B0," *eProceedings Eng.*, vol. 8, no. 6, pp. 3180–3187, 2022, Accessed: Oct. 01, 2024. [Online]. Available: <https://openlibrarypublications.telkomuniversity.ac.id/index.php/engineering/article/view/18982>
- [11] J. Sanjaya and M. Ayub, "Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup," *J. Tek. Inform. dan Sist. Inf.*, vol. 6, no. 2, Aug. 2020, doi: 10.28932/jutisi.v6i2.2688.
- [12] Rexion Alondeo Boimau and Yampi R. Kaesmetan, "Klasifikasi Citra Digital Bumbu dan Rempah Dengan Algoritma Convolutional Neural Network (CNN)," *Repeater Publ. Tek. Inform. dan Jar.*, vol. 2, no. 3, pp. 26–34, 2024, doi: 10.62951/repeater.v2i3.81.
- [13] M. Tan and Q. V. Le, "EfficientNet: Rethinking model scaling for convolutional neural networks," in *36th International Conference on Machine Learning, ICML 2019*, May 2019, pp. 10691–10700. [Online]. Available: <http://arxiv.org/abs/1905.11946>
- [14] J. Wang, L. Yang, Z. Huo, W. He, and J. Luo, "Multi-Label Classification of Fundus Images with EfficientNet," *IEEE Access*, vol. 8, pp. 212499–212508, 2020, doi: 10.1109/ACCESS.2020.3040275.
- [15] Wahyuningsih, G. S. Nugraha, and R. Dwiyanaputra, "Classification of Dental Caries Disease in Tooth Images Using A Comparison of EfficientNet-B0, MobileNetV2, ResNet-50, InceptionV3 Architectures," *J. Tek. Inform.*, vol. 5, no. 4, pp. 177–185, 2024, doi: 10.52436/jutif.
- [16] S. Asy Syifa and I. Amelia Dewi, "Arsitektur Resnet-152 dengan Perbandingan Optimizer Adam dan RMSProp untuk Mendeteksi Penyakit Paru-Paru," *J. MIND J. | ISSN*, vol. 7, no. 2, pp. 139–150, 2022, doi: 10.26760/mindjournal.v7i2.139-150.
- [17] M. Heydarian, T. E. Doyle, and R. Samavi, "MLCM: Multi-Label Confusion Matrix," *IEEE Access*, vol. 10, pp. 19083–19095, 2022, doi: 10.1109/ACCESS.2022.3151048.
- [18] M. Azhari, Z. Situmorang, and R. Rosnelly, "Perbandingan Akurasi, Recall, dan Presisi Klasifikasi pada Algoritma C4.5, Random Forest, SVM dan Naive Bayes," *J. MEDIA Inform. BUDIDARMA*, vol. 5, no. 2, p. 640, Apr. 2021, doi: 10.30865/mib.v5i2.2937.
- [19] T. Ma, L. Wu, S. Zhu, and H. Zhu, "Multiclassification Prediction of Clay Sensitivity Using Extreme Gradient Boosting Based on Imbalanced Dataset," *Appl. Sci.*, vol. 12, no. 3, 2022, doi: 10.3390/app12031143.