

**TESIS**

**DIAGNOSA PENYAKIT AYAM MELALUI CITRA GAMBAR FESES  
BERDASARKAN CNN**



Disusun oleh:

**Nama : Muhammad Sallmy Ahsan**  
**NIM : 21.51.2104**  
**Konsentrasi : Digital Transformation Intelligence**

**PROGRAM STUDI S2 TEKNIK INFORMATIKA**  
**PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA**  
**YOGYAKARTA**

**2023**

**TESIS**

**DIAGNOSA PENYAKIT AYAM MELALUI CITRA GAMBAR FESES  
BERDASARKAN CNN**

**DIAGNOSIS OF CHICKEN DISEASE THROUGH  
THE IMAGES OF FECES BASED ON CNN**

Diajukan untuk memenuhi salah satu syarat memperoleh derajat Magister



Disusun oleh:

Nama : Muhammad Sallmy Ahsan  
NIM : 21.51.2104  
Konsentrasi : Digital Transformation Intelligence

**PROGRAM STUDI S2 TEKNIK INFORMATIKA  
PROGRAM PASCASARJANA UNIVERSITAS AMIKOM YOGYAKARTA  
YOGYAKARTA**

**2023**

**HALAMAN PENGESAHAN**

**DIAGNOSA PENYAKIT AYAM MELALUI CITRA GAMBAR FESES  
BERDASARKAN CNN**

**DIAGNOSIS OF CHICKEN DISEASE THROUGH  
THE IMAGES OF FECES BASED ON CNN**

Dipersiapkan dan Disusun oleh

**Muhammad Salimy Ahsan**

**21.51.2104**

Telah Diujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari Jumat, 1 Desember 2023

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer

Yogyakarta, 1 Desember 2023

**Rektor**

**Prof. Dr. M. Suvanto, M.M.**  
**NIK. 190302001**

## HALAMAN PERSETUJUAN

### DIAGNOSA PENYAKIT AYAM MELALUI CITRA GAMBAR FESES BERDASARKAN CNN

#### DIAGNOSIS OF CHICKEN DISEASE THROUGH THE IMAGES OF FECES BASED ON CNN

Dipersiapkan dan Disusun oleh

**Muhammad Salimy Ahsan**

**21.51.2104**

Telah Dujikan dan Dipertahankan dalam Sidang Ujian Tesis  
Program Studi S2 Teknik Informatika  
Program Pascasarjana Universitas AMIKOM Yogyakarta  
pada hari Jumat, 1 Desember 2023

**Pembimbing Utama**

**Prof. Dr. Kusriani, M.Kom**  
NIK. 19030210

**Pembimbing Pendamping**

**Dhani Ariatmanto, M.Kom., Ph.D**  
NIK. 190302197

**Anggota Tim Penguji**

**Hanif Al Fatta, M.Kom., Ph.D.**  
NIK. 190302096

**Alva Hendi M, S.T., MEng., Ph.D.**  
NIK. 190302493

**Prof. Dr. Kusriani, M.Kom**  
NIK. 19030210

Tesis ini telah diterima sebagai salah satu persyaratan  
untuk memperoleh gelar Magister Komputer

Yogyakarta, 1 Desember 2023  
**Direktur Program Pascasarjana**

**Prof. Dr. Kusriani, M.Kom**  
NIK. 190302106

## HALAMAN PERNYATAAN KEASLIAN TESIS

Yang bertandatangan di bawah ini,

Nama mahasiswa : **Muhammad Salimy Ahsan**  
NIM : **21.51.2104**  
Konsentrasi : **Digital Transformation Intelligence**

Menyatakan bahwa Tesis dengan judul berikut:  
**DIAGNOSA PENYAKIT AYAM MELALUI CITRA GAMBAR FESES  
BERDASARKAN CNN**

Dosen Pembimbing Utama : Prof. Dr. Kusriani, M.Kom  
Dosen Pembimbing Pendamping : Dhani Ariatmanto, M.Kom., Ph.D

1. Karya tulis ini adalah benar-benar **ASLI** dan **BELUM PERNAH** diajukan untuk mendapatkan gelar akademik, baik di Universitas AMIKOM Yogyakarta maupun di Perguruan Tinggi lainnya
2. Karya tulis ini merupakan gagasan, rumusan dan penelitian **SAYA** sendiri, tanpa bantuan pihak lain kecuali arahan dari Tim Dosen Pembimbing
3. Dalam karya tulis ini tidak terdapat karya atau pendapat orang lain, kecuali secara tertulis dengan jelas dicantumkan sebagai acuan dalam naskah dengan disebutkan nama pengarang dan disebutkan dalam Daftar Pustaka pada karya tulis ini
4. Perangkat lunak yang digunakan dalam penelitian ini sepenuhnya menjadi tanggung jawab **SAYA**, bukan tanggung jawab Universitas AMIKOM Yogyakarta
5. Pernyataan ini **SAYA** buat dengan sesungguhnya, apabila di kemudian hari terdapat penyimpangan dan ketidakbenaran dalam pernyataan ini, maka **SAYA** bersedia menerima **SANKSI AKADEMIK** dengan pencabutan gelar yang sudah diperoleh, serta sanksi lainnya sesuai dengan norma yang berlaku di Perguruan Tinggi

Yogyakarta, 1 Desember 2023  
Yang Menyatakan,



Muhammad Salimy Ahsan

## HALAMAN PERSEMBAHAN


Pertama saya mengucapkan puja dan puji Syukur kepada Allah SWT atas berkat rahmat dan hidayah-Nya, sehingga penulis diberi kesempatan untuk menyelesaikan laporan tesis ini. Dengan begitu penulis mempersembahkan laporan tesis ini kepada :

1. Kedua orang tua dan adik-adik saya, yang senantiasa memberikan dukungan, bantuan, semangat, motivasi, dan doa, semoga selalu berada dalam lindungan Allah SWT.
2. Ibu Prof. Dr. Kusriani, M.Kom dan bapak Dhani Ariatmanto, M.Kom., Ph.D yang telah memberikan bantuan serta bimbingan selama pelaksanaan penelitian, semoga mendapatkan keberkahan dan dilancarkan segala urusannya.
3. Keluarga besar yang selalu memberikan dukungan dan doa selama ini.

Terimakasih atas semua semangat serta dukungan dari berbagai pihak. Semoga tesis ini dapat memberikan manfaat serta berguna dimasa yang akan datang.

## HALAMAN MOTTO

“Terlalu keras dan menutup diri terhadap orang lain akan mendatangkan musuh, dan terlalu terbuka juga akan mendatangkan kawan yang tidak baik. Maka posisikan dirimu di antara keduanya” - Imam Syafi’i





## KATA PENGANTAR

Puji Syukur penulis panjatkan atas kehadiran Allah SWT karena atas berkat Rahmat dan hidayah-Nya penulis masih diberikan kesempatan, kemudahan serta Kesehatan untuk menyelesaikan laporan tesis yang berjudul "Diagnosa Penyakit Ayam Melalui Citra Gambar Feses Berdasarkan CNN" dengan baik. Tesis ini disusun untuk memenuhi salah satu syarat untuk kelulusan dalam memperoleh gelar Magister Komputer pada program studi Magister Teknik Informatika Universitas Amikom Yogyakarta.

Dalam penyusunan dan penulisan laporan tesis ini tidak lepas dari bantuan dan bimbingan serta dukungan dari berbagai pihak. Oleh karena itu pada kesempatan ini penulis mengucapkan rasa Syukur dan terima kasih kepada :

1. Orang tua yang senantiasa memberikan doa, semangat, motivasi, serta dukungan kepada penulis agar senantiasa semangat dalam menuntut ilmu.
2. Ibu Prof. Dr. Kusriani, M.Kom selaku pembimbing utama yang telah memberikan bantuan dan bimbingan selama pelaksanaan penelitian.
3. Bapak Dhani Ariatmanto, M.Kom., Ph.D selaku pembimbing pendamping yang telah membantu dan memberikan bimbingan dalam penulisan tesis ini.
4. Keluarga besar, teman-teman serta semua pihak yang telah membantu dalam proses penelitian tesis ini, baik secara langsung maupun tidak langsung yang tidak bisa penulis sebutkan satu persatu.



Penulis berharap penelitian ini dapat membantu serta bermanfaat bagi berbagai pihak dimasa mendatang. Kekurangan dan ketidaksempurnaan masih dapat ditemukan, maka dari itu kritik dan saran sangat diharapkan penulis agar dapat menjadi lebih baik lagi pada kemudian hari.

Akhir kata penulis memohon maaf apabila terdapat salah kata dan salah dalam penyusunan laporan, dan penulis mengucapkan Terima kasih.

Yogyakarta, 10 November 2023

Penulis




## DAFTAR ISI

HALAMAN JUDUL.....	ii
HALAMAN PENGESAHAN.....	iii
HALAMAN PERSETUJUAN.....	iv
HALAMAN PERNYATAAN KEASLIAN TESIS.....	v
HALAMAN PERSEMBAHAN.....	vi
HALAMAN MOTTO.....	vii
KATA PENGANTAR.....	viii
DAFTAR ISI.....	x
DAFTAR TABEL.....	xiii
DAFTAR GAMBAR.....	xiv
INTISARI.....	xvi
<i>ABSTRACT</i> .....	xvii
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah.....	1
1.2. Rumusan Masalah.....	6
1.3. Batasan Masalah.....	6
1.4. Tujuan Penelitian.....	7
1.5. Manfaat Penelitian.....	7
BAB II TINJAUAN PUSTAKA.....	8
2.1. Tinjauan Pustaka.....	8
2.2. Keaslian Penelitian.....	10

2.3. Landasan Teori.....	15
2.3.1. Penyakit Ayam.....	15
2.3.2. Deep Learning.....	16
2.3.3. Convolutional Neural Networks .....	17
2.3.4. Transfer Learning.....	18
2.3.5. Resnet-50 .....	19
2.3.6. Inception-v3.....	20
<b>BAB III METODE PENELITIAN.....</b>	<b>22</b>
3.1. Jenis, Sifat, dan Pendekatan Penelitian.....	22
3.2. Metode Pengumpulan Data.....	22
3.3. Metode Analisis Data.....	23
3.4. Alur Penelitian.....	24
<b>BAB IV HASIL PENELITIAN DAN PEMBAHASAN.....</b>	<b>30</b>
4.1. Pengumpulan Data.....	30
4.2. Analisis Data.....	31
4.2.1. Persebaran Data.....	31
4.2.2. Pengolahan dataset.....	33
4.2.3. Preprocessing Data.....	35
4.3. Skenario Percobaan.....	38
4.4. Pembahasan Hasil Penelitian.....	44
4.4.1. Hasil Pelatihan Model.....	44
4.4.1.1. Pelatihan Skenario 1 .....	44
4.4.1.2. Pelatihan Skenario 2 .....	47

4.4.2. Hasil Pengujian Model.....	53
4.4.3. Perbandingan jumlah dataset .....	54
4.4.4. Perbandingan augmentasi data.....	57
4.4.5. Hasil Analisis Penelitian Terkait .....	62
<b>BAB V PENUTUP.....</b>	<b>66</b>
5.1. Kesimpulan.....	66
5.2. Saran.....	67
<b>DAFTAR PUSTAKA.....</b>	<b>68</b>



## DAFTAR TABEL

Tabel 2.1. Matriks literatur review dan posisi penelitian DIAGNOSA PENYAKIT AYAM MELALUI CITRA GAMBAR FESES BERDASARKAN CNN .	10
Tabel 4. 1 Dataset Penyakit Ayam.....	30
Tabel 4. 2 Skenario percobaan 2.....	40
Tabel 4.3 Hasil Pengujian Skenario 1.....	53
Tabel 4. 4 Hasil pengujian Skenario 2.....	53
Tabel 4. 5 Augmentasi skenario.....	58

## DAFTAR GAMBAR

Gambar 2. 1 Feses ayam normal dan tidak normal.....	16
Gambar 2. 2 Cara kerja Deep Learning .....	17
Gambar 2. 3 Struktur CNN .....	18
Gambar 2. 4 Arsitektur Resnet50.....	20
Gambar 2. 5 <i>Residual learning: a building block</i> .....	20
Gambar 2. 6 Arsitektur inception-v3 .....	21
Gambar 4. 1 Persebaran Dataset .....	32
Gambar 4. 2 Persentase persebaran dataset.....	33
Gambar 4. 3 Kode penyeimbangan data .....	34
Gambar 4. 4 Data setelah oversampling .....	35
Gambar 4. 5 Gambar Awal .....	37
Gambar 4. 6 Augmentasi Data.....	37
Gambar 4. 7 Pembagian Dataset.....	38
Gambar 4. 8 Alur Percobaan.....	40
Gambar 4. 9 Resnet50 Blok .....	41
Gambar 4. 10 InceptionV3 Blok.....	42
Gambar 4.11 Grafik accuracy dan loss InceptionV3 pada data asli .....	45
Gambar 4.12 Grafik accuracy dan loss Resnet50 pada data asli.....	46
Gambar 4.13 Grafik accuracy dan loss InceptionV3 pada data yang telah diseimbangkan.....	46

Gambar 4. 14 Grafik accuracy dan loss Resnet50 pada data yang telah diseimbangkan .....	47
Gambar 4. 15 Grafik skenario 2 InceptionV3 augmentasi pertama.....	48
Gambar 4.16 Grafik skenario 2 Resnet50 augmentasi pertama.....	48
Gambar 4.17 Grafik skenario 2 InceptionV3 augmentasi kedua .....	49
Gambar 4.18 Grafik skenario 2 Resnet50 augmentasi kedua .....	50
Gambar 4.19 Grafik skenario 2 InceptionV3 augmentasi ketiga.....	50
Gambar 4.20 Grafik skenario 2 Resnet50 augmentasi ketiga.....	51
Gambar 4.21 Grafik skenario 2 InceptionV3 augmentasi keempat.....	52
Gambar 4. 22 Grafik skenario 2 Resnet50 augmentasi keempat .....	52
Gambar 4. 23 Perbandingan akurasi pelatihan data asli dengan data seimbang...	54
Gambar 4. 24 Grafik perbandingan pengujian skenario 1 .....	56
Gambar 4. 25 Perbandigan akurasi pelatihan.....	59
Gambar 4. 26 perbandingan hasil pengujian.....	61
Gambar 4. 27 Perbandingan penelitian sebelumnya .....	63
Gambar 4. 28 Perbandingan penelitian sebelumnya .....	64



## INTISARI

Peternakan ayam memberikan kontribusi paling banyak terhadap kebutuhan sumber protein hewani, selain mudah ditemui daging dan telur ayam telah menjadi makanan pokok di Indonesia. Banyak dari kalangan masyarakat yang telah mencoba untuk memelihara ayam baik itu dengan skala yang kecil maupun yang besar. Adapun beberapa permasalahan yang sering terjadi dalam peternakan ayam adalah penyakit dan hal tersebut dapat memberikan dampak yang signifikan bagi peternakan. Dengan ketersediaan data yang cukup besar memungkinkan untuk dilakukannya proses pemantauan penyakit ayam dengan menggunakan teknologi deep learning untuk klasifikasi penyakit ayam. Proses klasifikasi akan dilakukan terhadap empat kelas, yaitu Healthy, Salmonella, Coccidiosis, and Newcastle disease. Metode dari hasil analisis klasifikasi dilakukan dengan menggunakan perhitungan akurasi, *precision*, *recall* dan *F1-Score*.

Proses klasifikasi dilakukan dengan menggunakan model algoritma InceptionV3 dan Resnet50. Sebelum proses klasifikasi dilakukan, proses penyeimbangan data, augmentasi data dan preprocessing data dilakukan untuk menyiapkan data sehingga dapat digunakan dalam proses klasifikasi. Dengan melakukan proses penyeimbangan data, dapat meningkatkan tingkat performa dari setiap algoritma baik itu dalam proses pelatihan maupun pengujian.

