

# Klasifikasi Spesies Burung Dengan Menggunakan *Convolutional Neural Network*

Mas Shoultan Satria Nugroho<sup>1\*</sup>, Farida Nurlaila<sup>1</sup>

<sup>1</sup>Fakultas Ilmu Komputer, Teknik Informatika, Universitas Pamulang, Jl. Raya Puspiptek No. 46, Kel. Buaran, Kec. Serpong, Kota Tangerang Selatan. Banten 15310, Indonesia

Email: <sup>1</sup>[Sultansatirionugroho@gmail.com](mailto:Sultansatirionugroho@gmail.com), <sup>2</sup>[faridanurlaila09@gmail.com](mailto:faridanurlaila09@gmail.com)

(\* : coressponding author)

**Abstrak**– Penggunaan model Convolutional Neural Network (CNN) untuk klasifikasi spesies burung menjadi fokus dalam penelitian ini. Metodologi yang digunakan dalam penelitian ini memanfaatkan dataset BIRDS400-SPECIES IMAGE CLASSIFICATION untuk diuji dengan model CNN Inception V3 dan terbatas hanya untuk 18 kelas. Eksperimen dijalankan pada platform Google Collabs versi gratis. Dari hasil eksperimen yang dilakukan, model CNN Inception V3 memerlukan waktu untuk melatih gambar selama 36 menit 46 detik serta mendapatkan akurasi training sebesar 93.36%. Untuk eksperimen pada tahap testing, model CNN Inception V3 yang telah dilatih pada platform Google Collabs dapat memprediksiseluruh gambar yang berada pada folder testing dengan benar. Berdasarkan hasil penelitian yang dilakukan, model CNN InceptionV3 mempunyai ketepatan yang sangat tinggi untuk menagani dataset tersebut serta platform Google Collabs versi gratis sudah cukup mampu untuk melakukan pengolahan dataset tersebut.

**Kata Kunci:** *Deep Learning, Convolutional Neural Network, Klasifikasi Burung, Spesies Burung.*

**Abstract**– *Theuse of the Convolutional Neural Network (CNN) model for the classification of bird species is the focus of this study. The methodology used in this study utilizes the BIRDS 400 - SPECIES IMAGE CLASSIFICATION dataset to be tested with the CNN Inception V3 model and is limited to only 18 classes. The experiment was run on the free version of the Google Collabs platform. From the results of experiments conducted, the CNN InceptionV3 model requires time to train images for 36 minutes 46 seconds and obtains a training accuracy of 93.36%. For experiments at the testing stage, the CNN InceptionV3 model that has been trained on the Google Collabs platform can correctly predict all images in the testing folder. Based on the results of the research conducted, the CNN InceptionV3 model has very high accuracy for handling the dataset and the free version of the Google Collabs platform is sufficiently capable of processing the dataset.*

**Keywords:** *Deep Learning, Convolutional Neural Network, Bird Classification, Bird Species.*

## 1. PENDAHULUAN

Masyarakat yang bertempat tinggal di wilayah Indonesia sering juga mengalami kesulitan untuk mengenali jenis burung secara tepat. Hal tersebut dikarenakan suatu spesies burung hanya terdapat pada suatu daerah. Sehingga untuk mendeteksi burung apa saja yang berada di suatu wilayah tanpa harus mengusik keberadaan burung adalah dengan menggunakan alat bantu. Alat bantu yang dimaksud disini bisa dengan menggunakan kamera untuk mengambil gambar lingkungan sekitar yang menjadi tempat hadirnya burung.

Untuk dapat mengklasifikasikan spesies burung, maka diperlukan sistem yang dapat mengenali suatu jenis burung berdasarkan hasil yang diperoleh dari alat bantu. Oleh karena itu, maka diperlukan sebuah sistem klasifikasi dengan algoritma tertentu untuk mengenali jenis burung dengan baik.

Sistem klasifikasi dengan memanfaatkan teknologi terbaru dikembangkan dalam sejumlah penelitian. Penelitian terkait dengan klasifikasi dengan teknologi terbaru telah dilakukan oleh Febrian Valentino beserta rekannya. Mereka melakukan penelitian dengan menggunakan *Convolutional Neural Network* (CNN) untuk mendeteksi melakukan klasifikasi buah menjadi 6 kelas (Valentino et al., 2021).

Sedangkan untuk deteksi jenis burung dengan memanfaatkan teknologi terbaru telah dilakukan oleh Warnia Nengsih Sikumbang. Dalam penelitian Warnia Nengsih Sikumbang menggunakan *Convolutional Neural Network* (CNN) untuk klasifikasi 13 jenis burung cendrawasih (Sikumbang, 2021).

*Convolutional Neural Network* (CNN) adalah jenis dari *Deep Learning* yang merupakan subbidang *Machine Learning* yang menggabungkan beberapa lapisan pemrosesan, menggunakan

beberapa elemen yang beroperasi secara paralel dan terinspirasi oleh sistem saraf (Wulandari et al., 2020). CNN memanfaatkan proses konvolusi dengan menggerakkan sebuah kernel konvolusi (filter) berukuran tertentu ke sebuah gambar, komputer mendapatkan informasi representatif barud ari hasil perkalian bagian gambar tersebut dengan filter yang digunakan. Dari latar belakang tersebut, diusulkan sebuah penelitian dengan menerapkan *Deep Learning* yang berjenis *Convolutional Neural Network* (CNN) untuk klasifikasi spesies burung.

