

**KLASIFIKASI SPERMA MANUSIA BERDASARKAN MORFOLOGI
MENGUNAKAN ARSITEKTUR *CONVOLUTIONAL NEURAL
NETWORK* GOOGLNET**

Skripsi

Oleh

SARAH CANTIKA PUTRI

2017051083



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

**KLASIFIKASI SPERMA MANUSIA BERDASARKAN MORFOLOGI
MENGUNAKAN ARSITEKTUR *CONVOLUTIONAL NEURAL*
NETWORK GOOGLNET**

Oleh

**SARAH CANTIKA PUTRI
2017051083**

Skripsi

**Sebagai Salah Satu Syarat untuk Mencapai Gelar
SARJANA KOMPUTER**

Pada

**Program Studi S1 Ilmu Komputer
Fakultas Matematika dan Ilmu Pengetahuan Alam**



**FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS LAMPUNG
BANDAR LAMPUNG
2024**

ABSTRAK

KLASIFIKASI SPERMA MANUSIA BERDASARKAN MORFOLOGI MENGUNAKAN ARSITEKTUR *CONVOLUTIONAL NEURAL NETWORK* GOOGLNET

Oleh

SARAH CANTIKA PUTRI

Infertilitas adalah suatu penyakit yang sering terjadi pada sistem reproduksi pria maupun wanita yang ditandai dengan kegagalan untuk mencapai kehamilan. Permasalahan infertilitas banyak disebabkan oleh faktor pria karena adanya kelainan pada hasil analisis sperma. *Deep Learning* diterapkan untuk memetakan fitur visual dalam melakukan analisis kelainan sperma ke dalam kategori yang sesuai. *Convolutional Neural Network* (CNN) merupakan algoritma pembelajaran yang memiliki kemampuan untuk pemrosesan dan pengenalan citra. Salah satu model arsitektur CNN yaitu GoogleNet diterapkan dalam melakukan klasifikasi sperma berdasarkan morfologi dengan melihat tingkat *accuracy* dan menghitung kinerja model menggunakan *confusion matrix*. Pada penelitian ini terdapat dua macam *dataset* yaitu HuSHeM dan SCIAN-MorphoSpermGS, data yang akan diuji dibagi menjadi data yang menerapkan augmentasi dan data yang tidak menerapkan augmentasi. Berdasarkan hasil pengujian didapatkan hasil bahwa model GoogleNet mendapatkan hasil *accuracy* tertinggi untuk data HuSHeM sebesar 98,46% dan data SCIAN-MorphoSpermGS sebesar 73,38%.

Kata Kunci : Sperma, *Convolutional Neural Network*, GoogleNet, HuSHeM, SCIAN-MorphoSpermGS

ABSTRACT

HUMAN SPERM CLASSIFICATION BASED ON MORPHOLOGY USING GOOGLNET CONVOLUTIONAL NEURAL NETWORK ARCHITECTURE

by

SARAH CANTIKA PUTRI

Infertility is a disease that often occurs in the male and female reproductive system characterized by failure to achieve pregnancy. Many infertility problems are caused by male factors due to abnormalities in sperm analysis results. Deep Learning is applied to map visual features in analyzing sperm abnormalities into appropriate categories. Convolutional Neural Network (CNN) is a learning algorithm that has the ability to process and recognize images. One of the CNN architecture models, GoogleNet, is applied in classifying sperm based on morphology by looking at the accuracy level and calculating the performance of the model using the confusion matrix. In this study there are two kinds of datasets, namely HuSHeM and SCIAN-MorphoSpermGS, the data to be tested is divided into data that applies augmentation and data that does not apply augmentation. Based on the test results, it is found that the GoogleNet model gets the highest accuracy results for HuSHeM data of 98.46% and SCIAN-MorphoSpermGS data of 73.38%.

Keywords: Sperm, Convolutional Neural Network, GoogleNet, HuSHeM, SCIAN-MorphoSpermGS

Judul Skripsi

**: KLASIFIKASIPERMA MANUSIA BERDASARKAN
MORFOLOGI MENGGUNAKAN ARSITEKTUR
CONVOLUTIONAL NEURAL NETWORK
GOOGLENET**

Nama Mahasiswa

: Sarah Cantika Putri

Nomor Pokok Mahasiswa : 2017051083

Program Studi

: S1 Ilmu Komputer

Jurusan

: Ilmu Komputer

Fakultas

: Matematika dan Ilmu Pengetahuan Alam

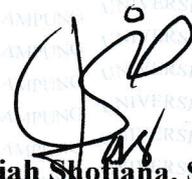
MENYETUJUI

1. Komisi Pembimbing



Dr. Aristoteles, S.Si., M.Si.

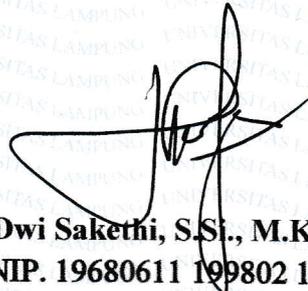
NIP. 19810521 200604 1 002



Dewi Asiah Shofiana, S.Komp., M.Kom

NIP. 19950929 202012 2 030

2. Ketua Jurusan Ilmu Komputer



Dwi Sakethi, S.Si., M.Kom.

NIP. 19680611 199802 1 001

MENGESAHKAN

1. **Tim Penguji**

Ketua : Dr. Aristoteles, S.Si., M.Si.



Sekretaris : Dwi Asiah Shofiana, S.Komp., M.Kom



Penguji Utama : Tristiyanto, S.Kom., M.I.S., Ph.D



2. **Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam**



Dr. Eng. Heri Satria, S.Si., M.Si.

NIP. 19711001 200501 1 002

Tanggal Lulus Ujian Skripsi : 17 Desember 2024

PERNYATAAN

Saya yang bertanda tangan di bawah ini, menyatakan bahwa skripsi saya yang berjudul "**Klasifikasi Sperma Manusia Berdasarkan Morfologi Menggunakan Arsitektur *Convolutional Neural Network* GoogleNet**" merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertuang di skripsi ini telah mengikuti kaidah penulisan karya tulis ilmiah Universitas Lampung. Apabila di kemudian hari terbukti skripsi saya merupakan hasil jiplakan atau dibuat orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang saya terima.

Bandar Lampung, 17 Desember 2024

Penulis,



Sarah Cantika Putri

NPM. 2017051083

RIWAYAT HIDUP



Penulis lahir di Bandar Lampung pada tanggal 24 November 2002 sebagai anak kedua dari pasangan Ekan Budianto dan Eliyana. Penulis telah menyelesaikan pendidikan formal di SD Negeri 2 Sawah Brebes pada tahun 2014. Kemudian SMP Negeri 31 Bandar Lampung pada tahun 2017 dan SMA Negeri 6 Bandar Lampung pada tahun 2020. Penulis terdaftar sebagai mahasiswi program studi Ilmu Komputer di Universitas Lampung melalui jalur tes tertulis atau SBMPTN.

Selama menjadi mahasiswi di Ilmu Komputer, penulis aktif dalam beberapa kegiatan di dalam Universitas Lampung. Kegiatan yang dilakukan adalah sebagai berikut.

1. Menjadi Asisten Dosen mata kuliah Rekayasa Perangkat Lunak di Jurusan Ilmu Komputer pada tahun 2022.
2. Menjadi Asisten Dosen mata kuliah Basis Data di Jurusan Ilmu Komputer pada tahun 2022.
3. Menjadi Anggota Bidang Internal Himpunan Mahasiswa Ilmu Komputer pada tahun 2022.
4. Mengikuti Praktik Kerja Lapangan di PT. Bukit Asam Unit Pelabuhan Tarahan pada tahun 2023.
5. Mengikuti Kuliah Kerja Nyata di Desa Gunung Rejo, Kecamatan Way Lima, Kabupaten Pesawaran pada tahun 2023.

PERSEMBAHAN

Segala puji saya panjatkan kepada Allah SWT atas segala Rahmat-Nya, serta shalawat dan salam senantiasa juga tercurahkan kepada Nabi Muhammad SAW sehingga dapat menyelesaikan skripsi ini.

Skripsi ini saya persembahkan kepada :

Kedua orang tua penulis serta kakak laki-laki penulis yang telah kebersamai serta memberikan dukungan moril maupun materil kepada penulis dalam menyelesaikan skripsi ini, juga untuk diri saya pribadi yang telah berhasil menyelesaikan pendidikan di Ilmu Komputer Universitas Lampung.

MOTTO

" لَا يُكَلِّفُ اللَّهُ نَفْسًا إِلَّا وُسْعَهَا "

“Allah tidak membebani seseorang melainkan sesuai dengan kesanggupannya.”

-Surah Al-Baqarah (Ayat 286)

“Pastikan kamu tidak menyerah apapun situasinya, jangan menyerah meskipun kamu merasa ingin menyerah.”

-Mark Lee

“Usaha membentuk kamu. Suatu hari kamu akan menyesal jika sekarang kamu tidak melakukan yang terbaik. Jangan berpikir bahwa ini sudah terlambat, tapi tetaplah berusaha untuk itu. Itu butuh waktu, tapi tidak ada satupun yang menjadi semakin buruk jika berlatih. Jadi berlatihlah! Kamu mungkin akan merasa tertekan, tapi itu membuktikan bahwa kamu melakukan yang terbaik.”

-Jeon Jungkook

“Jika tujuanmu baik, maka Allah akan memberikan kemudahan bagimu untuk mencapai tujuan tersebut. Dan dibalik semua cobaan yang kamu lalui akan ada hal baik yang menantimu di depan sana.”

-Sarah Cantika Putri

SANCAWACANA

Puji syukur kehadiran Allah SWT. yang telah memberikan rahmat dan hidayah-Nya kepada penulis, sehingga penulis dapat menyelesaikan skripsi ini tepat waktu. Shalawat serta salam penulis sanjungkan kepada Nabi dan Rasul Muhammad SAW yang penulis harapkan syafaatnya di hari akhir kelak.

Skripsi yang berjudul “Klasifikasi Sperma Manusia Berdasarkan Morfologi Menggunakan Arsitektur *Convolutional Neural Network* Googlenet” ini disusun sebagai salah satu syarat untuk memperoleh gelar sarjana jurusan Ilmu Komputer Universitas Lampung. Dalam proses penelitian ini, sangat banyak orang-orang yang terlibat dalam pelaksanaannya. Oleh sebab itu, penulis mengucapkan terima kasih yang sebesar-besarnya kepada:

1. Allah SWT yang telah memberikan hidayah kesehatan dan kemampuan untuk menyelesaikan skripsi ini.
2. Ayahanda penulis Ekan Budianto terima kasih karena selalu senantiasa memberikan dukungan moril, materil, motivasi dan semangat serta dorongan kepada penulis dalam menyelesaikan perkuliahan hingga sampai pada tahap skripsi ini.
3. Ibunda penulis Eliyana terima kasih selalu memberikan dukungan moril, materil, motivasi dan semangat serta do'a yang tidak pernah putus senantiasa mengiringi langkah penulis hingga penulis dapat menyelesaikan perkuliahan sehingga sampai pada tahap skripsi ini.
4. Kakak laki-laki penulis Ricky Prambudi Perdana terima kasih karena selalu mengalah, serta selalu memberikan bantuan moril maupun materil dan semangat serta dorongan kepada penulis dalam menyelesaikan skripsi ini.
5. Bapak Dwi Sakethi, S.Si., M.Kom. selaku Ketua Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.

6. Bapak Dr. Aristoteles, S.Si., M.Si. selaku pembimbing utama yang telah membimbing dan memberikan banyak arahan kepada penulis sehingga penelitian yang penulis lakukan dapat menjadi lebih baik.
7. Ibu Dwi Asiah Shofiana, S.Komp., M.Kom. selaku pembimbing kedua yang telah memberikan bimbingan dan arahan dalam penulisan skripsi sehingga penulis dapat menyelesaikan skripsi ini dengan baik.
8. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D. selaku pembahas yang telah banyak memberikan masukan dan saran bagi penulis dalam menyusun serta menyelesaikan skripsi.
9. Bapak, Ibu Dosen dan seluruh staf Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan banyak ilmu dan membantu segala urusan administrasi yang penulis butuhkan.
10. Sepupu, keponakan dan keluarga besar penulis yang tidak bisa disebutkan satu persatu, terima kasih telah mendoakan serta memberikan semangat dan dukungan kepada penulis dalam menyelesaikan skripsi.
11. Teman-teman seperjuangan Nesa Dwi Cahyani, Nasywa Nathania Wirawan, Regita Rose Prameswari dan Wina Fadhilah yang telah kebersamai serta memberikan dukungan kepada penulis dalam menyelesaikan skripsi.
12. Silvia, Irma, Nur Mita, Azzahra, Assyfa dan teman-teman S1 Ilmu Komputer 2020 yang merupakan teman satu angkatan yang sudah memberikan dukungan kepada penulis.
13. Teman-teman dari KKN Desa Gunung Rejo yang sudah memberikan dukungan kepada penulis sehingga dapat menyelesaikan skripsi.
14. Teman seperjuangan penulis sejak masa Sekolah Menengah Pertama Ira Rahmawati yang telah memberikan dukungan kepada penulis dalam menyelesaikan skripsi.
15. Teman seperjuangan penulis sejak masa Sekolah Menengah Atas yang namanya tidak bisa penulis sebutkan satu persatu, terima kasih karena telah memberikan dukungan kepada penulis dalam menyelesaikan skripsi.
16. Keseluruhan *member* BTS dan NCT terutama Park Jimin, Jeon Jungkook, Lee Taeyong dan Na Jaemin serta para penulis *Alternative Universe* yang

karyanya secara tidak langsung dapat memberikan motivasi kepada penulis dalam menyelesaikan skripsi ini.

