

Klasifikasi Spesies Burung Berbasis Citra Digital Menggunakan Metode *Convolutional Neural Network*

Kamila Hanum
School of Computing
Telkom University
Bandung, Indonesia

kamilahanum@student.telkomuniversity.ac.id

Febryanti Sthevanie, S.T., M.T
School of Computing
Telkom University
Bandung, Indonesia

febryantisthevanie@telkomuniversity.ac.id

Kurniawan Nur Ramadhani, S.T., M.T
School of Computing
Telkom University
Bandung, Indonesia

kurniawanurramadhani@telkomuniversity.ac.id

Abstrak — Klasifikasi spesies burung secara otomatis dari citra digital merupakan tantangan signifikan yang dihadapi oleh ornitologis, terutama dalam aktivitas *birdwatching* yang penting bagi konservasi burung. Penelitian ini bertujuan untuk mengembangkan sistem klasifikasi spesies burung menggunakan metode *Convolutional Neural Network* (CNN), yang terbukti efektif dalam menangani variasi visual seperti latar belakang dan pencahayaan yang beragam dalam habitat alami burung. Dalam penelitian ini, dua arsitektur CNN yang populer, VGG16 dan VGG19, digunakan untuk mengklasifikasikan 25 spesies burung India. Dataset yang digunakan terdiri dari 22.600 gambar burung yang dibagi menjadi *train*, *validation*, dan *test set*. Hasil pengujian menunjukkan bahwa model VGG19 dengan konfigurasi batch size 64 dan learning rate 0.0001 memberikan performa terbaik dengan akurasi pelatihan mencapai 92% dan akurasi pengujian sebesar 91%. Kesimpulannya, metode CNN, khususnya dengan arsitektur VGG19, efektif dalam mengklasifikasikan spesies burung dari citra digital, dan hasil ini diharapkan dapat berkontribusi pada upaya konservasi burung melalui monitoring otomatis

Kata kunci— : spesies burung , citra digital, klasifikasi, CNN

I. PENDAHULUAN

Burung merupakan salah satu kelompok fauna dengan keanekaragaman jenis yang sangat besar dan dapat ditemukan di berbagai tipe ekosistem[1]. Penyebaran yang luas ini menjadikan burung sebagai komponen penting dalam menjaga keseimbangan ekosistem dan juga sebagai indikator perubahan lingkungan[1]. Setiap jenis burung memiliki keindahan dan ciri khasnya sendiri, yang menjadikannya subjek penting dalam kegiatan konservasi dan monitoring lingkungan[2].

Salah satu metode yang sering digunakan untuk memantau populasi burung adalah *birdwatching*[2]. Aktivitas ini tidak hanya membantu dalam memantau burung, tetapi juga berguna untuk mengevaluasi kualitas lingkungan

sekitar karena beberapa spesies burung sangat responsif terhadap perubahan lingkungan[2]. Namun, proses mengenali spesies burung secara manual sering kali menjadi tantangan, mengingat kemiripan fisik antarspesies yang bisa sangat signifikan[3]. Oleh karena itu, diperlukan metode otomatis untuk mengidentifikasi spesies burung secara lebih efisien[4].

Convolutional Neural Network (CNN) digunakan sebagai metode deep learning yang efektif dalam mengklasifikasikan citra[5]. CNN melibatkan komponen-komponen seperti pooling, ekstraksi fitur, dan sebagainya, yang membuatnya sangat cocok untuk tugas klasifikasi gambar yang kompleks, seperti pengenalan spesies burung[6]. Salah satu arsitektur *Convolutional Neural Network* yang cukup populer adalah *Visual Geometry Group* (VGG)[7]. Desain VGG terdiri dari lapisan konvolusi kecil berukuran 3x3 yang diterapkan secara berulang-ulang, kemudian ada lapisan pooling yang menjaga struktur jaringan tetap sederhana namun efektif dalam menangkap detail halus dari gambar. VGG memiliki kedalaman arsitektur dengan 16 hingga 19 lapisan yang memberikan kemampuan generalisasi yang baik termasuk dalam menghadapi variasi latar belakang gambar dan pencahayaan gambar[7].