Deep Learning dipilih karena merupakan salah satu bidang dari *Machine Learning* yang memiliki kemampuan sangat baik untuk komputer dalam belajar mandiri, mulai dari pemrosesan bahasa alami hingga pemrosesan gambar (Lammieetal, 2019). Metode *Deep Learning* dikatakan memiliki kemampuan yang sangat baik dikarenakan *Deep Learning* mampu memproses data dalam bentuk mentah (Lecun et al., 2015). *Convolutional Neural Network* (CNN) merupakan jenis *Deep Learning* yang paling sering diterapkan untuk melakukan pengolahan citra, pengenalan wajah, klasifikasi citra, dan pendeteksian objek. Hal ini dikarenakan CNN merupakan salah satu jenis *Deep Learning* yang dapat menerima masukan dari gambar, dengan menentukan aspek atau objek apa dalam suatu gambar yang dapat dipelajari dan kemudian dapat membedakan antara gambar yang satu dengan yang lainnya.

Data yang digunakan dalam penelitian ini adalah data gambar jenis – jenis burung sehingga penelitian ini menggunakan Deep Learning yang berjenis *Convolutional Neural Network* (CNN). Untuk mendapatkan hasil yang optimal maka diperlukanlah sebuah arsitektur CNN yang tepat. Maka dilakukan perbandingan arsitektur CNN untuk klasifikasi jenis burung yang kemudian dievaluasi menggunakan dataset publik BIRDS400-SPECIES IMAGE CLASSIFICATION (Gerry, 2022).

## 2. METODOLOGI PENELITIAN

Metode penelitian yang digunakan dalam penelitian ini adalah melakukan perbandingan model CNN untuk memprediksi 18 spesies burung berdasarkan gambar.

Burung merupakan hewan peliharaan yang telah dikenal oleh banyak masyarakat di Indonesia. Namun, banyak diantara masyarakat awam kesulitan dalam membedakan jenis burung khususnya burung love bird. Dari segi jenis, masyarakat cenderung melihat sesuai dengan yang ada di pada umumnya. Semakin jenis burung berbeda dan jarang diketahui masyarakat, maka akan memiliki nilai jual yang tinggi pada burung lovebird. Hal ini juga akan membuat daya Tarik tersendiri kepada para pecinta burung love bird (Rahman, 2021). Untuk menyelesaikan masalah yang terjadi dalam penelitian ini maka dilakukan klasifikasi citra terhadap burung lovebird. Metode penelitian yang digunakan dalam penelitian ini yakni dengan membandingkan antara *Artificial Neural Network* dengan *Decision Tree* 48 yang kemudian dievaluasi menggunakan *accuracy*, *precision*, *recall*, dan *f-measure*. Hasil yang diperoleh dari penelitian ini yakni dengan pengujian dengan menggunakan *Artificial Neural Network* memperoleh nilai *accuracy* sebesar 33.70%, *precision* sebesar 0.400, *recall* sebesar 0.337, serta *f-measure* sebesar 0.308. Sedangkan pengujian dengan menggunakan *Decision Tree* j48 memperoleh nilai *accuracy* sebesar 100%, *precision* sebesar 1.000, *recall* sebesar 1.000, serta *f-measure* sebesar 1.000. Penelitian ini menunjukkan bahwa *Decision Tree* 48 memberikan hasil yang lebih baik jika dibandingkan dengan *Artificial Neural Network*.

Burung Jalak merupakan salah satu jenis burung yang terdapat di Indonesia. Jalak memiliki ciri khas tersendiri dalam hal jenis, warna, suara dan banyak lag lainnya. Di setiap kabupaten di Indonesia terdapat berbagai macam jenis burung jalak. Namun, sejumlah orang merasa sulit untuk mengenali jenis burung jalak (Rahman, 2022). Dari penelitian tersebut, diusulkan klasifikasi citra burung jalak menggunakan Random Forest dengan Wavelet. Klasifikasi ini bertujuan memperbaiki kinerja klasifikasi citra burung jalak menggunakan fitur tekstur, Gabor dan Wavelet. Nilai dalam akurasi terbaik dari data uji akan diketahui dan dibandingkan antara *Artificial Neural Network* dan Random Forest. Pada klasifikasi ini menggunakan fitur GLCM, Gabor dan Wavelet dalam pengujian yang digunakan. Dari hasil perbandingan antara *Artificial Neural Network* dengan *Random Forest* bisa disimpulkan bahwa pada fitur Wavelet memiliki hasil yang maksimal pada proses klasifikasi burung jalak. Hasil dalam pengujian dimulai dengan *Artificial Neural Network* memiliki nilai tertinggi pada *precision* mencapai 0.986 dengan perbandingan 50:50, *recall* 0.987 pada split ratio 80:20, *f-measure* mencapai 0.988 dengan split ratio 80:20 dan *accuracy* tertinggi

mencapai 89% perbandingan 90:10. Selanjutnya pada Random Forest memiliki hasil tertinggi pada *precision* mencapai 1.000, *recall* mencapai 0.877, *f-measure* mencapai 0.975 dan *accuracy* mencapai 100% dengan perbandingan mulai 20:80 sampai dengan 90:10.

Penelitian yang dilakukan oleh Yanuki dan Rahman dengan judul *Image Classification of Canaries Using Artificial Neural Network* (Yanuki & Rahman, 2021) terdapat masalah yaitu banyaknya jenis burung kenari yang terdapat di Indonesia dan masih belum ada riset yang membahas tentang burung kenari. Sehingga masalah tersebut diselesaikan dengan sistem klasifikasi citra burung kenari menggunakan *Artificial Neural Network* berdasarkan tekstur, bentuk dan warna yang bertujuan untuk mengidentifikasi semua jenis burung kenari.

Serta dapat memudahkan masyarakat umum dalam proses pemilihan burung kenari untuk dipelihara atau dibudidayakan. Dalam hal ini juga dapat mempermudah masyarakat untuk memilih burung kenari mana yang mahal dan mana burung kenari yang murah, sehingga nantinya akan memudahkan masyarakat dari segi ekonomi. Hasil penelitian yang diperoleh mulai dari Naïve Bayes nilai maksimal 65% split ratio 90:10. Variasi Linear SVMNU-SVC nilai maksimum 60% split ratio 90:10. Variasi nilai Polinomial NU-SVC maksimal 43% split ratio 90:10. Nilai maksimum variasi NU-SVC Radial 60% split ratio 90:10. Variasi NU-SVC Sigmoid nilai maksimum 42% split ratio 90:10. Metode *Artificial Neural Network* nilai akurasi maksimum 96% split ratio 90:10 antara data latih dan data uji.