17. Dan yang terakhir, apresiasi yang sebesar-besarnya kepada diri saya sendiri Sarah Cantika Putri, karena telah mampu bertahan sejauh ini dan bertanggung jawab untuk menyelesaikan apa yang sudah dimulai. Terima kasih untuk tidak menyerah sesulit apapun rintangan dalam perkuliahan maupun proses penyusunan skripsi. Terima kasih diriku, tetaplah rendah hati, ini baru awal dari perjalanan hidup tetap semangat.

Penulis menyadari bahwa penulisan skripsi ini masih jauh dari kata sempurna karena masih terbatasnya pengetahuan, pengalaman dan kemampuan penulis. Oleh karena itu, penulis sangat menghargai dan mengharapkan saran dan kritik untuk penelitian ini sebagai bahan pertimbangan untuk karya tulis yang akan datang. Semoga skripsi ini dapat bermanfaat bagi semua pihak.

Bandar Lampung, 17 Desember 2024

Penulis,



Sarah Cantika Putri

NPM. 2017051083

DAFTAR ISI

	Halaman
DAFTAR ISI	iii
DAFTAR GAMBAR	v
DAFTAR TABEL	viii
BAB I PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah.....	4
1.4 Tujuan Penelitian.....	4
1.5 Manfaat Penelitian.....	4
BAB II LANDASAN TEORI	5
2.1 Penelitian Terdahulu.....	5
2.2 Sperma.....	9
2.3 Morfologi.....	10
2.4 Pengolahan Citra Digital	10
2.5 <i>Cropping Images</i>	13
2.6 <i>Resize Images</i>	13
2.7 Augmentasi Data	14
2.9 <i>Machine Learning</i>	15
2.10 <i>Deep Learning</i>	15

2.11	<i>Convolutional Neural Network (CNN)</i>	16
2.12	GoogleNet	22
2.13	<i>Random Oversampling</i>	24
2.14	Python.....	25
2.15	<i>Confusion Matrix</i>	26
BAB III METODE PENELITIAN		29
3.1	Waktu dan Tempat Penelitian	29
3.2	Alat Pendukung	30
3.3	Tahapan Penelitian	30
BAB IV HASIL DAN PEMBAHASAN		34
4.1	Pengumpulan Data	34
4.2	<i>Pre-Processing</i>	36
4.3	Pembagian <i>Dataset</i>	40
4.4	<i>Training Model</i>	43
4.5	Evaluasi Kinerja Model.....	47
4.6	Perbandingan Hasil <i>Accuracy</i>	83
4.7	Waktu Komputasi.....	84
BAB V SIMPULAN DAN SARAN		86
5.1	Simpulan.....	86
5.2	Saran	87
DAFTAR PUSTAKA		88

DAFTAR GAMBAR

Gambar	Halaman
1. Morfologi Sperma (Iqbal et al., 2020).	9
2. Proses Pengolahan Citra (Munantri et al., 2020).	11
3. Gambar Biner (Priyambudi et al., 2022).	12
4. Gambar <i>Grayscale</i> (Priyambudi et al., 2022).	12
5. Gambar RGB (Priyambudi et al., 2022).	13
6. Augmentasi Data (Sanjaya & Ayub, 2020).	14
7. Arsitektur CNN (Fadilah et al., 2023).	16
8. Proses <i>Convolution Layer</i> (Nugroho et al., 2020).	18
9. <i>Pooling Layer</i> (Fadilah et al., 2023).	19
10. Aktivasi ReLU (Ramadhani et al., 2023).	20
11. <i>Fully Connected Layer</i> (Putra & Bunyamin, 2020).	21
12. Arsitektur GoogleNet (AL-Huseiny & Sajit, 2021).	23
13. <i>Random Oversampling</i>	25
14. Tahapan Penelitian.	31
15. Data HuSHeM format BMP dan SCIAN format TIF.	35
16. Data HuSHeM.	36
17. Data SCIAN-MorphoSpermGS.	36
18. Data HuSHeM dan SCIAN dengan <i>File JPEG</i>	37
19. Hasil <i>Cropping Images</i>	37
20. Hasil <i>Resize Image</i>	38
21. Hasil Augmentasi Data HuSHeM.	39
22. Hasil Augmentasi Data SCIAN.	39
23. <i>Inception Module</i>	44
24. <i>Auxiliary Classifier</i>	44

25. <i>Layer</i> GoogleNet.....	45
26. <i>Confusion Matrix</i> HuSHeM Tanpa Augmentasi dengan <i>Learning Rate</i> 0.001.	53
27. <i>Confusion Matrix</i> HuSHeM Tanpa Augmentasi dengan <i>Learning Rate</i> 0.0001.	54
28. <i>Confusion Matrix</i> HuSHeM Tanpa Augmentasi dengan <i>Learning Rate</i> 0.00001.	54
29. Grafik <i>Loss</i> dan <i>Accuracy</i> data HuSHeM Tanpa Augmentasi dengan <i>Learning Rate</i> 0.001.	55
30. Grafik <i>Loss</i> dan <i>Accuracy</i> data HuSHeM Tanpa Augmentasi dengan <i>Learning Rate</i> 0.0001.	55
31. Grafik <i>Loss</i> dan <i>Accuracy</i> data HuSHeM Tanpa Augmentasi dengan <i>Learning Rate</i> 0.00001.	56
32. <i>Confusion Matrix</i> SCIAN Tanpa Augmentasi dengan <i>Learning Rate</i> 0.001.	62
33. <i>Confusion Matrix</i> SCIAN Tanpa Augmentasi dengan <i>Learning Rate</i> 0.0001.	63
34. <i>Confusion Matrix</i> SCIAN Tanpa Augmentasi dengan <i>Learning Rate</i> 0.00001.	63
35. Grafik <i>Loss</i> dan <i>Accuracy</i> Data SCIAN Tanpa Augmentasi <i>Learning Rate</i> 0.001.....	64
36. Grafik <i>Loss</i> dan <i>Accuracy</i> Data SCIAN Tanpa Augmentasi <i>Learning Rate</i> 0.0001.....	64
37. Grafik <i>Loss</i> dan <i>Accuracy</i> Data SCIAN Tanpa Augmentasi <i>Learning Rate</i> 0.00001.....	65
38. <i>Confusion Matrix</i> HuSHeM dengan Augmentasi pada <i>Learning Rate</i> 0.001.	71
39. <i>Confusion Matrix</i> HuSHeM dengan Augmentasi pada <i>Learning Rate</i> 0.0001.	71
40. <i>Confusion Matrix</i> HuSHeM dengan Augmentasi pada <i>Learning Rate</i> 0.00001.	72
41. Grafik <i>Loss</i> dan <i>Accuracy</i> Data HuSHeM dengan Augmentasi pada <i>Learning Rate</i> 0.001.	72
42. Grafik <i>Loss</i> dan <i>Accuracy</i> Data HuSHeM dengan Augmentasi pada <i>Learning Rate</i> 0.0001.	73

43. Grafik <i>Loss</i> dan <i>Accuracy</i> Data HuSHeM dengan Augmentasi pada <i>Learning Rate</i> 0.00001.	74
44. <i>Confusion Matrix</i> SCIAN dengan Augmentasi pada <i>Learning Rate</i> 0.001....	80
45. <i>Confusion Matrix</i> SCIAN dengan Augmentasi pada <i>Learning Rate</i> 0.0001..	80
46. <i>Confusion Matrix</i> SCIAN dengan Augmentasi pada <i>Learning Rate</i> 0.00001.	81
47. Grafik <i>Loss</i> dan <i>Accuracy</i> Data SCIAN dengan Augmentasi <i>Learning Rate</i> 0.001.....	81
48. Grafik <i>Loss</i> dan <i>Accuracy</i> Data SCIAN dengan Augmentasi <i>Learning Rate</i> 0.0001.....	82
49. Grafik <i>Loss</i> dan <i>Accuracy</i> Data SCIAN dengan Augmentasi <i>Learning Rate</i> 0.00001.....	83

DAFTAR TABEL

Tabel	Halaman
1. Penelitian Terdahulu.	5
2. <i>Confusion Matrix</i>	27
3. Estimasi Waktu Penelitian.	29
4. Jumlah Citra Pada Tiap Kelas <i>Dataset</i> HuSHeM.	34
5. Jumlah Citra Pada Tiap Kelas <i>Dataset</i> SCIAN-MorphoSpermGS.....	35
6. Distrbusi <i>Dataset</i> HuSHeM Tanpa Augmentasi.	40
7. Distribusi <i>Dataset</i> SCIAN Tanpa Augmentasi.	41
8. Distribusi <i>Dataset</i> HuSHeM Dengan Augmentasi.	41
9. Distribusi <i>Dataset</i> SCIAN Dengan Augmentasi.....	42
10. Distribusi <i>Dataset</i> SCIAN Dengan Augmentasi dan ROS.	43
11. <i>Hyperparameter</i> data HuSHeM.	46
12. <i>Hyperparameter</i> data SCIAN.	46
13. Hasil <i>Accuracy</i> Data HuSHeM Tanpa Augmentasi dengan Pembagian Skenario <i>Training</i> 80%, <i>Validation</i> 10% dan <i>Testing</i> 10%.	48
14. Hasil <i>Accuracy</i> Data HuSHeM Tanpa Augmentasi dengan Pembagian Skenario <i>Training</i> 70%, <i>Validation</i> 25% dan <i>Testing</i> 5%.	49
15. Hasil <i>Accuracy</i> Data HuSHeM Tanpa Augmentasi dengan Pembagian Skenario <i>Training</i> 60%, <i>Validation</i> 20% dan <i>Testing</i> 20%.	50
16. Hasil <i>Accuracy</i> Tertinggi Data HuSHeM tanpa Augmentasi.	51
17. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data HuSHeM Tanpa Augmentasi <i>Learning Rate</i> 0.001.....	52
18. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data HuSHeM Tanpa Augmentasi <i>Learning Rate</i> 0.0001.....	52

19. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data HuSHeM Tanpa Augmentasi <i>Learning Rate</i> 0.00001.....	52
20. Hasil <i>Accuracy</i> Data SCIAN Tanpa Augmentasi dengan Pembagian Skenario <i>Training</i> 80%, <i>Validation</i> 10% dan <i>Testing</i> 10%.	57
21. Hasil <i>Accuracy</i> Data SCIAN Tanpa Augmentasi dengan Pembagian Skenario <i>Training</i> 70%, <i>Validation</i> 25% dan <i>Testing</i> 5%.	58
22. Hasil <i>Accuracy</i> Data SCIAN Tanpa Augmentasi dengan Pembagian Skenario <i>Training</i> 60%, <i>Validation</i> 20% dan <i>Testing</i> 20%.	59
23. Hasil <i>Accuracy</i> Data SCIAN-MorphospermGS Tanpa Augmentasi.....	60
24. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data SCIAN Tanpa Augmentasi dengan <i>Learning Rate</i> 0.001.	61
25. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data SCIAN Tanpa Augmentasi dengan <i>Learning Rate</i> 0.0001.	61
26. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data SCIAN Tanpa Augmentasi dengan <i>Learning Rate</i> 0.00001.	61
27. Hasil <i>Accuracy</i> Data HuSHeM dengan Augmentasi pada Pembagian Skenario <i>Training</i> 80%, <i>Validation</i> 10% dan <i>Testing</i> 10%.	66
28. Hasil <i>Accuracy</i> Data HuSHeM dengan Augmentasi pada Pembagian Skenario <i>Training</i> 70%, <i>Validation</i> 25% dan <i>Testing</i> 5%.	67
29. Hasil <i>Accuracy</i> Data HuSHeM dengan Augmentasi pada Pembagian Skenario <i>Training</i> 60%, <i>Validation</i> 20% dan <i>Testing</i> 20%.	68
30. Hasil <i>Accuracy</i> Tertinggi Data HuSHeM dengan Augmentasi.....	69
31. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data HuSHeM dengan Augmentasi <i>Learning Rate</i> 0.001.....	70
32. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data HuSHeM dengan Augmentasi <i>Learning Rate</i> 0.0001.....	70
33. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data HuSHeM dengan Augmentasi <i>Learning Rate</i> 0.00001.....	70
34. Hasil <i>Accuracy</i> Data SCIAN dengan Augmentasi pada Pembagian Skenario <i>Training</i> 80%, <i>Validation</i> 10% dan <i>Testing</i> 10%.	75
35. Hasil <i>Accuracy</i> Data SCIAN dengan Augmentasi pada Pembagian Skenario <i>Training</i> 75%, <i>Validation</i> 25% dan <i>Testing</i> 5%.	76

