

**KLASIFIKASI SPERMA MANUSIA BERDASARKAN MORFOLOGI
MENGUNAKAN ALGORITME *CONVOLUTIONAL NEURAL
NETWORK* ARSITEKTUR RESNET101 DENGAN *TRANSFER
LEARNING* DAN AUGMENTASI DATA**

(Skripsi)

Oleh

SILVIA RUKMANA

2017051047



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

**KLASIFIKASI SPERMA MANUSIA BERDASARKAN MORFOLOGI
MENGUNAKAN ALGORITME *CONVOLUTIONAL NEURAL
NETWORK* ARSITEKTUR RESNET101 DENGAN *TRANSFER
LEARNING* DAN AUGMENTASI DATA**

Oleh

SILVIA RUKMANA

Skripsi

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

Pada

**Jurusan Ilmu Komputer
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Lampung**



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

ABSTRAK

KLASIFIKASI SPERMA MANUSIA BERDASARKAN MORFOLOGI MENGUNAKAN ALGORITME *CONVOLUTIONAL NEURAL NETWORK* ARSITEKTUR RESNET101 DENGAN *TRANSFER LEARNING* DAN AUGMENTASI DATA

Oleh

SILVIA RUKMANA

Infertilitas merupakan gangguan yang menghambat reproduksi makhluk hidup untuk menghasilkan individu baru dari generasi keturunannya. Infertilitas pada pria dapat disebabkan oleh banyak faktor, salah satunya adalah kelainan morfologi sperma yang menyebabkan ketidaksuburan pada pria. Oleh karena itu, klasifikasi morfologi sperma penting dalam menganalisis kualitas sperma. Analisis kualitas sperma biasanya dilakukan secara manual dengan bantuan mikroskop. Namun, hal tersebut membutuhkan waktu yang lama dan hasil yang tidak selalu akurat. Perkembangan teknologi pada saat ini, dapat membantu menganalisis kualitas sperma secara otomatis dengan tingkat akurasi yang tinggi. Salah satunya menggunakan *deep learning* dengan pendekatan *convolutional neural network* yang mampu menganalisis sperma secara otomatis. *Convolutional neural network* (CNN) banyak digunakan dalam tugas pengenalan citra. Terdapat beberapa jenis arsitektur dalam CNN salah satunya adalah arsitektur ResNet101. Dalam penelitian ini digunakan algoritma CNN arsitektur ResNet101 dalam mengklasifikasikan morfologi sperma. Penelitian ini menggunakan dua *dataset* sperma, yaitu HuSHem dan SCIAN. Model yang digunakan yaitu ResNet101 dengan *transfer learning* dan dilakukan penambahan *layer* baru yang sesuai dengan data. Teknik augmentasi data diimplementasikan untuk memperbanyak variasi data yang mampu meningkatkan kinerja model. Hasil penelitian menunjukkan bahwa pada *dataset* HuSHem dengan hasil pengujian terbaik mencapai *accuracy* sebesar 97.73%, dengan *precision* 97.93%, *recall* 97.73% dan *f1-score* 97.73%. Sementara itu, pada *dataset* SCIAN hasil terbaik dengan *accuracy* sebesar 70.18%, dengan *precision* 69.51%, *recall* 69.17% dan *f1-score* 70.18%. Hasil pengujian tersebut menunjukkan kemampuan model ResNet101 dalam mengklasifikasikan morfologi sperma.

Kata Kunci: *Deep learning*, *convolutional neural network*, sperma, ResNet101, *transfer learning*

ABSTRACT

HUMAN SPERM CLASSIFICATION BASED ON MORPHOLOGY USING CONVOLUTIONAL NEURAL NETWORK ALGORITHM RESNET101 ARCHITECTURE WITH TRANSFER LEARNING AND DATA AUGMENTATION

By

SILVIA RUKMANA

Infertility is a disorder that inhibits the reproduction of living things to produce new individuals from their offspring. Infertility in men can be caused by many factors, one of which is sperm morphology abnormalities that cause infertility in men. Therefore, it is important to analyze sperm quality. Sperm quality analysis is usually done manually with the help of a microscope. However, it takes a long time and the results are not always accurate. Current technological developments can help analyze sperm quality with high accuracy results. One of them uses deep learning with a convolutional neural network approach that can analyze sperm automatically. In analyzing sperm evaluation, this research uses a convolutional neural network algorithm with ResNet101 architecture with transfer learning and data augmentation that can improve model performance. The purpose of this study is to evaluate the performance of the model in classifying sperm morphology. This study uses two sperm datasets, namely HuSHem and SCIAN. The results obtained on the HuSHem dataset with the best test results with accuracy 97.73%, precision 97.93%, recall 97.73% and f1-score 97.73% while for the SCIAN dataset the best results with accuracy 70.18%, precision 69.51%, recall 69.17% and f1-score 70.18%.

Keywords: Deep learning, convolutional neural network, sperm, ResNet101, transfer learning.

Judul Skripsi : **KLASIFIKASI SPERMA MANUSIA
BERDASARKAN MORFOLOGI
MENGUNAKAN ALGORITME
CONVOLUTIONAL NEURAL NETWORK
ARSITEKTUR RESNET101 DENGAN
TRANSFER LEARNING DAN
AUGMENTASI DATA**

Nama Mahasiswa : *Silvia Rukmana*

Nomor Pokok Mahasiswa : 2017051047

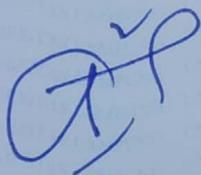
Program Studi : S1 Ilmu Komputer

Jurusan : Ilmu Komputer

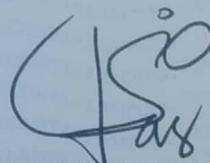
Fakultas : Matematika dan Ilmu Pengetahuan Alam

MENYETUJUI

1. Komisi Pembimbing

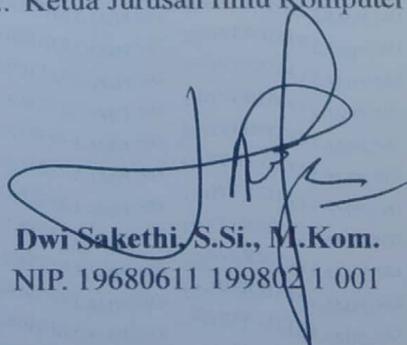


Dr. Aristoteles. S.Si., M.,Si.
NIP. 19810521 200604 1 002



Dewi Asiah Shofiana, S.Komp., M.Kom.
NIP. 19950929 202012 2 030

2. Ketua Jurusan Ilmu Komputer

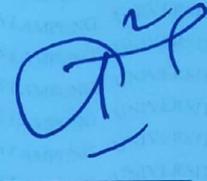


Dwi Sakethi, S.Si., M.Kom.
NIP. 19680611 199802 1 001

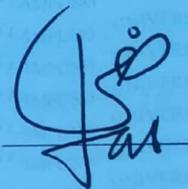
MENGESAHKAN

1. **Tim Penguji**

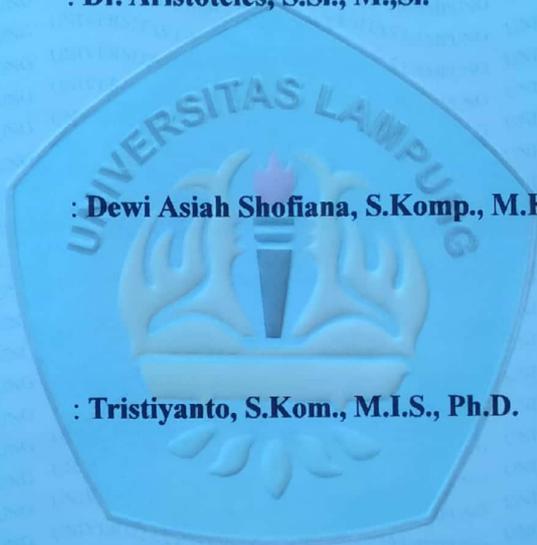
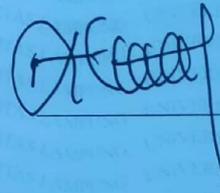
Ketua : Dr. Aristoteles, S.Si., M.Si.



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



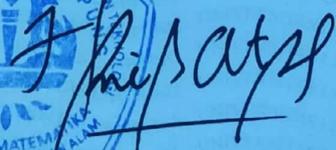
Penguji Utama : Tristiyanto, S.Kom., M.I.S., Ph.D.



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:

Nama : Silvia Rukmana

NPM : 2017051047

Menyatakan bahwa skripsi saya yang berjudul **“Klasifikasi Sperma Manusia Berdasarkan Morfologi Menggunakan Algoritme *Convolutional Neural Network* Arsitektur ResNet101 dengan *Transfer Learning* dan Augmentasi Data“** merupakan karya saya sendiri dan bukan karya orang lain. Semua tulisan yang tertulis di skripsi ini telah mengikuti kaidah penulisan karya tulis ilmiah Universitas Lampung. Apabila di kemudian hari terbukti bahwa skripsi saya merupakan hasil menjiplak karya orang lain, maka saya bersedia menerima sanksi berupa pencabutan gelar yang saya terima.

Bandar Lampung, 17 Desember 2024



Silvia Rukmana

NPM. 2017051047

RIWAYAT HIDUP



Penulis lahir di Cimanuk, pada tanggal 10 Juni 2003 sebagai anak terakhir dari pasangan Bapak Hasan Bisri dan Ibu Junariah. Pendidikan yang telah ditempuh oleh penulis diantaranya, menyelesaikan pendidikan formal di SD Negeri 3 Waylima yang berada di Kabupaten Pesawaran Provinsi Lampung pada tahun 2014. Kemudian menyelesaikan pendidikan menengah pertama di MTsN 2 Pesawaran pada tahun 2017 dan melanjutkan pendidikan menengah atas di MAN 1 Pesawaran yang diselesaikan pada tahun 2020. Pada tahun 2020 penulis terdaftar sebagai mahasiswa Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung melalui jalur Seleksi Bersama Masuk Perguruan Tinggi Negeri (SBMPTN).

Selama menjadi mahasiswa, penulis melakukan beberapa kegiatan antara lain:

1. Menjadi anggota bidang kajian dan keumatan Rois FMIPA Universitas Lampung pada periode 2021.
2. Menjadi anggota bidang kemuslimahan Rois FMIPA Universitas Lampung pada periode 2022.
3. Melaksanakan Kerja Praktik di Goodwood Publishing pada tahun 2023.
4. Melaksanakan KKN periode I tahun 2023 di Desa Kunyayan, Wonosobo, Tanggamus.
5. Menjadi koordinator divisi Publikasi, Desain dan Dokumentasi selama kegiatan Kuliah Kerja Nyata (KKN) di Kunyayan, Kecamatan Wonosobo, Kabupaten Tanggamus pada tahun 2023.

MOTTO

“Karena sesungguhnya setelah kesulitan itu ada kemudahan”

- *Al-Insyirah: 5*

“Anything we do is never in vain, let the experiences we've been through become valuable lessons. Keep moving forward and stepping ahead with full spirit”

- Silvia

“Always include prayers in every step you take”

- Silvia

PERSEMBAHAN

Alhamdulillahirobbilalamin

Segala puji dan syukur saya panjatkan kepada Allah Subhanahu Wa Ta'alaah atas segala rahmat dan karunia-Nya serta shalawat dan salam senantiasa tercurahkan kepada Nabi Muhammad SAW sehingga saya dapat menyelesaikan skripsi ini.