Model algoritma dari CNN terbukti dapat melakukan proses klasifikasi penyakit ayam dengan baik. Hal tersebut dibuktikan dengan tingkat performa dari model Resnet50 dimana menghasilkan nilai akurasi sebesar 96,38%, *precision* 96,40%, *recall* 96,36% dan *F1-Score* 96,38%, kemudian pada model InceptionV3 menghasilkan performa akurasi sebesar 95,33%, *precision* 95,36%, *recall* 95,32% dan *F1-Score* 95,33%.

Kata kunci: Klasifikasi Penyakit Ayam, *Convolutional Neural Network*, *Deep Learning*, *Transfer Learning*

## **ABSTRACT**

*Chicken farming contributes the most to the need for animal protein sources, apart from being easy to find, chicken meat and eggs have become a staple food in Indonesia. Many people have tried to raise chickens, both on a small and large scale. Some of the problems that often occur in chicken farming are disease and this can have a significant impact on livestock. With the availability of large enough data, it is possible to carry out the process of monitoring chicken diseases using deep learning technology for classifying chicken diseases. The classification process will be carried out for four classes, namely Healthy, Salmonella, Coccidiosis, and Newcastle disease. The method for classifying analysis results is carried out using accuracy, precision, recall and F1-Score calculations.*

*The classification process is carried out using the InceptionV3 and Resnet50 algorithm models. Before the classification process is carried out, the process of data balancing, data augmentation and data preprocessing is carried out to prepare the data so that it can be used in the classification process. By carrying out a data balancing process, you can increase the performance level of each algorithm, both in the training and testing processes.*

*The algorithm model from CNN has been proven to be able to carry out the process of classifying chicken diseases well. This is proven by the performance level of the Resnet50 model which produces an accuracy value of 96.38%, precision 96.40%, recall 96.36% and F1-Score 96.38%, then the InceptionV3 model produces an accuracy performance of 95.33 %, precision 95.36%, recall 95.32% and F1-Score 95.33%.*

**Keyword:** *Chicken Disease Classification, Convolutional Neural Network, Deep Learning, Transfer Learning*

# BAB I

## PENDAHULUAN

### 1.1. Latar Belakang Masalah

Ayam merupakan salah satu sumber protein hewani yang paling banyak diminati dan paling mudah untuk ditemui di Indonesia. Sebagai sumber protein hewani ayam juga menjadi salah satu penyumbang utama dalam pemenuhan kebutuhan pangan terbesar bagi masyarakat. Selain dari daging yang dikonsumsi, telur ayam juga banyak diminati semua kalangan masyarakat dalam memenuhi kebutuhan protein hewani. Daging dan telur ayam paling banyak diminati dan dikonsumsi karena kaya akan protein, rendah lemak dan rendah kolesterol dibandingkan dengan jenis ayam lainnya (Mohammed Ahmed & Ahmed Abdulaziz, 2021).

Pada penelitian (Blake et al., 2020) menyebutkan bahwa ayam merupakan suatu hal yang sangat penting secara ekonomi, karena pada tahun 2018 terdapat lebih dari 68 miliar budidaya ayam dan terhitung sebagai sepertiga dari produksi daging global, dengan tambahan 1,38 triliun telur yang tersedia untuk konsumsi oleh manusia. Setiap tahunnya penduduk Indonesia mengalami peningkatan yang cukup signifikan, sehingga hal ini berdampak kesadaran masyarakat akan pola hidup bergizi yang seimbang dan berdampak pada peningkatan konsumsi pangan nasional termasuk produk peternakan daging dan telur ayam.

Dengan meningkatnya kebutuhan pangan baik daging ayam maupun telur ayam, mendorong banyaknya pengusaha peternakan ayam baik itu oleh perusahaan

maupun mandiri. Peternakan ayam sendiri merupakan salah satu sektor yang mudah untuk dikembangkan dan memiliki prospek pasar yang besar di Indonesia (Setiadi et al., 2020). Dalam memperoleh kualitas hasil ayam yang baik dan keuntungan yang cukup besar seperti daging ayam maupun telur ayam, peternak harus mampu memelihara dan merawat ayam agar tidak mudah terserang penyakit.

Meskipun banyak masyarakat yang telah mendirikan sebuah usaha peternakan ayam akan tetapi masih banyak peternak yang memiliki pengetahuan yang sedikit terhadap gejala maupun penyakit yang sering terjadi pada ayam (Hadi Nasyuha, 2020). Dalam penelitian (Ismail et al., 2019) salah satu permasalahan yang sering muncul dalam industri peternakan ayam adalah penyebaran penyakit yang memiliki potensi untuk menular kepada ayam yang lain. Tidak hanya itu banyaknya permasalahan dapat menjadi hambatan dalam penanggulangan penyakit, sehingga sulit mencapai hasil diinginkan.

Menurut (Santosa et al., 2020) menyebutkan bahwa terdapat permasalahan lain yang menjadi tantangan dan sering terjadi pada peternakan ayam adalah mengenai pengolahan dan pemeliharaan lingkungan kandang yang masih belum maksimal, sehingga dapat menghadirkan sebuah penyakit bagi ayam itu sendiri. Kurangnya pengetahuan terhadap tata cara penanganan penyakit pada ayam dan yang tidak sesuai dengan prosedur, dapat mengakibatkan penyebaran penyakit ayam semakin meluas (Panangian Sinaga et al., 2022). Dalam penelitian yang dilakukan oleh (Isnawati et al., 2019) mengatakan bahwa terdapat sebuah penyakit ayam yang sifatnya menular dari hewan ke manusia dan dapat menyebabkan kematian pada manusia.



Dari hasil observasi peneliti masih terdapat banyak masyarakat yang melakukan proses pemeliharaan dan perawatan peternakan ayam secara tradisional. Hal tersebut menjadikan para peternak hanya mengetahui gejala-gejala awal pada ayam yang sakit tanpa mengetahui penyakit yang dideritanya. Sehingga penyakit ayam tidak dapat ditangani dengan benar dan dapat mengakibatkan penyebaran penyakit dilingkungan sekitar. Chigwada et al., (2022) mengatakan diperlukan teknik manajemen dan penerapan sistem dalam perawatan ayam dengan biaya yang murah namun efektif dan juga efisien yang memperhatikan kesejahteraan dan kesehatan ayam agar tidak mudah memunculkan sebuah penyakit.

Tujuan utama pada industri bidang peternakan ayam adalah untuk menghasilkan produksi tinggi, kualitas produk yang baik dan yang paling penting adalah untuk pengendalian penyakit ayam (Hafez & Attia, 2020). Penelitian (P. He et al., 2022) mengusulkan penggunaan teknologi untuk melakukan proses deteksi terhadap gejala penyakit serta dapat memantau status kesehatan ayam secara terus menerus dan otomatis, serta berpotensi membantu dalam proses pengambilan keputusan peringatan dini terhadap kesehatan ayam. Pada saat ini proses deteksi penyakit ayam dapat diteliti menggunakan metode *deep learning*. Peneliti-peneliti sebelumnya telah melakukan penelitian berdasarkan karakteristik citra digital, diantaranya: karakteristik suara (Du et al., 2020), karakteristik suhu tubuh (Noh et al., 2021), karakteristik feses (Wang et al., 2019), karakteristik postur tubuh ayam (Zhuang et al., 2018), karakteristik produksi dan karakteristik aktivitas (Astill et al., 2018). Penggunaan teknologi *Deep learning* menjadi sebuah terobosan yang luar biasa dalam bidang deteksi citra digital (Liu et al., 2020).

Sekarang ini deteksi citra digital pada *deep learning* telah diangkat secara luas pada seluruh bidang *computer vision*, citra digital pada deteksi objek sendiri merupakan sebuah teknologi yang terkait pada bidang *computer vision* dan *image processing* (Jiao et al., 2019). (Russel & Norvig, 2010) mengatakan perkembangan teknologi dan perputaran data yang sangat cepat menyebabkan semua bidang industri berkembang dengan sangat pesat terutama teknologi seperti sensor, robotika dan *computer vision*. Meningkatnya minat dalam pengembangan teknologi dengan bantuan *artificial intelligence* dan terutama pada bidang *computer vision* untuk mendeteksi sebuah objek perlahan mulai meningkat dan bertahap digunakan dalam mendeteksi objek serta digunakan untuk proses diagnosa (Camara et al., 2022). Terdapat beberapa algoritma yang digunakan dalam teknologi *computer vision*, salah satunya adalah *Convolutional Neural Network* (CNN).

Algoritma *Convolutional Neural Network* (CNN) merupakan *multi layer perceptron* yang dirancang secara khusus dalam mengidentifikasi sebuah objek dua dimensi atau gambar (Primartha, 2021). Sarvamangala & Kulkarni, (2022) menyatakan *Convolutional Neural Network* (CNN) merupakan sebuah algoritma *deep learning* yang terinspirasi oleh struktur dan operasi jaringan saraf organik yang ada di dalam otak, yang dapat mengambil gambar, melibatkan klasifikasi gambar, segmentasi, lokalisasi dan objek lainnya untuk membedakan satu objek dari yang lain.

Penelitian yang dilakukan (Li et al., 2021) mengusulkan sebuah kerangka untuk melakukan proses segmentasi terhadap objek atau citra ayam dengan menggunakan model MSAnet dari CNN untuk melakukan proses klasifikasi dalam

memantau dan mengawasi ayam, hal tersebut sangat berguna bagi pihak peternak dalam meningkatkan kesejahteraan ayam tersebut agar terhindar dari penyakit, proses pengambilan keputusan tersebut menghasilkan nilai akurasi sebesar 94.6%. Dalam penelitian yang dilakukan (Zhuang & Zhang, 2019) menerapkan algoritma *Improved Feature Fusion Single Shot MultiBox Detector* (IFSSD) untuk mendeteksi sebuah objek yang berdasarkan pada arsitektur CNN yaitu *Inception V3*, algoritma tersebut diusulkan untuk meningkatkan model algoritma *Single Shot Multibox Detector* (SSD) dalam mengidentifikasi ayam secara *real time* untuk menentukan status kesehatan berdasarkan dari ciri penampilan dengan hasil nilai 99.7% *mean average precision* *mAP* *intersection-overunion* ( $IoU > 0.5$ ) dan 48.1% *mAP* ( $IoU > 0.9$ ).

Penelitian (Wang et al., 2019) melakukan pendekatan dengan menggunakan *deep Convolutional Neural Network* (CNN) untuk melakukan deteksi penyakit pencernaan terhadap ayam berdasarkan citra feses dengan penerapan model CNN yaitu *Faster R-CNN* dan *YOLO-V3*. Pada pengujian data menggunakan *R-CNN* menghasilkan nilai *recall* sebesar 99.1 % dengan nilai *mean average precision* (*mAP*) sebesar 93.3%, sedangkan pada pengujian data menggunakan *YOLO-V3* menghasilkan nilai *recall* sebesar 88.7% dengan nilai *mean average precision* (*mAP*) sebesar 84.3%. Terdapat penelitian yang dilakukan oleh (Widyawati & Gunawan, 2022) dimana melakukan deteksi terhadap citra feses dengan menggunakan *YOLOv5* dengan mendeteksi citra feses ayam yang sakit dan citra feses ayam yang sehat.



Sesuai dengan penjelasan dan permasalahan diatas, salah satu upaya untuk mengetahui status kesehatan ayam adalah dengan melihat karakteristik dari ayam seperti karakteristik suara, karakteristik suhu tubuh, karakteristik feses, karakteristik produksi, karakteristik aktivitas dan postur ayam. Penelitian ini akan menerapkan CNN dengan menggunakan model arsitektur algoritma Resnet50 dan inceptionV3 pada citra feses untuk mengklasifikasikan penyakit ayam. Klasifikasi didasarkan empat kelas yaitu: Coccidiosis, Tidak sakit, New Castle Disease, dan Salmonella. Dari kedua model algoritma CNN tersebut akan dibandingkan accuracy, precision, recall dan F1-score untuk mengetahui performa dari setiap model.

### **1.2. Rumusan Masalah**

Berdasarkan penjelasan pada latar belakang masalah, maka rumusan masalah pada penelitian ini adalah sebagai berikut

- a. Berapakah tingkat akurasi dari kedua model algoritma CNN InceptionV3 dan Resnet-50 dalam melakukan diagnosa penyakit ayam berdasarkan citra feses?
- b. Manakah dari kedua model algoritma CNN InceptionV3 dan Resnet-50 yang memiliki hasil performa yang terbaik?

### **1.3. Batasan Masalah**

Batasan masalah dalam penelitian ini adalah sebagai berikut.

- a. Pada penelitian ini melakukan analisis terhadap citra feses ayam yang telah dibagi menjadi empat kelas yaitu Coccidiosis, Tidak sakit, New Castle Disease, dan Salmonella.

- b. Melakukan analisis terhadap penyakit ayam.
- c. Model yang digunakan pada penelitian ini yaitu InceptionV3 yang dikembangkan dalam penelitian (Szegedy et al., 2016)
- d. Model yang kedua yang digunakan dalam penelitian ini yaitu Resnet-50 yang dikembangkan dalam penelitian (K. He et al., 2016).
- e. Membandingkan hasil performa model InceptionV3 dan Resnet-50 dari CNN dengan menggunakan nilai indikator accuracy, precision, recall, fl-score.

#### **1.4. Tujuan Penelitian**

Tujuan dari penelitian yang dilakukan adalah sebagai berikut:

- a. Mengetahui model yang menghasilkan nilai akurasi tertinggi pada klasifikasi penyakit ayam berdasarkan citra feses.
- b. Mengetahui hasil performa dari setiap model yang menghasilkan akurasi paling tinggi dengan menggunakan indikator nilai accuracy, precision, recall, fl-score

#### **1.5. Manfaat Penelitian**

Bagian ini memuat penjelasan tentang:

- a. Mampu melakukan analisis dan klasifikasi mengenai penyakit ayam dengan menggunakan metode CNN.
- b. Menjadi referensi terhadap penelitian dimasa mendatang yang berkaitan dengan penggunaan dan manfaat pada metode InceptionV3 dan Resnet-50 pada gambar feses ayam dengan menggunakan CNN.

## **BAB II**

### **TINJAUAN PUSTAKA**

#### **2.1. Tinjauan Pustaka**

Penelitian yang dilakukan oleh (Mbelwa et al., 2021) melakukan suatu penelitian untuk mengidentifikasi penyakit yang paling umum menyerang ayam dengan menggunakan bantuan artificial intelligence dan machine learning yang berdasarkan pada computer vision dalam menganalisis gambar. Dalam penelitian ini mengusulkan deep learning yang berdasarkan pada Convolution Neural Networks (CNN) untuk diagnosa penyakit ayam berdasarkan gambar feses kedalam tiga kelas yaitu coccidiosis, health dan salmonella. Peneliti mengusulkan beberapa model berdasarkan arsitektur CNN dalam proses klasifikasi penyakit ayam seperti VGG 16, Resnet 50, MobileNet, XceptionNet dan model dasar CNN. Berdasarkan hasil percobaan model XceptionNet menunjukkan tingkat akurasi paling tinggi dibandingkan dengan model arsitektur lainnya dengan nilai akurasi sebesar 94% dalam mengidentifikasi penyakit ayam.

Dalam penelitian (H. Zhang & Chen, 2020) melakukan proses klasifikasi terhadap kesehatan ayam berdasarkan gambar dengan menggunakan arsitektur deep learning CNN yaitu ResNet. Berdasarkan jaringan ResNet peneliti mengembangkan jaringan tersebut sehingga menghasilkan sebuah model ResNet-FPN yang dirancang untuk meningkatkan tingkat akurasi dan untuk beradaptasi terhadap lingkungan pengenalan yang berbeda. Hasil eksperimen menunjukkan bahwa tingkat akurasi pada model tersebut setinggi 93,7%.

Penelitian lain yang dilakukan (Widyawati & Gunawan, 2022) menerapkan sebuah sistem otomatis deteksi dini penyakit pada industri ayam khususnya ayam yang berdasarkan arsitektur YOLOv5 yang dipilih karena model convolutional memiliki kecepatan memproses baik dan akurasi yang tinggi. Proses diagnosa penyakit ayam berdasarkan citra feses tersebut menggunakan arsitektur YOLOv5. Berdasarkan hasil yang diperoleh pada tahap pengujian rata-rata tingkat akurasi terbaik yang diperoleh adalah 89,2% dengan waktu pelatihan 0,742 jam dan waktu pengujian 0,55 (s).