36. Hasil <i>Accuracy</i> Data SCIAN dengan Augmentasi pada Pembagian Skenario <i>Training</i> 60%, <i>Validation</i> 20% dan <i>Testing</i> 20%.....	77
37. Hasil <i>Accuracy</i> Data SCIAN-MorphospermGS dengan Augmentasi.....	78
38. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data SCIAN dengan Augmentasi pada <i>Learning Rate</i> 0.001.....	79
39. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data SCIAN dengan Augmentasi pada <i>Learning Rate</i> 0.0001.....	79
40. Hasil <i>Precision</i> , <i>Recall</i> dan <i>F1-Score</i> pada Data SCIAN dengan Augmentasi pada <i>Learning Rate</i> 0.00001.....	79
41. Perbandingan Hasil Arsitektur Data HuSHeM.....	83
42. Perbandingan Hasil Arsitektur Data SCIAN.....	84
43. Waktu Komputasi.....	85

BAB I

PENDAHULUAN

1.1 Latar Belakang

Sperma manusia merupakan sel kecil yang berbentuk lonjong dan memiliki ekor untuk gerakan. Sperma manusia atau *Spermatozoa* mengandung makro molekul dalam jumlah besar, termasuk protein atau enzim dan karbohidrat yang berfungsi untuk mengatur dan melindungi sel sperma, selain itu spermatozoa juga mengandung materi genetik yang diperlukan untuk membuahi sel telur wanita. Pertemuan antara sel sperma dan sel telur disebut juga proses reproduksi. Proses reproduksi yang melibatkan penyatuan sel telur dan sperma disebut sebagai proses fertilisasi dimana kedua sel tersebut bergabung untuk membentuk zigot yang berkembang menjadi embrio dan kemudian berubah menjadi janin (Rima, 2022).

Namun, tidak semua sperma yang menyatu dengan sel telur akan berkembang menjadi janin karena adanya masalah pada sistem reproduksi seperti penyakit *infertilitas*. Menurut *World Health Organization* (WHO) *infertilitas* adalah penyakit yang terjadi pada sistem reproduksi pria atau wanita yang ditandai dengan kegagalan untuk mencapai kehamilan setelah 12 bulan atau lebih melakukan hubungan seksual secara teratur tanpa perlindungan alat kontrasepsi. Sebanyak lebih dari 10% pasangan di seluruh dunia dan lebih dari 30% kasus yang dilaporkan berhubungan dengan laki-laki (Iqbal et al., 2020). Ada beberapa faktor yang mungkin menjadi penyebab infertilitas pada laki-laki seperti usia, kecemasan,

patogen, dan pola makan yang dapat mempengaruhi jumlah sperma abnormal dalam air mani (Shahzad et al., 2023). Menurut *World Health Organization* (WHO), ada 11 kelainan kategori kepala sperma manusia, yang ditentukan menurut morfometrik. Ciri-ciri kepala sperma ini berbeda dalam hal bentuk, ukuran, dan teksturnya. Selain perbedaan antar kelas, ada juga kesamaan antar kelas. Misalnya, kepala Amorf yang memanjang mirip dengan kepala Tapered atau berbentuk buah pir seperti kepala Pyriform, dan kepala Tapered yang menyempit di dekat ekor identik dengan kepala Pyriform (Iqbal et al., 2020).

Namun, sistem yang tersedia tidak menyelesaikan masalah variabilitas tinggi dalam penilaian morfologi karena masih memerlukan pengoperasian manusia dan sensitif terhadap persiapan sampel dan pengaturan instrumen. *Deep learning* adalah bagian dari pembelajaran mesin yang memanfaatkan kemampuan komputasi modern untuk mempelajari hubungan kompleks antara data input dan output sekaligus sensitif terhadap detail penting dan tidak sensitif terhadap detail besar yang tidak relevan. *Convolutional Neural Networks* (CNN) adalah kelas algoritma pembelajaran yang secara rutin digunakan untuk pemrosesan dan pengenalan citra. Dalam melakukan analisis infertilitas pada laki-laki, *Deep Learning* telah digunakan untuk memetakan fitur visual yang ditemukan dalam gambar sperma ke kategori morfologi yang sesuai (Spencer et al., 2022).

Dalam penelitian (Yüzkat et al., 2021) menggunakan model arsitektur Convolutional Neural Network (CNN) Fusion dilakukan klasifikasi kelainan sperma manusia yang diambil dari tiga kumpulan *dataset* yaitu SMIDS, HuSHeM, dan SCIAN-Morpho. Hasilnya, performa klasifikasi maksimum masing-masing sebesar 90,73%, 85,18%, dan 71,91%. Pada penelitian (Riordon et al., 2019) dan (Iqbal et al., 2020) yang membandingkan pendekatan model *Visual Geometry Group 16* (VGG16) dengan model arsitektur *Class-Equalized Support Vector Machine* (CE-SVM), *Augmented Pattern Decomposition Learning* (APDL) dan

Morphological Classification of Human Sperm Heads (MC-HSH) dengan dua *dataset* yang sama yaitu HuSHeM dan SCIAN-Morpho, arsitektur VGG16 mendapatkan tingkat akurasi 94,1% untuk data HuSHem dan 62% untuk data SCIAN-Morpho, untuk model CE-SVM, APDL dan MC-HSH masing-masing mendapatkan tingkat akurasi 78,5%, 92,3% dan 95,7% untuk data HuSHeM dan 58%, 62% dan 63% untuk data SCIAN-Morpho. Arsitektur VGG16 mendapatkan tingkat akurasi yang lebih tinggi dibandingkan arsitektur CE-SVM dan APDL, tetapi memiliki tingkat akurasi yang sedikit lebih rendah dibandingkan dengan arsitektur MC-HSH.

Model arsitektur GoogleNet dinilai dapat membantu dalam melakukan klasifikasi karena memiliki tingkat akurasi yang cukup tinggi. Hal tersebut didukung dengan banyaknya penelitian mengenai klasifikasi dengan beberapa *dataset* berbeda menggunakan arsitektur GoogleNet yang menunjukkan tingkat akurasi lebih tinggi contohnya pada penelitian yang dilakukan oleh (Hoang et al., 2022) dengan membandingkan arsitektur VGG16, Resnet50, NASNet Mobile dan GoogleNet untuk dua *dataset* yang berbeda yaitu, data Lung dan Colon. Hasil masing-masing akurasi yang didapatkan dari dua *dataset* Lung dan Colon adalah 98,45% dan 98,71% untuk VGG16, 96,84% dan 97,92% untuk Resnet50, 97,71% dan 98,53% untuk NASNet Mobile serta 98,34% dan 98,97% untuk GoogLeNet.

Berdasarkan latar belakang tersebut, penelitian ini dibuat untuk melakukan pengklasifikasian sperma manusia berdasarkan morfologi menggunakan algoritma model CNN GoogleNet untuk mengetahui seberapa baik model arsitektur ini digunakan dalam melakukan klasifikasi data HuSHeM dan SCIAN-MorphoSpermgs dan mengetahui apakah model arsitektur ini dapat menghasilkan tingkat akurasi yang lebih baik dari model arsitektur yang pernah dilakukan pada penelitian sebelumnya dengan cara melakukan augmentasi data.

1.2 Rumusan Masalah

Berdasarkan latar belakang yang telah dijelaskan, maka didapatkan rumusan masalah pada penelitian ini yaitu mengklasifikasikan sperma manusia berdasarkan morfologi menggunakan model CNN GoogleNet.

1.3 Batasan Masalah

Berdasarkan latar belakang yang telah dijabarkan, maka penelitian ini dibatasi pada beberapa hal sebagai berikut:

- a. Penelitian ini menggunakan data citra berbentuk gambar dari *dataset Human Sperm Head Morphology* (HuSHeM) dan *SCIAN-MorphoSpermg*s. Pada data HuSHeM terdapat empat kelas data dengan jumlah 216 data dan pada data *SCIAN-MorphoSpermg*s terdapat lima kelas data dengan jumlah 1132 data.
- b. Proses pengklasifikasian data menggunakan bahasa pemrograman Python dengan model arsitektur GoogleNet.
- c. Menggunakan augmentasi data pada *dataset* untuk meningkatkan variasi data.

1.4 Tujuan Penelitian

Adapun tujuan dari penelitian ini adalah sebagai berikut:

- a. Mengimplementasikan model arsitektur CNN yaitu GoogleNet untuk proses klasifikasi sperma manusia berdasarkan morfologi.
- b. Melakukan pengujian evaluasi model arsitektur CNN GoogleNet dalam melakukan klasifikasi sperma manusia berdasarkan morfologi.

1.5 Manfaat Penelitian

Adapun manfaat yang didapatkan dari penelitian ini yaitu:

- a. Membantu mendiagnosis kelainan morfologi sperma dengan akurasi yang lebih baik dibandingkan dengan metode manual tradisional.
- b. Membantu untuk pengembangan metode klasifikasi lanjut yang lebih canggih atau integrasi dengan teknologi lainnya.

BAB II LANDASAN TEORI

2.1 Penelitian Terdahulu

Pada penelitian ini dibutuhkan penelitian terdahulu seperti yang dijelaskan pada Tabel 1 berikut.

Tabel 1. Penelitian Terdahulu.

No	Penulis	Judul	Objek	Pokok Pembahasan
1.	(Chang et al., 2017)	<i>Gold-standard for computer-assisted morphological sperm analysis.</i>	SCIAN-Morpho.	Penelitian ini menggunakan empat model pembelajaran yang diawasi yaitu 1-NN (<i>1-Nearest Neighbor</i>), <i>Naive Bayes</i> , <i>Decision Trees</i> dan <i>Support Vector Machine</i> (SVM), dengan hasil akurasi tertinggi didapatkan oleh model SVM yaitu mencapai 49%, untuk model 1-NN dan <i>Decision Trees</i> mendapatkan tingkat akurasi yang sama yaitu 39%, sedangkan model

No	Penulis	Judul	Objek	Pokok Pembahasan
				<i>Naive bayes</i> hanya mencapai tingkat akurasi 33%.
2.	(Riordon et al., 2019)	<i>Deep learning for the classification of human sperm.</i>	HuSHeM dan SCIAN-Morpho.	Penelitian ini menggunakan model <i>Visual Geometry Group 16</i> lapisan (VGG16), <i>Class-Equalized Support Vector Machine</i> (CE-SVM) dan <i>Augmented Pattern Decomposition Learning</i> (APDL). Pendekatan menggunakan model VGG16 mencapai 94,1% untuk data HuSHeM dan 62% untuk data SCIAN-Morpho, sedangkan dengan model CE-SVM dan APDL tingkat akurasi untuk data HuSHeM hanya mencapai 78,5% dan 92,3% dan untuk data SCIAN-Morpho tingkat akurasi hanya mencapai 58% dan 62%.
3.	(Iqbal et al., 2020)	<i>Deep learning-based morphologic</i>	HuSHeM dan SCIAN-Morpho.	Penelitian ini menggunakan model arsitektur <i>Morphological Classification of Human</i>

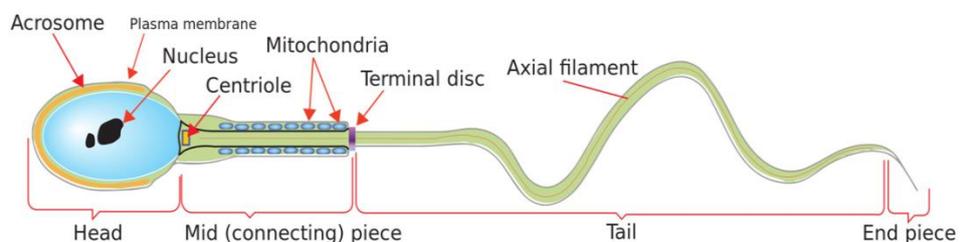
No	Penulis	Judul	Objek	Pokok Pembahasan
		<i>al classification of human sperm heads.</i>		<i>Sperm Heads</i> (MC-HSH), dengan hasil akurasi menggunakan model MC-HSH mencapai 95,7% untuk data HuSHem dan 63% untuk data SCIAN-Morpho.
4.	(Tortumlu & Ilhan, 2020)	<i>The analysis of mobile platform based CNN networks in the classification of sperm morphology.</i>	HuSHem, SMIDS dan SCIAN-Morpho.	Penelitian ini membandingkan dua model arsitektur MobileNet V1 dan MobileNet V2, dengan hasil akurasi menggunakan model MoblieNet V1 untuk data HuSHem 75%, untuk data SMIDS 88% dan 67% untuk data SCIAN-Morpho, sedangkan dengan menggunakan model arsitertur MobileNet V2 di dapatkan hasil akurasi 77% untuk data HuSHem, 87% untuk data SMIDS dan 66% untuk data SCIAN- Morpho.
5.	(Yüzkat et al., 2021)	<i>Multi-model cnn fusion for sperm</i>	SMIDS, HuSHem, dan	Penelitian ini menggunakan <i>Convolutional Neural</i>

No	Penulis	Judul	Objek	Pokok Pembahasan
		<i>morphology analysis.</i>	SCIAN-Morpho.	<i>Network (CNN) Fusion</i> dengan pendekatan kombinasi dua teknik <i>fusion</i> yaitu <i>soft-voting</i> dan <i>hard-voting</i> yang diusulkan dari enam model CNN seperti <i>Support Vector Machine (SVM)</i> , <i>MobileNet</i> dan <i>K-Nearest Neighbors (KNN)</i> dengan memperoleh hasil akurasi mencapai 90,73% untuk data SMIDS, 85,18% untuk data HuSHeM, dan 71,91% untuk data SCIAN-Morpho.
6.	(Rahouma et al., 2020)	<i>Applying Deep Learning Techniques for Heart Big Data Diagnosis.</i>	ECG datasets.	Penelitian ini menggunakan model arsitektur AlexNet, GoogleNet dan <i>Adaptive Neuro Fuzzy Inference System Classification-FCM (ANFIS)</i> untuk melakukan diagnosis data jantung dengan tingkat akurasi mencapai 94% untuk AlexNet, 97% untuk GoogleNet dan 99% untuk ANFIS.