Skripsi ini saya persembahkan kepada:

Kedua orang tua, kakak-kakak dan keluarga besar saya yang senantiasa memberikan semangat, motivasi, dukungan serta doa yang senantiasa selalu dipanjatkan. Terimakasih karena telah mendukung dan selalu mendoakan, sehingga saya dapat menyelesaikan pendidikan ini dengan baik.

SANCAWACANA

Puji syukur kehadiran Allah SWT yang telah memberikan rahmat dan hidayat-Nya sehingga penulis mampu menyelesaikan skripsi ini dengan baik yang berjudul “Klasifikasi Sperma Manusia Berdasarkan Morfologi Menggunakan Algoritme *Convolutional Neural Network* Arsitektur ResNet101 dengan *Transfer Learning* dan Augmentasi Data”. Tidak lupa pula shalawat dan salam senantiasa penulis curahkan kepada Nabi Muhammad SAW, yang telah memberikan pedoman dan petunjuk ke arah jalan yang benar.

Selama proses penelitian skripsi ini, tidak terlepas dari dukungan dan bantuan dari orang-orang kepada penulis dari berbagai pihak, baik secara langsung maupun tidak langsung. Oleh karena itu, penulis menyampaikan ucapan terima kasih yang sebesar besarnya kepada:

1. Allah Subhanahu Wa Ta'ala yang telah memberikan rahmat, karunia dan hidayat-Nya sehingga penulis dapat menyelesaikan skripsi ini dengan baik.
2. Kedua orang tuaku tercinta, kakak-kakak dan seluruh keluarga besar yang selalu memberikan motivasi, dukungan, semangat serta doa-doa yang senantiasa dipanjatkan.
3. Bapak Dr. Aristoteles, S.Si., M.Si. selaku dosen pembimbing utama yang telah membimbing dan memberikan banyak arahan dan saran kepada penulis sehingga penelitian yang penulis lakukan dapat menjadi lebih baik.
4. Ibu Dewi Asiah Shofiana, S.komp., M.Kom. selaku dosen pembimbing kedua yang selalu memberikan bimbingan, arahan, saran dan masukan yang sangat membantu dalam penulisan skripsi.

5. Bapak Tristiyanto, S.Kom., M.I.S., Ph.D. selaku dosen pembahas yang telah memberikan kritik, saran serta masukan yang bermanfaat bagi penulis dalam menyusun dan menyelesaikan skripsi.
6. Bapak Dwi Sakethi, S.Si., M.Kom. selaku Ketua Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung.
7. Bapak dan Ibu Dosen Jurusan Ilmu Komputer FMIPA Universitas Lampung yang telah memberikan banyak ilmu, pengetahuan dan pengalaman yang bermanfaat kepada penulis.
8. Seluruh Staf Jurusan Ilmu Komputer FMIPA Universitas Lampung: Ibu Ade Nora Maela, Bang Zainuddin, Mas Samanto, Mas Ardi Novalia, dan lainnya, yang telah membantu segala urusan administrasi penulis butuhkan selama proses perkuliahan.
9. Irma Azizah, Safiira Rahmah Linisa, Putri Santika Mayangsari, Nur Setiowati, Nafasya Rahmah Safitra, Yulia Dwi Putri, Sarah Cantika Putri yang telah kebersamai saya dalam proses menyelesaikan skripsi ini.
10. Nada Nadidah, Nanda Pertiwi, Mahya Lutfia Ridha, Deril Maura Tamba yang telah mendukung dan menemani penulis dalam menyelesaikan skripsi.
11. Seluruh pihak dan teman-teman Jurusan Ilmu Komputer yang terlibat dalam proses penyusunan laporan skripsi ini.

Penulis menyadari bahwa dalam penulisan skripsi ini masih banyak kekurangan dan jauh dari kata sempurna. Akan tetapi, semoga skripsi ini dapat memberikan manfaat dan keberkahan bagi semua pihak Aamiin Ya Rabbal Aalamiin.

Bandar Lampung, 17 Desember 2024

Penulis,



Silvia Rukmana

NPM. 2017051047

DAFTAR ISI

	Halaman
DAFTAR ISI	xi
DAFTAR TABEL	xiii
DAFTAR GAMBAR	xv
I. PENDAHULUAN	1
1.1 Latar Belakang	1
1.2 Rumusan Masalah	4
1.3 Batasan Masalah.....	4
1.4 Tujuan.....	5
1.5 Manfaat	5
II. TINJAUAN PUSTAKA	6
2.1 Penelitian Terdahulu.....	6
2.2 Sperma.....	9
2.3 Morfologi	9
2.4 Klasifikasi	10
2.5 Citra Digital.....	10
2.6 <i>Machine Learning</i>	11
2.7 <i>Deep Learning</i>	12
2.8 <i>Convolutional Neural Network (CNN)</i>	13
2.9 <i>Residual Network</i>	17
2.10 Augmentasi Data.....	19
2.11 <i>Transfer Learning</i>	20
2.12 <i>Random Oversampling</i>	21
2.13 Python	22
2.14 <i>Hyperparameter</i>	25
2.15 <i>Confusion Matrix</i>	26

III. METODOLOGI PENELITIAN	29
3.1 Tempat dan Waktu Penelitian.....	29
3.2 Data dan Alat.....	31
3.3 Alur Kerja Penelitian.....	32
IV. HASIL DAN PEMBAHASAN	37
4.1 Pengumpulan <i>Dataset</i>	37
4.2 <i>Preprocessing Dataset</i>	38
4.3 Pembagian Data	40
4.4 Augmentasi Data	42
4.5 Pelatihan Model ResNet101.....	44
4.6 Hasil Klasifikasi Model ResNet101.....	47
V. SIMPULAN DAN SARAN	85
5.1 Simpulan	85
5.2 Saran.....	86
DAFTAR PUSTAKA.....	87

DAFTAR TABEL

Tabel	Halaman
1. Kajian Jurnal Penelitian Terdahulu.	6
2. Rencana Penelitian.	30
3. <i>Hyperparameter Dataset</i> HuSHem.....	36
4. <i>Hyperparameter Dataset</i> SCIAN.....	36
5. Distribusi Kelas <i>Dataset</i> HuSHem dan SCIAN.	37
6. Distribusi <i>Dataset</i> Hushem Tanpa Augmentasi.	40
7. Distribusi <i>Dataset</i> SCIAN Tanpa Augmentasi.....	41
8. Distribusi <i>Dataset</i> SCIAN Tanpa Augmentasi dengan ROS.	41
9. Distribusi <i>Dataset</i> Hushem dengan Augmentasi pada <i>Data Training</i>	43
10. Distribusi <i>Dataset</i> Hushem dengan Augmentasi pada Seluruh Data.	43
11. Distribusi <i>Dataset</i> SCIAN dengan Augmentasi pada <i>Data Training</i>	43
12. Distribusi <i>Dataset</i> SCIAN dengan Augmentasi pada Seluruh Data dan ROS.	44
13. Hasil Penelitian Model pada <i>Dataset</i> HuSHem Tanpa Augmentasi Berdasarkan Skenario Pertama.	48
14. Hasil Penelitian Model pada <i>Dataset</i> HuSHem Tanpa Augmentasi Berdasarkan Skenario Kedua.	50
15. Hasil Penelitian Model pada <i>Dataset</i> HuSHem Tanpa Augmentasi Berdasarkan Skenario Ketiga.	52
16. Hasil Penelitian Model <i>Dataset</i> HuSHem dengan Augmentasi pada <i>Data Training</i> Berdasarkan Skenario Pertama.....	54
17. Hasil Penelitian Model <i>Dataset</i> HuSHem dengan Augmentasi pada <i>Data Training</i> Berdasarkan Skenario Kedua.	56
18. Hasil Penelitian Model <i>Dataset</i> HuSHem dengan Augmentasi pada <i>Data Training</i> Berdasarkan Skenario Ketiga.	58
19. Hasil Penelitian Model pada <i>Dataset</i> HuSHem dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Pertama.	60
20. Hasil Penelitian Model pada <i>Dataset</i> HuSHem dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Kedua.	62
21. Hasil Penelitian Model pada <i>Dataset</i> HuSHem dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Pertama.	64
22. Hasil Penelitian Model pada <i>Dataset</i> SCIAN tanpa Augmentasi Berdasarkan Skenario Pertama.	66

23. Hasil Penelitian Model pada <i>Dataset</i> SCIAN tanpa Augmentasi Berdasarkan Skenario Kedua.	68
24. Hasil Penelitian Model pada <i>Dataset</i> SCIAN Tanpa Augmentasi Berdasarkan Skenario Ketiga.	69
25. Hasil Penelitian Model pada <i>Dataset</i> SCIAN dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Pertama.	71
26. Hasil Penelitian Model pada <i>Dataset</i> SCIAN dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Kedua.	73
27. Hasil Penelitian Model pada <i>Dataset</i> SCIAN dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Ketiga.	75
28. Hasil Penelitian Model pada <i>Dataset</i> SCIAN dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Pertama.	77
29. Hasil Penelitian Model pada <i>Dataset</i> SCIAN dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Kedua.	78
30. Hasil Penelitian Model pada <i>Dataset</i> SCIAN dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Ketiga.	80
31. Hasil <i>Accuracy</i> Terbaik pada Masing-Masing Skema.	82
32. Hasil Perbandingan Model dengan Penelitian Terdahulu.	83

DAFTAR GAMBAR

Gambar	Halaman
1. Morfologi Sperma (Sherwood, 2012).	9
2. Koordinat Citra Digital (Nafi'iyah, 2015).	11
3. Arsitektur <i>Convolutional Neural Network</i> (Yanni et al., 2021).	13
4. Contoh <i>Convolution Layer</i> (Shi et al., 2021).	15
5. Fungsi aktivasi ReLU (Hasan et al., 2021).	15
6. <i>Pooling Layer</i> (Hasan et al., 2021).	16
7. Struktur <i>Fully Connected Layer</i> (Zhu & Song, 2020).	17
8. <i>Residual Learning: A Building Block</i> (He et al., 2016).	18
9. Arsitektur ResNet (Rajamani & Iyer, 2023).	19
10. <i>Transfer Learning</i> (Wijaya et al., 2021).	21
11. <i>Random Oversampling</i> (ROS) (Diantika, 2023).	22
12. <i>Confusion Matrix</i> (Menaouer et al., 2022).	27
13. <i>Dataset HuSHem</i>	31
14. <i>Dataset SCIAN</i>	31
15. Alur Penelitian.	33
16. <i>Dataset HuSHem</i> Sebelum Menghadap ke Rotasi yang Sama.	38
17. <i>Dataset HuSHem</i> Setelah Menghadap ke Rotasi yang Sama.	38
18. Contoh Citra Hasil <i>Cropping Dataset HuSHem</i>	39
19. Contoh Augmentasi <i>Horizontal</i>	42
20. Contoh Augmentasi <i>Rotation</i>	42
21. Contoh Augmentasi <i>Zoom</i>	42
22. Arsitektur ResNet101 (Kalshetty & Parveen, 2023).	45
23. <i>Source Code Transfer Learning Model ResNet101</i>	46
24. <i>Source Code Layer Tambahan Model ResNet101 Pretrained</i>	7
25. Grafik <i>Accuracy</i> dan <i>Loss</i> pada <i>Dataset HuSHem</i> Tanpa Augmentasi Berdasarkan Skenario Pertama.	49
26. <i>Confusion Matrix</i> pada <i>Dataset HuSHem</i> Tanpa Augmentasi Berdasarkan Skenario Pertama.	49
27. Grafik <i>Accuracy</i> dan <i>Loss</i> pada <i>Dataset HuSHem</i> Tanpa Augmentasi Berdasarkan Skenario Kedua.	51
28. <i>Confusion Matrix</i> pada <i>Dataset HuSHem</i> Tanpa Augmentasi Berdasarkan Skenario Kedua.	51
29. Grafik <i>Accuracy</i> dan <i>Loss</i> pada <i>Dataset HuSHem</i> Tanpa Augmentasi Berdasarkan Skenario Ketiga.	53