Dalam melakukan proses identifikasi dari beberapajenis penyakit ayam berdasarkan gambar dari feses ayam (Kholil et al., 2022) menggunakan deep learning Convolutional Neural Network (CNN). Hasil dari keseluruhan proses identifikasi dengan menggunakan CNN, 95,40% gambar feses ayam diprediksi terjangkit penyakit coccidiosis, 94,97% gambar feses ayam diprediksi sehat, 90,21% gambar feses ayam diprediksi terjangkit penyakit tetelo, dan 96,50% gambar feses ayam diprediksi terjangkit penyakit pullorum. Penelitian (Machuve et al., 2022) melakukan diagnosis penyakit ayam ke dalam empat kelas yaitu sehat, coccidiosis, salmonella, dan newcastle dengan menggunakan Convolutional Neural Network (CNN). Dalam proses klasifikasi penyakit ayam ini menggunakan model dasar CNN dan beberapa arsitektur CNN seperti VGG16, InceptionV3, MobileNetV2, dan model Xception

## 2.2. Keaslian Penelitian

Tabel 2.1. Matriks literatur review dan posisi penelitian  
DIAGNOSA PENYAKIT AYAM MELALUI CITRA GAMBAR FESES BERDASARKAN CNN

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
1	<i>Chicken Image Segmentation via Multi-Scale Attention-Based Deep Convolutional Neural Network</i>	Wei Li, Yang Xiao, Xibin Song, Na Lv, Xinbo Jiang, Yan Huang dan Jingliang Peng, IEEE Access, 2021	Mempelajari segmentasi citra ayam yang digunakan untuk memisahkan dari perlakuan tingkat kelompok dan melakukan perawatan ayam secara individual. Dengan demikian, dapat memantau perilaku ayam secara terus-menerus dan dapat menganggapnya sebagai indikator kesehatan dan kesejahteraan ayam.	Untuk kinerja segmentasi yang lebih baik, penulis mengusulkan untuk menggunakan informasi multi-skala dan strategi berbasis perhatian yang mencakup perhatian saluran dan perhatian tepi untuk ekstraksi fitur yang efektif. Dengan menggunakan MSAnet menghasilkan tingkat akurasi sebesar 94,6 %	Peneliti akan terus memperluas dataset ayam untuk memuat lebih banyak varian dan kondisi untuk studi perilaku ayam, seperti deteksi, segmentasi, pelacakan, dan pengenalan.	Pada penelitian sebelumnya melakukan klasifikasi terhadap perilaku ayam sebagai indikator kesehatan dan kesejahteraan ayam  Pada penelitian ini peneliti melakukan klasifikasi terhadap citra feses ayam dengan menggunakan model Resnet-50 dan Inception-V3 yang berdasarkan pada CNN dan membagi berdasarkan empat kelas, yaitu Coccidiosis, Tidak sakit, New Castle Disease, dan Salmonella,



Tabel 2.1 Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
2	Deep Convolutional Neural Network for Chicken Diseases Detection	Hope Mbelwa, Dina Machuve, Jimmy Mbelwa, International Journal of Advanced Computer Science and Applications (IJACSA), 2021	Melakukan klasifikasi dalam proses diagnosa penyakit ayam berdasarkan dari citra feses dengan menggunakan beberapa dari model arsitektur Convolutional Neural Networks (CNN)	Dengan menggunakan CNN dan beberapa arsitektur dari CNN seperti VGG 16, Resnet 50, MobileNet, Xception Net dalam proses klasifikasi citra feses. Model arsitektur Xception mendapatkan nilai akurasi paling tinggi dibandingkan dengan model lain yaitu 94%	Mencoba menerapkan dataset yang bervariasi dan menerapkan model arsitektur yang berbasis mobile	Pada penelitian sebelumnya menerapkan model CNN dengan arsitektur seperti VGG16, Resnet50, MobileNet dan Xception Net  Pada penelitian ini kan menerapkan dan melakukan perbandingan terhadap model CNN yaitu Resnet-50 dan Inception-V3 pada proses diagnosa penyakit ayam berdasarkan citra feses
3	Design of Sick Chicken Automatic Detection System Based on Improved Residual Network	Haiyang Zhang, Changxi Chen,	Untuk melakukan proses klasifikasi terhadap kesehatan ayam berdasarkan gambar dengan menggunakan arsitektur deep learning CNN yaitu ResNet.	Berdasarkan jaringan ResNet peneliti mengembangkan jaringan tersebut sehingga menghasilkan sebuah model ResNet-FPN yang dirancang untuk meningkatkan tingkat akurasi dan untuk beradaptasi terhadap	Menambahkan dataset berupa video dengan menggunakan model arsitektur cnn yang sama.	Penelitian sebelumnya menggunakan arsitektur Resnet yang kemudian dilakukan peningkatan terhadap arsitektur tersebut dalam mendeteksi ayam yang sakit berdasarkan gambar ayam.

Tabel 2.1 Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
		IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), 2020		lingkungan pengenalan yang berbeda. Hasil eksperimen menunjukkan bahwa tingkat akurasi pada model tersebut setinggi 93,7%		Penelitian ini akan menggunakan dua model arsitektur yaitu Resnet-50 dan Inception-v3 dalam proses klasifikasi penyakit ayam berdasarkan citra feses ayam tersebut
4	Early detection of sick chicken using artificial intelligence	Widyawati, Waliadi Ganawan TEKNIKA: JURNAL SAINS DAN TEKNOLOGI, 2022	Implementasi sebuah sistem otomatis deteksi dini penyakit pada industri ayam khususnya ayam yang berdasarkan arsitektur YOLOv5 yang dipilih karena model convolutional memiliki kecepatan memproses baik dan akurasi yang tinggi	Proses diagnosa penyakit ayam berdasarkan citra feses tersebut menggunakan arsitektur YOLOv5. Berdasarkan hasil yang diperoleh pada tahap pengujian rata-rata tingkat akurasi terbaik yang diperoleh adalah 89,2%	Mencoba menerapkan dataset yang bervariasi dan dibandingkan dengan model arsitektur yang dikembangkan telah ditentukan.	Dengan melakukan deteksi dini terhadap citra feses ayam menggunakan model CNN dengan arsitektur YOLOv5  Kemudian peneliti akan menerapkan arsitektur resnet-50 dan Inception-v3 untuk melakukan analisa terhadap citra feses ayam



Tabel 2.1 Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
5	Klasifikasi Penyakit Infeksi Pada Ayam Berdasarkan Gambar Feses Menggunakan Convolutional Neural Network	Moch. Kholil, Heri Priya Waspada, Rafika Akhsani, SINTECH (Science and Information	Melakukan penelitian untuk mengidentifikasi jenis penyakit ayam berdasarkan gambar dari feses ayam tersebut dengan menggunakan deep learning Convolutional Neural Network (CNN).	Dari keseluruhan proses identifikasi dengan menggunakan CNN 95,40% gambar feses ayam diprediksi terjangkit penyakit coccidiosis, 94,97% gambar feses ayam diprediksi sehat, 90,21% gambar feses ayam diprediksi terjangkit penyakit tetelo, dan 96,50% gambar feses ayam diprediksi terjangkit penyakit pullorum	Komparasi arsitektur model CNN dilakukan sendiri sehingga bisa mendapatkan validasi dan apakah memiliki perbedaan dengan penelitian sebelumnya.	Penelitian tersebut hanya menggunakan model CNN tanpa menerapkan model arsitektur lainnya  Penelitian ini akan melakukan analisis dan klasifikasi dari jenis-jenis penyakit ayam dan menambahkan arsitektur Resnet-50 dan Inception-v3 pada metode CNN.
6	Poultry diseases diagnostics models using deep learning	Dina Machuve, Ezinne Nwankwo,	Melakukan diagnosis penyakit ayam ke dalam empat kelas yaitu sehat, coccidiosis, salmonella,	Pada penelitian ini melakukan dua kali percobaan yang pertama dengan akurasi tes tanpa fine-tuning adalah 83,06% untuk baseline CNN, 85,85%	Mencoba menerapkan dataset yang bervariasi serta menerapkan proses diagnose secara realtime	Dengan menggunakan model CNN dan arsitektur lainnya seperti VGG16, InceptionV3, MobileNetV2, dan model Xception.

Tabel 2.1 Lanjutan

No	Judul	Peneliti, Media Publikasi, dan Tahun	Tujuan Penelitian	Kesimpulan	Saran atau Kelemahan	Perbandingan
		Neema Mduma, Jimmy Mbelwa Frontiers in Artificial Intelligence, 2022	dan newcastle dengan menggunakan Convolutional Neural Network (CNN). Dalam proses klasifikasi penyakit ayam ini menggunakan model dasar CNN dan beberapa arsitektur CNN seperti VGG16, InceptionV3, MobileNetV2, dan model Xception	untuk VGG16, 94,79% , untuk InceptionV3, 87,46% untuk MobileNetV2, dan 88,27% untuk Xception. Kemudian melakukan penyetelan halus sambil membekukan lapisan normalisasi batch meningkatkan akurasi model, menghasilkan 95,01% untuk VGG16, 95,45% untuk InceptionV3, 98,02% untuk MobileNetV2, dan 98,24% untuk Xception		Penelitian ini akan melakukan perbandingan antara arsitektur Resnet-50 dan InceptionV3 dalam melakukan diagnosis penyakit ayam

## 2.3. Landasan Teori

### 2.3.1. Penyakit Ayam

Kesehatan dan penyakit ayam merupakan sebuah aspek kritis dalam industri peternakan karena kedua aspek tersebut merupakan hal yang paling tidak dapat diprediksi. Penyakit ayam sendiri merupakan sebuah kondisi yang dapat mempengaruhi kesejahteraan serta kesehatan ayam. Penyakit tersebut disebabkan oleh virus, bakteri, protozoa, jamur, maupun parasit (Cadmus et al., 2019). Penyakit yang sering menyerang peternakan adalah penyakit Newcastle, Salmonella, dan Coccidiosis (Mappa et al., 2022). Penyakit Newcastle merupakan sebuah penyakit yang disebabkan oleh virus, Menurut (Wungak et al., 2022) penyakit Newcastle merupakan sebuah penyakit menular dan menyebar dengan sangat cepat, penyakit ini juga ini bersifat akut serta dapat memberikan kematian terhadap ayam yang terkena penyakit tersebut. Terdapat tanda-tanda yang dapat dilihat secara fisik bagi ayam yang terkena penyakit Newcastle dimana ayam tersebut sering mengantuk, keluarnya cairan dari hidung, kotoran berwarna hijau dan bengkak pada daerah wajah (Sahoo et al., 2022). Kemudian penyakit salmonella merupakan sebuah penyakit yang menyerang saluran pencernaan ayam dan disebabkan oleh bakteri. Ayam yang terkena infeksi oleh salmonella dapat menimbulkan penyakit tipus dan pullorum atau berak kapur (Revolledo, 2018). Terdapat gejala yang dapat dilihat pada ayam yang terkena penyakit salmonella meliputi diare dengan ciri feses yang encer berwarna putih seperti kapur dan menempel pada dubur, kemudian ayam terlihat lesu dan bergerak lambat, nafsu makan menurun

hingga penurunan produksi telur, pada sayap akan menggantung dan terlihat kusam (Tariq et al., 2022). Selanjutnya penyakit lain yang menyerang saluran pencernaan adalah penyakit coccidiosis, penyakit tersebut merupakan penyakit usus yang disebabkan oleh protozoa parasit Genus *Eimeria*. Terdapat beberapa gejala yang muncul pada ayam yang terkena tersebut, yaitu menyebabkan perdarahan pada saluran pencernaan serta terdapat darah pada tinja (Djara et al., 2020). Gambar menunjukkan feses yang normal dan feses yang tidak normal dari beberapa penyakit diatas. Adapun feses yang normal dan tidak normal merupakan ciri khas penyakit pada ayam. Kotoran ayam yang terinfeksi penyakit mungkin mengalami perubahan warna, bentuk, kadar air, dan kandungan yang tidak normal.



Gambar 2. 1 Feses ayam normal dan tidak normal

### 2.3.2. Deep Learning

Deep Learning dalam penelitian (Janiesch et al., 2021) secara garis besar merupakan pengembangan dari machine learning dan berdasarkan dari komponen jaringan saraf tiruan, dimana menirukan cara berpikir otak manusia yang memiliki berlapis-lapis layer. Menurut (Goodfellow et al., 2016) dalam buku Deep Learning menyebutkan deep learning adalah sebuah model dari

machine learning yang menerapkan jaringan saraf tiruan dengan memiliki layer atau lapisan yang banyak, pada deep learning memungkinkan untuk mengolah data yang kompleks dan abstrak secara efisien, sehingga dapat digunakan untuk mengidentifikasi dan mengenali berbagai macam objek seperti gambar, teks, suara, dan data lain.

Pada gambar 2.2, dijelaskan mengenai proses pada model deep learning, dengan memasukkan gambar mentah kedalam jaringan, dan kemudian melewati network layer untuk mengidentifikasi pola untuk menghasilkan fitur dari gambar tersebut. Berbeda dengan proses machine learning, dalam model deep learning dapat dianggap sebagai model yang dilatih secara menyeluruh dengan proses ekstraksi fitur dan melakukan proses klasifikasi dengan secara menyeluruh.



Gambar 2. 2 Cara kerja Deep Learning

### 2.3.3. Convolutional Neural Networks

Convolutional Neural Networks juga dikenal dengan CNN adalah jenis jaringan saraf tiruan yang merupakan bagian dari algoritma deep learning yang memiliki beberapa lapisan tersembunyi, dimana setiap layer saling terhubung pada lapisan sebelumnya. Jaringan Convolutional Neural Networks menggunakan konvolusi sebagai pengganti perkalian matriks umum untuk



melakukan transformasi data paling tidak pada salah satu lapisan layer (LeCun et al., 2010). Menurut (Chollet, 2017) Convolutional Neural Networks memiliki tiga struktur dasar lapisan yaitu: lapisan konvolusi, lapisan pooling, dan lapisan fully connected, dimana lapisan konvolusi bertugas untuk melakukan ekstraksi fitur-fitur dari sebuah data, pada lapisan pooling digunakan untuk mengurangi dimensi sebuah data dengan melakukan operasi downsampling, dan pada lapisan fully-connected digunakan untuk melakukan proses klasifikasi.

Secara umum arsitektur CNN terdiri dari Feature Extraction Layer (convolutional layer, activation layer ReLU dan pooling layer) dan Fully-Connected Layer (flatten, fully connected layer, dan Softmax) seperti pada gambar 2.3.



Gambar 2. 3 Struktur CNN

#### 2.3.4. Transfer Learning

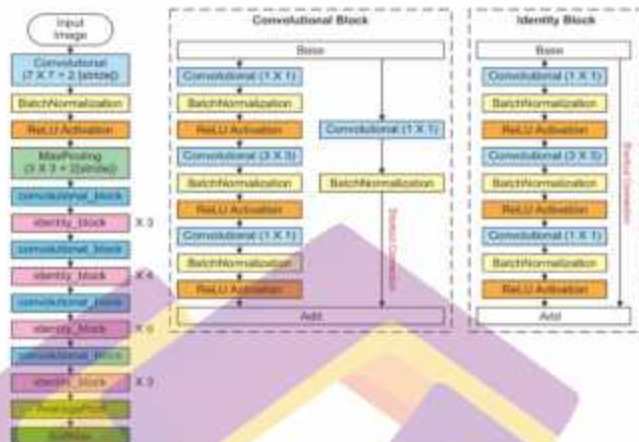
Transfer Learning dalam penelitian (Kim et al., 2022) dijelaskan bahwa transfer learning adalah suatu upaya untuk mentransfer pengetahuan yang dipelajari dengan tujuan utama untuk meningkatkan kinerja pada tugas yang telah ditetapkan dengan memanfaatkan pengetahuan tentang tugas yang dipelajari sebelumnya. Transfer learning dapat memberikan kontribusi besar

dalam mengatasi masalah kelangkaan data serta dapat menghemat waktu dan sumber daya perangkat keras. Pada umumnya proses transfer learning dilakukan pada saat model pertama kali dilatih untuk menyelesaikan permasalahan (Hashmi et al., 2020). Contoh dalam penggunaan transfer learning dalam model atau tugas dilatih menggunakan dataset adalah, ImageNet, Open Images dan sebagainya.