Arsitektur CNN yang populer, seperti VGG16 dan VGG19, telah banyak digunakan dalam tugas klasifikasi gambar karena kemampuannya dalam mengenali pola visual yang kompleks. VGG16 memiliki 16 layer, sedangkan VGG19 memiliki 19 layer, yang membuat VGG19 sedikit lebih kompleks. Dalam studi sebelumnya, Hindarto et al. (2023) membandingkan performa VGG16 dan VGG19 dalam klasifikasi serangga. Hasil studi tersebut menunjukkan bahwa VGG19 memberikan akurasi yang lebih tinggi dibandingkan dengan VGG16, dengan peningkatan akurasi sebesar 1.8% [7].

Penelitian tentang klasifikasi spesies burung telah banyak dilakukan menggunakan berbagai pendekatan deep learning. Salah satu pendekatan yang menonjol adalah penggunaan arsitektur

Convolutional Neural Network (CNN), seperti VGG16 dan VGG19. Penelitian oleh Choudhary et al. (2021) menunjukkan bahwa arsitektur VGG16 berhasil mencapai akurasi hingga 98% dalam tugas klasifikasi spesies burung, meskipun dataset yang digunakan memiliki variasi latar belakang dan pencahayaan yang signifikan. Temuan ini menegaskan bahwa VGG16 adalah salah satu model terbaik untuk tugas klasifikasi gambar burung. Menjadikannya pilihan yang tepat untuk digunakan dalam penelitian ini [5].

India memiliki berbagai ekosistem unik seperti Himalaya, padang rumput, dan hutan tropis yang mendukung beragam spesies burung[8]. Menurut artikel [9] populasi burung di India mengalami penurunan signifikan, dengan 60% populasi menurun dalam 30 tahun terakhir dan 40% dalam 8 tahun terakhir. Dataset yang digunakan dalam penelitian ini mencakup spesies burung umum dan yang terancam punah di India. Beberapa spesies dalam dataset termasuk burung pipit, gagak, dan terdapat burung bangau Sarus yang terancam punah.

Penelitian ini bertujuan untuk membangun sebuah sistem klasifikasi 25 spesies burung india menggunakan arsitektur VGG16 dan VGG19, serta melakukan analisis terhadap arsitektur yang optimal dalam memaksimalkan klasifikasi spesies burung india.

II. KAJIAN TEORI

Pada penelitian oleh Sharma et al. (2022), dilakukan identifikasi spesies burung di India untuk mendukung upaya konservasi menggunakan metode *Convolutional Neural Network* (CNN) dengan arsitektur GoogLeNet yang telah dilatih sebelumnya. Dataset yang digunakan terdiri dari 15 spesies burung India, dengan masing-masing spesies memiliki sekitar 120-140 gambar. Data tersebut dibagi menjadi 80% untuk training dan 20% untuk testing. Model ini mencapai akurasi sebesar 99,51%[8].

Penelitian oleh Choudhary et al. (2021), mengkaji pendekatan transfer learning berbasis deep learning untuk klasifikasi spesies burung[5]. Dalam penelitian ini, arsitektur VGG16 dan VGG19 digunakan untuk melatih model dengan dataset gambar burung, dan hasilnya dibandingkan dengan model lain seperti ResNet dan AlexNet. Dataset yang digunakan mencakup berbagai spesies burung dengan beragam variasi latar belakang dan pencahayaan. Hasil dari penelitian ini menunjukkan bahwa model VGG16 mencapai akurasi 98% dalam tugas klasifikasi, yang menegaskan keandalan VGG16 dalam menangani tugas klasifikasi gambar burung. VGG16 dipilih karena keseimbangan yang baik antara kedalaman arsitektur dan efisiensi komputasi, membuatnya menjadi pilihan yang sangat efektif untuk tugas-tugas klasifikasi dengan variabilitas tinggi.