30. <i>Confusion Matrix</i> pada <i>Dataset</i> HuSHem Tanpa Augmentasi Berdasarkan Skenario Ketiga.....	53
31. Grafik <i>accuracy</i> dan <i>Loss Dataset</i> HuSHem dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Pertama.....	55
32. <i>Confusion Matrix Dataset</i> HuSHem dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Pertama.	55
33. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> HuSHem dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Kedua.	57
34. <i>Confusion Matrix Dataset</i> HuSHem dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Kedua.	57
35. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> HuSHem dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Ketiga.	59
36. <i>Confusion Matrix Dataset</i> HuSHem dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Ketiga.	59
37. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> HuSHem dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Pertama.....	61
38. <i>Confusion Matrix Dataset</i> Hushem dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Pertama.....	61
39. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> HuSHem dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Kedua.	63
40. <i>Confusion Matrix Dataset</i> HuSHem dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Kedua.	63
41. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> HuSHem dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Ketiga.	65
42. <i>Confusion Matrix Dataset</i> HuSHem dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Ketiga.....	65
43. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> SCIAN tanpa Augmentasi Berdasarkan Skenario Pertama.	67
44. <i>Confusion Matrix Dataset</i> SCIAN tanpa Augmentasi Data Berdasarkan Skenario Pertama.	67
45. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> SCIAN Tanpa Augmentasi Berdasarkan Skenario Kedua.....	68
46. <i>Confusion Matrix Dataset</i> SCIAN Tanpa Augmentasi Data Berdasarkan Skenario Kedua.....	69
47. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> SCIAN Tanpa Augmentasi Berdasarkan Skenario Ketiga.....	70
48. <i>Confusion Matrix Dataset</i> SCIAN Tanpa Augmentasi Data Berdasarkan Skenario Ketiga.....	71
49. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> SCIAN dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Pertama.....	72
50. <i>Confusion Matrix Dataset</i> SCIAN dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Pertama.	73
51. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> SCIAN dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Kedua.	74

52. <i>Confusion Matrix Dataset</i> SCIAN dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Kedua.....	75
53. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> SCIAN dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Ketiga.....	76
54. <i>Confusion Matrix Dataset</i> SCIAN dengan Augmentasi pada Data <i>Training</i> Berdasarkan Skenario Ketiga.....	76
55. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> SCIAN dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Pertama.....	77
56. <i>Confusion Matrix Dataset</i> SCIAN dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Pertama.....	78
57. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> SCIAN dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Kedua.....	79
58. <i>Confusion Matrix Dataset</i> SCIAN dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Kedua.....	80
59. Grafik <i>Accuracy</i> dan <i>Loss Dataset</i> SCIAN dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Ketiga.....	81
60. <i>Confusion Matrix Dataset</i> SCIAN dengan Augmentasi pada Seluruh Data Berdasarkan Skenario Ketiga.....	81

I. PENDAHULUAN

1.1 Latar Belakang

Sebagai makhluk hidup yang dapat berkembang biak manusia melakukan proses reproduksi untuk menghasilkan individu baru dari keturunannya sebagai generasi penerus. Terjadinya proses reproduksi ketika bertemunya sel sperma dengan sel telur (*ovum*) sehingga membentuk individu baru atau disebut juga dengan fertilisasi (Ani et al., 2021). Terdapat beberapa gangguan yang dapat menghambat reproduksi salah satunya ialah infertilitas. Penyakit infertilitas ini ditandai dengan kegagalan untuk mencapai kehamilan setelah 12 bulan berhubungan seksual secara teratur tanpa pengaman atau karena penurunan kemampuan seseorang dalam bereproduksi yang disebut sebagai infertilitas (Zegers-Hochschild et al., 2017).

Menurut data dari badan kesehatan *World Health Organization* (WHO) terdapat sekitar 17,5% orang dewasa atau 1 dari 6 orang di seluruh dunia mengalami infertilitas. Infertilitas pada pria sendiri terjadi disebabkan oleh banyak faktor yang mempengaruhinya. Faktor risiko gaya hidup dapat meningkatkan infertilitas pada pria seperti kebiasaan merokok, mengkonsumsi alkohol, infeksi menular seksual yang tidak diobati atau diurus dengan baik, pergaulan bebas, kelebihan berat badan/obesitas, pengobatan dan frekuensi berhubungan seks (Okonofua et al., 2022).

Selain itu, penyebab utamanya disebabkan karena gangguan pada spermatogenesis dan kelainan genetik (Babakhanzadeh et al., 2020). Spermatogenesis merujuk pada pembentukan spermatozoa yang matang dan proses biologis yang terjadi di dalam tubulus seminiferus pada testis (Kang et al., 2022). Gangguan pada spermatogenesis dapat mengakibatkan beberapa hal salah satunya dapat meningkatkan jumlah cacat morfologi, yang seringkali mengarah ke *teratozoospermia* (sperma dengan morfologi *abnormal*) (Jakubik-Uljasz et al., 2020). Morfologi sel sperma yang *abnormal* dapat menurunkan kualitas dari sperma dan menyebabkan ketidaksuburan pada pria.

Dalam mengatasi masalah infertilitas dapat dilakukan suatu upaya dengan menentukan kualitas sperma. Untuk menganalisis sperma cara paling umum yang bisa dilakukan yaitu dengan cara manual menggunakan bantuan mikroskop oleh seorang ahli yang hasilnya dapat menentukan kualitas sperma. Namun analisis sperma yang dilakukan secara manual membutuhkan waktu yang lama dan hasilnya tidak selalu akurat. Dengan perkembangan teknologi dapat membantu dalam menganalisis kualitas sperma dengan hasil akurasi yang tinggi, salah satunya menggunakan *deep learning* dengan pendekatan *Convolutional Neural Network* (CNN).

Convolutional Neural Network (CNN) umumnya sering digunakan dalam tugas memprediksi citra. CNN mampu menangkap fitur spasial dan pola dalam citra dengan menggunakan arsitektur hierarkis dari lapisan-lapisan yang melakukan operasi konvolusi dan mengekstraksi fitur pada berbagai tingkat abstraksi. Lapisan tersebut terdiri atas serangkaian lapisan *convolutional* dan *pooling* yang mengekstrak fitur-fitur relevan dari citra masukan, diikuti oleh satu atau lebih lapisan *fully connected* yang menggunakan fitur-fitur ini untuk membuat prediksi (Krichen, 2023).

Adapun penelitian terkait dalam mengklasifikasikan sperma ke dalam salah satu dari beberapa kategori, dilakukan oleh (Riordon et al., 2019). Penelitian

tersebut menggunakan dua *dataset* yaitu *Human Sperm Head Morphology* (HuSHeM) dan SCIAN, dengan mengusulkan pendekatan CNN VGG16 yang telah dilatih ulang. Hasil penelitian menunjukkan bahwa arsitektur usulan tersebut mendapatkan 49% akurasi, 62% *recall* pada *dataset* SCIAN dan 94% akurasi, 94.1% *recall* pada *dataset* HuSHeM untuk klasifikasi kepala sperma manusia. Penelitian selanjutnya (Iqbal et al., 2020) dengan menggunakan dua *dataset* yang sama, yaitu HuSHeM dan SCIAN. Penelitian yang dilakukan menggunakan arsitektur *deep* CNN, yaitu *Morphological Classification of Human Sperm Heads* (MC-HSH). Hasil penelitian menunjukkan bahwa arsitektur usulan tersebut mendapatkan 63% akurasi, 68% *recall* pada *dataset* SCIAN dan 95.7% akurasi, 95.5% *recall* pada *dataset* HuSHeM untuk klasifikasi kepala sperma manusia. Pada penelitian (Yüzkat et al., 2021) menganalisis morfologi sperma menggunakan tiga *dataset*, yaitu SMIDS, HuSHem, dan SCIAN. Pada penelitian tersebut mengusulkan enam model CNN yang berbeda dengan dua teknik fusi, yaitu *hard-voting* dan *soft-voting*. Hasil akurasi yang diperoleh masing-masing 90,73%, 85,18%, dan 71,91% untuk kumpulan data SMIDS, HuSHem dan SCIAN.

ResNet101 merupakan salah satu arsitektur dari *Convolutional Neural Network* yang menerapkan *skip connection* atau *shortcut* untuk mencegah kehilangan informasi saat proses pelatihan model pada jaringan yang dalam (Sujatmiko et al., 2022). Penelitian terkait arsitektur ResNet101 (Jusman, 2023) membandingkan algoritme CNN arsitektur ResNet101 dan VGG19 dalam mengklasifikasikan citra sel prostat. Hasil penelitian menunjukkan arsitektur ResNet101 memperoleh akurasi terbesar. Selanjutnya dalam penelitian lain, model ResNet101 yang telah dilatih menggunakan *transfer learning* dengan menerapkan penambahan lapisan model yang sesuai dengan jumlah data yang tersedia. *Transfer learning* memungkinkan dalam meningkatkan akurasi dan mempercepat proses pembelajaran pada tugas yang berbeda (Hernandoko et al., 2024). Model ResNet101 mampu mengklasifikasikan penyakit pada tanaman padi secara akurat bahkan dengan jumlah data yang sedikit (Wicaksono & Andreawan, 2023). Penelitian (Wagle

et al., 2021) mengidentifikasi dan klasifikasi penyakit pada tanaman tomat menggunakan model *deep learning* ResNet50, ResNet18, dan ResNet101 dengan menerapkan augmentasi data. Kumpulan data tambahan dari augmentasi yang diusulkan memiliki kinerja lebih baik yang diungguli oleh model ResNet101 dengan akurasi pengujian 99,99% dan akurasi validasi 95,83%. Augmentasi bertujuan meningkatkan kinerja pada model dengan cara menambah variasi data, sehingga model dapat belajar dan mengenali data dengan baik.

Berdasarkan uraian tersebut, maka pada penelitian menggunakan metode algoritme *Convolutional Neural Network* (CNN) arsitektur ResNet101 dengan *transfer learning* dan augmentasi data untuk mengklasifikasikan sperma manusia berdasarkan morfologi menggunakan kumpulan dua *dataset*, yaitu HuSHem dan SCIAN. Penelitian ini dilakukan untuk mengevaluasi kinerja algoritme yang digunakan dalam mengklasifikasikan sperma manusia berdasarkan morfologi.

1.2 Rumusan Masalah

Adapun rumusan masalah yang dijabarkan pada penelitian ini adalah sebagai berikut:

- a. Bagaimana mengklasifikasikan sperma manusia berdasarkan morfologi menggunakan suatu algoritme CNN arsitektur ResNet101 dengan *transfer learning* serta penerapan augmentasi pada data.
- b. Bagaimana kinerja yang dihasilkan oleh model arsitektur ResNet101 dalam mengklasifikasikan sperma manusia berdasarkan morfologi.