### **2.3.5. Resnet-50**

Resnet merupakan salah satu model arsitektur dari CNN yang dikembangkan oleh He, Xiangyu Zhang, Shaoqing Ren, dan Jian Sun. Arsitektur ini dibentuk untuk mengatasi proses pelatihan deep learning yang membutuhkan waktu yang cukup lama serta terbatasnya pelatihan data pada beberapa layer tertentu (Sarwinda et al., 2021). Model arsitektur ResNet memiliki keunggulan dimana model ini tidak menurun walaupun arsitekturnya semakin dalam. Selain itu perhitungan perhitungan menjadi lebih ringan, dan kemampuan untuk melatih jaringan menjadi lebih baik. (K. He et al., 2016) mengembangkan Resnet yang diimplementasikan dengan melewati koneksi pada dua hingga tiga layer atau lapisan yang berisikan ReLU dan batch normalization di antara model arsitektur pada gambar 2.4, Resnet50 juga mengadopsi residual learning untuk diterapkan pada beberapa lapisan lapisan. Residual block pada ResNet ditentukan pada gambar 2.5.





Gambar 2. 4 Arsitektur Resnet50




Gambar 2. 5 Residual learning: a building block.

### 2.3.6. Inception-v3

Inception-v3 memiliki jaringan dengan total 42 jumlah layer, dalam penelitian (Szegedy et al., 2016) membuat beberapa perbaikan yang dimuat kedalam inception-v3 termasuk menggunakan Label Smoothing, Factorized 7 x 7 convolutions, dan menggunakan classifier tambahan untuk menyebarkan informasi label ke bawah jaringan. Model arsitektur itu sendiri terdiri dari beberapa blok bangunan simetris dan asimetris, termasuk konvolusi, rata-rata pooling, max pooling, concatenations, dropout, dan layer yang terhubung

penyempurnaan. Kemudian batch normalization digunakan secara luas normalization seluruh model dan diterapkan pada input aktivasi. Pada gambar 2.6 dan tabel 1 memuat mengenai arsitektur dari inception-v3.



Gambar 2. 6 Arsitektur inception-v3

Tabel 2. 1 Arsitektur inception-v3

Layer (Type)	Path Size/stride or remarks	Input Size
Conv	3x3/2	299x299x3
Conv	3x3/1	149x149x32
Conv padded	3x3/1	147x147x32
Pool	3x3/2	147x147x64
Conv	3x3/1	63x73x64
Conv	3x3/2	71x71x80
Conv	3x3/1	35x35x192
3x Inception A		35x35x288
5x Inception B		17x17x768
2x Inception C		8x8x1280
Pool	8x8	8x8x2048
Linear	Logits	1x1x2048
Softmax	Classifier	1x1x1000

## **BAB III**

### **METODE PENELITIAN**

#### **3.1. Jenis, Sifat, dan Pendekatan Penelitian**

Jenis dan pendekatan penelitian adalah penelitian kuantitatif. Pada penelitian ini melakukan perhitungan secara matematis terhadap data-data penelitian, serta sifat dari penelitian ini adalah penelitian eksperimental komputasi. Sifat dari penelitian ini dilakukan secara mandiri menggunakan metode deskriptif dan kasual dari data yang diperoleh kemudian dilatihkan dan diuji. Penelitian menggunakan pendekatan kuantitatif untuk melakukan suatu eksperimen untuk analisis komparasi terhadap performa model arsitektur Resnet50 dan InceptionV3 dalam klasifikasi penyakit ayam berdasarkan citra feses dengan menggunakan CNN. Pada penelitian ini dilakukan serangkaian tindakan pengumpulan dataset, preprocessing data, pemodelan menggunakan beberapa model dari arsitektur CNN, proses training dan testing data. Serangkaian langkah tersebut dilakukan untuk mendapatkan hasil pengujian berupa tingkat accuracy, precision, recall, f1-score dalam proses klasifikasi penyakit ayam berdasarkan citra feses.

#### **3.2. Metode Pengumpulan Data**


Pengumpulan data yang telah dilakukan dalam memenuhi berbagai macam kebutuhan yang diperlukan dalam penelitian untuk mendapatkan data yang diperlukan dalam penelitian. Dataset tersebut berupa gambar, yaitu gambar feses ayam yang diambil dari platform Kaggle dengan jumlah data sebesar 8067 gambar.

### 3.3. Metode Analisis Data

Setelah data terkumpul, langkah selanjutnya adalah melakukan analisis terhadap data dengan melakukan pengolahan data atau pre-processing data sehingga data tersebut dapat digunakan sesuai dengan kebutuhan penelitian. Pada proses ini akan dilakukan perhitungan terhadap jumlah data yang akan digunakan, menetapkan data yang akan digunakan, melakukan pengecekan terhadap data, kemudian melakukan labeling atau pemberian label terhadap data, setelah pemberian labeling pada data kemudian membagi data tersebut kedalam empat kelas yaitu Coccidiosis, Tidak sakit, New Castle Disease, dan Salmonella. Setelah itu akan dilakukan proses resize untuk menyesuaikan semua ukuran gambar agar menjadi seragam, lalu dilakukan proses splitting atau pembagian data menjadi data training, data testing dan validasi data.



### 3.4. Alur Penelitian



Gambar 3. 1 Alur Penelitian

Pada penelitian ini terdapat beberapa langkah utama pada penelitian seperti pada gambar 3.1 dengan rincian alur sebagai berikut :



a. Pengumpulan Dataset dan menentukan model

Pada pengumpulan data, menggunakan dataset yang berasal dari platform Kaggle, dengan jumlah data sebesar 8067 gambar feces ayam. Algoritma yang akan digunakan pada klasifikasi penyakit daun teh adalah Inception V3 dan ResNet-50

b. Menentukan Skenario

Penentuan skenario percobaan pada penelitian ini digunakan untuk menganalisa perbandingan hasil percobaan dengan memperhatikan penggunaan jumlah persebaran data pada setiap kelasnya dan teknik augmentasi yang digunakan pada proses training.

c. Preprocessing Data

Tahapan preprocessing data merupakan tahapan yang digunakan untuk mengolah dan mengelola data sehingga dapat digunakan, pada tahap ini terdapat beberapa proses yang dilakukan yaitu mulai dari labeling data, resize, yang kemudian melakukan splitting data.

i. Rezise

Proses resize pada setiap dataset yang telah dikumpulkan agar semua gambar memiliki ukuran yang sama. Pada proses ini berguna untuk menyesuaikan data masukan pada sistem agar tidak terjadi sebuah kesalahan karena ketidakseimbangan ukuran pada data. Pada tahap ini gambar akan dilakukan proses rezise dengan ukuran 224x224 pixel

## ii. Augmentasi Data

Augmentasi data sendiri merupakan sebuah serangkaian teknik yang digunakan untuk meningkatkan kualitas dan ukuran data yang akan digunakan dalam klasifikasi (Shorten & Khoshgoftaar, 2019). Tahapan pertama yang dilakukan pada augmentasi data yaitu melakukan penyeimbangan data terhadap dataset agar memiliki jumlah data yang sama antar kelas. Kemudian melakukan augmentasi terhadap citra dimana akan augmentasi data yang akan dilakukan yaitu zoom, rotation, dan vertical flip.

## iii. Split Data

Proses split data dilakukan pembagian dataset sebesar 80% untuk data training, 10% untuk data testing dan 10% untuk validasi data. Split data dilakukan pada dataset yang akan digunakan.

## d. CNN Model

Model CNN digunakan untuk mengetahui tingkat performa dari proses klasifikasi dan pengenalan citra dari dataset. Pada proses ini menggunakan model algoritma dari CNN yaitu Resnet50 dan InceptionV3.

### i. Resnet50

Arsitektur resnet50 menggunakan pembelajaran residual dengan mempertimbangkan input layer sebagai

referensi pada setiap prosesnya. Setelah dilakukannya preprocessing data, dilakukan proses pelatihan model dengan menggunakan resnet50. Pada tahap pertama citra gambar dilakukan proses konvolusi dengan ukuran filter 7 x 7 dan stride 2 yang kemudian menghasilkan feature map. Selanjutnya dilakukan proses normalisasi dengan Batch Normalization, hasil dari proses normalisasi selanjutnya masuk kedalam aktivasi layer, yang didalamnya terdapat fungsi ReLU untuk membuat hasil dari ekstraksi fitur menjadi non-linear. Setelah proses yang dilakukan oleh fungsi ReLU kemudian dilakukan proses reduksi pada setiap lapisan layer dengan maxpooling sebelum diteruskan pada tahap konvolusi kedua. Diantara tahap convolution kedua sampai dengan kelima, proses feature extraction dilakukan oleh kombinasi convolutional block dan identity block. Setelah proses feature extraction selesai, kemudian feature map diproses ke dalam fully connected layer untuk melakukan proses prediksi dibantu dengan activation function sigmoid seperti pada gambar 3.2.



Gambar 3. 2 Diagram proses Resnet50

#### ii. InceptionV3

Pada model arsitektur InceptionV3 terdiri dari blok bangunan simetris dan asimetris building blocks seperti pada gambar 3.3. Pada tahapan ini menggunakan ukuran input gambar yang akan digunakan sebesar 224 x 224, tahapan tersebut antara lain konvolusi, average pooling, max pooling, concatenations, dropouts, dan fully connected layers. Batch normalization digunakan pada seluruh rangkaian model dan diterapkan pada input aktivasi. Loss terhadap proses yang terjadi pada model dihitung menggunakan softmax.



Gambar 3. 3 Diagram arsitektur InceptionV3

e. Training

Pada proses training dilakukan untuk melatih setiap model algoritma yang digunakan sehingga mendapatkan hasil evaluasi yang dapat memberikan nilai akurasi yang tinggi.

f. Evaluasi

Tahapan pembahasan digunakan untuk melakukan evaluasi terhadap setiap pelatihan menggunakan scenario Resnet-50 dan InceptionV3. Terdapat dua hasil evaluasi yang akan dilakukan, yaitu mengetahui tingkat performa dari setiap arsitektur Resnet-50 dan InceptionV3, selanjutnya membandingkan hasil accuracy, precision, recall, f1-score dari arsitektur Resnet-50 dan InceptionV3

g. Kesimpulan

Tahap akhir dari alur penelitian ini merupakan pengambilan kesimpulan yang dilakukan setelah beberapa tahapan mulai dari pengumpulan dataset dan menentukan model hingga evaluasi yang dilakukan. Tahapan ini memaparkan temuan yang dihasilkan dari setiap skenario yang digunakan.



## BAB IV

### HASIL PENELITIAN DAN PEMBAHASAN

Bab ini merupakan pembahasan mengenai hasil dari penelitian yang akan dilakukan. Pada penelitian ini diselesaikan dengan beberapa tahapan dimulai dari pengumpulan data yang akan digunakan untuk model klasifikasi, kemudian analisis data, membuat beberapa skenario percobaan dengan menggunakan algoritma yang telah ditentukan, dan yang terakhir melakukan evaluasi dengan menguji skenario percobaan dari model klasifikasi untuk mendapatkan hasil yang terbaik.

#### 4.1. Pengumpulan Data

Pada tahapan pengumpulan data diperoleh melalui website penyedia data public yang dapat diakses oleh semua orang. Data yang digunakan diperoleh dari situs [www.kaggle.com](http://www.kaggle.com) dengan nama dataset Chicken Disease Image Classification.

Tabel 4. 1 Dataset Penyakit Ayam

Kelas	Jumlah Data
Healthy	2404
Coccidiosis	2476
New Castle Disease	562
Salmonella	2625

Pada dataset chicken disease image classification ini menyediakan data citra penyakit ayam dari beberapa jenis penyakit yang ada. Data yang dipilih dalam penelitian ini adalah data penyakit yang terlihat pada feses atau kotoran ayam yang digunakan untuk menganalisis fungsi dari model klasifikasi pada penyakit ayam.

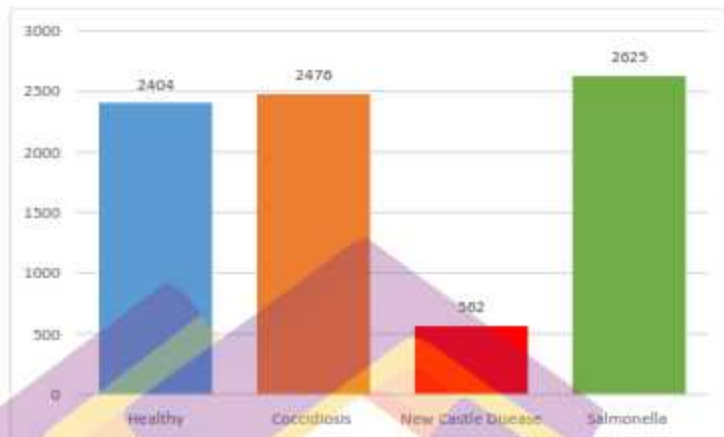
Pada table 4.1 merupakan detail dari data yang akan digunakan pada penelitian, dengan total keseluruhan dari data yang digunakan adalah 8067 data gambar. Persebaran data gambar penyakit ayam dibagi kedalam empat kelas dengan rincian data Healthy 2404, data dengan penyakit Coccidiosis berjumlah 2476, data dengan penyakit New Castle Disease 562, dan yang terakhir data dengan penyakit salmonella dengan jumlah data 2625.

## **4.2. Analisis Data**

Setelah data berhasil dikumpulkan, tahapan selanjutnya adalah untuk menganalisis data. Pada tabel 4.1 menunjukkan bahwa persebaran data gambar penyakit ayam yang digunakan memiliki ketidakseimbangan data dalam setiap kelasnya. Tahapan analisis dilakukan agar data yang akan digunakan sesuai dengan kebutuhan serta menjadi cukup ideal agar dapat digunakan pada model klasifikasi yang telah ditentukan.

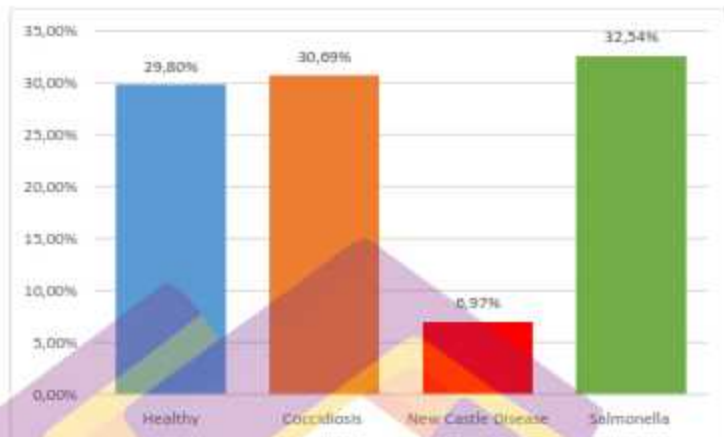
### **4.2.1. Persebaran Data**

Data yang digunakan pada penelitian memiliki persebaran yang dapat dilihat pada gambar 4.1, dataset tersebut terdiri atas empat kelas dimana memiliki jumlah data yang bervariasi dengan data Healthy 2404, data penyakit Coccidiosis berjumlah 2476, data dengan penyakit New Castle Disease 562, dan yang terakhir data dengan penyakit salmonella dengan jumlah data 2625.