*Deep Learning* menjadi salah satu tren terbaru dalam penelitian *Machine Learning* dan *Artificial Intelligence* (Minar & Naher, 2018). *Deep Learning* merupakan program komputasi yang dapat membuat mesin bekerja layaknya kecerdasan manusia. Sehingga *Deep Learning* banyak digunakan untuk memecahkan berbagai masalah yang dihadapi manusia seperti permasalahan keuangan (Syafrudinet al., 2021), diagnosis medis (Hastomo, 2021) dan pengambilan keputusan (Priyono & Indrajit, 2017).

Penjelasan lebih lanjut mengenai *Deep Learning* yaitu, *Deep Learning* merupakan metode pembelajaran representasi dengan beberapa tingkat representasi yang diperoleh dengan menyusun modul sederhana namun non-linier yang masing-masing mengubah representasi pada satu tingkat dimulai dari input mentah menjadi representasi pada tingkat yang lebih tinggi sehingga *Deep Learning* lebih baik dari *Conventional Machine Learning* yang tidak mampu memproses data dalam bentuk mentah (Lecun et al., 2015).

Selain dari penjelasan di atas, *Deep Learning* juga dijelaskan sebagai pandangan baru tentang representasi pembelajaran dari data yang menekankan pada pembelajaran lapisan berturut-turut dari representasi yang semakin bermakna oleh Chollet Francois (Chollet, 2021).

Dalam buku yang berjudul “*Deep Learning: Aplikasinya di Bidang Geospasial*” karya Yaya Heryadi dan Edy Irwansyah dijelaskan masalah utama yang menjadi faktor pendorong perkembangan *Deep Learning* saat ini adalah dataset serta perangkat keras komputer seperti *Graphics Processing Unit* (GPU) atau *Tensor Processing Unit* (TPU) (Heryadi & Irwansyah, 2020). Karena saat ini banyak yang memiliki data dalam jumlah besar akan tetapi kualitasnya rendah atau sebaliknya memiliki jumlah data yang sedikit akan tetapi kualitasnya tinggi. Selain data, banyak juga yang terkendala dengan perangkat yang dimiliki tidak terlalu canggih. Hal tersebut menjadikan jumlah data serta kualitas dari dataset dapat mempengaruhi hasil dari pembelajaran model serta pemanfaatan perangkat keras seperti GPU atau TPU memungkinkan percepatan waktu proses pembelajaran model *deep learning* dengan jumlah parameter yang besar.

Dari *Deep Learning* yang telah berkembang saat ini menjadikan banyak bidang pekerjaan yang terbantu. Untuk bidang pekerjaan penting seperti sektor kesehatan, pembelajaran mendalam dapat mengklasifikasikan kanker kulit (Hosny et al., 2018) dan kanker payudara (Pardamean et al., 2018) yang merupakan penyakit menyebabkan banyak kematian di dunia (Siege et al., 2022). Selain sektor kesehatan, ada juga sektor pertanian & perkebunan. Di sektor pertanian & perkebunan, *deep learning* diterapkan untuk mengklasifikasikan buah kelapa sawit berdasarkan kematangan (Herman et al., 2021) yang kemudian dikembangkan sebagai mesin pemetik buah kelapa sawit otomatis yang dapat memanen buah kelapa sawit sesuai dengan tingkat kematangannya (Rahutomo et al., 2020).

Landasan teori dalam penelitian ini adalah teori *Deep Learning* dengan model *Convolutional Neural Network* (CNN). Kini banyak model-model CNN yang diciptakan untuk digunakan dalam melakukan deteksi, klasifikasi, dan prediksi pada gambar. Teori dalam penelitian ini antara lain diambil dari berbagai jurnal penelitian dengan model CNN.

Dalam *Deep Learning*, *Convolutional Neural Network* (CNN) merupakan kelas pada *Deep Neural Network* yang paling umum diterapkan untuk menganalisa citra visual, dan digunakan untuk melakukan pengenalan gambar, klasifikasi gambar, deteksi objek, dan pengenalan wajah (Perdananto, 2019).

CNN terdiri dari neuron yang memiliki bobot dan bias yang dapat dipelajari. Setiap neuron dapat menerima beberapa input, dengan menghasilkan titik sebagai produk dan secara opsional mengikutinya dengan non-linearitas. Seluruh jaringan masih mengekspresikan fungsi skor tunggal yang dapat dibedakan dari piksel gambar mentah di satu titik ke skor kelas di ujung lainnya. Secara algoritma, CNN merupakan salah satu arsitektur model *Deep Learning*, yang dapat mengambil gambar sebagai input, dengan menetapkan nilai bobot dan bias yang dapat dipelajari dari berbagai aspek/objek dalam gambar dan dapat membedakan satu dari yang lain.

Preprocessing yang diperlukan dalam CNN jauh lebih ekonomis dibandingkan dengan algoritma klasifikasi lainnya. Sementara dalam metode yang terdahulu filter direkayasa secara manual, sedangkan CNN dengan pelatihan yang cukup, mampu untuk mempelajari filter/karakteristik dari sebuah objek.

CNN mempunyai keunggulan dan efisiensi secara komputasi dimana menggunakan operasi convolution, penyatuan khusus dan menggunakan parameter sharing. Sehingga memungkinkan model CNN berjalan diperangkat apapun termasuk perangkat mobile. Hal ini menjadikan CNN menarik secara universal.