1.3 Batasan Masalah

Adapun batasan-batasan masalah yang digunakan dalam penelitian ini adalah sebagai berikut:

- a. Penelitian ini menggunakan dua buah *dataset* morfologi kepala sperma yaitu *Human Sperm Head Morphology* (HuSHeM) dan SCIAN. *Dataset* HuSHeM berjumlah 216 data dan *dataset* SCIAN berjumlah 1132 data.
- b. Algoritme yang digunakan dalam proses klasifikasi ialah algoritme CNN arsitektur ResNet101 dengan *transfer learning*.
- c. Menggunakan augmentasi data pada *dataset* untuk menambah dan meningkatkan variasi data.
- d. Citra yang digunakan pada *dataset* HuSHeM memiliki ekstensi *file* berformat (.bmp) dengan nilai intensitas piksel dalam mode warna RGB, sedangkan pada *dataset* SCIAN memiliki ekstensi *file* berformat (.tif) dengan intensitas piksel dalam mode *grayscale*.

1.4 Tujuan

Berdasarkan rumusan masalah yang telah dijabarkan, tujuan yang dicapai dalam penelitian ini adalah sebagai berikut:

- a. Mengimplementasikan algoritme CNN arsitektur ResNet101 dengan *transfer learning* dan augmentasi data dalam klasifikasi sperma manusia berdasarkan morfologi.
- b. Menganalisis hasil dari kinerja algoritme CNN arsitektur ResNet101 dengan *transfer learning* dan augmentasi data dalam mengklasifikasikan sperma manusia berdasarkan morfologi.

1.5 Manfaat

Manfaat yang didapat dari penelitian ini adalah membantu menganalisis kelainan morfologi pada sperma untuk menentukan kualitas sperma. Selain itu, dapat digunakan sebagai referensi untuk penelitian lainnya mengenai klasifikasi sperma manusia berdasarkan morfologi dengan menggunakan algoritme *Convolutional Neural Network* (CNN) arsitektur ResNet101.

II. TINJAUAN PUSTAKA

2.1 Penelitian Terdahulu

Penelitian ini tidak terlepas dari penelitian yang telah dilakukan sebelumnya. Ringkasan dari penelitian terdahulu dapat dilihat pada Tabel 1.

Tabel 1. Kajian Jurnal Penelitian Terdahulu.

No	Judul	Metode	Data	Hasil
1	<i>Deep learning for the classification of human sperm</i> (Riordon et al., 2019).	<i>Convolutional Neural Network</i> (CNN) arsitektur VGG16.	<i>Dataset</i> SCIAN yang terdiri dari 1132 data dan HuSHem yang terdiri dari 216 data.	SCIAN: <i>Accuracy</i> = 49% <i>Recall</i> = 62% HuSHem: <i>Accuracy</i> = 94% <i>Recall</i> = 94,1%
2	<i>Deep learning-based morphological classification of human sperm heads</i> (Iqbal et al., 2020).	Arsitektur <i>deep CNN</i> , <i>Morphological Classification of Human Sperm Heads</i> (MC-HSH).	<i>Dataset</i> SCIAN yang terdiri dari 1132 data dan HuSHem yang terdiri dari 216 data.	SCIAN: <i>Accuracy</i> = 63% <i>Recall</i> = 68% HuSHem: <i>Accuracy</i> = 95,7% <i>Recall</i> = 95,5%

No	Judul	Metode	Data	Hasil
3	<i>Multi-model CNN fusion for sperm morphology analysis</i> (Yüzkat et al., 2021).	Menggabungkan enam model CNN yang berbeda dengan dua teknik fusi, yaitu <i>hard-voting</i> dan <i>soft-voting</i> .	<i>Dataset</i> SCIAN yang terdiri dari 1132, HuSHem yang terdiri dari 216 data, dan SMIDS yang terdiri dari 3000 data.	SCIAN: <i>Accuracy</i> = 71,91% HuSHem: <i>Accuracy</i> = 85,18%, SMIDS: <i>Accuracy</i> = 90,73%

Berdasarkan Tabel 1 terdapat beberapa penelitian terdahulu yang telah dilakukan sebelumnya sebagai acuan dalam melakukan penelitian ini. Penjelasan terkait penelitian terdahulu yang digunakan adalah sebagai berikut.

2.1.1 *Deep learning for the classification of human sperm* (Riordon et al., 2019)

Penelitian ini mengimplementasikan *deep learning* untuk mengklasifikasikan sperma ke dalam beberapa kategori. Metode yang digunakan adalah CNN arsitektur VGG16 yang dilatih ulang untuk klasifikasi sperma menggunakan dua *dataset* kepala sperma yang tersedia secara gratis (HuSHem dan SCIAN). Pendekatan ini sangat efektif, menghasilkan rata-rata tingkat positif sebenarnya sebesar 94,1% pada kumpulan data HuSHem (mencocokkan pendekatan APDL dan melampaui pendekatan CE-SVM) dan 62% pada kumpulan data SCIAN perjanjian parsial (mencocokkan pendekatan pembelajaran mesin sebelumnya).

2.1.2 *Deep learning-based morphological classification of human sperm heads* (Iqbal et al., 2020)

Penelitian ini mengusulkan arsitektur CNN khusus, yaitu *Morphological Classification of Human Sperm Heads* (MC-HSH) untuk mengklasifikasikan kepala sperma secara akurat berdasarkan citra sperma. Dalam arsitektur ini, terdapat total 53 lapisan konvolusional. *Dataset* yang digunakan pada penelitian ini menggunakan *dataset* HuSHem dan SCIAN. Pada penelitian ini dilakukan pra-pemrosesan, partisi, dan argumentasi yang cermat terhadap kumpulan data SCIAN dan HuSHem. Hal ini menunjukkan bahwa arsitektur usulan yang digunakan dalam penelitian ini mengungguli metode canggih, menunjukkan 88% *recall* pada *dataset* SCIAN dalam pengaturan perjanjian total dan 95% *recall* pada *dataset* HuSHem untuk klasifikasi kepala sperma manusia.

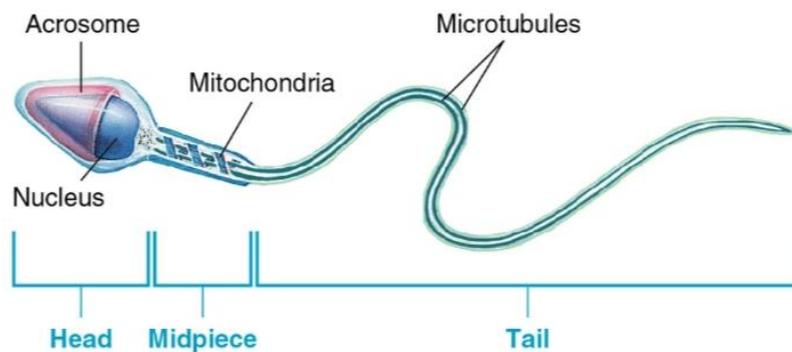
2.1.3 *Multi-model CNN fusion for sperm morphology analysis* (Yüzkat et al., 2021)

Penelitian ini dilakukan oleh (Yüzkat et al., 2021). Dalam penelitian ini menggunakan 3 kumpulan *dataset* (HuSHem, SCIAN dan SMIDS). Pada penelitian ini digabungkan enam model CNN yang berbeda dalam mengklasifikasikan morfologi citra sperma. Selain itu juga, diterapkan dua teknik fusi *decision-level* yaitu *hard-voting* dan *soft-voting*. Untuk analisis objektif, teknik validasi silang diterapkan dengan membagi kumpulan data menjadi lima subkumpulan. Selain itu, berbagai skala augmentasi data dan analisis *mini-batch* digunakan untuk mendapatkan akurasi klasifikasi tertinggi. Terakhir, dalam klasifikasi, akurasi diperoleh masing-masing 90,73%, 85,18%, dan 71,91% untuk kumpulan data SMIDS, HuSHem dan SCIAN-Morpho, menggunakan pendekatan fusi berbasis *soft-voting* pada enam model CNN yang dibuat.

2.2 Sperma

Sperma atau spermatozoa adalah sel khusus yang mempunyai struktur unik yang penting dalam proses pembuahan dan perkembangan awal embrio. Sperma matang umumnya terdiri dari tiga bagian, yaitu kepala dengan *nucleas* (inti sel), leher dan ekor yang memungkinkan *motilitas*-nya (Boguenet et al., 2021).

Sel sperma diproduksi dari serangkaian proses yang terjadi dalam saluran reproduksi pria dan perlu melakukan perjalanan ke saluran reproduksi wanita untuk membuahi sel telur pada individu lain. Tugas utama dari sperma bertujuan dalam mengantarkan sebuah gen paternal (*haploid*) ke sel telur dan menginisiasi perkembangan embrio (Suoth et al., 2023). Gambar 1 merupakan tampilan dari morfologi sperma.



Gambar 1. Morfologi Sperma (Sherwood, 2011).

2.3 Morfologi

Morfologi dalam cabang ilmu biologi adalah suatu hal yang mempelajari tentang bentuk dan struktur dari organisme hidup (Carrillo-López & Yahia, 2019). Morfologi pada sperma adalah salah satu parameter untuk menilai kualitas sperma yang dapat dilihat dari bentuk sel spermatozoa pada

pemeriksaan dengan menggunakan mikroskop. Morfologi yang diukur adalah kepala, leher dan ekor sperma. Untuk bentuk atau struktur kepala yang normal tidak terdapat *macrohead*, *double head*, *microhead*, *leptohead*, dan beberapa kelainan lainnya. Namun pada leher dan ekor yang dalam keadaan normal tidak ditemukan suatu kelainan seperti bentuk *doubletail* (Aryoseto, 2009).

2.4 Klasifikasi

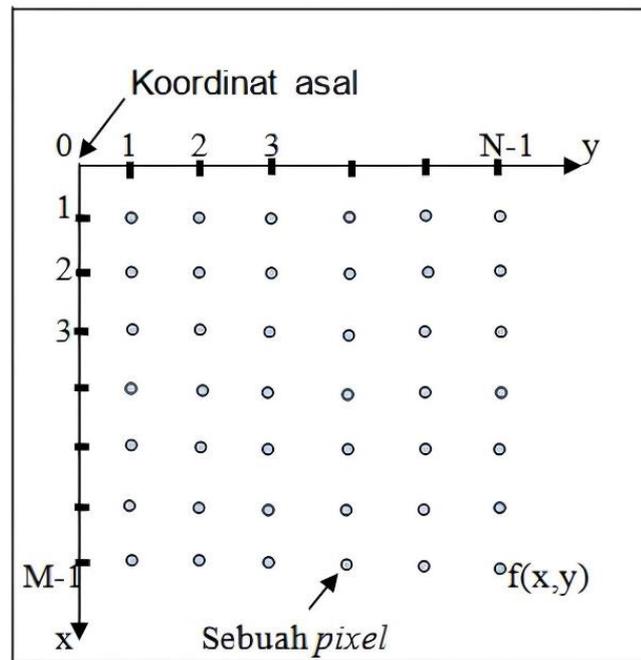
Klasifikasi adalah proses untuk mengelompokkan objek kedalam beberapa kelas yang memiliki karakteristik atau ciri yang sama (Widiastuti et al., 2017). Pengertian klasifikasi dalam citra adalah proses mengelompokkan piksel pada suatu citra ke dalam beberapa kategori atau kelas, dimana setiap kelas mendeskripsikan suatu objek yang memiliki ciri-ciri tertentu yang sama (Herdiansah et al., 2022).

2.5 Citra Digital

Citra digital merupakan suatu citra dua dimensi yang diperoleh dari analog dua dimensi yang kontinu menjadi suatu citra melalui proses *sampling*. Untuk menjadi citra diskrit, citra analog dibagi menjadi N baris dan M. Citra digital dapat diproses oleh komputer dan yang disimpan pada komputer berupa angka-angka yang menunjukkan besarnya nilai intensitas pada setiap piksel. Citra digital berbentuk data numerik, oleh karena itu dapat diolah dengan menggunakan komputer (Munantri, 2020).