Pada penelitian oleh Hindarto et al. (2023), dilakukan perbandingan performa antara dua arsitektur deep learning yaitu, VGG16 dan

VGG19, dalam klasifikasi serangga. Penelitian ini menggunakan dataset besar yang heterogen, terdiri dari spesies serangga umum dan serangga yang bermanfaat, untuk menyesuaikan model VGG16 dan VGG19 serta menganalisis performa klasifikasinya. Hasil penelitian menunjukkan bahwa VGG19 memberikan akurasi sebesar 97,07%, yang lebih tinggi dibandingkan dengan VGG16 yang mencapai akurasi 96,28%. VGG19 dipilih karena memiliki kedalaman lapisan yang lebih besar, memungkinkan model ini untuk menangkap fitur yang lebih halus dan kompleks, yang merupakan faktor penting dalam konteks klasifikasi yang memerlukan detail presisi tinggi. [7].

Pada penelitian oleh Ong et al. (2021), dilakukan pengujian performa beberapa model deep learning untuk klasifikasi gambar bunga, termasuk VGG19, ResNet50, dan model yang terinspirasi oleh SqueezeNet. Penelitian ini menggunakan dua dataset utama, yaitu dataset 5 kategori dan Flower-102. Hasil penelitian menunjukkan bahwa VGG19 memberikan performa terbaik dengan akurasi validasi sebesar 88% pada dataset 5 kategori dan 84% pada dataset Flower-102[10].

Dalam penelitian oleh Junaidi et al. (2021), dilakukan klasifikasi gambar pada inkubator telur menggunakan model deep learning VGG16 dan VGG19 yang di-pretrain. Penelitian ini bertujuan untuk mengotomatisasi deteksi objek di dalam inkubator, seperti telur, telur yang sedang menetas, dan anak ayam. Dengan menggunakan dataset yang berisi 3.924 gambar dari ketiga kategori tersebut, hasil penelitian menunjukkan bahwa model VGG19 menghasilkan akurasi terbaik dengan 92%, diikuti oleh VGG16 dengan akurasi 90%. Hasil ini menunjukkan bahwa transfer learning dengan menggunakan model VGG19 lebih efektif dalam meningkatkan akurasi klasifikasi gambar dibandingkan dengan model kustom CNN yang hanya mencapai akurasi 87% [11].

A. *Convolutional Neural Network*

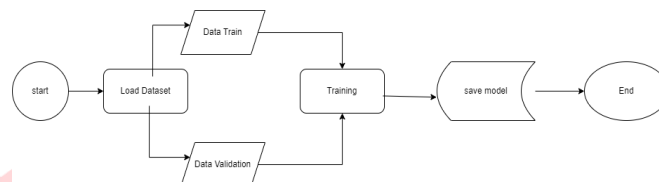
Artikel *Convolutional Neural Network* (CNN) merupakan salah satu arsitektur deep learning yang paling banyak digunakan untuk pengenalan dan klasifikasi gambar. CNN bekerja dengan mempelajari hirarki fitur secara otomatis dari gambar input, yang kemudian digunakan untuk melakukan klasifikasi. Alih-alih membuat fitur secara manual, CNN menggunakan lapisan konvolusi untuk membuat peta fitur (feature maps) dari gambar input melalui proses yang disebut konvolusi. CNN juga merupakan pengembangan dari Multilayer Perceptron (MLP) yang dirancang khusus untuk memproses data dua dimensi. CNN termasuk kedalam kategori *Deep Neural Network* dan merupakan salah satu jenis neural network yang sering digunakan dalam pengolahan data gambar untuk mendeteksi atau mengenali objek dari sebuah gambar. CNN terdiri dari banyak set konvolusi dan

pooling yang dipisahkan oleh fungsi aktivasi non-linear seperti *Rectified Linear Unit* (ReLU)[12].

Secara umum CNN terdiri dari 3 lapisan atau layer utama, yaitu *convolutional layer* yang merupakan elemen kunci dalam CNN yang terdiri dari berbagai filter yang berfungsi sebagai alat ekstraksi fitur, pooling layer digunakan untuk menyederhanakan representasi dengan melakukan pengukuran sehingga membantu untuk mengurangi beban komputasi, dan fully-connected layer. Merupakan lapisan yang berfungsi untuk menerima volume input sehingga menghasilkan vektor dengan dimensi N, dimana N menunjukkan jumlah kelas yang bertujuan untuk mengklasifikasikan gambar ke dalam berbagai kelas berdasarkan inialisasi yang telah dilakukan pada data pelatihan [12].