2.2 Sperma

Sperma merupakan sel yang dihasilkan oleh fungsi reproduksi pria. Sel tersebut mempunyai bentuk khas yaitu mempunyai kepala, leher dan ekor. Sperma, juga dikenal sebagai spermatozoa atau sel sperma yang mengandung kromosom dan berfungsi untuk membuahi sel telur dalam proses pembuahan. Spermatozoa merupakan sel hasil maturasi dari sel epitel germinal yang disebut spermatogonia. Spermatogonia terletak dalam dua sampai tiga lapisan sepanjang batas luar epitel tubulus. Proses perkembangan spermatogonia menjadi sperma disebut spermatogenesis (Dewanto et al., 2017).

Spermatogenesis adalah proses pembentukan sperma menjadi sperma dewasa dari germinal sel atau yang sering disebut sel induk. Spermatogenesis dimulai dari proses *proliferasi* dan *diferensiasi germinal* sel dan diakhiri dengan terbentuknya formasi sperma dewasa. Spermatogonia berkembang menjadi spermatozot primer, kemudian perkembangan berlanjut menjadi spermatozot sekunder. Pematangan spermatozot sekunder terbentuklah spermatid, tahap akhir spermatogenesis adalah pematangan spermatid menjadi sel sperma, keseluruhan proses ini membutuhkan waktu sekitar 64 hari (Krisna, 2018). Gambar 1 berikut ini menunjukkan gambaran umum morfologi sperma dari kepala, leher hingga ekor sperma.



Gambar 1. Morfologi Sperma (Iqbal et al., 2020).

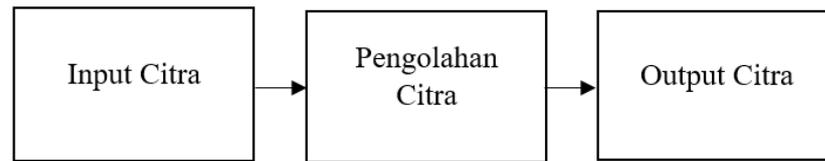
2.3 Morfologi

Secara etimologi kata morfologi berasal dari kata *morf* yang berarti bentuk dan kata *logi* yang berarti ilmu. Jadi, secara harfiah kata morfologi berarti ilmu mengenai bentuk. Di dalam kajian linguistik, morfologi berarti cabang ilmu bahasa yang mengkaji seluk-beluk bentuk kata dan perubahannya serta dampak dari perubahan itu terhadap arti kata (makna) (Gani & Arsyad, 2019).

2.4 Pengolahan Citra Digital

Citra digital merupakan gambar dua dimensi yang dihasilkan dari analog dua dimensi yang kontinu menjadi gambar melalui proses *sampling*. Citra digital juga merupakan sebuah larik (*array*) yang berisi nilai-nilai *real* maupun kompleks yang direpresentasikan dengan deretan bit tertentu. Suatu citra dapat didefinisikan sebagai fungsi $f(x,y)$ berukuran M baris dan N kolom, dengan x dan y adalah koordinat spasial, dan amplitudo f di titik koordinat (x,y) dinamakan intensitas atau tingkat keabuan dari citra pada titik tersebut. Apabila nilai x, y, dan nilai amplitudo f secara keseluruhan berhingga (*finite*) dan bernilai diskrit maka dapat dikatakan bahwa citra tersebut adalah citra digital (Yulianti, 2020).

Pengolahan citra (*image processing*) adalah salah satu bentuk pemrosesan informasi dengan inputan berupa citra (*image*) dan keluaran yang juga berupa citra atau berupa bagian dari citra itu sendiri. Tujuan dari pengolahan citra ini adalah untuk memperbaiki kualitas citra agar mudah diinterpretasi oleh manusia dan mesin komputer. Pengolahan citra ini sangat diperlukan karena walaupun citra sangat kaya dengan informasi, namun seringkali citra mengalami penurunan mutu (*degradasi*), misalnya mengandung cacat atau derau (*noise*), warnanya terlalu kontras, kurang tajam, kabur (*blurring*), dan sebagainya. Tentu saja citra semacam ini menjadi lebih sulit diinterpretasi karena informasi yang disampaikan oleh citra tersebut menjadi berkurang. Proses pengolahan citra dapat dilihat pada Gambar 2 berikut.



Gambar 2. Proses Pengolahan Citra (Munantri et al., 2020).

$$f = \begin{bmatrix} f(1,1) & f(1,2) & \cdots & f(1,N) \\ f(2,1) & f(2,2) & \cdots & f(2,N) \\ \vdots & \vdots & \cdots & \vdots \\ f(M,1) & f(M,2) & \cdots & f(M,N) \end{bmatrix} \quad (1)$$

Berdasarkan Persamaan 1, maka secara matematis citra digital dapat dituliskan sebagai intensitas $f(x,y)$ dimana nilai x (baris) dan y (kolom) adalah koordinat posisi dan $f(x,y)$ adalah nilai fungsi pada setiap titik (x,y) yang menyatakan besar intensitas yang diterima oleh citra atau tingkat keabuan atau warna dari piksel di titik tersebut. Besarnya tergantung pada intensitas yang dipantulkan oleh objek. Ini berarti $f(x,y)$ sebanding dengan energi yang dipancarkan oleh sumber cahaya, sehingga besar intensitas $f(x,y)$.

Berdasarkan jenisnya, citra digital dapat dibagi menjadi 3, yaitu sebagai berikut.

2.4.1 Citra Biner

Citra biner adalah citra digital yang hanya memiliki dua kemungkinan nilai piksel yaitu hitam dan putih. Citra biner juga disebut sebagai citra B&W (*black and white*). Citra biner merupakan citra dengan setiap piksel yang hanya dapat dinyatakan dengan sebuah nilai dari dua buah kemungkinan, yaitu nilai 0 dan 1. Nilai 0 untuk menyatakan warna hitam dan nilai 1 untuk menyatakan warna putih (Maulana, 2022). Gambar 3 berikut merupakan contoh dari citra biner.



Gambar 3. Gambar Biner (Priyambudi et al., 2022).

2.4.2 Citra *Grayscale*

Citra berskala keabuan (*grayscale*) adalah citra menggunakan gradasi warna abu-abu yang merupakan kombinasi antara warna hitam dan putih. Setiap warna di dalam citra berskala keabuan dinyatakan dengan sebuah nilai bulat antara 0 dan 255 dan nilai tersebut disebut sebagai intensitas (Fadjeri, 2020). Gambar 4 berikut merupakan contoh dari citra *Grayscale*.



Gambar 4. Gambar *Grayscale* (Priyambudi et al., 2022).

2.4.3 Citra RGB

RGB adalah aturan skema warna yang terdiri dari 3 warna yaitu merah (*red*), hijau (*green*) dan biru (*blue*) yang diolah menggunakan berbagai teknik untuk mendapatkan berbagai macam warna lainnya. Pada citra warna ini setiap warna memiliki piksel yang berbeda,

dimana setiap warna memiliki nilai rentang piksel mulai dari 0 hingga 255 (Fadjeri et al., 2022). Gambar 5 berikut merupakan contoh citra RGB.



Gambar 5. Gambar RGB (Priyambudi et al., 2022).

2.5 *Cropping Images*

Proses pengambilan area tertentu yang berisi objek pada suatu citra disebut pemotongan citra atau *cropping images*. *Cropping images* merupakan teknik yang digunakan untuk menentukan secara tepat bagian mana dari suatu citra yang mengandung area objek yang akan diolah, sehingga bagian objek tersebut dapat dipisahkan dari area yang tidak dibutuhkan, hasil dari *cropping* tersebut berupa data citra yang hanya menampilkan objek yang dibutuhkan untuk diolah. Pemotong bagian dari suatu citra dapat dilakukan dengan menggunakan dua koordinat acuan, yaitu koordinat sudut kiri-atas sebagai awal koordinat bagi citra hasil pemotongan dan koordinat sudut kanan-bawah yang merupakan titik koordinat akhir dari citra hasil pemotongan. Dari dua titik koordinat ini dapat dibentuk bangun segi empat sebagai ukuran citra baru hasil *cropping* yang didalamnya terdapat semua objek yang akan diproses (Yuhandri, 2019).

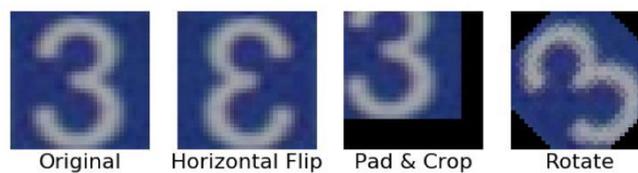
2.6 *Resize Images*

Resize Images adalah proses mengubah ukuran dimensi suatu citra menjadi lebih besar atau kecil dari sebelumnya sesuai dengan ukuran yang diinginkan.

Proses *resize* ini dapat dilakukan menggunakan alat-alat *online* atau *software* perangkat lunak. Biasanya proses *resize* pada data citra dilakukan untuk menyamaratakan ukuran data citra ataupun untuk menghindari terjadinya *blurring* pada data citra (Mulyana & Wibowo, 2023).

2.7 Augmentasi Data

Augmentasi data adalah strategi yang memungkinkan praktisi untuk secara signifikan meningkatkan keragaman data yang tersedia untuk model pelatihan, tanpa benar-benar mengumpulkan data baru. Teknik augmentasi data seperti *cropping*, *padding*, dan *flipping horizontal* umumnya digunakan untuk melatih jaringan *neural* besar (Sanjaya & Ayub, 2020). Gambar 6 berikut merupakan contoh dari augmentasi data.



Gambar 6. Augmentasi Data (Sanjaya & Ayub, 2020).

Teknik augmentasi yang digunakan harus dipertimbangkan dengan karakteristik citra untuk menghindari terganggunya informasi asli yang diperoleh dari citra (Yüzkat et al., 2021).

2.8 *Artificial Intelligence*

Artificial Intelligence atau kecerdasan buatan adalah teknik yang digunakan untuk meniru kecerdasan buatan yang dimiliki oleh manusia dalam menyelesaikan sebuah persoalan (Ahmad, 2017). *Artificial Intelligence* melibatkan penggunaan algoritma dan model matematika untuk memungkinkan komputer dan sistem lainnya untuk mempelajari data, mengenali pola, dan membuat keputusan yang cerdas. Dalam konteks AI, terdapat beberapa konsep penting yang diterapkan seperti, *machine learning* (pembelajaran mesin), *neural networks* (jaringan saraf tiruan), *natural*

language processing (pemrosesan bahasa alami), dan masih banyak lagi (Eriana & Zein, 2019).