Gambar 4. 1 Persebaran Dataset

Dengan begitu dapat dilihat bahwa persentase persebaran dataset tersebut menjadi tidak seimbang hal tersebut dapat dilihat pada Gambar 4.2, dengan kelas salmonella sebagai penyakit yang paling umum dengan jumlah paling besar 32,54% dan New Castle Disease 6,96% sebagai penyakit yang jarang terjadi. Efek dari ketidakseimbangan data dapat menyebabkan sebagian besar kinerja model klasifikasi kurang maksimal karena penyebaran data yang ada pada setiap kelas tidak merata. Permasalahan pada data tidak seimbang ini dapat diatasi dengan menggunakan teknik penyeimbangan dataset untuk menyeimbangkan jumlah data yang ada pada setiap kelas.



Gambar 4. 2 Persentase persebaran dataset

#### 4.2.2. Pengolahan dataset

Pada tahapan ini digunakan untuk mengolah dan mengelola dataset sebelum dilakukannya proses klasifikasi dengan menggunakan model algoritma yang telah ditentukan. Dapat dilihat pada gambar 4.2 dimana persebaran data New Castle Disease memiliki jumlah data yang paling sedikit dengan persentase 6.97% dibandingkan dengan jumlah data yang ada pada kelas lainnya, maka peneliti harus melakukan proses penyeimbangan data untuk menyeimbangkan jumlah data yang ada pada setiap kelas. Teknik yang digunakan untuk menyeimbangkan data tersebut adalah oversampling, teknik oversampling sendiri merupakan sebuah teknik untuk meningkatkan jumlah sampel dari kelas minoritas dengan cara menduplikasi sampel data sehingga membuat kumpulan tersebut terdistribusi secara merata. Proses penyeimbangan data ini menggunakan

salah satu metode oversampler yaitu ROS (RandomOverSampler) untuk meningkatkan kelas minoritas sehingga memiliki jumlah data yang sama dengan kelas mayoritas. Penyeimbangan data dengan menggunakan RandomOverSampler yang dilakukan pada google colab dengan menggunakan library imblearn, berikut potongan dari kode yang akan diterapkan dalam menyeimbangkan data gambar penyakit ayam yang dapat dilihat pada gambar 4.3.

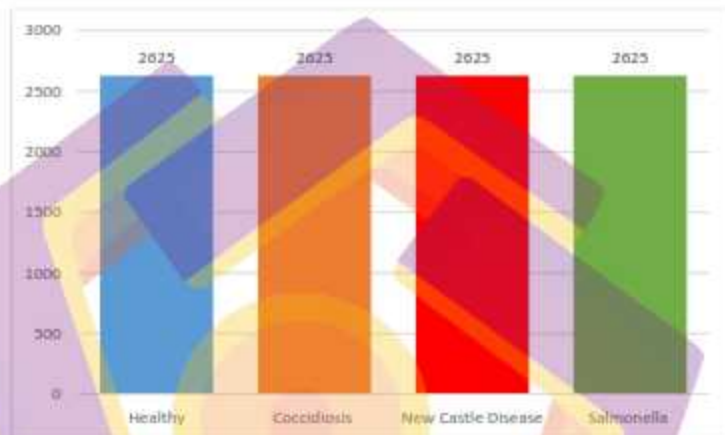
```
from imblearn.over_sampling import RandomOverSampler  
  
oversampler = RandomOverSampler(random_state=42)  
X_resampled, y_resampled = oversampler.fit_resample(data_df, labels)
```

Gambar 4. 3 Kode penyeimbangan data

Pada kode tersebut dapat dilihat bahwa untuk menyeimbangkan data yang tidak seimbang menggunakan library imblearn untuk agar dapat mengakses teknik RandomOverSampler dalam melakukan penyeimbangan data, proses tersebut dilakukan setelah data berhasil didapatkan dan sebelum dilakukannya preprocessing data. Dalam teknik RandomOverSampler data dari kelas minoritas dipilih secara acak dan digandakan untuk menyeimbangkan data sehingga data antara kelas minoritas dan mayoritas seimbang. Disini data dengan kelas minoritas terdapat pada kelas Healthy, New Castle Disease, dan kelas Coccidiosis dan kelas mayoritas terdapat pada kelas Salmonella dimana memiliki data yang lebih tinggi dibandingkan dengan kelas lainnya, maka kelas Healthy, New Castle Disease, dan kelas Coccidiosis yang memiliki jumlah data lebih sedikit dibandingkan kelas



Salmonella dilakukan proses penyeimbangan data agar data tersebut memiliki jumlah yang sama dengan kelas mayoritas. Perubahan jumlah data setelah dilakukan proses penyeimbangan data dapat dilihat pada gambar 4.4 dimana jumlah keseluruhan kelas menjadi 10500 data gambar.



Gambar 4. 4 Data setelah oversampling

Dengan begitu data yang telah dilakukan proses penyeimbangan memiliki jumlah persebaran data yang seimbang dan menjadi lebih ideal daripada sebelumnya dimana kelas minoritas menjadi seimbang dengan data kelas lainnya.

#### 4.2.3. Preprocessing Data


Tahapan preprocessing data merupakan suatu proses untuk mengolah dan mengelola data sehingga dapat digunakan untuk mendapatkan kualitas yang lebih baik serta dapat meningkatkan kinerja

klasifikasi. Setelah proses penyeimbangan data pada tahapan dataset preprocessing, maka tahapan selanjutnya adalah dengan melakukan preprocessing data terhadap dataset yang akan digunakan untuk proses klasifikasi. Tahapan dalam preprocessing data yang digunakan dalam mempersiapkan data adalah sebagai berikut :

- a. Pengubahan ukuran (rezise) : Proses pengubahan ukuran (resize) dilakukan terhadap keseluruhan data gambar agar memiliki keseragaman ukuran yang sama. Nilai ukuran atau bentuk gambar yang semula tidak sama diubah menjadi ukuran 224x224 piksel. Proses perubahan ukuran gambar dilakukan tanpa memotong bentuk gambar. Proses ini berguna untuk menyesuaikan datamasukan pada sistem agar tidak terjadi sebuah kesalahan karena ketidakseimbangan ukuran pada data.
- b. Augmentasi Data : pada proses augmentasi data memiliki tujuan untuk memaksimalkan citra dan proses untuk klasifikasi dengan memanipulasi atau memodifikasi gambar yang pada awalnya memiliki bentuk standar kemudian diubah bentuk dan posisinya. Augmentasi data yang digunakan meliputi zoom, rotation, dan vertical flip. Pada gambar 4.5 merupakan gambar asli sebelum dilakukannya augmentasi data, sedangkan gambar 4.6 merupakan hasil gambar setelah dilakukannya proses augmentasi.



Gambar 4. 5 Gambar Awal



Gambar 4. 6 Augmentasi Data

- c. Pembagian data (Split Data): Pada proses pembagian data digunakan untuk membagi data menjadi data training data validasi dan data testing. Data training merupakan sekumpulan data yang digunakan untuk melatih model selama tahap pelatihan, data pelatihan memiliki fungsi untuk melakukan klasifikasi pada data yang belum pernah dilihat sebelumnya. Kemudian data validasi merupakan data yang digunakan untuk mengevaluasi kinerja dari data training saat proses pelatihan, data validasi. Dan data testing merupakan sekumpulan

data yang digunakan untuk proses pengujian data setelah proses data training yang nantinya dapat digunakan sebagai evaluasi dari model klasifikasi yang kita tentukan. Pembagian mengenai data yang akan digunakan dapat dilihat pada gambar 4.7, dimana data training dibagi dengan jumlah data 80% untuk data training, 10% untuk data validasi dan 10% untuk data testing.



Gambar 4. 7 Pembagian Dataset

#### 4.3. Skenario Percobaan

Pada penelitian ini menggunakan beberapa skenario yang akan dilakukan dalam percobaan penelitian, beberapa skenario tersebut dilakukan untuk proses analisa dari hasil percobaan yang dilakukan. Hasil analisis dari beberapa skenario percobaan yang akan dilakukan, nantinya dapat digunakan sebagai acuan dalam menentukan model klasifikasi yang terbaik. Setelah dilakukannya proses analisa data maka pada penelitian ini akan menggunakan beberapa skenario percobaan guna mengetahui hasil dari klasifikasi dengan menggunakan model algoritma yang akan digunakan. Skenario penelitian terdiri dari beberapa percobaan sebagai berikut:

a. Skenario percobaan 1

Pada skenario percobaan pertama merupakan skenario yang dilakukan terhadap data awal (data raw) dan data yang telah diseimbangkan dengan menggunakan metode penyeimbangan data yang telah ditentukan. Percobaan ini menggunakan dua model algoritma dari CNN yaitu InceptionV3 dan Resnet50. Pada percobaan ini dilakukan untuk menganalisa mengenai dampak dari penggunaan dataset yang tidak seimbang pada setiap kelasnya dan untuk mengetahui hasil terhadap penggunaan data yang memiliki persebaran data yang seimbang pada setiap kelasnya. Pada skenario ini juga digunakan untuk mengetahui masing-masing performa dari algoritma yang telah ditentukan.

b. Skenario percobaan 2


Skenario percobaan kedua merupakan skenario yang dilakukan dengan menerapkan augmentasi data, penggunaan augmentasi data yang berbeda akan digunakan untuk menganalisa dampak dari penggunaan augmentasi data yang berbeda terhadap masing-masing model algoritma yang akan digunakan yaitu InceptionV3 dan Resnet50 serta untuk mengetahui tingkat performa dari setiap model algoritma. Adapun beberapa augmentasi yang akan digunakan pada skenario ini dapat dilihat pada tabel 4.2.



Tabel 4. 2 Skenario percobaan 2

No	Skenario	Augmentasi Data
1	Augmentasi Pertama	<i>zoom, rotation, horizontal flip</i>
2	Augmentasi Kedua	<i>zoom, rotation, vertical flip, horizontal flip</i>
3	Augmentasi Ketiga	<i>zoom, rotation, vertical flip, horizontal flip, width shift range</i>
4	Augmentasi Keempat	<i>zoom, rotation, vertical flip, horizontal flip, width shift range, height shift range</i>


Setiap skenario yang diujikan akan menggunakan pendekatan yang sama pada setiap model algoritma yang digunakan, dimana pada arsitektur InceptionV3 dan Resnet50 menggunakan gambar input dengan ukuran 224 x 224 piksel serta melakukan normalisasi nilai piksel agar berada dalam rentang 0 hingga 1.



Gambar 4. 8 Alur Percobaan

Kemudian dilakukan proses untuk ekstraksi fitur dari gambar pada blok yang terdapat didalam model InceptionV3 dan Resnet50, dimana pada proses

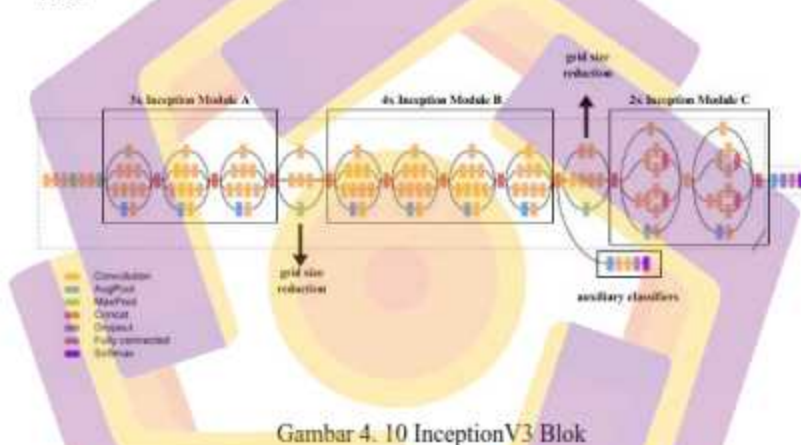
Resnet50 akan melewati lapisan konvolusi pertama dengan ukuran  $7 \times 7$ , serta 64 filter dan 2 langkah untuk ekstraksi fitur-fitur awal pada gambar. Setelah lapisan pertama, gambar akan melewati lapisan Max pooling dengan kernel ukuran  $3 \times 3$  dan 2 langkah. Setelah itu pada blok pertama terdiri dari tiga lapisan konvolusi yang terdiri dari lapisan konvolusi  $1 \times 1$  dengan 64 filter, lapisan konvolusi  $3 \times 3$  dengan 64 filter dan  $1 \times 1$  dengan 128 filter. Pada blok kedua terdiri dari lapisan konvolusi  $1 \times 1$  dengan 128 filter, lapisan konvolusi  $3 \times 3$  dengan 128 filter dan  $1 \times 1$  dengan 512 filter. Pada blok selanjutnya terdiri dari lapisan konvolusi  $1 \times 1$  dengan 256 filter, lapisan konvolusi  $3 \times 3$  dengan 256 filter dan  $1 \times 1$  dengan 1024 filter. Lalu pada blok terakhir terdiri dari lapisan konvolusi  $1 \times 1$  dengan 512 filter, lapisan konvolusi  $3 \times 3$  dengan 512 filter dan  $1 \times 1$  dengan 2048 filter, hal tersebut dapat dilihat sesuai dengan blok proses yang terdapat pada gambar 4.9.



Gambar 4. 9 Resnet50 Blok

Pada proses inceptionV3 terdapat beberapa lapisan dimana setelah melewati beberapa lapisan konvolusi selanjutnya akan masuk kedalam lapisan modul inception dimana terdapat 3 blok lapisan, selanjutnya setelah melewati lapisan modul inception pertama akan masuk kedalam grid size reduction untuk mengurangi dimensi spasial dari fitur yang diekstraksi. Kemudian setelah dilakukan

pengurangan dimensi gambar akan masuk kedalam lapisan 4 blok module inception dan selanjutnya gambar akan melalui proses auxiliary classifiers, untuk mengurangi risiko masalah pemudaran gradien (vanishing gradient problem) saat melatih jaringan yang sangat dalam, setelah itu gambar akan masuk kedalam lapisan grid size reduction yang kedua. Terakhir gambar akan diproses pada lapisan 2 blok module inception C untuk ekstraksi fitur. Proses tersebut dapat dilihat pada gambar 4.10.



Gambar 4. 10 InceptionV3 Blok

Setelah melakukan ekstraksi fitur kemudian menggunakan tambahan lapisan layer GlobalAveragePooling2D yang memiliki fungsi untuk mengurangi dimensi data tanpa menambahkan parameter lainnya sehingga menghasilkan vektor fitur yang lebih ringkas. Selanjutnya menambahkan lima lapisan layer yang dilakukan setelah lapisan layer GlobalAveragePooling2D, lapisan pertama menggunakan lapisan dense dengan 512 unit dan menggunakan fungsi aktivasi relu, pada lapisan kedua menambahkan lapisan Dropout dengan rate 0,5 setelah lapisan dense pertama yang akan secara acak membuat sekitar 50% neuron tidak aktif pada

setiap iterasi selama pelatihan data. Pada lapisan ketiga akan menggunakan lapisan dense dengan nilai unit 256 dan fungsi aktivasi relu, kemudian pada lapisan keempat menambahkan lapisan Dropout dengan rate 0,5. Pada akhir lapisan yang akan digunakan yaitu lapisan dense dengan 4unit dan fungsi aktivasi softmax, hal tersebut memungkinkan model untuk melakukan prediksi terhadap empat kelas yang akan digunakan.

Pada alur percobaan yang telah dijelaskan diatas menunjukan bahwa model arsitektur Resnet50 memiliki model struktur yang lebih sederhana dibandingkan dengan model arsitektur InceptionV3, pada model Resnet50 juga terdapat blok residu yang efektif menangani *vanishing gradient*, serta efisiensi parameter. Sedangkan pada InceptionV3 merupakan model yang memiliki fleksibilitas ekstraksi fitur yang tinggi, sehingga memiliki keuntungan terutama untuk tugas-tugas yang memerlukan pemrosesan dengan fitur yang kompleks.

Setelah menentukan model arsitektur yang akan digunakan, selanjutnya adalah menentukan kompilasi model dimana pada tahap ini digunakan untuk menentukan bagaimana model akan belajar dan menentukan kinerja model yang akan diukur. Kompilasi model dilakukan dengan menggunakan *optimizer Adam*, serta menggunakan fungsi *loss categorical\_crossentropy* dan menggunakan *metrics accuracy* untuk mengawasi kinerja model selama proses pelatihan dan validasi pada proses klasifikasi.