III. METODE

Rancangan sistem dapat dilihat pada gambar 3.1 yang dimana penelitian ini melakukan 2 proses yaitu ada proses *training validation* dan juga proses *testing*. Proses *training validation* ini merupakan langkah awal untuk melakukan proses klasifikasi dengan melakukan *training* model sebanyak 100 epoch yang akan menghasilkan *output* berupa model CNN yang akan digunakan untuk proses *testing*.



Gambar 3 1 Flowchart

B. Visual Geometry Group (VGG)

Arsitektur VGG, yang dikembangkan oleh Simonyan dan Zisserman pada tahun 2014, merupakan salah satu model *Convolutional Neural Network* (CNN) yang paling banyak digunakan dalam tugas-tugas klasifikasi gambar. VGG dikenal dengan struktur jaringannya yang dalam, dengan varian seperti VGG16 dan VGG19 yang masing-masing memiliki 16 dan 19 lapisan yang dapat dilatih. Ciri khas dari VGG adalah penggunaan filter berukuran 3x3 pada setiap lapisan konvolusinya, yang memungkinkan model untuk menangkap fitur gambar dengan sangat detail[13].

C. Visual Geometry Group 16 (VGG16)

Arsitektur VGG16 memiliki total 16 lapisan yang terdiri dari 13 lapisan konvolusi (Conv) dan 3 lapisan fully connected (FC). Arsitektur ini dibagi menjadi beberapa blok konvolusi, di mana setiap blok terdiri dari tumpukan lapisan konvolusi yang diikuti oleh lapisan max-pooling. Dua blok pertama masing-masing memiliki dua lapisan konvolusi, sementara tiga blok berikutnya masing-masing memiliki tiga lapisan konvolusi. Setiap lapisan konvolusi menggunakan filter berukuran 3×3 , dengan jumlah filter yang meningkat seiring dengan bertambahnya kedalaman jaringan. Fungsi aktivasi ReLU diterapkan setelah setiap lapisan Conv dan FC, dan Batch Normalization (BN) digunakan setelah setiap lapisan konvolusi dan sebelum ReLU[13].

. D. Visual Geometry Group 19 (VGG19)

Arsitektur VGG19 memiliki total 19 lapisan yang terdiri dari 16 lapisan konvolusi dan 3 lapisan fully connected. Struktur VGG19 mirip dengan VGG16, namun dengan tambahan satu lapisan konvolusi di blok ketiga, keempat, dan kelima. Seperti VGG16, semua lapisan konvolusi di VGG19 menggunakan filter 3×3 dan fungsi aktivasi ReLU diterapkan setelah setiap lapisan Conv dan FC, dengan Batch Normalization digunakan dalam cara yang sama seperti di VGG16. Dropout tidak digunakan pada kedua arsitektur ini[13].

digunakan setelah setiap lapisan konvolusi dan sebelum ReLU[13].




Gambar 3 2 Flowchart

1.1 Dataset

Dataset yang akan digunakan pada penelitian ini merupakan data yang telah diperoleh melalui *website Kaggle.com* yang berisi 25 spesies burung india yang berjumlah 22.600 gambar. Dataset dalam penelitian ini berbentuk TFRecords, yang telah dibagi menjadi train, validation, dan test set. Proses load data dilakukan dengan TensorFlow, di mana data diambil dari file TFRecord. Setiap record diparsing menggunakan fungsi yang akan mengubah gambar dari format biner ke tensor dan mengkonversi label ke format numerik. Gambar-gambar ini kemudian di-resize sesuai resolusi input model (224x224 piksel) sebelum diproses dalam batch untuk pelatihan, validasi, dan pengujian.

Gambar di bawah menampilkan contoh beberapa spesies burung dari dataset yang digunakan dalam penelitian ini. Gambar ini mencakup berbagai spesies seperti White Wagtail, Kingfisher, Indian Peacock, dan lainnya, yang menunjukkan variasi dalam pose, latar belakang, dan pencahayaan. Lampiran ini bertujuan untuk

memberikan visualisasi sampel data yang akan digunakan untuk melatih model klasifikasi burung.