2.9 *Machine Learning*

Machine Learning adalah cabang dari kecerdasan buatan (AI) dan ilmu komputer yang banyak digunakan untuk menggantikan atau meniru perilaku manusia untuk menyelesaikan masalah atau melakukan otomatisasi (Ahmad, 2017). Penelitian terkini mengungkapkan bahwa *machine learning* terbagi menjadi tiga kategori: *Supervised Learning*, *Unsupervised Learning*, dan *Reinforcement Learning*. Teknik yang digunakan oleh *Supervised Learning* adalah metode klasifikasi dengan kumpulan data sepenuhnya diberikan label untuk mengklasifikasikan kelas yang tidak dikenal, sedangkan teknik *Unsupervised Learning* sering disebut *cluster* karena tidak ada kebutuhan untuk pemberian label dalam kumpulan data dan hasilnya tidak mengidentifikasi contoh di kelas yang telah ditentukan dan teknik *Reinforcement Learning* biasanya berada antara *Supervised Learning* dan *Unsupervised Learning* teknik ini bekerja dalam lingkungan yang dinamis konsepnya harus menyelesaikan tujuan tanpa adanya pemberitahuan dari komputer secara eksplisit jika tujuan tersebut telah tercapai (Roihan et al., 2020).

2.10 *Deep Learning*

Deep learning adalah cabang dari *machine learning* yang terinspirasi oleh struktur dan fungsi otak manusia, yang disebut sebagai jaringan saraf tiruan atau *artificial neural network*. Pembelajaran ini disebut *deep* atau mendalam karena dalam proses pemodelan data dimanipulasi oleh sejumlah lapisan tersembunyi. Dalam jenis pemodelan ini informasi yang spesifik akan dikumpulkan dari setiap lapisan (Ramadhani et al., 2023).

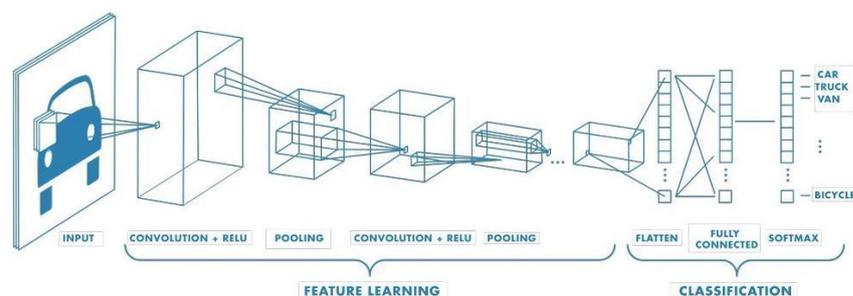
Metode pendekatan *deep learning* mengklasifikasi data dalam dua sesi yaitu sesi *training* dan *testing*. Pada sesi *training* mempelajari ekstraksi fitur dari setiap data supaya dapat membedakan suatu label dengan label yang lain.

Pada sesi *testing* data-data yang diuji dapat dianalisis dari hasil sesi *training* (Azizah et al., 2018).

2.11 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah salah satu algoritma dari *deep learning* yang merupakan pengembangan dari *Multilayer Perceptron* (MLP) yang termasuk dalam *neural network* bertipe *feed forward* (bukan berulang). *Convolutional Neural Network* (CNN) dirancang untuk mengolah data dalam bentuk dua dimensi, misalnya gambar atau suara. CNN digunakan untuk mengklasifikasi data yang berlabel dengan menggunakan metode *supervised learning*. Cara kerja dari *supervised learning* adalah terdapat data yang dilatih dan terdapat variabel yang ditargetkan sehingga tujuan dari metode ini adalah mengelompokkan suatu data ke data yang sudah ada (Ilahiyah & Nilogiri, 2018).

CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. CNN digunakan untuk menganalisis citra visual, mendeteksi dan mengenali objek pada *image*, yang merupakan vektor berdimensi tinggi yang akan melibatkan banyak parameter untuk mencirikan jaringan. Secara garis besar, CNN tidak terlalu jauh berbeda dengan *neural network* biasanya. CNN terdiri dari *neuron* yang memiliki *weight*, *bias* dan *activation function*. Gambar 7 berikut merupakan ilustrasi dari arsitektur CNN.

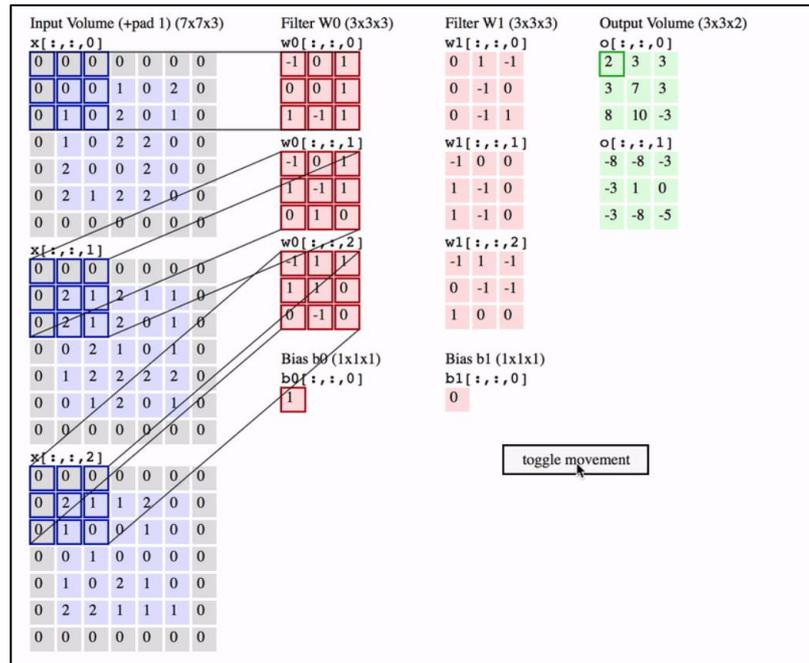


Gambar 7. Arsitektur CNN (Fadilah et al., 2023).

Secara umum tipe lapisan pada CNN dibagi menjadi dua. Lapisan pertama adalah lapisan ekstraksi fitur (*feature extraction layer*), letaknya berada pada awal arsitektur tersusun atas beberapa lapisan dan setiap lapisan tersusun atas *neuron* yang terkoneksi pada daerah lokal (*local region*) dari lapisan sebelumnya. Lapisan jenis pertama adalah *convolutional layer* dan lapisan kedua adalah *pooling layer*. Setiap lapisan diberlakukan fungsi aktivasi dengan posisinya yang berselang-seling antara jenis pertama dengan jenis kedua. Lapisan ini menerima input citra secara langsung dan memprosesnya hingga menghasilkan *output* berupa vektor untuk diolah pada lapisan berikutnya. Lapisan kedua adalah lapisan klasifikasi (*classification layer*), tersusun atas beberapa lapisan dan setiap lapisan tersusun atas neuron yang terkoneksi secara penuh (*fully connected*) dengan lapisan lainnya. *Layer* ini menerima input dari hasil keluaran *layer* ekstraksi fitur citra berupa vektor, kemudian ditransformasikan seperti *Multi Neural Networks* dengan tambahan beberapa *hidden layer*. Hasil keluaran berupa akurasi kelas untuk klasifikasi (Ilahiyah & Nilogiri, 2018).

2.11.1 Convolutional Layer

Convolutional layer merupakan komponen utama CNN yang memiliki tugas menerima input citra untuk kemudian melakukan ekstraksi fitur pada citra tersebut. Masukan berupa citra yang dimasukkan ke dalam proses, akan diproses pada tahap ekstraksi fitur. Citra akan dibagi menjadi beberapa bagian sesuai piksel yang ditentukan oleh parameter tertentu. Konvolusi ini akan menghasilkan citra yang lebih kecil atau citra dengan ukuran yang sama namun tingkat kedalaman citra akan berbeda (Ramadhani et al., 2023). Proses *Convolution Layer* dapat dilihat pada Gambar 8.



Gambar 8. Proses *Convolution Layer* (Nugroho et al., 2020).

Seluruh data yang menyentuh lapisan konvolusional akan mengalami proses konvolusi. Lapisan akan mengkonversi setiap *filter* ke seluruh bagian data masukan dan menghasilkan sebuah *activation map* atau *feature map 2D*. *Filter* yang terdapat pada *Convolutional Layer* memiliki panjang, tinggi dan tebal sesuai dengan *channel* data masukan. Setiap *filter* akan mengalami pergeseran dan operasi “dot” antara data masukan dan nilai dari *filter*. Lapisan *convolutional* secara signifikan mengalami kompleksitas model melalui optimalisasi *output*-nya. Hal ini dioptimalkan melalui tiga parameter, *depth*, *stride* dan pengaturan *zero padding* (Nugroho et al., 2020).

2.11.2 *Pooling Layer*

Pooling Layer adalah lapisan yang digunakan untuk memperkecil ukuran dimensi menggunakan *feature map* sebagai masukan dan mengolahnya dengan berbagai macam operasi statistik berdasarkan nilai piksel terdekat. Pada model CNN, lapisan *pooling* biasanya disisipkan secara teratur setelah beberapa lapisan konvolusi

(Ilahiyah & Nilogiri, 2018). Gambar 9 berikut ini merupakan contoh *max pooling* dan *average pooling* pada *pooling layer*.

2	3	5	4
5	6	7	8
3	2	1	0
1	2	3	4

<i>Max Pooling</i>	
6	8
3	4

<i>Average Pooling</i>	
4	8
8	8

Gambar 9. *Pooling Layer* (Fadilah et al., 2023).

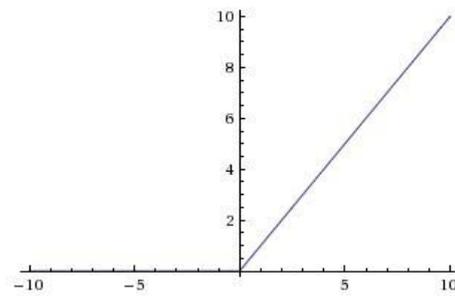
Bentuk lapisan *pooling* yang paling umum adalah dengan menggunakan *filter* berukuran 2x2 yang diaplikasikan dengan langkah sebanyak 2 dan kemudian beroperasi pada setiap irisan dari input. Terdapat dua macam *pooling* yang sering digunakan yaitu *max pooling* dan *average pooling*. *Max pooling* mengambil nilai tertinggi dari setiap piksel citra, sedangkan *Average pooling* mengambil nilai rata-rata dari tiap piksel citra (Saidah et al., 2022).

2.11.3 Aktivasi ReLU

ReLU merupakan transformasi nonlinear yang dapat digunakan untuk mengubah masukan menjadi keluaran. Fungsi aktivasi yang akan digunakan adalah ReLU (*Rectified Linear Unit*) yang merupakan fungsi aktivasi yang dapat meningkatkan kecepatan proses pelatihan dan memiliki perhitungan sederhana (Ramadhani et al., 2023).

Adapun persamaan dari fungsi ReLU dapat dilihat pada Persamaan 2 dan Gambar 10 berikut.

$$f(x) = \max(0, x) \quad (2)$$

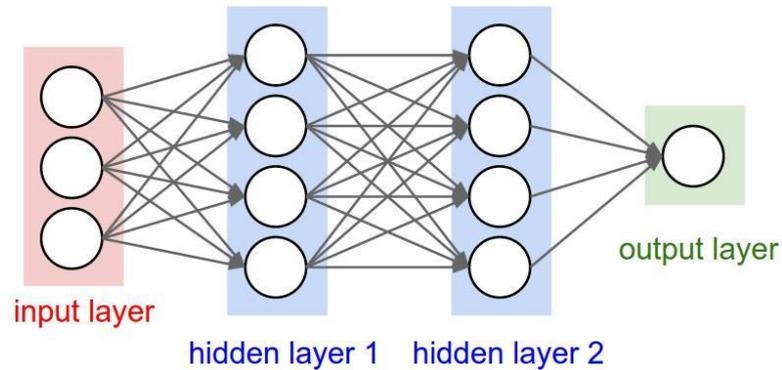


Gambar 10. Aktivasi ReLU (Ramadhani et al., 2023).

Proses *forward* dan *backward* melalui ReLU hanya menggunakan kondisi *if*. Jika elemen bernilai negatif maka nilainya akan diatur atau dikembalikan menjadi 0, tidak ada operasi eksponensial, perkalian atau pembagian. Dengan karakteristik ini, ReLU memiliki kelebihan yang akan muncul saat berhadapan dengan jaringan yang memiliki *neuron* yang banyak sehingga dapat mengurangi waktu *training* dan *testing* dengan signifikan (Putra & Bunyamin, 2020).

2.11.4 Fully Connected Layer

Fully Connected Layer adalah *layer* terakhir setelah *convolution layer* dan *pooling layer* yang digunakan sebagai *layer* penyatuan akhir yang melakukan klasifikasi ke dalam kelas pada data *training*. Sebelum masuk pada tahap *Fully Connected Layer*, *Feature Map* yang dihasilkan pada tahap sebelumnya akan melalui proses “*flatten*” atau *reshape*. Proses *flatten* menghasilkan sebuah vektor yang akan digunakan sebagai *input* dari *Fully Connected Layer*. *Fully Connected Layer* memiliki beberapa *Hidden Layer*, *Action Layer*, *Output Layer*, dan *Loss Function* (Nugroho et al., 2020).



Gambar 11. *Fully Connected Layer* (Putra & Bunyamin, 2020).