Citra digital menggambarkan intensitas cahaya dalam bentuk diskrit dalam dua dimensi. Citra digital terdiri dari sekumpulan piksel (picture element) dengan koordinat (xy) dan amplitudo $f(xy)$. Tempat piksel pada citra ditunjukkan oleh koordinat (x, y) dan amplitudo $f(x, y)$ menunjukkan nilai

intensitas warna citra (Ratna, 2020). Gambar 2 mendeskripsikan koordinat suatu citra digital.



Gambar 2. Koordinat Citra Digital (Nafi'iyah, 2015).

2.6 Machine Learning

Machine Learning (ML) merupakan bidang ilmu komputer yang mempelajari algoritme dan teknik untuk membuat suatu solusi secara otomatis terhadap masalah kompleks yang sulit diprogram menggunakan metode tradisional dalam pemrograman (Rebala et al., 2019). *Machine learning* berfokus belajar dari sebuah data (*learn from data*), yaitu fokus pada pengembangan sistem yang dapat belajar secara “mandiri” tanpa harus berulang kali diprogram oleh manusia. Untuk memperoleh hasil *output* yang optimal, *machine learning* membutuhkan suatu data yang *valid* sebagai bahan belajar (ketika proses *training*) sebelum digunakan ketika *testing* (Cholissodin et al., 2020).

Dalam banyak kasus penggunaan *machine learning*, tujuannya adalah untuk mempelajari sebuah data yang dapat digunakan untuk klasifikasi/prediksi dengan menggunakan suatu model. Terdapat dua pendekatan utama dalam *machine learning* yang sering digunakan yaitu, *supervised learning* dan *unsupervised learning*. *Supervised learning* ialah dimana sebuah data pelatihan sudah diberi label yang bertujuan untuk mengambil fitur masukan dan menetapkannya ke salah satu kelas yang sudah diberi label. Dua jenis *supervised learning* adalah klasifikasi (yang keluarannya berupa label-label tersendiri) dan regresi (yang keluarannya dinilai secara nyata misalnya, prediksi/perkiraan deret waktu). *Unsupervised learning* adalah kumpulan yang tidak memiliki label, yang ingin ditemukan polanya. Salah satu pendekatan *unsupervised learning* adalah *clustering* (Sahli, 2020).

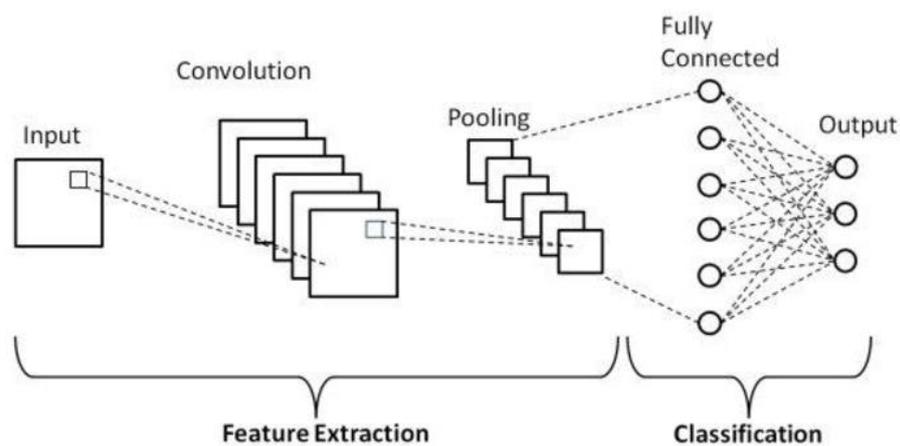
2.7 *Deep Learning*

Deep Learning (DL) merupakan salah satu pembelajaran mesin (*machine learning*) yang terdiri dari algoritme pemodelan abstraksi tingkat tinggi pada data, dengan fungsi transformasi nonlinear yang berlapis dan mendalam bahkan bisa mencapai hingga ratusan lapisan (Adrianto et al., 2021). *Deep learning* mempunyai kemampuan yang baik dalam *computer vision*, yaitu klasifikasi citra atau klasifikasi objek pada citra dalam bentuk dua dimensi misalnya citra dan suara (Pratiwi et al., 2021).

Teknik yang digunakan dalam *deep learning* menggunakan jaringan saraf yang memanfaatkan banyak *hidden layer* di antara *layer input* dan *output*, berbeda dengan jaringan saraf biasa yang hanya menggunakan satu *hidden layer*. Dalam implementasi *deep learning* pengaturan nilai *hyperparameter* sangat penting karena berpengaruh besar pada kinerja *deep learning*, salah satunya adalah topologi jaringan, yang melibatkan jumlah pada *hidden layer* dan *hidden neuron* (Choldun & Surendro, 2018).

2.8 Convolutional Neural Network (CNN)

Convolutional Neural Network (CNN) adalah metode pembelajaran mendalam yang mengadopsi kinerja *neuron* otak manusia yang disebut jaringan saraf dan fungsi konvolusi untuk mengklasifikasikan citra (Andika et al., 2019). CNN termasuk dalam jenis *neural network* yang dirancang khusus sebagai metode yang efektif untuk menangani masalah dalam pengolahan citra yaitu mengklasifikasikan, mengidentifikasi, dan mengenali pola di dalam citra. CNN mampu memahami detail citra dengan lebih baik karena memiliki arsitektur yang sesuai dengan cara otak manusia memproses informasi visual. Data yang digunakan pada CNN adalah data dua dimensi, seperti citra atau suara dan menggunakan operasi konvolusi dalam matriks serta bobot yang berbentuk empat dimensi yang merupakan sekumpulan kernel konvolusi. Dengan sifat proses konvolusi tersebut, CNN hanya dapat digunakan pada data yang memiliki struktur data dua dimensi (Putra, 2016).



Gambar 3. Arsitektur *Convolutional Neural Network* (Yanni et al., 2021).

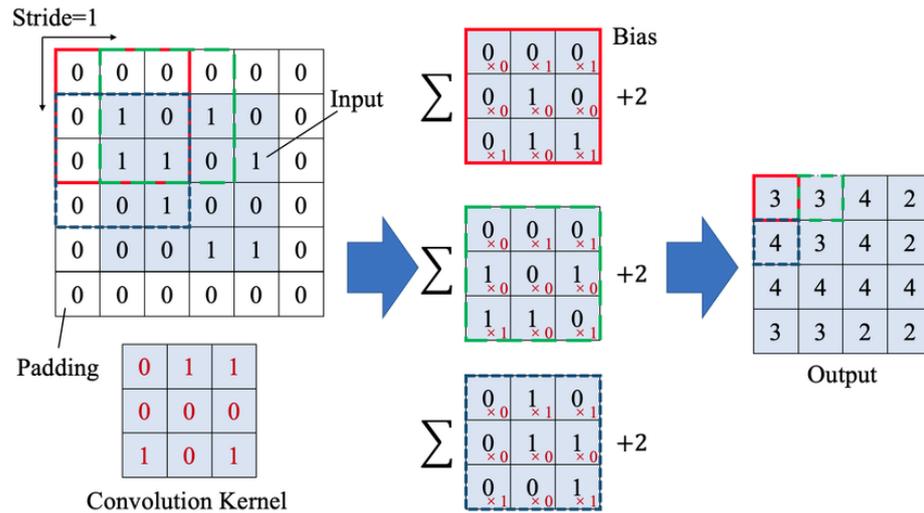
Dapat dilihat pada Gambar 3 bahwa secara umum arsitektur CNN dibagi menjadi 2 tahap, yaitu *feature learning* dan *classification*. *Feature learning* terdiri dari 3 lapisan proses. Proses-proses ini sering disebut dengan *convolution*, *activation*, dan *pooling*. Pada tahap *classification* terdiri dari *fully connected layer* yang mana lapisan tersebut tersusun dari lapisan-lapisan

neuron dan di akhir terdapat fungsi *softmax* untuk menentukan kelas dari citra yang dimasukkan (Denata et al., 2021).

2.8.1 *Convolution Layer*

Convolution merupakan *layer* yang mendasari proses utama dari arsitektur CNN. *Convolution layer* melakukan operasi konvolusi pada *output* dari *layer* sebelumnya (Putra, 2016). *Convolution layer* merupakan lapisan yang terdiri dari kumpulan *filter* konvolusi atau *kernel* dan menghasilkan hasil akhir dari proses tersebut adalah *feature map*. *Input* berupa citra yang dimasukkan ke dalam model diproses pada tahap ekstraksi fitur. *Input* citra dibagi menjadi beberapa bagian pada setiap piksel yang ditentukan oleh parameter tertentu. Dari proses konvolusi menghasilkan suatu *output* citra yang bisa lebih kecil atau citra dengan ukuran yang sama namun tingkat kedalaman citra akan berbeda (Ilahi et al., 2022).

Convolution layer berisi atas sekumpulan *kernel* atau disebut juga dengan *filter*. *Kernel* adalah matriks kecil yang terdiri atas nilai atau angka diskret, dimana setiap nilai disebut sebagai *weight* dari *kernel* tersebut. Pada awal proses pelatihan, semua *weight* diinisialisasi dengan nilai *random* (Ghosh et al., 2020). Setiap *kernel* bergeser di atas *array input* dengan ukuran langkah tertentu yang disebut *stride*. Pada setiap posisi, elemen *kernel* dikalikan dengan elemen yang sesuai pada *array input*. Hasil perkalian tersebut kemudian dijumlahkan untuk menghasilkan satu nilai dalam *array output* atau disebut dengan *feature map*. Untuk menjaga agar ukuran *array output* sama dengan ukuran *array input* digunakan teknik *zero padding*, yaitu dengan menambahkan nilai nol di sekitar tepi pada *array input* (Shi et al., 2021). Gambar 4 merupakan contoh ilustrasi dari operasi *convolution layer*.

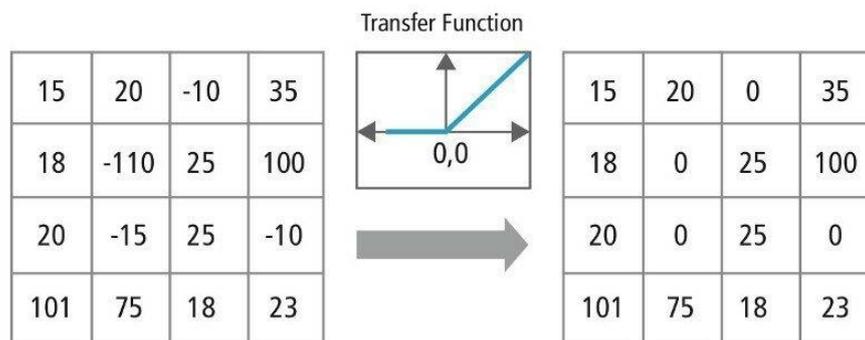


Gambar 4. Contoh *Convolution Layer* (Shi et al., 2021).

2.8.2 Fungsi Aktivasi *Rectified Linear Unit* (ReLU)

Fungsi aktivasi adalah nonlinear transformasi yang digunakan untuk mengubah sinyal *input* menjadi sinyal *output*. *Rectified Linear Unit* (ReLU) adalah salah satu fungsi aktivasi yang berguna untuk meningkatkan kecepatan proses pelatihan. Dapat dilihat pada Gambar 5 Fungsi aktivasi ReLU membuat nilai piksel negatif pada citra menjadi bernilai 0 dan jika nilai piksel positif maka *output*-nya nilai itu sendiri (Ilahi et al., 2022). Fungsi aktivasi ReLU didefinisikan pada Persamaan 1.