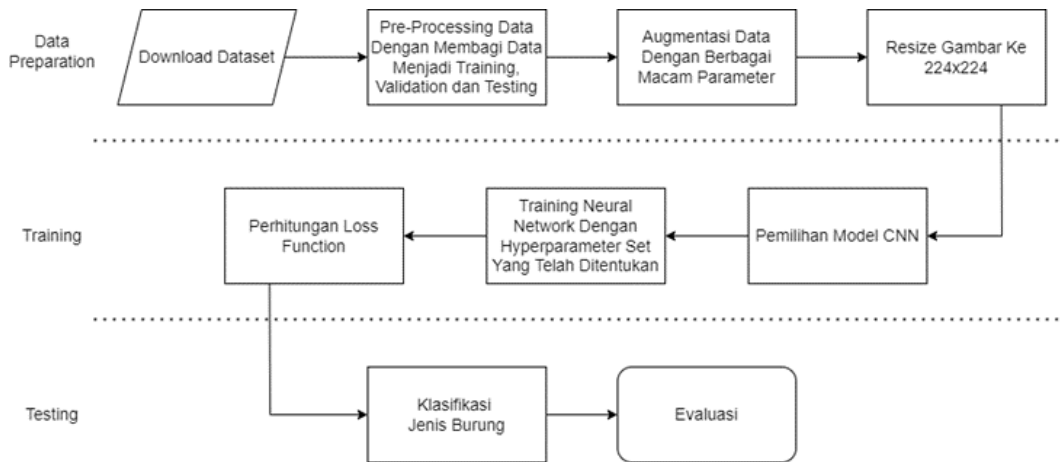
Dengan karakteristik dan keunggulan yang disebutkan di atas membuat CNN model menarik untuk digunakan dalam penelitian untuk mengidentifikasi gambar, termasuk klasifikasi jenis pada burung.

### 3. ANALISA DAN PEMBAHASAN

Dengan karakteristik dan keunggulan yang disebutkan di atas membuat CNN model menarik untuk digunakan dalam penelitian untuk mengidentifikasi gambar, termasuk klasifikasi jenis pada burung.

Penelitian ini dilakukan menggunakan Google Colab atau Google Colaboratory. Google Colab atau Google Colaboratory adalah sebuah executable document yang dapat digunakan untuk menyimpan, menulis, serta membagikan program yang telah ditulis melalui Google Drive. Google Colab pada dasarnya serupa dengan Jupyter Notebook gratis berbentuk cloud yang dijalankan menggunakan browser, seperti *Mozilla Firefox* dan *Google Chrome*. Google Colab memungkinkan penggunaannya untuk menjalankan kode Python tanpa perlu melakukan proses instalasi dan setup lainnya. Justru, semua keperluan setting dan adjustment akan diserahkan ke cloud. Dikarenakan proses diserahkan ke cloud sehingga tidak diperlukan komputer dengan spesifikasi besar untuk melakukan proses tersebut. Keuntungan terbesar dari Google Colab adalah bahwa Google Colab memiliki kumpulan built-in-library machine learning paling populer yang dapat dimuat dengan mudah dalam notebook yang dibuat. Sehingga produk ciptaan Google Research ini juga dikenal sebagai software yang dapat menunjang seluruh keperluan data science dan machine learning.

Selain menggunakan Google Colab, penelitian ini juga menggunakan Ubuntu Virtual Machine yang dilengkapi dengan tools untuk menjalankan *Convolutional Neural Network* yakni, Python 3.6, TensorFlow, OpenCV, Keras serta Numpy. Pengujian dilakukan di Google Colab dengan menjalankan skrip dalam bahasa python dengan menggunakan gambar yang telah disiapkan. Setelah itu hasil pengujian akan dikirim ke kalkulator matriks online untuk mendapatkan nilai Akurasi, Presisi, Recall serta F1-Score. Tahap perancangan sistem diilustrasikan dalam diagram alir pada Gambar 1.



**Gambar 1.** Diagram Alir

Dalam persiapan data, akan diunduh dataset public BIRDS 400 - SPECIESIMAGE CLASSIFICATION yang kemudian dilakukan pre-processing data dengan membagi dataset menjadi tiga bagian yaitu data training sebanyak 80%, data validation sebanyak 20% serta data testing. Selain membagi menjadi data training, validation, testing, jumlah data kelas yang digunakan dikurangi menjadi 18 kelas spesies burung. Setelah dilakukan pre-processing data, kemudian Augmentasi data dilakukan untuk memperbanyak data. Parameter augmentasi yang digunakan dalam penelitian ini adalah  $rescale = 1./255$ ,  $width\_shift\_range = 0.2$ ,  $height\_shift\_range = 0.2$ ,  $zoom\_range = 0.3$ ,  $shear\_range = 0.2$ ,  $brightness\_range = [0.8,1.2]$ ,  $fill\_mode = 'nearest'$  serta  $horizontal\_flip = True$ . Jumlah data hasil augmentasi yakni sebanyak 2600 gambar yang terbagi ke dalam 18 kelas. Setelah melewati proses pre-processing data serta augmentasi data, kemudian data image dilakukan resize menjadi 224x224 untuk model CNN Inception V3.

Proses selanjutnya adalah training data dengan model CNN yang digunakan dan parameter list yang akan ditentukan seperti Optimizer, learning rate dan jumlah epoch training. Pada proses ini keakuratan akan dihitung menggunakan loss function, dan perhitungan waktu training. Proses testing dengan menggunakan Google Colab serta Ubuntu Virtual Machine dilakukan setelah proses training selesai dengan memberikan data testing sehingga dapat dilakukan evaluasi model.

Model CNN yang dibandingkan telah disebutkan pada subbab 3.1. Pemilihan model yang digunakan kemudian dibandingkan tidak muncul dengan sendirinya, pemilihan model yang digunakan untuk dibandingkan berdasarkan studi literatur. Model CNN Inception V3 dipilih karena model tersebut merupakan perbaikan dari Inception sebelumnya yakni Inception V2 serta Inception V1 atau yang dikenal juga sebagai GoogLeNet yang merupakan pemenang kompetisi *ImageNet Large Scale Visual Recognition Challenge (ILSVRC) 2014* dari Google.