Gambar 11 merupakan contoh *Fully Connected Layer*, layer tersebut merupakan lapisan yang digunakan dalam penerapan MLP (*Multilayer Perceptron*) dan bertujuan untuk melakukan transformasi pada dimensi data agar data dapat diklasifikasikan secara linear. Setiap *neuron* pada *convolution layer* perlu ditransformasikan menjadi data satu dimensi terlebih dahulu sebelum dapat dimasukkan ke dalam *Fully Connected Layer* (Ilahiyah & Nilogiri, 2018).

2.11.5 Aktivasi *SoftMax*

Softmax merupakan salah satu fungsi aktivasi yang digunakan untuk mengklasifikasikan suatu data dengan melihat nilai probabilitas tertinggi. Aktivasi *softmax* juga merupakan bentuk lain dari algoritma *logistic regression* yang dapat digunakan untuk mengklasifikasikan lebih dari dua kelas. Fungsi *softmax* dipilih karena dapat mengurangi kemungkinan nilai error yang dihasilkan oleh fungsi objektif *cross-entropy*.

Softmax adalah fungsi yang mengambil sebagai *input* vektor dari bilangan *real* dari K , dan menormalisasi menjadi distribusi probabilitas yang terdiri dari probabilitas K . Sebelum menerapkan *softmax*, beberapa komponen vektor dapat bernilai *negatif*, atau lebih

besar dari satu dan mungkin tidak berjumlah 1, tetapi setelah menerapkan *softmax*, setiap komponen akan berada dalam interval (0 - 1), dan komponen akan bertambah hingga 1, sehingga mereka dapat diartikan sebagai probabilitas. Selanjutnya, komponen *input* yang lebih besar akan sesuai dengan probabilitas yang lebih besar. *Softmax* sering digunakan dalam *neural network*, *softmax* ini digunakan untuk menentukan *output* yang sesuai (Pangestu et al., 2020).

Persamaan 3 berikut ini menunjukkan fungsi aktivasi *softmax*.

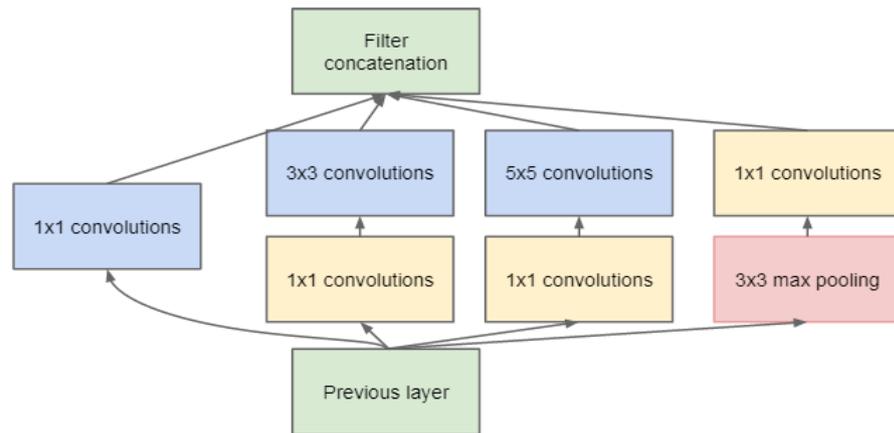
$$p_j(x) = \frac{e^{x_j}}{\sum_{i=1}^k e^{x_i}} \quad (3)$$

Notasi p_j menunjukkan hasil fungsi untuk setiap elemen ke- j pada vektor keluaran kelas. Argumen x adalah hipotesis yang diberikan oleh model pelatihan untuk diklasifikasi oleh fungsi *softmax*. *Softmax* memungkinkan menghitung probabilitas untuk semua label. Dari label yang ada akan diambil sebuah vektor nilai yang bernilai *real* dan merubahnya menjadi vektor dengan nilai antara nol dan satu yang bila semua dijumlah akan bernilai satu (Ilahiyah & Nilogiri, 2018).

2.12 GoogleNet

GoogleNet merupakan salah satu jenis arsitektur yang ada pada CNN dan pertama kali dikenalkan oleh Google pada tahun 2014. Pada tahun 2014 arsitektur ini memperoleh penghargaan sebagai arsitektur terbaik pada ILSVRC14. CNN memiliki *inception modules* yang terdiri dari sejumlah *convolution* kecil. Konsep kerja arsitektur ini didasarkan pada *activation values* pada *deep network* yang tidak sepenuhnya penting karena terdapat *value of zero* akibat korelasi sebelumnya, sehingga dibutuhkan *activation values* yang tidak terkoneksi sepenuhnya. Untuk memenuhi kondisi

tersebut, pada GoogleNet terdapat lapisan *inception module* yang terinspirasi dari model *visual cortex* manusia yang berperan untuk mengoptimalkan *sparse structure* sehingga menunjang komputasi (Saidah et al., 2022). Gambar 12 berikut menunjukkan arsitektur GoogleNet.



Gambar 12. Arsitektur GoogleNet (AL-Huseiny & Sajit, 2021).

GoogleNet memiliki lapisan *inception module* konvolusi dengan matriks 1×1 , 3×3 , 5×5 dengan 3×3 blok operasi pengumpulan *maks* yang bertindak sebagai operasi arbitrer paralel. Blok awal tersebut menerima data dari lapisan sebelumnya, kemudian menerapkan operasi paralel sembarang pada data yang sama. Untuk mengurangi kerugian perhitungan, 1×1 operasi konvolusi berlaku sebelum operasi konvolusi paralel. Namun, 1×1 sub lapisan konvolusi ditempatkan setelah lapisan penggabungan maksimal di dalam modul awal. Di setiap cabang lapisan *Inception*, fitur berbeda dihitung berdasarkan data yang diterima dari lapisan sebelumnya. Kemudian setiap keluaran digabungkan pada akhir operasi paralel ini sebagai masukan untuk lapisan CNN berikutnya. Daripada menggunakan lapisan yang terhubung penuh, model ini menggunakan modul awal untuk mengatasi masalah *overfitting* (Yilmaz & Trocan, 2021).

GoogleNet terdiri dari 22 lapisan termasuk lapisan penggabungan dan 9 *inception module* yang dipasang secara linier. Lapisan tersebut terdiri dari 9 *inception module*, 3 SoftMax layers untuk *auxiliary classifiers* utama, 4

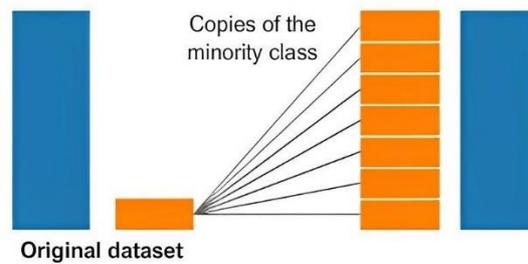
max-pooling layer, 4 *convolutional layers*, 3 *average-pooling*, 5 *fully connected layer* dan 4 *max-pooling layers*. Arsitektur GoogleNet juga menggunakan operasi ReLU di semua *convolutional layers* dan *dropout regularization* di dalam *fully connected layer* (Swarup et al., 2023).

Secara umum, pada arsitektur *GoogleNet*, lapisan konvolusi dan *pooling* berperan dalam melakukan ekstraksi data, sedangkan *inception module* berperan dalam mengurangi beban komputasi dan meningkatkan kedalaman data dan pada bagian akhir arsitektur *GoogleNet*, *fully connected layer* berperan untuk menampung hasil proses lapisan *pooling*. Keluaran sistem akan diganti dengan *simple global average pooling* untuk mengurangi ukuran total parameter tanpa mengurangi akurasi.

2.13 *Random Oversampling*

Random oversampling adalah proses sampling yang dilakukan dengan menambahkan jumlah data pada kelas minoritas secara acak (Amelia et al., 2024). *Random oversampling* biasanya digunakan untuk menyeimbangkan suatu data ketika salah satu kelas data memiliki jumlah data yang lebih sedikit dibanding dengan kelas data lainnya. Teknik *random oversampling* biasanya ditambahkan pada kumpulan data *training* setelah keseluruhan data dibagi menjadi *training*, *validation* dan *testing*.

Random oversampling dilakukan dengan cara menghitung selisih antara kelas mayoritas dan kelas minoritas untuk menentukan seberapa banyak sampel data tambahan yang diperlukan untuk menyamakan jumlah kelas minoritas dengan kelas mayoritas. Setelah itu, sampel-sampel dari kelas minoritas tersebut akan dilakukan duplikasi (penggandaan) sehingga jumlah datanya menjadi lebih seimbang dengan kelas mayoritas (Diantika, 2023).



Gambar 13. *Random Oversampling*.

2.14 Python

Python adalah bahasa pemrograman tingkat tinggi yang dirancang dengan filosofi yang menekankan keterbacaan kode dan sintaksis yang jelas serta ringkas. Python pertama kali ditemukan oleh *programmer* Belanda bernama Guido Van Rossum di Amsterdam pada tahun 1991. Python merupakan bahasa pemrograman dengan tujuan untuk membuat *source code* mudah dibaca. Python mengadopsi paradigma pemrograman dari beberapa bahasa lain, termasuk paradigma pemrograman prosedural seperti bahasa C, pemrograman berorientasi objek seperti Java dan bahasa fungsional seperti Lisp (Rahman et al., 2023).

Python bersifat *open source* yang berarti kodenya terbuka untuk umum sehingga semua orang dapat mengambil, memodifikasi, hingga ikut andil dalam mengembangkan bahasa ini. Python juga memiliki *library* yang lengkap, sehingga memungkinkan para *programmer* untuk dapat membuat suatu aplikasi dengan menggunakan *source code* yang tampak sederhana (Ardianto & Widiyatmoko, 2024). Pada penelitian ini digunakan beberapa *library* seperti berikut.

2.14.1 *Library NumPy*

Library Numerical Python (NumPy) merupakan salah satu *library* Python yang digunakan untuk komputasi numerik seperti mengimplementasikan *array* dan matriks multidimensi bersama dengan operasi matematika tingkat tinggi (Chalik et al., 2021).

2.14.2 *Library Tensorflow*

Library Tensorflow adalah salah satu *framework deep learning* dan salah satu *library* yang bersifat *open source* dan dikembangkan oleh Google. *Library Tensorflow* menggabungkan aljabar komputasi dan teknik pengoptimalan kompilasi untuk mempermudah penghitungan ekspresi matematis dan dapat mengurangi masalah waktu dalam melakukan perhitungan (Prima, 2023).

2.14.3 *Library Keras*

Library Keras adalah *high level neural network API* yang digunakan untuk melakukan komputasi numerik dan *machine learning*, yang ditulis dalam bahasa Python dan mempunyai kemampuan berjalan di atas *Tensorflow* (Purnama & Negara, 2021).

2.14.4 *Library Scikit-learn*

Library Scikit-learn merupakan *library* Python yang digunakan dalam *machine learning*. *Library scikit-learn* mendukung berbagai algoritma *machine learning* yang menyediakan alat untuk klasifikasi, regresi, pengelompokan dan pengurangan dimensi (Setiady & Apatya, 2020).

2.14.5 *Library Matplotlib*

Library Matplotlib adalah sebuah *library* Python yang bertanggung jawab untuk merencanakan data numerik. *Library Matplotlib* berfungsi untuk menampilkan hasil analisis berupa visualisasi data seperti *plot* grafik berwarna dengan lebih rapi dan menarik (Ramadhyagita et al., 2022).

2.15 *Confusion Matrix*

Confusion Matrix merupakan salah satu metode yang digunakan untuk menyatakan hasil klasifikasi data yang teruji benar dan salah. *Confusion matrix* berbentuk Tabel yang digunakan untuk mengevaluasi kinerja dari

suatu model klasifikasi. Tabel ini berisi informasi mengenai jumlah prediksi yang dilakukan menggunakan sebuah model. Kategori hasil prediksi *confusion matrix* dalam bentuk Tabel dapat dilihat pada Tabel 2.

Tabel 2. *Confusion Matrix*.

Sampel \ Prediksi	Positif	Negatif
	Positif	<i>True Positive</i>
Negatif	<i>False Positive</i>	<i>True Negative</i>

Keterangan:

True Positive (TP) = Data positif yang terdeteksi positif.

False Positive (FP) = Data positif yang terdeteksi negatif.

True Negative (TN) = Data negatif yang terdeteksi negatif.

False Negative (FN) = Data negatif yang terdeteksi positif.

Dalam *confusion matrix* pengukuran performa secara umum dilakukan dengan menghitung nilai *accuracy*, *precision*, *recall*, dan *f1-score*.