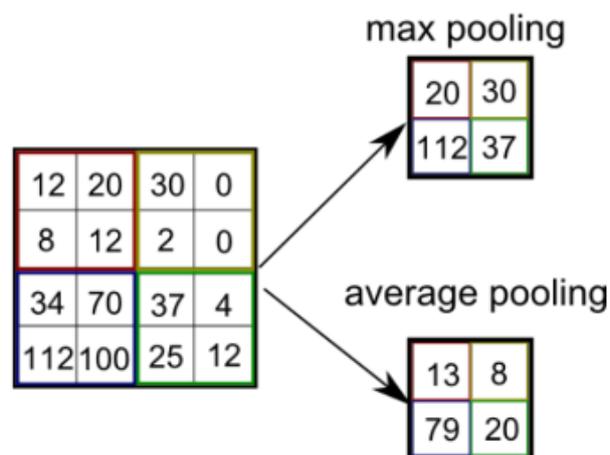
$$f(h) = \max(0, h) = \begin{cases} h & \text{jika } h \geq 0 \\ 0 & \text{jika } h < 0 \end{cases} \quad \text{Persamaan (1)}$$



Gambar 5. Fungsi aktivasi ReLU (Hasan et al., 2021).

2.8.3 Pooling Layer

Pooling layer adalah komponen dari CNN yang digunakan secara bertahap untuk mengurangi ukuran spasial yang bertujuan mengurangi jumlah parameter dan komputasi dalam jaringan. *Pooling layer* juga berfungsi untuk mencegah terjadinya *overfitting*, yaitu dimana model dengan akurat memprediksi data latih tetapi gagal dalam mengenali data di luar data latih. Terdapat dua jenis pendekatan *pooling* yang banyak digunakan secara umum, yaitu *max pooling* dan *average pooling*. *Max pooling* mengambil nilai maksimum pada daerah tertentu, sedangkan *average pooling* mengambil nilai rata-rata (Hariyani et al., 2020). Gambar 6 merupakan gambaran proses dari *pooling layer*.

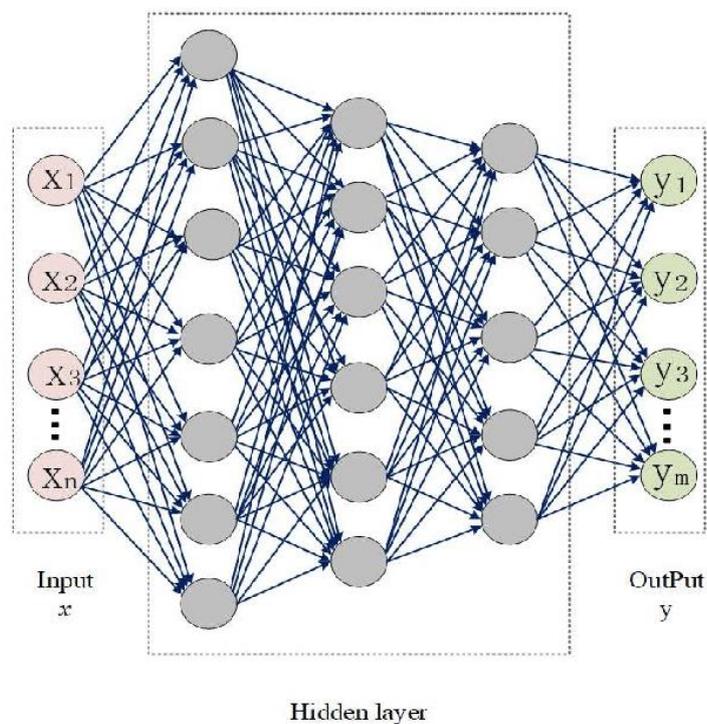


Gambar 6. *Pooling Layer* (Hasan et al., 2021).

2.8.4 Fully Connected Layer

Fully connected layer merupakan jaringan syaraf tiruan *feedforward* yang terdiri atas *input layer*, *hidden layer* dan *output layer*. Setiap *neuron* pada *fully connected layer* terhubung secara penuh antara *neuron* sebelumnya dan setelahnya (Hariyani et al., 2020). Hasil dari *layer* konvolusi atau *pooling* diubah menjadi sebuah vektor satu dimensi (*flatten*), di mana setiap elemen dalam vektor tersebut merepresentasikan peluang atau kemungkinan fitur tertentu dikaitkan

dengan sebuah kategori. Di *layer* ini, setiap *neuron* terhubung langsung ke semua *neuron* di *layer* sebelumnya, memungkinkan penggabungan semua fitur yang telah dipelajari menjadi satu representasi terpadu. Proses ini mempermudah klasifikasi akhir karena semua informasi yang diekstraksi dari *layer* sebelumnya telah dirangkum (Zhu & Song, 2020). Fungsi *softmax* digunakan dalam proses klasifikasi untuk merubah *output* dari *layer* akhir menjadi distribusi *probabilitas* pada setiap kelas dari rentang 0-1 dan dijumlahkan hasilnya harus bernilai satu (Radikto et al., 2022).

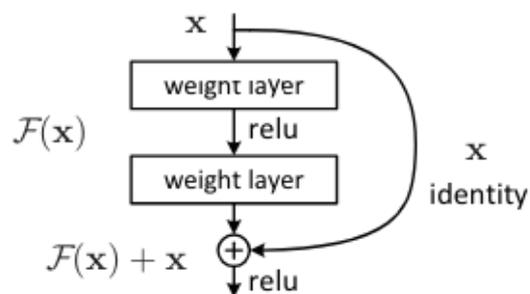


Gambar 7. Struktur *Fully Connected Layer* (Zhu & Song, 2020).

2.9 *Residual Network*

Residual Network atau yang disingkat dengan ResNet merupakan arsitektur CNN yang terdiri dari beberapa macam jenis *layer* diantaranya yaitu 18, 34, 50, 101, dan 152 *layer*. Arsitektur ini di perkenalkan oleh Kaiming He dan rekannya pada tahun 2015 untuk mengatasi masalah *degradasi* pada jaringan

yang sangat dalam. Arsitektur ResNet menerapkan prinsip *skip connection* atau *shortcut connection* dengan melewati satu atau beberapa *layer* untuk mengurangi masalah *vanishing gradient* dengan mengizinkan jalur pintas alternatif untuk mengalirkan gradien dalam melakukan pemetaan identitas data citra (He et al., 2016). *Vanishing gradient* terjadi ketika jaringan memiliki banyak lapisan atau sangat dalam sehingga gradien fungsi kehilangan menyusut mendekati nilai 0 setelah beberapa iterasi sebelum mencapai konvergen dikenal sebagai gradien menyusut. Akibatnya nilai bobot lapisan atas tidak akan pernah diperbaharui selama proses pelatihan sehingga tidak ada proses pembelajaran. Penambahan jalan pintas pada arsitektur ResNet ini memungkinkan metode optimasi untuk memperbarui bobot pada gradien pada lapisan yang lebih awal. Ini memungkinkan lapisan awal untuk memperbarui bobotnya dengan lebih baik. (Thiodorus et al., 2021). *Skip connection* diimplementasikan pada Gambar 8.



Gambar 8. *Residual Learning: A Building Block* (He et al., 2016).

Penelitian ini menggunakan arsitektur ResNet101. ResNet101 atau *Residual Network* dengan 101 *layer* merupakan jaringan saraf konvolusional yang dalam. ResNet101 telah terbukti efektif dalam melakukan berbagai tugas *computer vision*, termasuk pengenalan citra. Hal tersebut ditandai dengan penggunaan *residual block*, yang memfasilitasi pelatihan yang sangat mendalam pada jaringan (Sonavane et al., 2024). Gambar 9 merupakan arsitektur dari ResNet.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2_x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4_x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5_x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10^9	3.6×10^9	3.8×10^9	7.6×10^9	11.3×10^9

Gambar 9. Arsitektur ResNet (He et al., 2016).

2.10 Augmentasi Data

Augmentasi data adalah teknik yang digunakan secara signifikan untuk memperbanyak jumlah dan variasi data yang tersedia tanpa mengumpulkan suatu data baru (Sanjaya et al., 2020). Augmentasi data penting karena kadang terdapat kumpulan data yang tersedia terbatas jumlahnya. Ada beberapa operasi augmentasi data yang tersedia seperti *cropping*, *rotation*, *flipping*, *zoom*, *brightness* dan lain-lain. Operasi tersebut dapat diterapkan secara terpisah ataupun digabungkan dalam membuat variasi baru dari satu sampel data (Ghosh et al., 2020).

2.10.1 Augmentasi *Rotation*

Augmentasi *rotation* atau rotasi adalah operasi augmentasi yang menerapkan pemutaran citra secara acak. Citra diputar ke berbagai sudut rotasi yang berbeda untuk meningkatkan model dalam mengenali objek (Alin et al., 2023).

2.10.2 Augmentasi *Zoom*

Augmentasi *zoom* digunakan untuk menciptakan variasi data pelatihan dalam tugas klasifikasi citra dengan memperbesar atau memperkecil citra (Prasetyo et al., 2024). Operasi ini memungkinkan model menjadi lebih kuat terhadap perubahan ukuran objek dalam citra. Dengan memperbesar atau memperkecil data citra, model dapat belajar mengenali objek dengan berbagai skala.

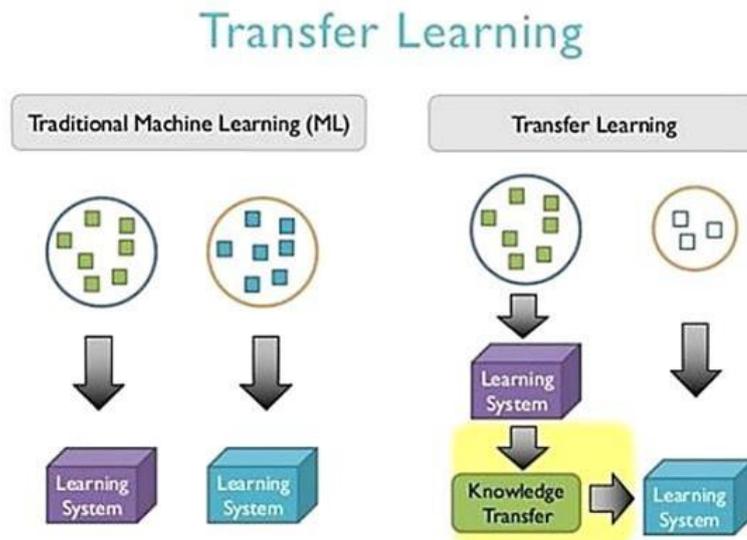
2.10.3 Augmentasi *Flip*

Augmentasi ini terdiri dari *horizontal flip* dan *vertical flip*. Pada *horizontal flip*, citra diputar secara *horizontal*, sehingga objek yang muncul di sisi kanan akan muncul di sisi kiri, dan sebaliknya. Untuk *vertical flip*, citra diputar secara *vertical* dari atas ke bawah (Aprillia et al., 2024).