Model Inception V3 memiliki parameter sejumlah 28.358.834 parameter. Untuk melihat penjelasan lebih lanjut mengenai parameter yang telah disebutkan dapat dilihat pada Tabel 3.1.

**Tabel 1.** Penjelasan Lanjut Dari Parameter Model Inception V3

Layer	Konfigurasi	Jumlah Parameter
Model (Inception V3)	51200	21802784
Dense	128	6553728
Dropout	128	0
Dense	18	2322
<b>Total Parameter</b>		28358834
<b>Trainable Parameter</b>		6556050
<b>Non-Trainable Parameter</b>		21802784

Data yang akan digunakan dalam penelitian adalah dataset BIRDS 400 –SPECIES IMAGE CLASSIFICATION yang berasal dari kaggle dan sudah direkayasa dengan dikumpulkan, dipisahkan, dan kemudian diberikan label. Dataset ini mencakup 98.388 gambar dari 400 jenis



burung diseluruh dunia. Dalam penelitian ini memisahkan gambar dengan membuat label ke dalam 18 jenis burung seperti Tabel 3.2.

Dalam skenario percobaan ini, digunakan hyper parameter stuning. Hyper parameter stuning yang dilakukan adalah batch\_sizesebesar 32, learning rates ebesar0.0001, ADAM sebagai optimizer serta epoch sebanyak 25.

Evaluasi akan dilakukan dalam duatahap, tahap pertamanya itu proses training yang dilakukan di Google Colab berupa akurasi serta runtime. Untuk tahap kedua yaitu pada proses testing yang dilakukan di Google Colab dan Ubuntu Virtual Machinedengan mengukur Akurasi, Presisi, Recall serta F1-Score.

Dalam tahapan training ada hal yang akan dilakukan yaitu, menyiapkan dataset, proses training itu sendiri dan melakukan evaluasi model yang sudah ditraining s rta membuat hasil analisa yang akan dibahass ecara rinci.

Hasil Akurasi sebuah model biasanya ditentukan setelah model dengan parameter yang telah ditetapkan selesai dipelajari serta tidak ada lagi proses training yang dijalankan. Kemudian sampel tes dimasukkan ke model dan jumlah kesalahayang dibuat model dicatat. Proses training akan memisahkan dataset antara datatraining dan validasi dengan komposisi pemisahan data dapat diubah menggunakan parameter. Misalkan pemisahan 80% untuk data training serta 20% untuk datavalidasi. Proses training yang berjalan akan menghasilkan serangkaian output darisetiap langkah, masing-masing menunjukkan akurasi training, akurasi validasi, dan *crossentropy*.

- Akurasi training menunjukkan berapa persen dari gambar yang digunakan dalam kumpulan training saat ini dilabeli dengan kelas yang benar.
- Akurasi validasi merupakan ketepatan pada kelompok gambar yang dipilih secara acak dari dataset yang berbeda. Perbedaannya adalah keakuratan dari training didasarkan dengan gambar yang telah dipelajari oleh jaringan sehingga jaringan dapat menyesuaikan dengan noise dalam data training.
- Crossentropy merupakan loss function yang memberikan pandangan sekilas tentang seberapa efektif proses training berkembang.

## 4. IMPLEMENTASI

Berdasarkan analisis dan perancangan pada bab tiga, eksperimen dalam penelitian ini terbagi menjadi dua tahap, yakni eksperimen proses training, serta eksperimen proses testing.

Pada prose straining serta testing, penelitian ini menggunakan platform Google Collabs versi gratis dengan spesifikasi yang dapat dilihat pada Tabel 2.

**Tabel 1.** Spesifikasi Perangkat Keras dan Lunak (*Hardware & Software*)

No	<i>Hardware &amp; Software</i>	<b>Spesifikasi</b>
1	<i>Memory</i>	13GB
2	<i>Processor (CPU)</i>	Intel(R) Xeon(R) CPU@2.30GHz
3	<i>Operating System</i>	Linux x86_64
4	Bahasa Pemrograman	Python3.8.16
5	Library Pendukung	Tensor Flow2.9.2

Berikut merupakan hal yang dibutuhkan dalam membuat sistem cerdas untuk diagnosa penyakit kanker mulut rahim.

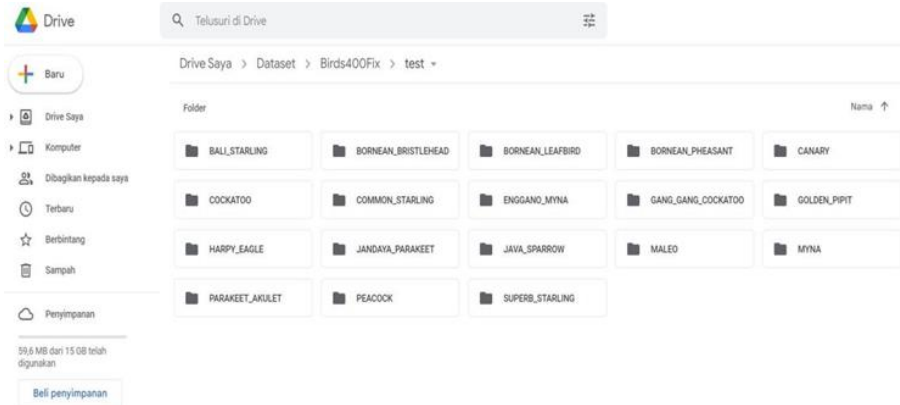
Proses training dilakukan dengan melakukan eksperimen menggunakan bahasa pemrograman python yang dibuat dalam platform Google Collabs yang mirip dengan platform jupyter notebook.

Eksperimen diawali dengan pengelompokan dan dijalankannya skrip pemrograman diplatform Google Collabs yang bertujuan untuk mempermudah melakukan analisa tahap-tahap dalam proses training dengan menggunakan kernel yang dapat dijalankan satu per satu maupun secara bersamaan. Skrip lengkap akan disertakan dalam lampiran. Dataset input dipisahkan dengan menggunakan sub direktori antara training dan validasi.