#### **4.4. Pembahasan Hasil Penelitian**

Proses klasifikasi penyakit ayam berdasarkan citra fesesnya dilakukan dengan menggunakan beberapa skenario percobaan yang telah ditentukan, Hasil dari percobaan yang telah dilakukan selanjutnya akan dijelaskan dan dilakukan proses analisa terhadap faktor apa saja yang mempengaruhi performa dari setiap model algoritma yang digunakan untuk proses klasifikasi. Untuk mengetahui tingkat performa dari setiap model algoritma yang akan digunakan, metode pengujian yang digunakan pada adalah dengan menggunakan Confusion Matrix, dengan menggunakan metode dapat memberikan nilai akurasi, precision, recall, fl-score yang dapat digunakan untuk mengetahui performa dari model algoritma untuk proses klasifikasi penyakit ayam.

##### **4.4.1. Hasil Pelatihan Model**

Hasil pelatihan dari model algoritma yang digunakan telah dilakukan sesuai dengan skenario yang ditentukan dalam penelitian ini, sehingga hasil dari pelatihan data training dan data validasi pada masing-masing skenario dapat dilakukan proses analisa untuk mengetahui performa setiap model algoritma pada masing-masing skenario percobaan.


###### **4.4.1.1. Pelatihan Skenario 1**

Pada skenario pertama adalah dengan melakukan percobaan dengan menggunakan dataset asli dan dataset yang telah dilakukan proses penyeimbangan data. Pada percobaan ini dilakukan untuk mengetahui tingkat performa pelatihan




model InceptionV3 dan Resnet50 dengan menampilkan grafik accuracy data pelatihan dan data validasi serta menampilkan grafik loss data pelatihan dan data validasi.

Percobaan pertama dilakukan dengan menggunakan arsitektur InceptionV3 dimana menghasilkan akurasi data pelatihan sebesar 96,60% dan data validasi sebesar 93,30%, untuk nilai loss pada data pelatihan 9,24% dan untuk data validasi sebesar 19,80%. Pada gambar 4.8 dapat dilihat dari grafik pelatihan bahwa percobaan dengan menggunakan InceptionV3 cenderung memiliki masalah overfitting.




Gambar 4.11 Grafik accuracy dan loss InceptionV3 pada data asli

Percobaan selanjutnya dilakukan dengan menggunakan model arsitektur Resnet50, pada model tersebut menghasilkan nilai akurasi pada data pelatihan sebesar 98,10% dan data validasi sebesar 94,17%, kemudian untuk nilai loss dari hasil data pelatihan memiliki nilai 5,22% dan 22,47% pada data validasi. Grafik accuracy dan loss pada arsitektur Resnet50 dapat dilihat pada gambar 4.9.




Gambar 4.12 Grafik accuracy dan loss Resnet50 pada data asli

Kemudian pada percobaan yang dilakukan dengan data yang telah diseimbangkan dengan menggunakan InceptionV3 menghasilkan grafik akurasi dan loss yang lebih baik, dimana pada gambar 4.10 menunjukkan grafik dari model data yang dilatih tanpa mengalami masalah overfitting. Pada model data yang dilatih dengan menggunakan data yang seimbang menghasilkan nilai akurasi pada data pelatihan memiliki sebesar 96,73% dan 96,19 % pada data validasi, kemudian untuk nilai loss terhadap data yang dilatih memiliki nilai sebesar 9,48% untuk data pelatihan dan 12,81% untuk data validasi.



Gambar 4.13 Grafik accuracy dan loss InceptionV3 pada data yang telah diseimbangkan

Pada percobaan dengan menggunakan Resnet50, pelatihan model dengan menggunakan data yang telah diseimbangkan menghasilkan nilai akurasi pada data pelatihan sebesar 98,42% dan pada data validasi sebesar 97,04%. Tingkat performa dari akurasi model pelatihan diketahui dari grafik gambar 4.11.



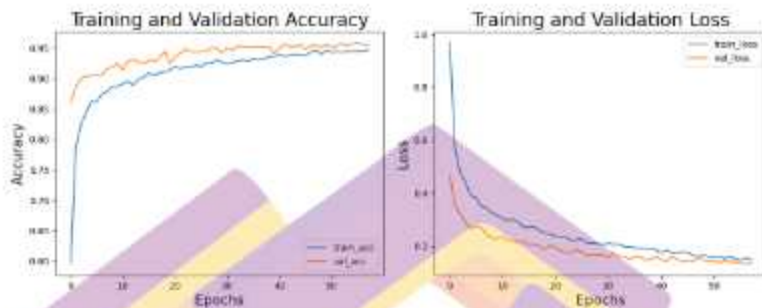
Gambar 4. 14 Grafik accuracy dan loss Resnet50 pada data yang telah diseimbangkan

#### 4.4.1.2. Pelatihan Skenario 2

Pada skenario kedua merupakan percobaan yang dilakukan dengan menggunakan teknik augmentasi data yang telah ditentukan. Pada percobaan ini dilakukan untuk mengetahui dampak dari augmentasi data terhadap tingkat performa model InceptionV3 dan Resnet50.


Percobaan pada augmentasi data pertama yang dilakukan pada skenario ketiga ini adalah dengan menggunakan aritektur InceptionV3 terhadap data yang telah diseimbangkan dengan menggunakan augmentasi data *zoom*, *rotation*, dan *horizontal flip*. Pada percobaan ini berhasil mendapatkan tingkat akurasi pada model pelatihan, dimana data pelatihan mendapatkan akurasi sebesar 96,13%, sebaliknya tingkat akurasi pada data validasi sebesar 95,52%. nilai loss yang

didapatkan pada data pelatihan sebesar 11,13% dan data validasi sebesar 13,56%. Mengenai grafik dari model pelatihan data dapat dilihat pada gambar 4.12.




Gambar 4. 15 Grafik skenario 2 InceptionV3 augmentasi pertama

Percobaan dengan menggunakan Resnet50 menunjukkan nilai akurasi yang didapatkan pada data pelatihan sebesar 99,01% dan pada data validasi sebesar 96,66%. Kemudian nilai loss yang diperoleh pada data validasi berhasil mendapatkan penurunan yang baik dimana pada data validasi mendapatkan nilai loss sebesar 9,89% sedangkan pada data pelatihan sebesar 3,24%. Gambar 4.13 merupakan grafik performa dari pelatihan model yang dilakukan.



Gambar 4.16 Grafik skenario 2 Resnet50 augmentasi pertama


Percobaan augmentasi kedua dilakukan dengan menggunakan augmentasi *zoom*, *rotation*, *vertical flip* dan *horizontal flip*, dengan menggunakan dataset yang telah diseimbangkan. Dengan menggunakan model InceptionV3 menghasilkan nilai akurasi pada data pelatihan sebesar 96,38% dan data validasi sebesar 96,28%, untuk nilai loss yang dihasilkan pada data pelatihan dan data validasi adalah 10,19% dan 11,50 %. Mengenai grafik kinerja dari model pelatihan dapat dilihat pada gambar 4.15.



Gambar 4.17 Grafik skenario 2 InceptionV3 augmentasi kedua


Kemudian percobaan berikutnya dilakukan dengan menggunakan arsitektur Resnet50. Performa dari model pelatihan dapat dilihat pada grafik gambar 4.17, dimana pada percobaan ini mendapatkan nilai akurasi pada data pelatihan sebesar 98,27% sedangkan pada data validasi mendapatkan nilai akurasi sebesar 97,14%. Kemudian untuk nilai loss pada data pelatihan dan data validasi menghasilkan nilai sebesar 4,97% dan 10,59%.






Gambar 4.18 Grafik skenario 2 Resnet50 augmentasi kedua

Selanjutnya pada percobaan augmentasi data ketiga dengan menggunakan perubahan augmentasi data yaitu *zoom*, *rotation*, *vertical flip*, *horizontal flip* dan *width shift range*. Percobaan pertama dilakukan dengan menggunakan model InceptionV3. Pada percobaan ini memiliki tingkat performa yang dapat dilihat sesuai grafik model pelatihan pada gambar 4.20, nilai akurasi yang dihasilkan pada data pelatihan sebesar 94,98% dan nilai pada data validasi adalah 95,33%, kemudian nilai loss yang pada data pelatihan adalah 14,22% dan 15,28% pada data validasi.




Gambar 4.19 Grafik skenario 2 InceptionV3 augmentasi ketiga

Selanjutnya percobaan dilakukan dengan menggunakan model Resnet50. Pada percobaan ini tingkat performa akurasi dari data pelatihan dan data validasi yang dihasilkan sebesar 97,34% dan 96,76%, dan nilai loss pada data pelatihan adalah 7,45% dan pada data validasi sebesar 9,65%. Mengenai performa dari percobaan pada model pelatihan data yang dilakukan dapat dilihat pada gambar 4.22.




Gambar 4.20 Grafik skenario 2 Resnet50 augmentasi ketiga

Percobaan dengan menggunakan augmentasi data keempat dilakukan dengan menggunakan augmentasi *zoom*, *rotation*, *vertical flip*, *horizontal flip*, *width shift range* dan *height shift range*. Percobaan pertama dilakukan dengan menggunakan InceptionV3. Percobaan ini menghasilkan nilai akurasi dari data validasi sebesar 95,01% dan pada data pelatihan sebesar 95,33%, kemudian nilai loss yang dihasilkan pada data pelatihan adalah 14,11% dan 15,43% pada data validasi. Performa dari model pelatihan data dapat dilihat pada gambar 4.23.



Gambar 4.21 Grafik skenario 2 InceptionV3 augmentasi keempat

Selanjutnya pada percobaan yang dilakukan adalah dengan menggunakan model Resnet50, dimana pada arsitektur ini menghasilkan nilai akurasi pada data pelatihan sebesar 96,82% dan data validasi sebesar 96,38%, kemudian nilai loss yang dihasilkan sebesar 8,63% pada data pelatihan dan 11,30% pada data validasi. Tingkat performa dari grafik model pelatihan dapat dilihat pada gambar 4.26.



Gambar 4. 22 Grafik skenario 2 Resnet50 augmentasi keempat

#### 4.4.2. Hasil Pengujian Model

Setelah dilakukan proses pelatihan model pada masing-masing skenario, kemudian akan dilakukan proses pengujian untuk mengetahui tingkat akurasi dan kinerja masing-masing model dalam melakukan proses klasifikasi penyakit ayam berdasarkan citra fesusnya. Pada pengujian yang dilakukan terhadap model menggunakan *Confusion matrix*, dimana metode tersebut digunakan untuk mengukur kinerja dari sebuah model klasifikasi. Hasil pengujian yang telah dilakukan, menunjukkan tingkat performa dari proses klasifikasi pada setiap skenario. Pada hasil pengujian skenario pertama setiap model dapat dilihat pada tabel 4.3.

Tabel 4.3 Hasil Pengujian Skenario 1

Skenario	Model	Accuracy	Precision	Recall	F1-score
Data Asli	InceptionV3	92,94%	93,81%	87,81%	90,07%
	Resnet50	92,06%	92,55%	85,36%	87,69%
Data Seimbang	InceptionV3	95,14%	95,13%	95,14%	95,13%
	Resnet50	96,38%	96,38%	96,37%	96,37%

Kemudian hasil pengujian yang dilakukan pada skenario kedua dimana menggunakan beberapa augmentasi data yang telah ditentukan, mendapatkan hasil yang dapat dilihat pada tabel 4.4.

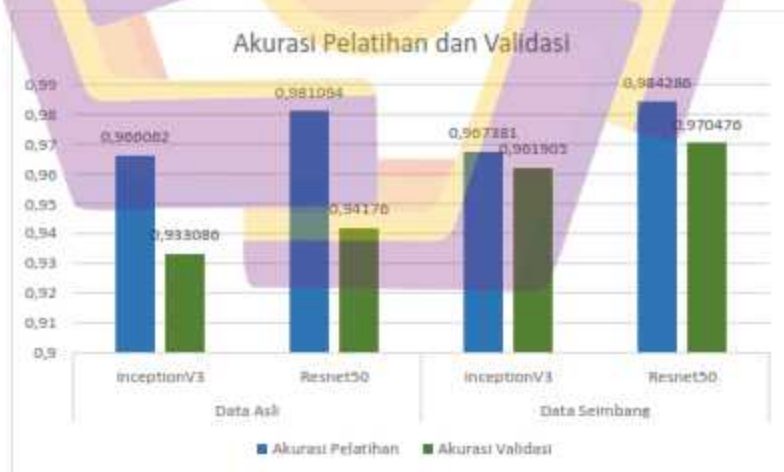
Tabel 4. 4 Hasil pengujian Skenario 2

Skenario	Model	Accuracy	Precision	Recall	F1-score
Augmentasi Pertama	InceptionV3	93,62%	93,65%	93,62%	93,63%
	Resnet50	96,38%	96,40%	96,36%	96,38%
Augmentasi Kedua	InceptionV3	95,33%	95,36%	95,32%	95,33%
	Resnet50	95,33%	95,34%	95,33%	95,33%
Augmentasi Ketiga	InceptionV3	94,10%	94,12%	94,08%	94,10%
	Resnet50	96,29%	96,29%	96,30%	96,28%
Augmentasi Keempat	InceptionV3	93,71%	93,72%	93,73%	93,72%
	Resnet50	95,33%	95,34%	95,35%	95,33%

Hasil yang dipaparkan pada tabel 4.3 dan tabel 4.4 merupakan hasil pengujian model yang telah dilakukan sesuai dengan skenario yang telah ditentukan. Pada pengujian model yang dilakukan digunakan untuk mengetahui tingkat performa dari setiap arsitektur, dengan menampilkan nilai *accuracy*, *precision*, *recall* dan *f1-score*.

#### 4.4.3. Perbandingan jumlah dataset

Pada percobaan skenario satu merupakan percobaan yang dilakukan untuk melihat hasil dan perbandingan mengenai tingkat performa dari model arsitektur terhadap data yang tidak seimbang dan data yang seimbang. Pada skenario tersebut dilakukan proses klasifikasi dengan menggunakan data yang tidak seimbang, kemudian proses klasifikasi juga dilakukan dengan menggunakan data yang telah diseimbangkan.



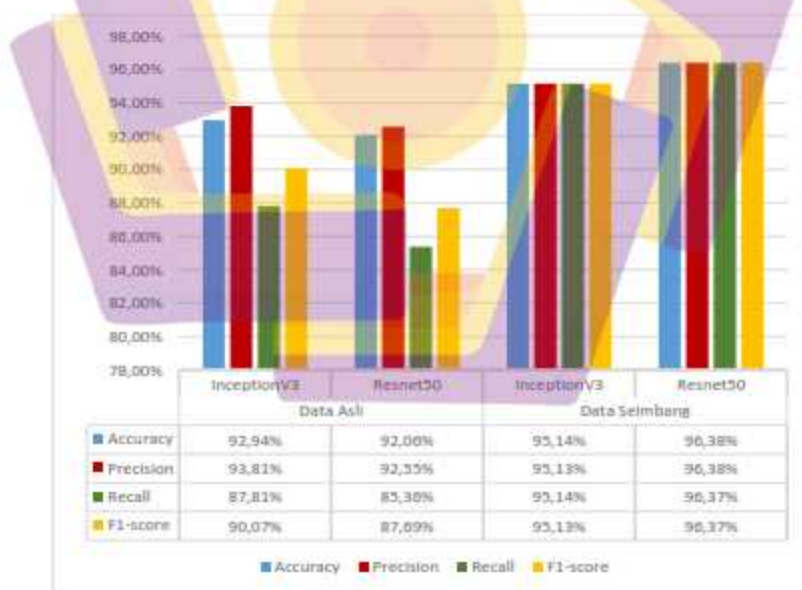
Gambar 4. 23 Perbandingan akurasi pelatihan data asli dengan data seimbang



Pada gambar 4.27 merupakan grafik perbandingan antara model pelatihan dengan menggunakan data yang tidak seimbang dan data seimbang dengan grafik batang berwarna biru merupakan tingkat akurasi data pelatihan dan grafik batang berwarna hijau merupakan tingkat akurasi pada data validasi. Percobaan yang terhadap data yang tidak seimbang, cenderung memiliki masalah overfitting baik itu pada model Resnet50 maupun InceptionV3. Overfitting sendiri terjadi karena data pelatihan yang memiliki ukuran terbatas sehingga menyebabkan model menjadi terlalu rumit dan memiliki banyak noise atau batasan algoritma (Ying, 2019). Masalah overfitting terlihat sangat jelas terutama pada model InceptionV3 hal tersebut dapat dilihat pada gambar 4.8, dimana parameter jaringan yang diperoleh setelah pelatihan tidak dapat secara akurat melakukan distribusi ke data baru atau sejumlah besar data memiliki noise selama proses pelatihan (Xiao et al., 2021). Kemudian percobaan dengan menggunakan data yang telah diseimbangkan yang dilakukan dengan menggunakan data yang telah diseimbangkan, memiliki grafik yang menunjukkan bahwa kinerja dari proses pelatihan lebih konsisten antara data pelatihan dan validasi yang terjadi pada model InceptionV3, hal tersebut dapat dilihat pada gambar 4.10 yang merupakan grafik hasil percobaan dengan menggunakan data yang telah diseimbangkan. Pada percobaan yang dilakukan dengan menyeimbangkan data pada setiap kelasnya dapat diketahui bahwa memiliki dampak yang signifikan terhadap model data yang dilatih, selain memperbaiki overfitting yang terjadi pada percobaan sebelumnya, model data yang dilatih dengan menggunakan data yang seimbang mengalami kenaikan tingkat

peforma dimana nilai akurasi pada data terutama pada data validasi. Pada grafik gambar 4.27 dalam perbandingan akurasi pelatihan menunjukkan bahwa model arsitektur Resnet50 selalu memiliki nilai akurasi model pelatihan yang lebih tinggi daripada model arsitektur InceptionV3.