A. *Accuracy*

Accuracy merupakan persentase yang menggambarkan kinerja dari sebuah model pembelajaran mesin atau sistem klasifikasi. *Accuracy* dapat diukur dengan cara menghitung jumlah objek yang benar dikelompokkan dalam kelas yang sesuai dengan jumlah objek yang ada dalam *dataset*. Persamaan *accuracy* dapat dilihat pada Persamaan 4 berikut.

$$accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (4)$$

B. *Precision*

Precision merupakan metode pengujian yang menghitung kemampuan model dalam mengidentifikasi data *false positive* (FP). *Precision* dihitung dengan membagi jumlah prediksi *true positive* (TP) dengan

jumlah prediksi *true positive* (TP) ditambah prediksi *false positive* (FP). Persamaan presisi dapat dilihat pada Persamaan 5 berikut.

$$precision = \frac{TP}{TP+FP} \times 100\% \quad (5)$$

C. Recall

Recall merupakan metode pengujian yang menghitung akurasi model dalam memprediksi sampel yang bernilai benar. *Recall* dihitung dengan cara membagi jumlah prediksi *true positive* (TP) dengan jumlah sampel yang bernilai benar. Persamaan *recall* dapat dilihat pada Persamaan 6 berikut.

$$recall = \frac{TP}{TP+FN} \times 100\% \quad (6)$$

D. F1-Score

F1-Score merupakan metode pengujian yang digunakan untuk menilai kinerja model klasifikasi, terutama ketika data tidak seimbang. *F1-Score* dihitung dengan menggunakan nilai presisi dan *recall*. *F1-Score* berguna untuk meminimalkan *false positive* (FP) dan *false negatif* (FN) secara seimbang. Persamaan *F1-Score* dapat dilihat pada Persamaan 7 berikut.

$$F1 - score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (7)$$

BAB III METODE PENELITIAN

3.1 Waktu dan Tempat Penelitian

3.1.1 Waktu Penelitian

Penelitian ini dilakukan pada semester genap dengan perkiraan waktu bulan Februari 2024 hingga bulan Oktober 2024. Estimasi waktu pelaksanaan penelitian digambarkan pada Tabel 3 berikut.

Tabel 3. Estimasi Waktu Penelitian.

No.	Jadwal Kegiatan	Bulan Pelaksanaan						
		April	Mei	Juni	Juli	Agustus	September	Oktober
1.	Penulisan Laporan Bab 1-3	■						
2.	Pengumpulan Data	■						
3.	<i>Pre-Processing</i> Data		■					
4.	Seminar Usul Proposal			■				
5.	Pembagian Data <i>Training</i> dan Data <i>Testing</i>			■				
6.	<i>Training</i> Model GoogleNet			■	■	■	■	
7.	Evaluasi Model			■	■	■	■	
8.	Penulisan Laporan Bab 4-5					■	■	■
9.	Seminar Hasil Penelitian							■

3.1.2 Tempat Penelitian

Penelitian ini dilakukan di Laboratorium Komputasi Dasar Jurusan Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung yang beralamat di Jalan. Prof. Dr. Ir. Sumantri Brojonegoro No.1, Gedung Meneng, Kecamatan Rajabasa, Kota Bandar Lampung.

3.2 Alat Pendukung

Adapun alat pendukung dalam penelitian ini sebagai berikut:

3.2.1 Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan dalam penelitian ini yaitu:

- a. Laptop : Lenovo Ideapad Slim 3.
- b. *Processor* : Intel Core I5-12450H.
- c. Penyimpanan : SSD 512GB.
- d. RAM : 8 GB.
- e. GPU : Intel HD Graphics.

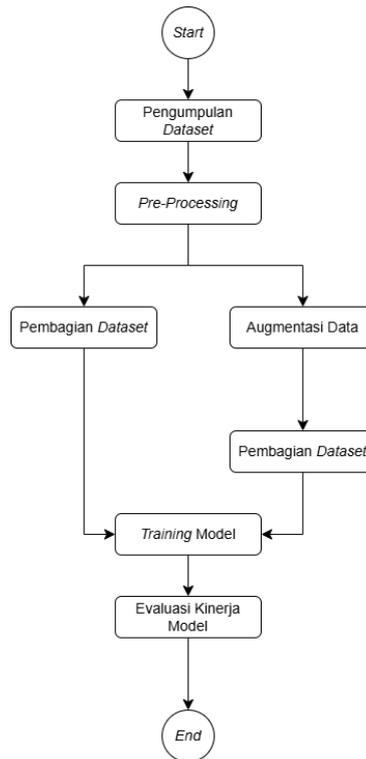
3.2.2 Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan dalam penelitian ini yaitu :

- a. Sistem Operasi *Windows 11 Home Single Language 64-bit*.
- b. Google Colab dan Kaggle merupakan kode editor untuk melakukan proses *coding*.
- c. Google Drive merupakan tempat untuk penyimpanan *dataset*.
- d. Python merupakan kode program untuk model.
- e. *Library* yang digunakan dalam penelitian ini seperti *Tensorflow/Keras, Scikit-learn, NumPy, dan Matplotlib*.

3.3 Tahapan Penelitian

Penelitian ini melalui beberapa tahapan terstruktur ditunjukkan pada Gambar 13 berikut ini.



Gambar 14. Tahapan Penelitian.

3.3.1 Pengumpulan *Dataset*

Dataset pada penelitian ini diperoleh dari *open dataset* <https://data.mendeley.com/datasets/> untuk data HuSHeM dan (Chang et al., 2017) untuk data SCIAN-MorphoSpermGS. *Dataset* HuSHeM memiliki jumlah data sebanyak 216 citra dengan format citra BMP dan berukuran 131x131 piksel. Pada *dataset* HuSHeM terdapat empat kelas yaitu Normal, *Pyriiform*, *Tapered* dan *Amorphous*. *Dataset* SCIAN-MorphoSpermGS memiliki jumlah data 1132 citra dengan format TIF dan berukuran 35x35 piksel. Berbeda dengan *dataset* HuSHeM pada *dataset* SCIAN-MorphoSpermGS terdapat lima kelas data yaitu, Normal, *Pyriiform*, *Tapered*, *Amorphous* dan *Small*.

3.3.2 *Pre-processing*

Pada tahapan *pre-processing*, ada beberapa tahapan yang harus dilakukan yaitu:

a. **Mengubah Ekstensi *File* Citra**

Pada tahap pertama *pre-processing* adalah mengubah ekstensi *file* citra. Proses ekstensi *file* citra ini dilakukan untuk menyamakan seluruh *file* citra dan memudahkan proses pengujian data. Pada data HuSHeM dan SCIAN-MorphoSpermGS *file* citra sebelumnya adalah BMP dan TIF, kemudian *file* gambar tersebut diubah menjadi JPEG.

b. ***Cropping Images***

Tahapan *cropping images* dilakukan untuk menghilangkan bagian tertentu dari suatu citra dan memfokuskannya pada area penting atau yang area yang diinginkan dari suatu objek citra, sehingga hasil dari data yang telah di-*crop* bisa lebih detail dan efektif untuk dilakukan pengujian data. Proses *cropping images* ini hanya diterapkan pada data HuSHeM saja, karena pada data SCIAN sudah menampilkan bagian terpenting dari data yang akan diolah, sedangkan di data HuSHeM masih terdapat banyak area kosong di sekitar objek penting yang akan diuji.

c. ***Resize Images***

Tahapan *resize images* dilakukan untuk mengubah citra menjadi lebih besar atau lebih kecil untuk menyamakan ukuran dan mendapatkan kualitas data. Dalam penelitian ini *resize images* digunakan untuk mengubah citra pada data SCIAN-MorphoSpermGS menjadi lebih besar dari 35x35 piksel menjadi 131x131 piksel untuk menghasilkan kualitas citra yang lebih baik. Pada data HuSHeM tidak dilakukan *resize images*, karena ukuran pada data HuSHeM sudah sebesar 131x131 piksel.

d. Augmentasi Data

Pada tahap augmentasi data dilakukan untuk meningkatkan keragaman data, dalam penelitian ini dilakukan augmentasi menggunakan teknik augmentasi seperti *horizontal flip*, *rescale*, *rotation* dan *zoom*.

3.3.3 Pembagian Dataset

Pada tahap pembagian *dataset*, data dibagi menjadi data latih (*training dataset*), data validasi (*validation dataset*) dan data uji (*testing dataset*). *Dataset* dibagi menjadi tiga macam yaitu:

- a) *Training* 80%, *Validation* 10% dan *Testing* 10%.
- b) *Training* 70%, *Validation* 25% dan *Testing* 5%.
- c) *Training* 60%, *Validation* 20% dan *Testing* 20%.

3.3.4 Training Model

Dalam melakukan *training* model, model yang digunakan adalah GoogleNet atau Inception V1. Model GoogleNet harus didefinisikan terlebih dahulu *modul inception*, *classifier* tambahan serta *global average poolingnya*, kemudian model diinisialisasi dengan *hyperparameter* yang telah ditentukan, seperti *learning rate*, *batch size* dan jumlah *epoch*-nya.

3.3.5 Evaluasi Kinerja Model

Evaluasi kinerja model digunakan untuk mendeteksi tingkat akurasi model GoogleNet dalam melakukan klasifikasi sperma. Evaluasi kinerja model dilakukan menggunakan *precision*, *recall* dan F1-score, untuk memberikan gambaran mengenai seberapa baik model dapat mengklasifikasikan data dengan benar.

BAB V

SIMPULAN DAN SARAN

5.1 Simpulan

Berdasarkan penelitian yang telah dilakukan didapatkan beberapa simpulan yaitu sebagai berikut :

- a. Penelitian ini berhasil mengimplementasikan model GoogleNet pada kumpulan data HuSHeM dan SCIAN-MorphospermGS yang masing-masing kumpulan data berjumlah 216 data citra untuk data HuSHeM dan 1132 data citra untuk data SCIAN-MorphospermGS.
- b. Pada penelitian ini pengujian dilakukan dengan membagi data menjadi 3 skenario pembagian dengan menggunakan 3 macam *learning rate* yang berbeda. Berdasarkan pembagian data dan pengujian yang telah dilakukan didapatkan hasil akurasi yang paling tinggi pada data HuSHeM yang menggunakan augmentasi, adapun hasil pengujian dengan *learning rate* 0.001 dan 0.0001 didapatkan pada pembagian data 70%, *validation*, 25% dan *testing* 5% dengan hasil akurasi sebesar 0.9846 atau 98% dan 0.9692 atau 97%, sedangkan hasil pengujian dengan *learning rate* 0.00001 didapatkan pada pembagian data 80%, *validation*, 10% dan *testing* 10% dengan hasil akurasi sebesar 0.8846 atau 88%.
- c. Pada data SCIAN-MorphospermGS hasil akurasi tertinggi didapatkan *learning rate* 0.0001 pada pembagian data 80%, *validation*, 10% dan *testing* 10% dengan hasil akurasi 0.7338 atau 73%, sedangkan untuk *learning rate* 0.001 dan 0.00001 sama-sama didapatkan pada pembagian data 70%.

validation, 25% dan *testing* 5% dengan hasil akurasi sebesar 0.5558 atau 55% dan 0.6764 atau 68%.

- d. Pada data HuSHeM yang tidak menggunakan augmentasi hasil akurasi tertinggi untuk data HuSHem dengan *learning rate* 0.001 didapatkan pada pembagian data *training* 80%, *validation* 10% dan *testing* 10% yaitu sebesar 0.4545 atau 45% untuk *learning rate* 0.0001 dan 0.00001 didapatkan pada pembagian data *training* 60%, *validation* 20% dan *testing* 20% sebesar 0.5 atau 50% dan 0.5454 atau 58%.
- e. Pada data SCIAN-MorphospermGS yang tidak menggunakan augmentasi hasil akurasi tertinggi untuk *learning rate* 0.0001 dan 0.00001 didapatkan pada pembagian data *training* 60%, *validation* 20% dan *testing* 20% yaitu sebesar 0.6666 atau 67% dan 0.6696 atau 67%, sedangkan hasil *learning rate* 0.001 didapatkan pada pembagian data *training* 80%, *validation* 10% dan *testing* 10% yaitu sebesar 0.5877 atau 59%.

5.2 Saran

Berdasarkan penelitian yang telah dilakukan, adapun saran dari penelitian yang telah dilakukan yaitu :

1. Pada penelitian selanjutnya dapat melakukan penelitian dengan menggunakan model arsitektur terbaru dari arsitektur GoggleNet yaitu Inception V3 atau menggunakan model arsitektur lainnya.
2. Pada penelitian selanjutnya dapat menambahkan variasi data dengan menambahkan augmentasi yang lainnya ataupun dapat mencoba menggunakan nilai *learning rate* lainnya.