Evaluasi proses training dilakukan dengan menganalisa tingkat keakurasian dan loss cross entropy untuk menghasilkan akurasi yang lebih baik dan juga memastikan apakah model yang digunakan sudah ideal, yaitu tidak mengalami under fitting maupun overfitting. Pada proses ini juga

dievaluasi waktuyangdibutuhkan dalam proses training per satu epoch dan total waktu keseluruhan yang dibutuhkan dalam menjalankan proses training.

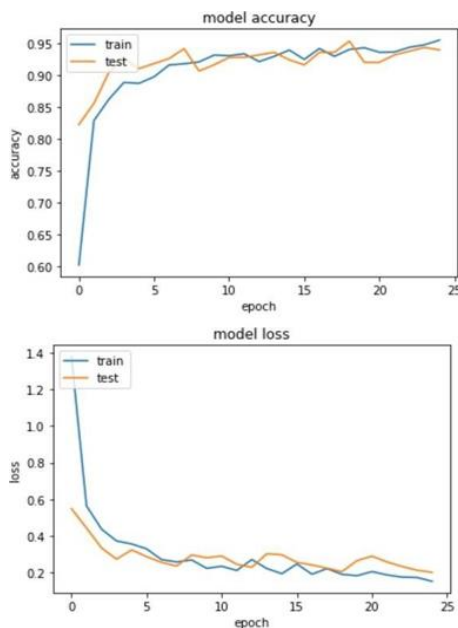
Proses testing dilakukan pada saat proses training telah selesai dilakukan untuk mengevaluasi model. Proses testing menggunakan data yang telah disediakan pada folder test yang dapat dilihat pada Gambar 2.



**Gambar 2.** Folder Test

Pada Gambar 2 dapat dilihat pengujian dilakukan dengan menggunakan folder test dari dataset BIRDS400- SPECIES IMAGE CLASSIFICATION. Folder test tersebut awalnya berisi gambar burung yang terdiri dari 400 spesies yang berbeda. Dikarenakan pada batasan masalah bab satu sudah dijelaskan data yang digunakan terbatas untuk 18 jenis burung yang familiar di kawasan Indonesia maka dari folder test saat ini sudah berkurang menjadi hanya 18 spesies burung yang terlihat pada Gambar 2. Hasil perbandingan dirangkum dalam tabel-tabel perbandingan, dalam subbab hasil implementasi.

Eksperimen dilakukan dengan menjalankan skrip dalam Google Collabs. Model Inception V3 yang digunakan dalam penelitian ini adalah model Inception V3 dengan hyper parameter  $batch\_size=32$ ,  $learningrate=0.0001$  serta ADAM sebagai optimizer. Dari hasil training terhadap model InceptionV3 menunjukkan hasil akhir akurasi sebesar 93.36% dan hasil akhir loss sebesar 0.23 dengan waktu training 36 Menit 46 Detik. Performa model InceptionV3 diilustrasikan secara grafis pada Gambar 3 untuk performa akurasi dan performa crossentropy.



**Gambar 3.** Performa Akurasi dan Performa Crossentropy





Gambar 5. menunjukkan ketepatan klasifikasi yang baik pada semua kelas. Model InceptionV3 yang telah dilatih tidak menunjukkan adanya kesalahan prediksi dalam mengklasifikasi. Setelah pemetaan Confusion Matrix selesai dilakukan maka langkah selanjutnya adalah menghitung Akurasi, Presisi serta Recall secara manual yang akan dirangkum pada Tabel 2.

**Tabel 2.** Menghitung Akurasi, Presisi Serta Recall Secara Manual

No	Class	InceptionV3		
		Precision	Recall	F1
1	CANARY	1.0	1.0	1.0
2	BALISTARLING	1.0	1.0	1.0
3	COCKATOO	1.0	1.0	1.0
4	COMMONSTARLING	1.0	1.0	1.0
5	GANG GANGCOCK ATOO	1.0	1.0	1.0
6	GOLDENPIPIT	1.0	1.0	1.0
7	HARPYEAGLE	1.0	1.0	1.0
8	JANDAYAPARKEET	1.0	1.0	1.0
9	JAVA SPARROW	1.0	1.0	1.0
10	MALEO	1.0	1.0	1.0
11	MYNA	1.0	1.0	1.0
12	PARKEETAKULET	1.0	1.0	1.0
13	PEACOCK	1.0	1.0	1.0
14	SUPERBSTARLING	1.0	1.0	1.0
15	CANARY	1.0	1.0	1.0
16	BALISTARLING	1.0	1.0	1.0
17	COCKATOO	1.0	1.0	1.0
18	COMMONSTARLING	1.0	1.0	1.0

Tabel 2 menunjukkan model InceptionV3 memiliki performa yang sangat baik dalam menangani datast BIRDS400- SPECIES IMAGE CLASSIFICATION. Sehingga dapat disimpulkan bahwa model InceptionV3 merupakan model yang sudah cukup baik untuk menangani dataset tersebut.

## 5. KESIMPULAN

Penelitian ini telah mengevaluasi model CNN bernama InceptionV3. Dalam proses training disimpulkan bahwa model InceptionV3 memakan waktu selama 36 Menit 46 Detik. Untuk file output yang dihasilkan dari proses training yang dijalankan, model InceptionV3 menghasilkan file output Sebesar 5.3 MB.