2.11 *Transfer Learning*

Transfer learning merupakan strategi yang digunakan dalam *deep learning* dengan mengambil model yang sudah dilatih pada *dataset* sebelumnya dan menerapkannya pada *dataset* yang berbeda. Dibandingkan dengan arsitektur CNN sederhana *transfer learning* memiliki lapisan *convolution* dan *pooling* yang lebih dalam sehingga mampu mengekstraksi tekstur citra dengan lebih banyak dan mendapatkan hasil informasi dari citra yang lebih baik (Abdul et al., 2021). *Transfer learning* berguna dalam meningkatkan akurasi dalam suatu model karena memanfaatkan model yang sudah dilatih sebelumnya dan telah terbukti mampu untuk menangani sebuah data yang besar dan umum dengan baik. Dalam *transfer learning*, pada *layer* bagian akhir model yang digunakan sebagai “bahan baku” biasanya dilakukan penyesuaian pada lapisan bagian akhirnya untuk membangun model baru. *Layer* tersebut dapat dioptimalkan dengan mengubah beberapa parameter atau dengan

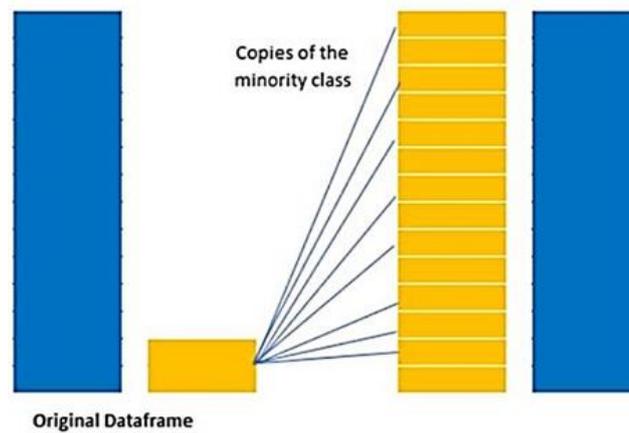
menambahkan lapisan baru (Anhar & Putra, 2023). Gambar 10 merupakan ilustrasi dari *transfer learning*.



Gambar 10. *Transfer Learning* (Wijaya et al., 2021).

2.12 *Random Oversampling*

Random Oversampling merupakan salah satu teknik yang digunakan untuk mengatasi masalah pada jumlah kelas yang tidak seimbang dengan melakukan penambahan data pada kelas minoritas ke dalam data data *training* secara acak. Proses penambahan data ini diulang sehingga jumlah data kelas minoritas sama rata dengan jumlah data pada kelas mayoritas. Langkah awal yang dilakukan yaitu dengan menghitung selisih antara kelas mayoritas dan kelas minoritas. Kemudian, dilakukan perulangan sebanyak hasil penghitungan beda data sambil membaca data kelas minoritas secara acak dan dimasukkan ke dalam data *training* (Diantika, 2023). Ilustrasi dari *random oversampling* dapat dilihat pada Gambar 11.



Gambar 11. *Random Oversampling (ROS)* (Diantika, 2023).

2.13 Python

Python merupakan bahasa pemrograman tingkat tinggi yang memiliki *script* dan interpretasi. Python bersifat *open-source* dan juga mendukung berbagai pemrograman paradigma, seperti berorientasi objek, imperatif, dan fungsional. Python mudah digunakan karena menggunakan *keyword* yang mirip dengan bahasa Inggris, sehingga program yang ditulis dengan Python biasanya lebih singkat dibandingkan dengan program yang dibuat menggunakan C++ atau Java (Chromiński et al., 2021).

2.13.1 *Library Numpy*

Numpy adalah *library* untuk melakukan komputasi numerik menggunakan Python. Numpy digunakan pada pemrosesan *array* dalam Python. Dalam Numpy tersedia fungsi dan operator yang dioptimalkan untuk bekerja dengan *array* multidimensi. Fitur utama Numpy mencakup penyediaan fungsi cepat dan dikompilasi untuk rutinitas numerik, pendekatan berorientasi *array* untuk efisiensi yang lebih baik dan dukungan untuk pendekatan berorientasi objek. Numpy sangat berguna untuk berbagai keperluan dalam menganalisis data, pembuatan

array dengan dimensi yang kuat, komputasi ilmiah dan masih banyak lagi (Saabith et al., 2020).

2.13.2 *Library Tensorflow*

Tensorflow merupakan *library* untuk komputasi numerik berkinerja tinggi yang melibatkan tensor. Tensorflow berguna dalam mengenali ucapan dan citra, aplikasi berbasis teks, analisis deret waktu dan deteksi video. Salah satu fitur utama Tensorflow adalah kemampuan visualisasi grafik komputasi yang lebih baik. *Library* ini juga mendukung komputasi paralel untuk model yang kompleks dan memiliki manajemen perpustakaan yang lancar didukung oleh Google (Saabith et al., 2020).

2.13.3 *Library Matplotlib*

Matplotlib memiliki kemampuan dalam menghasilkan grafik dan *plot* yang menarik, sehingga Matplotlib banyak digunakan dalam visualisasi data. Selain itu, Matplotlib menyediakan API berorientasi objek, yang memungkinkan *plot* disematkan ke dalam aplikasi dengan mudah. Matplotlib sangat berguna untuk menganalisis korelasi variabel, visualisasi interval kepercayaan model, mendeteksi *outlier* menggunakan *plot* sebar, dan memvisualisasikan distribusi data untuk mendapatkan wawasan yang cepat (Saabith et al., 2020).

2.13.4 *Library Keras*

Keras adalah salah satu *library* yang paling populer dan *open-source* untuk Python. Awalnya dikembangkan oleh insinyur Google untuk proyek ONEIROS (*Open-Ended Neuro Electronic Intelligent Robot Operating System*), Keras kemudian diintegrasikan ke dalam Tensorflow sehingga dapat digunakan di atas Tensorflow. Keras menyediakan antarmuka tingkat tinggi untuk pembuatan model jaringan saraf yang dapat berjalan di atas Tensorflow, CNTK, atau Theano dan

dapat beroperasi baik di CPU maupun GPU. Keras dirancang untuk memudahkan pemula dalam pembuatan dan desain *neural network*, serta memungkinkan *prototyping* yang cepat dan mudah. Selain itu, keras mendukung berbagai jenis *neural network*, termasuk *Convolutional Neural Network* (CNN) dan *Recurrent Neural Network* (RNN), serta *neural network* standar lainnya (Saabith et al., 2020).

2.13.5 *Library Scikit-learn*

Scikit-learn adalah sebuah *library* yang menawarkan integrasi yang lancar. Scikit-learn merupakan salah satu perpustakaan pembelajaran mesin klasik yang paling populer, dibangun di atas dasar-dasar Python yaitu Numpy dan Scipy. Perpustakaan ini menyediakan dukungan untuk berbagai algoritma pembelajaran yang diawasi dan tidak diawasi. Selain itu, Scikit-Learn juga dapat digunakan untuk penambahan data dan analisis data, menjadikannya alat yang sangat berharga bagi mereka yang baru memasuki dunia pembelajaran mesin (Saabith et al., 2020).

2.13.6 *Library Seaborn*

Seaborn adalah *library* yang digunakan untuk visualisasi data yang dibangun di atas Matplotlib. *Library* ini juga sering digunakan untuk membuat suatu *plot* yang menarik dan informatif. Seaborn memungkinkan hasil *plot* dari Matplotlib ditampilkan langsung di dalam *notebook* (Pratama et al., 2024).

2.13.7 *Library Os*

Library Os adalah *library* standar dalam Python yang menyediakan berbagai fungsi untuk berinteraksi dengan sistem operasi. *Library* ini memungkinkan fungsionalitas, seperti mengelola *file* dan direktori, mengelola variabel *environment* dan mengeksekusi program eksternal (Rajamani et al., 2023).

2.14 *Hyperparameter*

Hyperparameter merupakan parameter yang harus ditentukan terlebih dahulu sebelum melakukan pelatihan model karena parameter model tidak ditentukan dari data pelatihan. Nilai *hyperparameter* biasanya ditentukan dengan menggunakan metode *trial-and-error* atau metode pencarian *brute force*. Memilih nilai *hyperparameter* yang tepat sangat penting untuk meningkatkan kinerja model secara signifikan karena jika salah dalam menentukan nilai *hyperparameter* dapat mengakibatkan model menjadi tidak akurat dan kurang optimal (Sen, 2021). *Hyperparameter* yang umum digunakan pada suatu model, yaitu *epoch*, *optimizer*, *learning rate* dan *batch size*.

2.14.1 *Epoch*

Epoch merupakan satu rangkaian perhitungan yang dimulai dari awal hingga akhir dan kemudian kembali ke awal dalam proses *training dataset* atau yang dikenal sebagai satu putaran atau satu *epoch*. *Epoch* berguna dalam mencapai akurasi yang tinggi dan *loss* yang rendah. Penentuan jumlah *epoch* mempengaruhi pada bobot model dan bentuk kurva yang dihasilkan. Proses pelatihan diperlukan beberapa kali pembaruan karena kurang optimal jika *epoch* hanya dilakukan sekali putaran (Masykur et al., 2022).

2.14.2 *Optimizer*

Optimizer merupakan algoritma yang digunakan untuk menyesuaikan parameter seperti bobot dan bias pada *neural network* guna mengurangi *error* atau *loss*. Terdapat berbagai jenis algoritma *optimizer*, seperti *Gradient Descent*, *Stochastic Gradient Descent*, *Adaptive Moment Estimation* (Adam), *RMSprop* dan lain-lain (Fawwaz et al., 2021).

2.14.3 *Learning Rate*

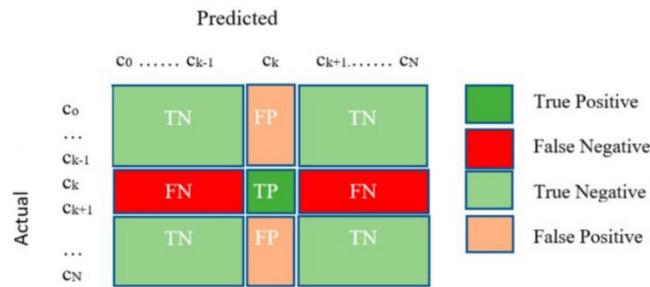
Learning rate merupakan *hyperparameter* yang mengontrol tingkat perubahan bobot model setelah setiap iterasi pada fase pelatihan berdasarkan perkiraan kesalahannya. *Learning rate* dapat ditentukan secara manual, biasanya dalam rentang 10^{-6} hingga 1.0. *Learning rate* yang terlalu rendah memperlambat pelatihan, sementara *learning rate* yang terlalu tinggi dapat menyebabkan pelatihan berisik dan gagal mencapai minimum *global*. Pemilihan nilai *learning rate* yang sesuai dapat mengurangi nilai *loss* dan meningkatkan kinerja model (Jeba, 2021).

2.14.4 *Batch Size*

Batch size merupakan salah satu *hyperparameter* terpenting yang perlu disesuaikan dalam sistem *deep learning*. Dalam *machine learning*, istilah *batch size* merujuk pada jumlah contoh pelatihan yang digunakan dalam satu iterasi. Pada proses *training*, parameter *batch size* perlu ditentukan (Rochmawati et al., 2021).

2.15 *Confusion Matrix*

Confusion matrix merupakan suatu metode evaluasi yang digunakan untuk menganalisis prediksi dan mengukur kinerja dari suatu model *machine learning* berbasis klasifikasi. *Confusion matrix* umumnya digambarkan dalam bentuk tabel yang menyatakan ringkasan dari prediksi yang benar dan salah yang dihasilkan dari suatu model *machine learning* yang digunakan untuk tugas klasifikasi. Di dalam *confusion matrix* menampilkan perbandingan antara hasil klasifikasi kelas prediksi dengan klasifikasi kelas yang sebenarnya (Mahardhika et al., 2016). Representasi *confusion matrix* dapat dilihat pada Gambar 12.