DAFTAR PUSTAKA

- Ahmad, A. (2017). Mengenal Artificial Intelligence, Machine Learning, Neural Network, dan Deep Learning. *Jurnal Teknologi Indonesia*, 1(June), 1–6. <https://amt-it.com/mengenal-perbedaan-artificial-intelligence-machine-learning-deep-learning/>
- AL-Huseiny, M. S., & Sajit, A. S. (2021). Transfer learning with GoogLeNet for detection of lung cancer. *Indonesian Journal of Electrical Engineering and Computer Science*, 22(2), 1078–1086. <https://doi.org/10.11591/ijeecs.v22.i2.pp1078-1086>
- Amelia, R., Fitrianto, A., Rizki, A., Barat-indonesia, J., Biner, R. L., & Merokok, B. (2024). *Komparasi Teknik Undersampling Dan Oversampling Pada Regresi*. X(2), 1–11.
- Ardianto, D., & Widiyatmoko, A. T. (2024). Color Detector in an Image using Python and Computer Vision Library. *Journal of Intelligent Systems and Information Technology*, 1(1), 25–30. <https://doi.org/10.61971/jisit.v1i1.27>
- Azizah, L. M., Umayah, S. F., & Fajar, F. (2018). Deteksi Kecacatan Permukaan Buah Manggis Menggunakan Metode Deep Learning dengan Konvolusi Multilayer. *Semesta Teknika*, 21(2), 230–236. <https://doi.org/10.18196/st.212229>
- Chalik, A. M., Qowy, B. A., Hanafi, F., & Nuraminah, A. (2021). Mouse Tracking Tangan dengan Klasifikasi Gestur Menggunakan OpenCV dan Mediapipe. *Jurnal Ilmiah Teknik Informatika Dan Komunikasi*, 1(2), 10–18. <https://doi.org/10.55606/juitik.v1i2.323>

Chang, V., Garcia, A., Hitschfeld, N., & Härtel, S. (2017). Gold-standard for computer-assisted morphological sperm analysis. *Computers in Biology and Medicine*, 83(March), 143–150. <https://doi.org/10.1016/j.combiomed.2017.03.004>

Dewanto, H., Lisdiana, & Isnaeni, W. (2017). Pengaruh Ekstrak Kulit Buah Rambutan terhadap Kualitas Sperma Tikus yang Terpapar Asap Rokok. *Life Science*, 6(2), 62–68. [https://journal.unnes.ac.id/sju/index.php/UnnesJLifeSci/article/view/25349#:~:text=Hasil penelitian menunjukkan bahwa ekstrak,mg%2Fkg BB%2Fhari](https://journal.unnes.ac.id/sju/index.php/UnnesJLifeSci/article/view/25349#:~:text=Hasil%20penelitian%20menunjukkan%20bahwa%20ekstrak%20mg%20Fkg%20BB%20Fhari).

Diantika, S. (2023). Penerapan Teknik Random Oversampling Untuk Mengatasi Imbalance Class Dalam Klasifikasi Website Phishing Menggunakan Algoritma Lightgbm. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(1), 19–25. <https://doi.org/10.36040/jati.v7i1.6006>

Eriana, E. S., & Zein, D. A. (2019). Artificial Intelligence. *Angewandte Chemie International Edition*, 6(11), 951–952., 2.

Fadilah, S. N., Novitasari, D. C. R., & Hakim, L. (2023). Pengaruh Reduksi Fitur Pada Klasifikasi Kanker Paru Menggunakan CNN Dengan Arsitektur GoogLeNet. *Jurnal Fourier*, 12(1), 20–32. <https://doi.org/10.14421/fourier.2023.121.20-32>

Fadjeri, A. (2020). Pengolahan Citra Digital Untuk Menghitung Ekstraksi Ciri Greenbean Kopi Robusta Dan Arabika (Studi Kasus: Kopi Temanggung). *Indonesian Journal of Applied Informatics*, 4(2), 92. <https://doi.org/10.20961/ijai.v4i2.39253>

Fadjeri, A., Saputra, B. A., Adri Ariyanto, D. K., & Kurniatin, L. (2022). Karakteristik Morfologi Tanaman Selada Menggunakan Pengolahan Citra Digital. *Jurnal Ilmiah SINUS*, 20(2), 1. <https://doi.org/10.30646/sinus.v20i2.601>

Gani, S., & Arsyad, B. (2019). Kajian Teoritis Struktur Internal Bahasa (Fonologi, Morfologi, Sintaksis, dan Semantik). *A Jamiy : Jurnal Bahasa Dan Sastra Arab*, 7(1), 1. <https://doi.org/10.31314/ajamiy.7.1.1-20.2018>

Hoang, T. H., Binh, N. T., Van, V., & Tan, N. Q. (2022). Lung and Colon Tumor Classification Based on Transfer Learning-Based Techniques. *Communications in Computer and Information Science*, 1688 CCIS(November), 614–624. https://doi.org/10.1007/978-981-19-8069-5_42

Ilahiyah, S., & Nilogiri, A. (2018). Implementasi Deep Learning Pada Identifikasi Jenis Tumbuhan Berdasarkan Citra Daun Menggunakan Convolutional Neural Network _ Ilahiyah _ JUSTINDO (Jurnal Sistem dan Teknologi Informasi Indonesia). *JUSTINDO(Jurnal Sistem & Teknologi Informasi Indonesia)*, 3(2), 49–56.

Iqbal, I., Mustafa, G., & Ma, J. (2020). Deep learning-based morphological classification of human sperm heads. *Diagnostics*, 10(5). <https://doi.org/10.3390/diagnostics10050325>

Krisna, I. (2018). *Pengaruh Suhu Terhadap Pemeriksaan Motilitas Sperma*. Jurusan Analis Kesehatan.

Maulana, A. (2022). *Segmentasi Citra Biner Menggunakan Metode Sauvola Pada Studi Kasus Daun Kuping Gajah (Anthurium)*. Universitasl Muhammadiyah Purwokerto.

Mulyana, D. I., & Wibowo, D. R. (2023). Implementasi Tingkat Kematangan Buah Monk Dengan Menggunakan Ekstraksi Gray-Level Co-Occurrence Matrix (GlcM) Dan Support Vector Machine (Svm). *Jurnal Informatika Teknologi Dan Sains (Jinteks)*, 5(3), 334–339. <https://doi.org/10.51401/jinteks.v5i3.2512>

Munantri, N. Z., Sofyan, H., & Florestiyanto, M. Y. (2020). Aplikasi Pengolahan Citra Digital Untuk Identifikasi Umur Pohon. *Telematika*, 16(2), 97. <https://doi.org/10.31315/telematika.v16i2.3183>

Nugroho, P. A., Fenriana, I., & Arijanto, R. (2020). Implementasi Deep Learning Menggunakan Convolutional Neural Network (CNN) Pada Ekspresi Manusia. *Algor*, 2(1), 12–21.

Pangestu, R. A., Rahmat, B., & Anggraeny, F. T. (2020). Implementasi Algoritma

Cnn Untuk Klasifikasi CitraLahan Dan Perhitungan Luas. *Jurnal Informatika Dan Sistem Informasi*, 1(1), 166–174.

Prima, A. (2023). Rancang Bangun Sistem Pendeteksi Aneka Ragam Buah Menggunakan MobileNetv2. *Jurnal Sistim Informasi Dan Teknologi*, 5(2), 208–215. <https://doi.org/10.60083/jsisfotek.v5i2.217>

Priyambudi, I. A., Fauzi Tresna, H., Kumalasari, N., & Pratiwi, C. (2022). *Identifikasi Jenis Kelamin Individu Melalui Pola Sidik Bibir Berbasis Smartphone Android Identification of Gender Throught Lips Print Pattern Based on Smatrphone Android*. 9(1), 1–13.

Purnama, N., & Negara, P. K. (2021). *Deteksi Masker Pencegahan Covid19 Menggunakan Convolutional Neural*. 1(10), 576–583.

Putra, A. K., & Bunyamin, H. (2020). Pengenalan Simbol Matematika dengan Metode Convolutional Neural Network (CNN). *Jurnal Strategi*, 2(November), 426.

Rahman, S., Sembiring, A., Siregar, D., Khair, H., Gusti Prahmana, I., Puspadini, R., & Zen, M. (2023). Python : Dasar Dan Pemrograman Berorientasi Objek. In *Penerbit Tahta Media*.

Rahouma, K. H., Aly, R. H. M., & Hamed, H. F. A. (2020). Applying deep learning techniques for heart big data diagnosis. In *Lecture Notes in Networks and Systems* (Vol. 114, Issue January). Springer Singapore. https://doi.org/10.1007/978-981-15-3075-3_19

Ramadhani, F., Satria, A., & Salamah, S. (2023). Implementasi Algoritma Convolutional Neural Network dalam Mengidentifikasi Dini Penyakit pada Mata Katarak. *Sudo Jurnal Teknik Informatika*, 2(4), 167–175. <https://doi.org/10.56211/sudo.v2i4.408>

Ramadhyagita, I. L., Annisa, A., Kamindra, F., & Rizky, F. M. (2022). Kajian Discrete Fourier Transform untuk Menganalisis Sinyal Arbitrer. *Mitra Pilar: Jurnal Pendidikan, Inovasi, Dan Terapan Teknologi*, 1(1), 7–16. <https://doi.org/10.58797/pilar.0101.02>

- Rima, M. (2022). Kajian Materi Sistem Reproduksi Manusia Terintegrasi Sains Dan Hukum Islam. *Skripsi*. <http://repository.radenintan.ac.id/18916/>
- Riordon, J., McCallum, C., & Sinton, D. (2019). Deep learning for the classification of human sperm. *Computers in Biology and Medicine*, 111(June). <https://doi.org/10.1016/j.combiomed.2019.103342>
- Roihan, A., Sunarya, P. A., & Rafika, A. S. (2020). Pemanfaatan Machine Learning dalam Berbagai Bidang: Review paper. *IJCIT (Indonesian Journal on Computer and Information Technology)*, 5(1), 75–82. <https://doi.org/10.31294/ijcit.v5i1.7951>
- Saidah, S., Suparta, I. P. Y. N., & Suhartono, E. (2022). Modifikasi Convolutional Neural Network Arsitektur GoogLeNet dengan Dull Razor Filtering untuk Klasifikasi Kanker Kulit. *Jurnal Nasional Teknik Elektro Dan Teknologi Informasi*, 11(2), 148–153. <https://doi.org/10.22146/jnteti.v11i2.2739>
- Sanjaya, J., & Ayub, M. (2020). Augmentasi Data Pengenalan Citra Mobil Menggunakan Pendekatan Random Crop, Rotate, dan Mixup. *Jurnal Teknik Informatika Dan Sistem Informasi*, 6(2), 311–323. <https://doi.org/10.28932/jutisi.v6i2.2688>
- Setiady, W., & Apatya, Y. B. A. (2020). Design Design the temperature and humidity classification of the workspace by using a decision tree model. *Electro Luceat*, 6(2), 169–178. <https://doi.org/10.32531/jelekn.v6i2.228>
- Shahzad, S., Ilyas, M., Lali, M. I. U., Rauf, H. T., Kadry, S., & Nasr, E. A. (2023). Sperm Abnormality Detection Using Sequential Deep Neural Network. *Mathematics*, 11(3). <https://doi.org/10.3390/math11030515>
- Spencer, L., Fernando, J., Akbaridoust, F., Ackermann, K., & Nosrati, R. (2022). Ensembled Deep Learning for the Classification of Human Sperm Head Morphology. *Advanced Intelligent Systems*, 4(10). <https://doi.org/10.1002/aisy.202200111>
- Swarup, C., Singh, K. U., Kumar, A., Pandey, S. K., varshney, N., & Singh, T. (2023). Brain tumor detection using CNN, AlexNet & GoogLeNet ensembling

learning approaches. *Electronic Research Archive*, 31(5), 2900–2924.
<https://doi.org/10.3934/ERA.2023146>

Tortumlu, O. L., & Ilhan, H. O. (2020). The Analysis of Mobile Platform based CNN Networks in the Classification of Sperm Morphology. *TIPTEKNO 2020 - Tip Teknolojileri Kongresi - 2020 Medical Technologies Congress, TIPTEKNO 2020*, 11–14. <https://doi.org/10.1109/TIPTEKNO50054.2020.9299281>

Yilmaz, E., & Trocan, M. (2021). A modified version of GoogLeNet for melanoma diagnosis. *Journal of Information and Telecommunication*, 5(3), 395–405.
<https://doi.org/10.1080/24751839.2021.1893495>

Yuhandri. (2019). Perbandingan Metode Cropping Pada Sebuah Citra Untuk Pengambilan Motif Tertentu Pada Kain Songket Sumatera Barat. *JurnalKomtekInfo(KomputerTeknologiInformasi)*, 96–105.
<http://lppm.upiypk.ac.id/ojsupi/index.php/KOMTEKINFO>

Yulianti, H. (2020). *Klasifikasi Tanaman Obat Menggunakan Metode Gray Level Co-Occurrence Matrix Dan Support Vector Machine*. Universitas Komputer Indonesia.

Yüzkat, M., Ilhan, H. O., & Aydin, N. (2021). Multi-model CNN fusion for sperm morphology analysis. *Computers in Biology and Medicine*, 137(August), 104790.
<https://doi.org/10.1016/j.combiomed.2021.104790>