Dari hasil yang didapatkan disimpulkan bahwa dengan penerapan metode *Convolutional Neural Network* secara efektif dapat mengidentifikasi jenis burung dengan mendapatkan nilai akurasi yang sangat baik yakni sebesar 100%. Nilai rata-rata performa (Precision, Recall, F1-Score) dari model InceptionV3 juga mendapatkan hasil yang sangat baik. Nilai rata-rata Precision memiliki sebesar 1.0, Recal lmemiliki sebesar 1.0, dan F1-Score memiliki sebesar 1.0. Selainitu dapat disimpulkan juga untuk melakukan klasifikasi 18 jenis burung dari dataset BIRDS400-SPECIESIMAGECLASSIFICATION dengan menggunakan platform Google Collabs versi gratis sudah cukup untuk menagani dataset tersebut.

## REFERENCES

- Ayumi, V., Nurhaida, I., & Noprisson, H. (2022). Implementation of Convolutional Neural Networks for Batik Image Dataset. (IJCSAM) International Journal of Computing Science and Applied Mathematics, 8(1), 5–8.
- Boom, B. J., Huang, P. X., He, J., & Fisher, R. B. (2012). Supporting ground-truth annotation of image datasets using clustering. Proceedings of the 21st International Conference on Pattern Recognition (ICPR2012), 1542–1545.
- Charli, F., Syaputra, H., Akbar, M., Sauda, S., & Panjaitan, F. (2020). Implementasi Metode Faster Region Convolutional Neural Network (Faster R-CNN) Untuk Pengenalan Jenis Burung Lovebird. Journal of Information Technology Ampera, 1(3), 185–197.
- Chollet, F. (2021). Deep learning with Python. Simon and Schuster. Christianto, E., Sambul, A. M., & Kambey, F. D. (2021). Implementation of Convolutional Neural Network on Images for Starlings Classification.
- Gerry. (2022). BIRDS 400 - SPECIES IMAGE CLASSIFICATION | Kaggle. <https://www.kaggle.com/datasets/gpiosenka/100-bird-species>
- Harjoseputro, Y., Yuda, I., & Danukusumo, K. P. (2020). MobileNets: Efficient convolutional neural network for identification of protected birds. IJASEIT (International Journal on Advanced Science, Engineering and Information Technology), 10(6), 2290–2296.
- Hastomo, W. (2021). Diagnosa COVID-19 Chest X-Ray Dengan Convolution Neural Network Arsitektur Resnet-152. KERNEL: Jurnal Riset Inovasi Bidang Informatika Dan Pendidikan Informatika, 2(1), 26–33.
- Herman, H., Cenggoro, T. W., Susanto, A., & Pardamean, B. (2021). Deep Learning for Oil Palm Fruit Ripeness Classification with DenseNet. 2021 International Conference on Information Management and Technology (ICIMTech), 1, 116–119.
- Heryadi, Y., & Irwansyah, E. (2020). Deep Learning: Aplikasinya di Bidang Geospasial. AWI Technology Press.
- Hesthaven, J. S., & Ubbiali, S. (2018). Non-intrusive reduced order modeling of nonlinear problems using neural networks. Journal of Computational Physics, 363, 55–78.
- Hosny, K. M., Kassem, M. A., & Foad, M. M. (2018). Skin cancer classification using deep learning and transfer learning. 2018 9th Cairo International Biomedical Engineering Conference (CIBEC), 90–93.
- Jayawardana, J. K. R., & Bandaranayake, T. S. (2021). ANALYSIS OF OPTIMIZING NEURAL NETWORKS AND ARTIFICIAL INTELLIGENT

## MODELS FOR GUIDANCE, CONTROL, AND NAVIGATION SYSTEMS.

- International Research Journal of Modernization in Engineering, Technology and Science, 3, 743–759.
- Joly, A., Goëau, H., Glotin, H., Spampinato, C., Bonnet, P., Vellinga, W.-P., Planqué, R., Rauber, A., Palazzo, S., & Fisher, B. (2015). LifeCLEF 2015: multimedia life species identification challenges. International Conference of the Cross-Language Evaluation Forum for European Languages, 462–483.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. Advances in Neural Information Processing Systems, 25, 04015009. [https://doi.org/10.1061/\(ASCE\)GT.1943-5606.0001284](https://doi.org/10.1061/(ASCE)GT.1943-5606.0001284)
- Lambers, K. (2019). Learning to look at LiDAR: The use of R-CNN in the automated detection of archaeological objects in LiDAR data from the Netherlands. Journal of Computer Applications in Archaeology, 2(1), 31–40.
- Lammie, C., Olsen, A., Carrick, T., & Azghadi, M. R. (2019). Low-Power and High-Speed Deep FPGA Inference Engines for Weed Classification at the Edge. IEEE Access, 7, 51171–51184.
- Lauw, K. O., Santoso, L. W., & Intan, R. (2020). Identifikasi Jenis Anjing Berdasarkan Gambar Menggunakan Convolutional Neural Network Berbasis Android. Jurnal Infra, 8(2), 37–43.
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521. <https://doi.org/10.1038/nature14539>