Kemudian hasil pengujian yang dilakukan dengan menggunakan *confusion matrix* yang terdapat pada gambar 4.24. Dimana grafik tersebut merupakan perbandingan antara model klasifikasi dengan menggunakan data tidak seimbang dan data yang seimbang. Pada grafik batang berwarna biru menunjukkan nilai *akurasi*, kemudian grafik dengan warna merah menunjukkan nilai *precision*, lalu pada grafik batang dengan warna hijau menunjukkan nilai *recall*, dan yang terakhir grafik batang dengan warna kuning menunjukkan nilai *F1-score*.



Gambar 4. 24 Grafik perbandingan pengujian skenario 1

Hasil pengujian yang dilakukan menunjukkan bahwa model pengujian dengan menggunakan data yang telah diseimbangkan menunjukkan hasil klasifikasi dengan kinerja yang lebih stabil dan konsisten dengan memiliki sedikit variasi nilai dalam *matrix* seperti nilai *accuracy*, *precision recall* dan *f1-score*. Hal tersebut juga menunjukkan bahwa dengan menggunakan data yang telah diseimbangkan dapat meningkatkan tingkat performa terhadap masing-masing model arsitektur yang digunakan. Sebaliknya dengan menggunakan data awal yang belum diseimbangkan ketidakstabilan performa pengujian terhadap data yang diuji, hal tersebut dilihat bahwa nilai *recall* yang dihasilkan cukup rendah pada kedua model arsitektur yang digunakan. Nilai *recall* sendiri merupakan kemampuan dari suatu model untuk menemukan kembali data yang sesungguhnya. Jadi dampak yang dialami jika menggunakan data yang tidak seimbang adalah data pengujian akan kesulitan untuk menemukan kembali data yang sebenarnya hal tersebut disebabkan oleh kelas yang memiliki jumlah data paling sedikit dibandingkan dengan kelas lainnya.

Pada pengujian ini model Resnet50 lebih unggul dibandingkan dengan InceptionV3 baik itu pada pengujian dengan menggunakan data yang tidak seimbang maupun dengan data yang seimbang.

#### **4.4.4. Perbandingan augmentasi data**

Penggunaan augmentasi data memiliki tujuan untuk mengolah dataset sesuai dengan keperluan yang akan digunakan dalam penelitian. Pada augmentasi data pertama sampai dengan augmentasi data keempat merupakan percobaan yang dilakukan untuk mengetahui teknik augmentasi data apa saja yang dapat digunakan

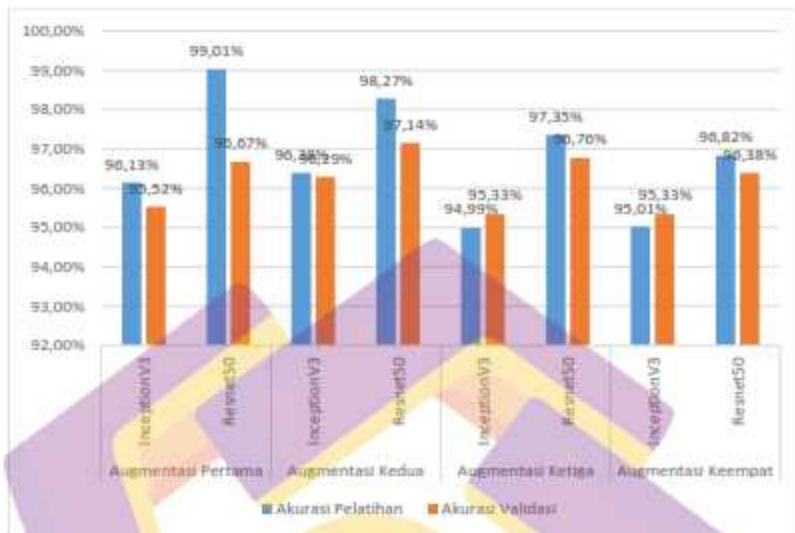
serta memiliki tingkat peforma yang tinggi untuk klasifikasi penyakit ayam berdasarkan citra fesses, hal tersebut dilakukan karena tidak semua teknik augmentasi dapat digunakan pada karakteristik dataset yang akan digunakan, pada satu sisi melakukan augmentasi yang sederhana dapat menghasilkan pelatihan yang rendah dan tidak dapat meningkatkan peforma model, pada sisi lain augmentasi yang rumit memiliki efek yang besar sehingga merugikan peforma model (L. Zhang & Ma, 2023).

Tabel 4. 5 Augmentasi skenario

No	Skenario	Augmentasi
1	Augmentasi pertama	Zoom, rotation, horizontal flip
2	Augmentasi kedua	Zoom, rotation, vertical flip, horizontal flip
3	Augmentasi ketiga	Zoom rotation, vertical flip, horizontal flip, width shift range
4	Augmentasi keempat	Zoom rotation, vertical flip, horizontal flip, width shift range, height shift range

Percobaan augmentasi data yang dilakukan dapat dilihat pada tabel 4.5, dimana setiap percobaan yang dilakukan menggunakan data yang telah dilakukan proses penyeimbangan data terlebih dahulu, karena dengan menggunakan data yang telah diseimbangkan menunjukan hasil klasifikasi dengan kinerja yang lebih stabil dan konsisten dengan memiliki sedikit variasi nilai dalam peforma model yang digunakan.





Gambar 4. 25 Perbandingan akurasi pelatihan.

Tingkat performa dari hasil percobaan model pelatihan data dari beberapa penggunaan teknik augmentasi dapat dilihat pada gambar 4.22, grafik tersebut menunjukkan performa dari akurasi pelatihan model pada setiap skenario yang dilakukan. Pada percobaan augmentasi pertama sampai dengan augmentasi keempat dapat dilihat bahwa performa pelatihan dari arsitektur InceptionV3 memiliki nilai akurasi yang lebih rendah dari pada arsitektur Resnet50. Pada augmentasi data pertama dengan menggunakan arsitektur InceptionV3 menghasilkan nilai akurasi pelatihan sebesar 96,13% kemudian pada arsitektur Resnet50 menghasilkan nilai akurasi pada model pelatihan sebesar 99,01%. Pada augmentasi data kedua arsitektur InceptionV3 menghasilkan peningkatan performa pada model pelatihan dimana nilai akurasi yang dihasilkan sebesar 96,38% akan tetapi apabila arsitektur Resnet50 mengalami penurunan tingkat performa pelatihan



dengan menghasilkan nilai akurasi 98,27%. Pada percobaan dengan menggunakan augmentasi data ketiga model arsitektur InceptionV3 menghasilkan nilai akurasi paling rendah dibandingkan dengan skenario sebelumnya dimana nilai akurasi yang didapatkan sebesar 94,99% dan pada arsitektur Resnet50 menghasilkan akurasi sebesar 97,35%. Kemudian pada augmentasi keempat model arsitektur Resnet50 menghasilkan nilai akurasi paling rendah dibandingkan dengan skenario sebelumnya dengan nilai akurasi sebesar 96,82% dan pada model arsitektur InceptionV3 menghasilkan nilai akurasi sebesar 95,01%.

Hasil percobaan yang dilakukan pada model pelatihan data menunjukkan bahwa model arsitektur InceptionV3 mendapatkan nilai akurasi paling tinggi pada augmentasi data kedua dimana augmentasi yang digunakan adalah *zoom, rotation, vertical flip, horizontal flip*, kemudian nilai akurasi terendah dihasilkan dari percobaan augmentasi data ketiga dimana augmentasi data yang digunakan adalah *zoom rotation, vertical flip, horizontal flip, width shift range*. Pada model arsitektur Resnet50 tingkat performa tertinggi dalam model pelatihan data diperoleh pada augmentasi data pertama dimana augmentasi data yang digunakan adalah *zoom, rotation, horizontal flip*, kemudian performa terendah dihasilkan pada augmentasi data keempat dengan augmentasi data *zoom rotation, vertical flip, horizontal flip, width shift range, height shift range*.

Setelah dilakukan percobaan dengan melakukan pelatihan model terhadap data, langkah selanjutnya adalah dengan melakukan pengujian terhadap data pada masing-masing skenario. Perbandingan dari hasil pengujian dari beberapa

penggunaan augmentasi data sesuai dengan skenario percobaan yang dilakukan dapat dilihat pada gambar 4.23.



Gambar 4. 26 perbandingan hasil pengujian

Pada grafik berwarna biru menunjukan nilai akurasi dari pengujian model, kemudian warna merah menunjukkan nilai dari presisi, selanjutnya warna abu-abu mewakili dari nilai *recall* dan yang terakhir warna kuning adalah nilai dari F1-score. Pada hasil pengujian dengan augmentasi data pertama dapat dilihat bahwa model arsitektur Resnet50 memiliki tingkat performa yang lebih baik dibandingkan dengan model InceptionV3, dengan hasil pengujian dengan menggunakan model Resnet50 sebesar 96,38% pada akurasi, 96,40% pada precision, 96,36% pada recall dan 96,38% pada F1-score. Kemudian pada model InceptionV3 menghasilkan nilai akurasi 93,62%, nilai precision 93,65%, nilai recall 93,62% dan F1-score 93,63%. Pada augmentasi data kedua model Resnet50 dan InceptionV3 memiliki performa

pengujian yang hampir sama, dimana pada model Resnet50 nilai akurasi yang dihasilkan sebesar 95,33%, nilai precision sebesar 95,34, nilai recall sebesar 95,33% dan F1-score sebesar 95,33%. Kemudian pada model InceptionV3 menghasilkan nilai akurasi sebesar 95,33%, nilai precision sebesar 95,36%, nilai recall sebesar 95,32% dan F1-score sebesar 95,33%. Pada augmentasi data ketiga arsitektur InceptionV3 menghasilkan nilai akurasi sebesar 94,10%, nilai precision sebesar 94,12%, nilai recall sebesar 94,08% dan F1-score sebesar 94,10%. Kemudian pada model Resnet50 menghasilkan nilai akurasi sebesar 96,29%, nilai precision sebesar 96,29%, nilai recall sebesar 96,30% dan F1-score sebesar 96,28%. Pada augmentasi data keempat model InceptionV3 menghasilkan nilai akurasi sebesar 93,71%, nilai precision sebesar 93,72%, nilai recall sebesar 93,73% dan F1-score sebesar 93,72%. Selanjutnya pada model Resnet50 menghasilkan nilai akurasi sebesar 95,33%, nilai precision sebesar 95,34%, nilai recall sebesar 95,35% dan F1-score sebesar 95,33%.

Hasil percobaan pengujian yang dilakukan menunjukkan bahwa pada model pengujian dengan menggunakan Resnet50 menghasilkan performa paling tinggi pada augmentasi data pertama dimana augmentasi data yang digunakan adalah zoom, rotation, horizontal flip dan pada model InceptionV3 mendapatkan performa paling tinggi pada augmentasi data ketiga dengan menggunakan augmentasi data zoom, rotation, vertical flip, horizontal flip.

#### **4.4.5. Hasil Analisis Penelitian Terkait**

Berdasarkan pada penelitian (Kholil et al., 2022) yang melakukan proses klasifikasi citra feses berdasarkan empat kelas dengan menggunakan CNN

menghasilkan akurasi pengujian sebesar 95.28%. Pada penelitian yang dilakukan dengan menggunakan model arsitektur Resnet50 dan InceptionV3 memberikan hasil akurasi pengujian yang lebih tinggi, hal tersebut dapat dilihat pada gambar 4.24.



Gambar 4. 27 Perbandingan penelitian sebelumnya

Kemudian terdapat penelitian lain yang dilakukan oleh (Mbelwa et al., 2021) dengan melakukan klasifikasi terhadap citra feses ayam dengan menggunakan tiga kelas diantaranya health, coccidiosis dan salmonella, dengan jumlah data yang digunakan pada penelitian tersebut cenderung lebih sedikit dimana menggunakan 1590 jumlah data. Pada penelitian tersebut menggunakan model arsitektur XceptionNet dengan menghasilkan akurasi pelatihan sebesar 93,76% dan akurasi validasi sebesar 94%. Kemudian penelitian yang dilakukan memberikan hasil akurasi pelatihan dan hasil akurasi dari validasi data lebih besar dibandingkan penelitian sebelumnya, hal tersebut dapat dilihat pada gambar 4.25.





Gambar 4. 28 Perbandingan penelitian sebelumnya

Dengan menggunakan skenario penyeimbangan jumlah data dan menggunakan beberapa variasi augmentasi data terbukti meningkatkan tingkat performa proses klasifikasi dibandingkan dengan penelitian yang telah dilakukan sebelumnya, pada penelitian yang dilakukan peneliti menggunakan model arsitektur Resnet50 dan InceptionV3 dimana model Resnet50 memiliki Tingkat performa tertinggi dibandingkan dengan inceptionV3 dan penelitian sebelumnya yang dilakukan oleh (Mbelwa et al., 2021), (Kholil et al., 2022) dan (Widyawati & Gunawan, 2022).

Dari hasil penelitian yang sudah didapatkan terdapat beberapa keterbatasan yang terjadi yaitu terdapat kendala dalam mendapatkan dataset dimana jumlah citra data feses ayam yang didapatkan memiliki jumlah yang beragam dan terdapat salah satu kelas yang mempunyai data paling sedikit dibandingkan dengan kelas yang lainnya, kemudian kualitas citra yang diperoleh tidak konsisten dalam hal resolusi,



penerangan dan kejelasan. Kemudian terdapat kendala dalam menentukan model arsitektur yang digunakan, dimana model arsitektur Resnet50 dan InceptionV3 dapat mudah overfitting disebabkan oleh dataset pelatihan yang tidak cukup seimbang, sehingga dilakukan beberapa percobaan dengan menggunakan layer tambahan untuk mengatasi masalah overfitting dan digunakan untuk meningkatkan akurasi dari kinerja model arsitektur yang digunakan.