Gambar 3 3 Sample Dataset

1.1 Pelatihan Model

Untuk melatih model yang akan dibangun menggunakan TensorFlow dan Keras pada model VGG16 dan VGG19, dataset yang digunakan telah di-preprocess dan disimpan dalam format TFRecords, yang sudah terbagi menjadi train, validation, dan test set. Gambar-gambar di-resize ke ukuran 224x224 piksel sebelum dilatih. Model dilatih selama 100 epoch, dengan data validation digunakan untuk mengevaluasi performa model selama pelatihan.

Model dibangun dengan memanfaatkan arsitektur VGG16 dan VGG19, di mana lapisan konvolusi pre-trained dari ImageNet digunakan sebagai feature extractor. Lapisan-lapisan ini dibekukan untuk mencegah perubahan selama pelatihan. Pada VGG19, yang memiliki 19 lapisan, model lebih dalam dan mampu menangkap fitur yang lebih kompleks dibandingkan VGG16 yang memiliki 16 lapisan, menjadikannya lebih cepat dalam pelatihan tetapi dengan kemampuan fitur yang sedikit lebih sederhana. Setelah pelatihan selesai, model yang telah dilatih akan disimpan untuk digunakan kembali, dan kemudian dilakukan evaluasi performa model untuk mengukur seberapa baik model tersebut dapat

mengklasifikasikan spesies burung dalam dataset yang digunakan.

1.1 Pengujian Model

Pengujian model dilakukan dengan membandingkan grafik akurasi dan loss pada tahap pelatihan dan validasi untuk mengevaluasi performa model VGG16 dan VGG19. Setelah pelatihan selesai, kedua model tersebut digunakan untuk mengklasifikasikan dataset spesies burung, dan hasilnya divisualisasikan dalam bentuk confusion matrix. Dari sini, performa model dianalisis menggunakan metrik akurasi, presisi, recall, dan F1-score, yang dihitung berdasarkan True Positive (TP), False Positive (FP), dan False Negative (FN) untuk

setiap kelas. Rumus perhitungan masing-masing metrik adalah sebagai berikut :

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

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

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

IV. HASIL DAN PEMBAHASAN

a. Training dan Validation

Pada tahap ini dilakukan skenario *training* dan *validation* pada 100 *epoch*.

- **Tingkat Akurasi**

Hasil eksperimen konfigurasi pada batch size dan learning rate yang berbeda. Eksperimen dengan ini dilakukan untuk menemukan nilai optimal yang memungkinkan untuk menemukan ukuran batch yang optimal dan menemukan model belajar dengan cepat tanpa melewatkan solusi optimal.


Tabel 4. 1 Tabel eksperimen konfigurasi

| Model | Batch size | Training accuracy | Validation accuracy | Learning rate |
|-------|------------|-------------------|---------------------|---------------|
| VGG16 | 32 | 0.80 | 0.89 | 0.00001 |
| VGG19 | 32 | 0.82 | 0.90 | 0.00001 |
| VGG16 | 64 | 0.85 | 0.91 | 0.0001 |
| VGG19 | 64 | 0.89 | 0.92 | 0.0001 |


Pada tabel 4.1 Tabel hasil menunjukkan bahwa VGG19 consistently lebih unggul dibandingkan VGG16 dalam semua konfigurasi yang diuji. Pada batch size 32 dengan learning rate 0.00001, VGG19 mencapai akurasi pelatihan 0.82 dan validasi 0.90, sementara VGG16 mencapai 0.80 dan 0.89. Saat batch size ditingkatkan menjadi 64 dengan learning rate 0.0001, akurasi VGG19 naik menjadi 0.89 pada pelatihan dan 0.92 pada validasi, lebih tinggi dibandingkan VGG16 yang mencapai 0.85 dan 0.91. Kesimpulannya, VGG19 lebih efektif dalam menangkap fitur kompleks dan memberikan akurasi yang lebih tinggi dalam klasifikasi dataset ini.