- Lee, C. Y., Gallagher, P. W., & Tu, Z. (2016). Generalizing pooling functions in convolutional neural networks: Mixed, gated, and tree. *Proceedings of the 19th International Conference on Artificial Intelligence and Statistics, AISTATS 2016*, 464–472.
- Manohar, N., Kumar, Y. H., Rani, R., & Kumar, G. H. (2019). Convolutional neural network with SVM for classification of animal images. In *Emerging Research in Electronics, Computer Science and Technology* (pp. 527–537). Springer.
- Meena, S. D., & Agilandeswari, L. (2019). An efficient framework for animal breeds classification using semi-supervised learning and multi-part convolutional neural network (MP-CNN). *IEEE Access*, 7, 151783–151802.
- Minar, M. R., & Naher, J. (2018). Recent Advances in Deep Learning: An Overview. *ArXiv Preprint ArXiv:1807.08169*, 2006, 1–31. <https://doi.org/10.13140/RG.2.2.24831.10403>
- Mostafa, S., & Wu, F.-X. (2021). Diagnosis of autism spectrum disorder with convolutional autoencoder and structural MRI images. In *Neural Engineering Techniques for Autism Spectrum Disorder* (pp. 23–38). Elsevier.
- Özgül, A., & Nar, F. (2020). Effect of dropout layer on classical regression problems. *2020 28th Signal Processing and Communications Applications Conference (SIU)*, 1–4.
- Pardamean, B., Cenggoro, T. W., Rahutomo, R., Budiarto, A., & Karuppiah, E. K. (2018). Transfer Learning from Chest X-Ray Pre-trained Convolutional Neural Network for Learning Mammogram Data. *Procedia Computer Science*, 135, 400–407. <https://doi.org/10.1016/j.procs.2018.08.190>
- Perdananto, A. (2019). Penerapan deep learning pada Aplikasi prediksi penyakit Pneumonia berbasis Convolutional Neural networks. *Journal of ICT (Informatics and Communication Technology)*, 1(2), 1–10.
- Priyono, F., & Indrajit, R. E. (2017). Perbandingan Teknik Klasifikasi Untuk Prediksi Status Kontrak Kerja Karyawan. *Prosiding Semnastek*.
- Putra, I. (2016). Klasifikasi citra menggunakan convolutional neural network (CNN) pada caltech 101. *Institut Teknologi Sepuluh Nopember*.
- Putro, E. C., Awangga, R. M., & Andarsyah, R. (2020). Tutorial Object Detection People with Faster region-Based Convolutional Neural Network (Faster R- CNN) (Vol. 1). Kreatif.
- Rachmatullah, M. N., & Supriana, I. (2018). Low resolution image fish classification using convolutional neural network. *2018 5th International Conference on Advanced Informatics: Concept Theory and Applications (ICAICTA)*, 78–83.
- Rahman, A. Y. (2021). Klasifikasi Citra Burung Lovebird Menggunakan Decision Tree dengan Empat Jenis Evaluasi. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(4), 688–696.
- Rahman, A. Y. (2022). Klasifikasi Citra Burung Jalak Menggunakan Artificial Neural Network dan Random Forest. *JEPIN (Jurnal Edukasi Dan Penelitian Informatika)*, 8(2), 255–268.
- Rahutomo, R., Mahesworo, B., Wawan Cenggoro, T., Budiarto, A., Suparyanto, T., Bosco Surya Atmaja, D., Samoedro, B., & Pardamean, B. (2020). AI- Based Ripeness Grading for Oil Palm Fresh Fruit Bunch in Smart Crane Grabber. *E&ES*, 426(1), 12147.
- Raj, S., Garyali, S., Kumar, S., & Shidnal, S. (2020). Image based bird species identification using convolutional neural network. *International Journal of Engineering Research & Technology (IJERT)*, 9(6), 346.
- Rathi, D., Jain, S., & Indu, S. (2017). Underwater fish species classification using convolutional neural network and deep learning. *2017 Ninth International Conference on Advances in Pattern Recognition (ICAPR)*, 1–6.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). *Mobilenetv2: Inverted residuals and linear bottlenecks*. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 4510–4520.
- Santos, C. F. G. dos, & Papa, J. P. (2022). Avoiding overfitting: A survey on regularization methods for convolutional neural networks. *ACM Computing Surveys (CSUR)*.
- Sari, D. F., & Swanjaya, D. (2020). Implementasi Convolutional Neural Network Untuk Identifikasi Penyakit Daun Gambas. *Prosiding SEMNAS INOTEK (Seminar Nasional Inovasi Teknologi)*, 4(3), 137–142.

- Siegel, R. L., Miller, K. D., Fuchs, H. E., & Jemal, A. (2022). Cancer statistics, 2022. CA: A Cancer Journal for Clinicians, 72(1), 7–33. <https://doi.org/10.3322/caac.21708>
- Sikumbang, W. N. (2021). Klasifikasi Burung Cendrawasih Menggunakan Recognition Cnn Keras. ILKOM Jurnal Ilmiah, 13(3).
- Singh, S. A., Meitei, T. G., & Majumder, S. (2020). Short PCG classification based on deep learning. In Deep Learning Techniques for Biomedical and Health Informatics (pp. 141–164). Elsevier.
- Syafrudin, S., Nugraha, R. A., Handayani, K., Linawati, S., & Gata, W. (2021). Prediksi Status Pinjaman Bank dengan Deep Learning Neural Network. Jurnal Teknik Komputer, 7(2), 130–135.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 07-12-June, 1–9. <https://doi.org/10.1109/CVPR.2015.7298594>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the inception architecture for computer vision. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2818–2826.
- Tan, M., Chen, B., Pang, R., Vasudevan, V., Sandler, M., Howard, A., & Le, Q. V. (2019). Mnasnet: Platform-aware neural architecture search for mobile. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2820–2828.
- Tan, M., & Le, Q. (2019). Efficientnet: Rethinking model scaling for convolutional neural networks. International Conference on Machine Learning, 6105–6114.
- Valentino, F., Cenggoro, T. W., & Pardamean, B. (2021). A Design of Deep Learning Experimentation for Fruit Freshness Detection. IOP Conference Series: Earth and Environmental Science, 794(1), 12110.
- Wulandari, I., Yasin, H., & Widiharih, T. (2020). Klasifikasi citra digital bumbu dan rempah dengan algoritma convolutional neural network (cnn). Jurnal Gaussian, 9(3), 273–282.
- Xia, X., Xu, C., & Nan, B. (2017). Inception-v3 for flower classification. 2017 2nd International Conference on Image, Vision and Computing (ICIVC), 783–787.
- Yanuki, B., & Rahman, A. Y. (2021). Image Classification of Canaries Using Artificial Neural Network. 2021 5th International Conference on Informatics and Computational Sciences (ICICoS), 12–17.
- Zoph, B., Vasudevan, V., Shlens, J., & Le, Q. V. (2018). Learning transferable architectures for scalable image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 8697–8710.
- Zufar, M. (2016). Convolutional neural networks untuk pengenalan wajah secara real-time. Institut Technology Sepuluh Nopember.