Dengan segala percobaan yang telah dilakukan mulai dari mendefinisikan permasalahan hingga mendapatkan hasil penelitian maka sistem yang diusulkan dikembangkan untuk mengatasi masalah kesalahan manusia selama pemeriksaan yang rumit dan kompleks yang diperlukan untuk pemeriksaan laboratorium ayam. Penelitian ini memiliki tujuan untuk mengidentifikasi penyakit unggas yang paling umum, Coccidiosis, Salmonella, dan Penyakit New Castle dari citra feses ayam. Sistem yang dikembangkan dapat digunakan di peternakan unggas untuk membantu peternak dan dokter hewan. Hal ini juga dapat digunakan sebagai dasar bagi peneliti lain untuk perbaikan sistem lebih lanjut serta melakukan pengumpulan dataset yang lebih banyak, khususnya untuk penyakit-penyakit yang tidak dimasukkan dalam penelitian ini dapat meningkatkan akurasi.

## **BAB V**

### **PENUTUP**

#### **5.1. Kesimpulan**

Berdasarkan hasil percobaan yang telah dilakukan terhadap dua model arsitektur yang digunakan, maka dapat disimpulkan bahwa :

1. Penggunaan data yang memiliki ketidakseimbangan dalam persebaran jumlah data dalam setiap kelasnya dapat menimbulkan beberapa permasalahan sehingga dapat mempengaruhi performa dalam proses klasifikasi.
2. Penerapan teknik penyeimbangan data terbukti meningkatkan hasil atau kinerja dari model klasifikasi dimana pada skenario kedua menunjukkan bahwa pada model pelatihan data dan pengujian data menghasilkan hasil akurasi, precision, recall dan F1-Score yang lebih baik dibandingkan dengan menggunakan data yang tidak seimbang.
3. Penerapan augmentasi data memberikan dampak positif dengan menciptakan variasi ditunjukkan meningkatnya tingkat performa dari proses klasifikasi. Pada arsitektur Resnet50 dengan menggunakan augmentasi zoom, rotation, horizontal flip performa pengujian data menghasilkan nilai yang tinggi, kemudian pada arsitektur InceptionV3 dengan menggunakan zoom, rotation, vertical flip, horizontal flip menghasilkan performa yang tinggi dalam pengujian data.

## 5.2. Saran

Adapun beberapa saran bagi pengembangan penelitian yaitu :

1. Melakukan beberapa percobaan terhadap arsitektur dengan menambahkan penggunaan fine tuning agar mendapatkan hasil yang maksimal
2. Melakukan ekstraksi background untuk memisahkan objek yang akan dilakukan klasifikasi dengan menghilangkan atau mengurangi gangguan dari elemen-elemen lain dalam citra, hal tersebut dapat dilakukan pada proses preprocessing data untuk meningkatkan performa dari klasifikasi.
3. Menerapkan beberapa augmentasi data dengan menambahkan beberapa variasi terhadap citra yang digunakan.
4. Mempertimbangkan jumlah data pada setiap kelas yang digunakan agar tidak terjadi perbedaan jumlah data yang cukup besar pada setiap kelas

## DAFTAR PUSTAKA

### PUSTAKA BUKU

- Chollet, F. (2017). *Deep Learning with Python*. Manning.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Primartha, R. (2021). *Algoritma Machine Learning*. INFORMATIKA.
- Russel, S., & Norvig, P. (2010). *Artificial intelligence: a modern approach* (3rd ed.). Prentice Hall.

### PUSTAKA MAJALAH, JURNAL ILMIAH ATAU PROSIDING

- Astill, J., Dara, R. A., Fraser, E. D. G., & Sharif, S. (2018). Detecting and Predicting Emerging Disease in Poultry With the Implementation of New Technologies and Big Data: A Focus on Avian Influenza Virus. *Frontiers in Veterinary Science*, 5. <https://doi.org/10.3389/fvets.2018.00263>
- Blake, D. P., Knox, J., Dehaeck, B., Huntington, B., Rathinam, T., Ravipati, V., Ayoade, S., Gilbert, W., Adebambo, A. O., Jatau, I. D., Raman, M., Parker, D., Rushton, J., & Tomley, F. M. (2020). Re-calculating the cost of coccidiosis in chickens. *Veterinary Research*, 51(1), 115. <https://doi.org/10.1186/s13567-020-00837-2>
- Cadmus, K. J., Mete, A., Harris, M., Anderson, D., Davison, S., Sato, Y., Helm, J., Boger, L., Odani, J., Ficken, M. D., & Pabilonia, K. L. (2019). Causes of mortality in backyard poultry in eight states in the United States. *Journal of Veterinary Diagnostic Investigation*, 31(3), 318–326. <https://doi.org/10.1177/1040638719848718>

- Camara, J., Neto, A., Pires, I. M., Villasana, M. V., Zdravevski, E., & Cunha, A. (2022). A Comprehensive Review of Methods and Equipment for Aiding Automatic Glaucoma Tracking. *Diagnostics*, 12(4). <https://doi.org/10.3390/diagnostics12040935>
- Chigwada, J., Mazunga, F., Nyamhere, C., Mazheke, V., & Taruvinga, N. (2022). Remote poultry management system for small to medium scale producers using IoT. *Scientific African*, 18, e01398. <https://doi.org/https://doi.org/10.1016/j.sciaf.2022.e01398>
- Djara, D. V. S., Ardana, I. B. K., & Winaya, I. B. O. (2020). Perubahan Patologik Sekum Ayam Pedaging (*Gallus gallus*) yang Terinfeksi Koksidiosis di Kabupaten Tabanan, Bali. *Indonesia Medicus Veterinus*, 187–196. <https://doi.org/10.19087/imv.2020.9.2.187>
- Du, X., Carpentier, L., Teng, G., Liu, M., Wang, C., & Norton, T. (2020). Assessment of Laying Hens' Thermal Comfort Using Sound Technology. *Sensors*, 20(2). <https://doi.org/10.3390/s20020473>
- Hadi Nasyuha, A. (2020). *JURNAL MEDIA INFORMATIKA BUDIDARMA Implementasi Teorema Bayes Dalam Diagnosa Penyakit Ayam Broiler*. 4, 1062–1068. <https://doi.org/10.30865/mib.v4i4.2366>
- Hafez, H. M., & Attia, Y. A. (2020). Challenges to the Poultry Industry: Current Perspectives and Strategic Future After the COVID-19 Outbreak. *Frontiers in Veterinary Science*, 7. <https://doi.org/10.3389/fvets.2020.00516>



- Hashmi, M. F., Katiyar, S., Keskar, A. G., Bokde, N. D., & Geem, Z. W. (2020). Efficient Pneumonia Detection in Chest Xray Images Using Deep Transfer Learning. *Diagnostics*, *10*(6). <https://doi.org/10.3390/diagnostics10060417>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- He, P., Chen, Z., Yu, H., Hayat, K., He, Y., Pan, J., & Lin, H. (2022). Research Progress in the Early Warning of Chicken Diseases by Monitoring Clinical Symptoms. *Applied Sciences*, *12*(11). <https://doi.org/10.3390/app12115601>
- Ismail, M., Cahyadi, E. R., & Hardjomidjojo, H. (2019). Manajemen Risiko Penyakit Unggas pada Peternak dan Pedagang Ayam Broiler di Jawa Barat. *MANAJEMEN IKM: Jurnal Manajemen Pengembangan Industri Kecil Menengah*, *14*(1). <https://doi.org/10.29244/mikm.14.1.44-53>
- Isnawati, R., Wuryastuti, H., & Wasito, R. (2019). Peneguhan diagnosis Avian Influenza pada Ayam Petelur yang Mengalami Gejala Penurunan Produksi. *Jurnal Sain Veteriner*, *37*(1). <https://doi.org/10.22146/jsv.40602>
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, *31*(3), 685–695. <https://doi.org/10.1007/s12525-021-00475-2>
- Jiao, L., Zhang, F., Liu, F., Yang, S., Li, L., Feng, Z., & Qu, R. (2019). A Survey of Deep Learning-Based Object Detection. *IEEE Access*, *7*, 128837–128868. <https://doi.org/10.1109/ACCESS.2019.2939201>

- Kholil, Moch., Priya, W. H., & Rafika, A. (2022). Klasifikasi Penyakit Infeksi Pada Ayam Berdasarkan Gambar Feses Menggunakan Convolutional Neural Network. *SINTECH (Science and Information Technology) Journal*, 5(2), 198–204. <https://doi.org/10.31598/sintechjournal.v5i2.1179>
- Kim, H. E., Cosa-Linan, A., Santhanam, N., Jannesari, M., Maros, M. E., & Ganslandt, T. (2022). Transfer learning for medical image classification: a literature review. *BMC Medical Imaging*, 22(1), 69. <https://doi.org/10.1186/s12880-022-00793-7>
- LeCun, Y., Kavukcuoglu, K., & Farabet, C. (2010). Convolutional networks and applications in vision. *Proceedings of 2010 IEEE International Symposium on Circuits and Systems*, 253–256. <https://doi.org/10.1109/ISCAS.2010.5537907>
- Li, W., Xiao, Y., Song, X., Lv, N., Jiang, X., Huang, Y., & Peng, J. (2021). Chicken Image Segmentation via Multi-Scale Attention-Based Deep Convolutional Neural Network. *IEEE Access*, 9, 61398–61407. <https://doi.org/10.1109/ACCESS.2021.3074297>
- Liu, L., Ouyang, W., Wang, X., Fieguth, P., Chen, J., Liu, X., & Pietikäinen, M. (2020). Deep Learning for Generic Object Detection: A Survey. *International Journal of Computer Vision*, 128(2), 261–318. <https://doi.org/10.1007/s11263-019-01247-4>
- Machuve, D., Nwankwo, E., Mduma, N., & Mbelwa, J. (2022). Poultry diseases diagnostics models using deep learning. *Frontiers in Artificial Intelligence*, 5. <https://doi.org/10.3389/frai.2022.733345>

- Mappa, N., Rahmawati, R., & Nurfadillah, N. (2022). ANALISIS RESIKO USAHA AYAM POTONG MANDIRI DAN ALTERNATIF PENANGGULANGANNYA. *Jurnal Sosial Ekonomi Pertanian dan Agribisnis*, 2(1). <https://doi.org/10.26618/agm.v2i1.6891>
- Mbelwa, H., Machuve, D., & Mbelwa, J. (2021). Deep Convolutional Neural Network for Chicken Diseases Detection. *IJACSA*, 12(2). <https://doi.org/10.14569/IJACSA.2021.0120295>
- Mohammed Ahmed, A.-J. A., & Ahmed Abdulaziz, A.-Q. M. (2021). Analysis of Operations of Poultry Farm Using IoT Technology. *2021 2nd International Conference on Big Data Economy and Information Management (BDEIM)*, 336–339. <https://doi.org/10.1109/BDEIM55082.2021.00074>
- Noh, J.-Y., Kim, K.-J., Lee, S.-H., Kim, J.-B., Kim, D.-H., Youk, S., Song, C.-S., & Nahm, S.-S. (2021). Thermal Image Scanning for the Early Detection of Fever Induced by Highly Pathogenic Avian Influenza Virus Infection in Chickens and Ducks and Its Application in Farms. *Frontiers in Veterinary Science*, 8. <https://doi.org/10.3389/fvets.2021.616755>
- Panangian Sinaga, I., Soebroto, A. A., & Cholissodin, I. (2022). *Sistem Pakar untuk Diagnosis Penyakit Ayam menggunakan Metode Certainty Factor (Studi Kasus: Balai Besar Pelatihan Peternakan Batu)* (Vol. 6, Issue 6). <http://j-ptiik.ub.ac.id>

- Revolledo, L. (2018). Vaccines and vaccination against fowl typhoid and pullorum disease: An overview and approaches in developing countries. *JAPR*, 27(3), 279–291. <https://doi.org/https://doi.org/10.3382/japr/pfx066>
- Sahoo, N., Bhuyan, K., Panda, B., Behura, N. C., Biswal, S., Samal, L., Chaudhary, D., Bansal, N., Singh, R., Joshi, V. G., Jindal, N., Mahajan, N. K., Maan, S., Ravishankar, C., Rajasekhar, R., Radzio-Basu, J., Herzog, C. M., Kapur, V., Mor, S. K., & Goyal, S. M. (2022). Prevalence of Newcastle disease and associated risk factors in domestic chickens in the Indian state of Odisha. *PLoS ONE*, 17(2 February). <https://doi.org/10.1371/journal.pone.0264028>
- Santosa, Y. M., Suprpto, S., & Wahyono, W. (2020). An Expert System of Chicken Disease Diagnosis by Using Dempster Shafer Method. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 14(3), 265. <https://doi.org/10.22146/ijccs.55632>
- Sarvamangala, D. R., & Kulkarni, R. V. (2022). Convolutional neural networks in medical image understanding: a survey. *Evolutionary Intelligence*, 15(1), 1–22. <https://doi.org/10.1007/s12065-020-00540-3>
- Sarwinda, D., Paradisa, R. H., Bustamam, A., & Anggia, P. (2021). Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer. *Procedia Computer Science*, 179, 423–431. <https://doi.org/https://doi.org/10.1016/j.procs.2021.01.025>



- Setiadi, A., Santoso, S. I., Nurfadillah, S., Prayoga, K., & Prasetyo, E. (2020). Production and Marketing System of Kampong Chicken in Batang Regency, Central Java, Indonesia. *Caraka Tani: Journal of Sustainable Agriculture*, 35(2), 326. <https://doi.org/10.20961/carakatani.v35i2.40907>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1). <https://doi.org/10.1186/s40537-019-0197-0>
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking the Inception Architecture for Computer Vision. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2818–2826. <https://doi.org/10.1109/CVPR.2016.308>
- Tariq, S., Samad, A., Hamza, M., Ahmer, A., Muazzam, A., Ahmad, S., & Amhabj, A. M. A. (2022). Salmonella in Poultry: An Overview. *International Journal of Multidisciplinary Sciences and Arts*, 1(1), 80–84.
- Wang, J., Shen, M., Liu, L., Xu, Y., & Okinda, C. (2019). Recognition and Classification of Broiler Droppings Based on Deep Convolutional Neural Network. *Journal of Sensors*, 2019, 3823515. <https://doi.org/10.1155/2019/3823515>
- Widyawati, W., & Gunawan, W. (2022). Early detection of sick chicken using artificial intelligence. *Teknika: Jurnal Sains Dan Teknologi*, 18(2), 170–176.



- Wungak, Y. S., Alhassan, A., Judith, D. B., Bitrus, I., Shallangwa, I. B., & Ularamu, H. G. (2022). Detection of Newcastle Disease antibodies amongst local chicken slaughtered in live bird markets in Kaduna, Nigeria. *Nigerian Journal of Basic and Applied Sciences*, 30(1). <https://doi.org/10.4314/njbas.v30i1.1>
- Xiao, M., Wu, Y., Zuo, G., Fan, S., Yu, H., Shaikh, Z. A., & Wen, Z. (2021). Addressing Overfitting Problem in Deep Learning-Based Solutions for Next Generation Data-Driven Networks. *Wireless Communications and Mobile Computing*, 2021, 8493795. <https://doi.org/10.1155/2021/8493795>
- Ying, X. (2019). An Overview of Overfitting and its Solutions. *Journal of Physics: Conference Series*, 1168(2), 22022. <https://doi.org/10.1088/1742-6596/1168/2/022022>
- Zhang, H., & Chen, C. (2020). Design of Sick Chicken Automatic Detection System Based on Improved Residual Network. *Proceedings of 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference*, 2020. <https://doi.org/10.1109/ITNEC48623.2020.9084666>
- Zhang, L., & Ma, K. (2023). A Good Data Augmentation Policy is not All You Need: A Multi-Task Learning Perspective. *IEEE Transactions on Circuits and Systems for Video Technology*, 33(5), 2190–2201. <https://doi.org/10.1109/TCSVT.2022.3219339>
- Zhuang, X., Bi, M., Guo, J., Wu, S., & Zhang, T. (2018). Development of an early warning algorithm to detect sick broilers. *Computers and Electronics in Agriculture*, 144, 102–113. <https://doi.org/https://doi.org/10.1016/j.compag.2017.11.032>

Zhuang, X., & Zhang, T. (2019). Detection of sick broilers by digital image processing and deep learning. *Biosystems Engineering*, 179, 106–116. <https://doi.org/https://doi.org/10.1016/j.biosystemseng.2019.01.003>