- **Grafik training dan validation**

Grafik training dan validation yang di lampirkan adalah grafik yang memiliki nilai training dan validation accuracy yang paling tinggi. Dimana kedua grafik ini menggunakan konfigurasi batch size 64 dan learning rate 0.0001



Gambar 4 1 Grafik Training Validation VGG16



Gambar 4.2 Grafik Training Validation VGG19

Dari gambar 4.1.1 dapat dilihat bahwa VGG19 menunjukkan kemampuan yang lebih baik dalam belajar dan generalisasi dibandingkan VGG16, menghasilkan performa yang lebih unggul pada dataset ini.

- Tabel performansi model

Tabel 4.2 Tabel Performansi Model

| Model | Akurasi | Presisi | Recall | F1-Score |
|-------|-------------|-------------|-------------|-------------|
| VGG16 | 0.90 | 0.90 | 0.90 | 0.90 |
| VGG19 | 0.91 | 0.91 | 0.91 | 0.91 |

Pada tabel 4 tahap testing, menampilkan hasil performa model VGG16 dan VGG19 setelah tahap testing, di mana semua metrik (Akurasi, Presisi, Recall, dan F1-Score) diperoleh dari perhitungan macro average. ilai macro average dipilih karena memberikan bobot yang sama pada setiap kelas, tanpa memperhitungkan ukuran kelas. Hasilnya menunjukkan bahwa VGG19 memiliki performa yang sedikit lebih baik di semua metrik dengan nilai 0.91 dibandingkan VGG16 yang memperoleh nilai 0.90. Penggunaan macro average memastikan bahwa setiap kelas dianggap sama pentingnya, sehingga metrik yang ditampilkan memberikan gambaran yang adil terhadap kemampuan model dalam mengklasifikasikan seluruh kelas yang ada.

- Hasil Analisa Pengujian

Dalam penelitian ini, didapati bahwa konfigurasi batch size dan learning rate mempengaruhi performa model dan waktu pemrosesannya. Hasil pengujian menyimpulkan bahwa VGG19 dengan konfigurasi batch size 64 dan learning rate 0.0001 memiliki performa tertinggi, dengan akurasi training sebesar 92% dan akurasi testing sebesar 91%. Karena VGG19 dengan konfigurasi tersebut memiliki performa tertinggi, maka hasil model inilah yang digunakan untuk melakukan prediksi.

Kemudian, berdasarkan tabel 4.4, kelas dengan akurasi tertinggi adalah Cattle Egret yang dapat diprediksi dengan benar oleh model. Sementara itu, akurasi terendah terdapat pada kelas Indian Grey Hornbill, di mana model sering salah mengklasifikasikannya sebagai House Crow. Hal ini kemungkinan disebabkan oleh kemiripan visual pada bentuk fisik kedua burung tersebut di

dapati bahwa eksperimen konfigurasi batch size dan learning rate, mempengaruhi performansi mode dan lamanya model di proses. Hasil dari pengujian, menyimpulkan bahwa VGG19 yang menggunakan konfigurasi batch size 64 dengan nilai learning rate 0.0001 memiliki performansi paling tinggi. Dengan hasil akurasi training 92% dan akurasi testing 91%.

Gambar 4.3 Hasil Prediksi Label

| | Input Gambar | Prediksi Gambar |
|--------------------------|------------------------------------|----------------------------|
| Akurasi tertinggi | <p><i>Cattle egret</i></p> | <p><i>Cattle egret</i></p> |
| Akurasi terendah | <p><i>Indian Grey Hornbill</i></p> | <p><i>House Crow</i></p> |

V. KESIMPULAN

Penelitian ini berhasil mengembangkan sistem klasifikasi spesies burung menggunakan *Convolutional Neural Networks* (CNN), dengan model VGG19 yang menunjukkan performa terbaik, mencapai akurasi pelatihan sebesar 92% dan akurasi pengujian sebesar 91%. Model ini efektif dalam mengklasifikasikan sebagian besar spesies burung, namun terdapat tantangan dalam membedakan spesies yang memiliki kemiripan visual, seperti Indian Grey Hornbill dan House Crow.

Untuk peningkatan lebih lanjut, disarankan untuk mengeksplorasi arsitektur CNN yang lebih terbaharukan, serta mengatasi tantangan dalam klasifikasi spesies yang mirip dengan memperkaya dataset dan menerapkan teknik augmentasi data. Hal ini diharapkan dapat meningkatkan akurasi dan kehandalan sistem dalam aplikasi nyata, terutama dalam konteks konservasi burung.

REFERENSI

- [1] Hadinoto, A. Mulyadi, and Y. I. Siregar, "Keanekaragaman Jenis Burung di Hutan Kota Pekanbaru," *J. Ilmu Lingkungan.*, vol. 6, no. 1, pp. 25–42, 2012.
- [2] S. Kamal, N. Mahdi, and N. Senja, "Keanekaragaman Jenis Burung Pada Perkebunan Kopi di Kecamatan Bener Kelipah Kabupaten Bener Meriah Provinsi Aceh," *Biot. J. Ilm. Biol. Teknol. dan Kependidikan*, vol. 1, no. 2, p. 73, 2015, doi: 10.22373/biotik.v1i2.216.
- [3] S. Branson, G. Van Horn, S. Belongie, and P. Perona, "Bird species categorization using pose normalized deep convolutional nets," *BMVC 2014 - Proc. Br. Mach. Vis. Conf. 2014*, 2014.
- [4] E. Reyes, "A Comparison of Image Processing Techniques for Bird Detection," *Thesis*, no. June, pp. 9–13, 2014.
- [5] D. Garg, K. Wong, and J. Sarangapani, *Advanced Computing Part 2*. 2020.
- [6] A. Saxena, "An Introduction to Convolutional Neural Networks," *Int. J. Res. Appl. Sci. Eng. Technol.*, vol. 10, no. 12, pp. 943–947, 2022, doi: 10.22214/ijraset.2022.47789.
- [7] D. Hindarto, N. Afarini, and E. T. Esthi H, "Comparison Efficacy of VGG16 and VGG19 Insect Classification Models," *JIKO (Jurnal Inform. dan Komputer)*, vol. 6, no. 3, pp. 189–195, 2023, doi: 10.33387/jiko.v6i3.7008.
- [8] Y. K. Sharma, M. S. Karyakarte, G. H. Chavhan, R. Khan, M. Patil, and R. S. Talware, "Identification of Indian Bird Species to Promote Conservation Endeavors," *Artic. Hist. Artic.*, vol. 71, no. 4, pp. 8803–8824, 2022, [Online]. Available: <http://philstat.org.ph>
- [9] ScienceDaily, "Global bird population steadily declining," 2022, [Online]. Available: <https://www.telegraphindia.com/india/decline-in-indian-bird-species-alarming-report-reveals-60-per-cent-decrease-over-30-years/cid/1961533>.
- [10] O. Zi Yuan, C. Kah Kien, K. Huay Wen, and T. Chi Wee, "Flower Recognition Model based on Deep Neural Network with VGG19," *J. Inst. Eng. Malaysia*, vol. 82, no. 3, pp. 41–46, 2022, [Online]. Available: <https://iemjournal.com.my/index.php/iem/article/view/97>.
- [11] A. Junaidi, F. D. Adhinata, A. R. Iskandar, and J. Lasama, "Image Classification for Egg Incubator Using Transfer Learning VGG16 and InceptionV3," *Lect. Notes Electr. Eng.*, vol. 898, pp. 85–95, 2022, doi: 10.1007/978-981-19-1804-9_7.
- [12] M. M. Taye, "Theoretical Understanding of Convolutional Neural Network ;," *Mdpi Ag*, vol. 11, no. 3, p. 52, 2023.
- [13] M. Manataki, N. Papadopoulos, N. Schetakis, and A. Di Iorio, "Exploring Deep Learning Models on GPR Data: A Comparative Study of AlexNet and VGG on a Dataset from Archaeological Sites," *Remote Sens.*, vol. 15, no. 12, 2023, doi: 10.3390/rs15123193.