Gambar 12. *Confusion Matrix* (Menaouer et al., 2022).

Berikut keterangan dari Gambar 12.

- True Positive* (TP) adalah nilai kelas yang sebenarnya positif dan model memprediksi dengan benar suatu kelas sebagai positif.
- False Positive* (FP) adalah nilai kelas yang sebenarnya negatif dan model keliru dalam memprediksi suatu kelas sebagai positif.
- True Negative* (TN) adalah nilai kelas yang sebenarnya negatif dan model dengan benar dalam memprediksi suatu kelas sebagai negatif.
- False Negative* (FN) adalah nilai kelas yang sebenarnya positif dan model keliru dalam memprediksi suatu kelas sebagai negatif.

Berdasarkan Gambar 12 didapatkan parameter untuk mengukur kinerja model yaitu *accuracy*, *precision*, *recall* dan *f1-score*.

- Accuracy*

Accuracy adalah ukuran seberapa banyak hasil prediksi benar yang dibuat oleh suatu model (Saputro & Sari, 2020). Nilai *accuracy* dapat dihitung dengan menggunakan Persamaan 2.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

- Precision*

Precision adalah ketika model memprediksi dengan positif, seberapa banyak prediksi itu benar (Saputro & Sari, 2020). Nilai *precision* dapat dihitung dengan menggunakan Persamaan 3.

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

c. *Recall*

Recall adalah ketika kelas aktualnya positif dan seberapa sering model memprediksi sebagai positif (Saputro & Sari, 2020). Nilai *recall* dapat dihitung menggunakan Persamaan 4.

$$Recall = \frac{TP}{FN + TP} \quad (4)$$

d. *F1-score*

F1-score adalah rata-rata harmonik dari *precision* dan *recall* (Saputro & Sari, 2020). Nilai *f1-score* dapat dihitung dengan menggunakan Persamaan 5.

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5)$$

III. METODOLOGI PENELITIAN

3.1 Tempat dan Waktu Penelitian

3.1.1 Tempat Penelitian

Penelitian dilaksanakan di Laboratorium Komputasi Dasar Jurusan Ilmu Komputer Fakultas Matematika dan Ilmu Pengetahuan Alam Universitas Lampung, bertempat di Jalan Prof. Dr. Soemantri Brojonegoro No. 1. Gedung Meneng, Bandar Lampung.

3.1.2 Waktu Penelitian

Penelitian ini dilaksanakan pada bulan Februari tahun ajaran 2023/2024 sampai dengan bulan Oktober tahun ajaran 2023/2024. Penelitian ini dimulai dengan pemahaman tema dan studi literatur, pengumpulan *dataset*, tahap *preprocessing*, pembagian data, *training* model menggunakan arsitektur ResNet101 dan evaluasi kinerja pada model. Waktu penelitian yang dilakukan dapat dilihat pada Tabel 2.

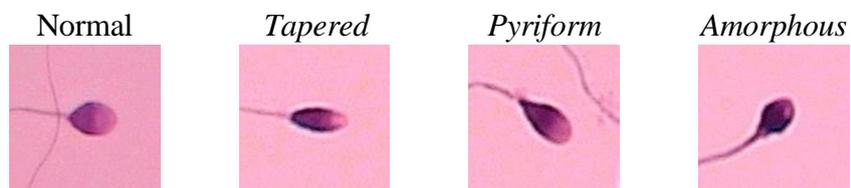
Tabel 2. Jadwal Penelitian.

Nama Kegiatan	2024																																			
	Februari				Maret				April				Mei				Juni				Juli				Agustus				September				Oktober			
	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4	1	2	3	4
Studi literatur dan pemahaman tema penelitian	■	■	■	■	■	■	■	■	■																											
Pengumpulan <i>dataset</i>							■	■																												
<i>Pre-Processing</i>									■	■	■	■	■	■	■	■																				
Pembagian data																	■	■	■	■																
<i>Training</i> model CNN arsitektur ResNet101																					■	■	■	■	■	■	■	■	■	■	■	■				
Evaluasi model																									■	■	■	■	■	■	■	■	■	■	■	■

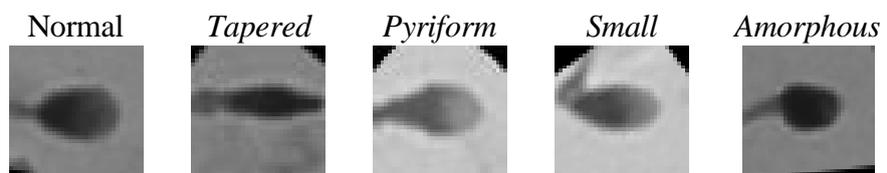
3.2 Data dan Alat

3.2.1 Data

Data yang digunakan dalam penelitian ini menggunakan dua *dataset* yaitu *dataset* HuSHem dan SCIAN. *Dataset* yang pertama adalah HuSHem (*Human Sperm Head Morphology*) *dataset* bersumber dari penelitian yang dilakukan oleh (Shaker et al., 2017) yang diunduh dari mendeley beralamat (<https://data.mendeley.com/datasets/tt3yj2pf38/1>). *Dataset* HuSHem berjumlah 216 citra yang terdiri dari empat kelas bentuk kepala sperma, yaitu *normal*, *tapered*, *pyriform* dan *amorphous*. *Dataset* kedua ialah SCIAN-*MorphoSpermGS* bersumber dari penelitian yang dilakukan oleh (Chang et al., 2017). *Dataset* SCIAN berjumlah 1132 citra yang terdiri dari lima kelas bentuk sperma yaitu *normal*, *tapered*, *pyriform*, *small* dan *amorphous*. Citra dari *dataset* HuSHem dapat dilihat pada Gambar 13 dan citra *dataset* SCIAN dilihat pada Gambar 14.



Gambar 13. *Dataset* HuSHem.



Gambar 14. *Dataset* SCIAN.

3.2.2 Alat

a. Perangkat Keras (*Hardware*)

Perangkat keras yang digunakan pada penelitian ini dengan spesifikasi sebagai berikut.

- i. *Acer Aspire* A514-53
- ii. *Processor* Intel Core i3 1005-G1
- iii. *Installed* RAM 4.00 GB

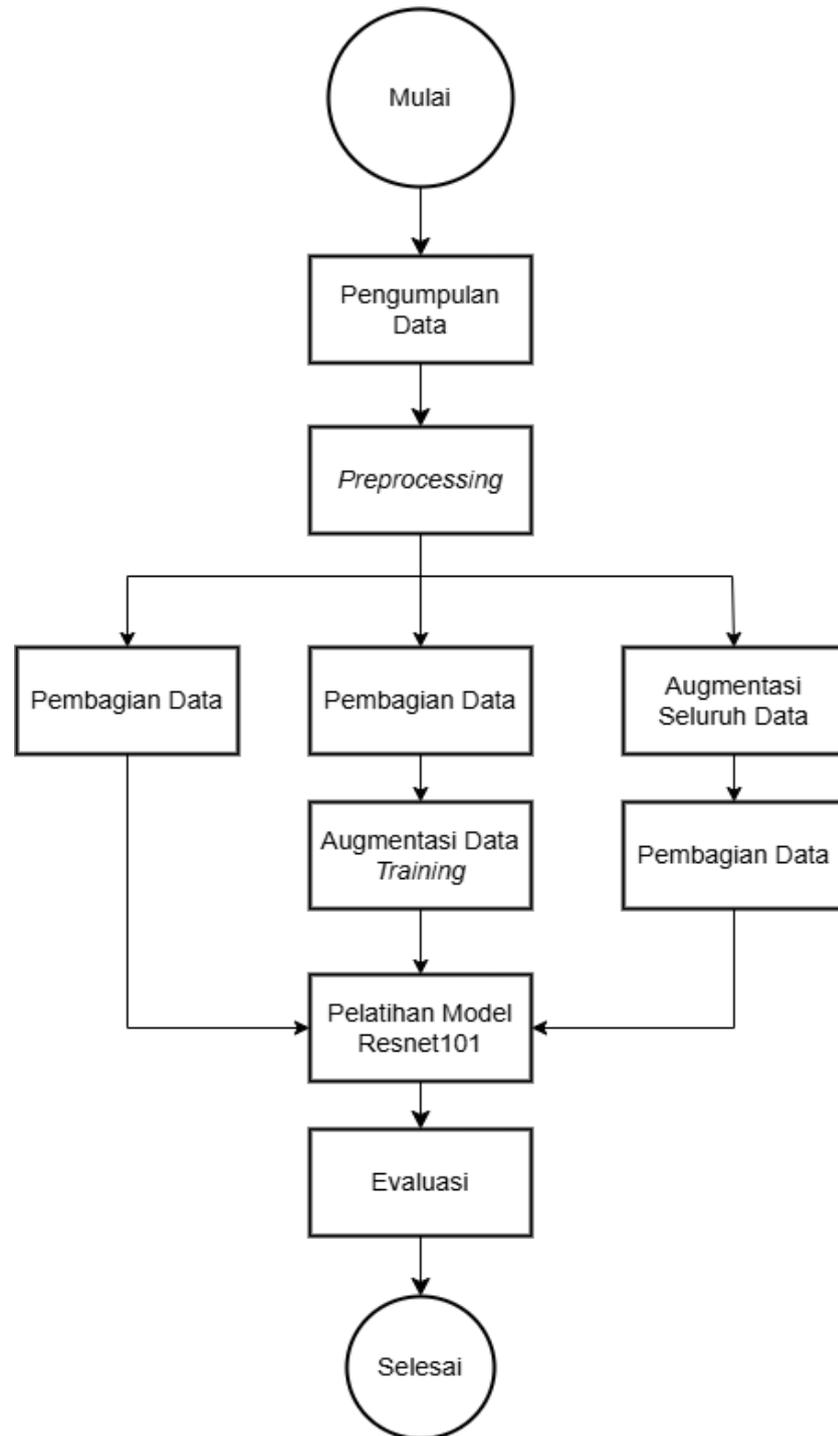
b. Perangkat Lunak (*Software*)

Perangkat lunak yang digunakan pada penelitian ini, yaitu sistem operasi windows 11 64-bit, Google Colaboratory, Google Drive dan beberapa jenis *library* Python antara lain:

- i. *Library* Numpy
- ii. *Library* Keras
- iii. *Library* Tensorflow
- iv. *Library* Matplotlib
- v. *Library* Scikit-Learn
- vi. *Library* Os
- vii. *Library* Seaborn

3.3 Alur Kerja Penelitian

Penelitian ini terdiri dari 3 tahapan berbeda dalam prosesnya. Tahapan pertama dilakukan tanpa menerapkan augmentasi data. Tahapan kedua dilakukan dengan menerapkan augmentasi data hanya pada data *training*. Tahapan ketiga dengan menerapkan augmentasi pada seluruh data. *Flowchart* skema penelitian ini dapat dilihat pada Gambar 15.



Gambar 15. Alur Penelitian.

Tahapan yang dilakukan dalam penelitian ini dapat dilihat pada Gambar 15 dengan penjelasannya sebagai berikut.

3.3.1 Pengumpulan *Dataset*

Data yang digunakan dalam penelitian ini menggunakan dua *dataset* yaitu *dataset* HuSHem dan SCIAN. *Dataset* yang pertama adalah HuSHem (*Human Sperm Head Morphology*) *dataset* bersumber dari penelitian (Shaker et al., 2017) yang diunduh dari mendeley (<https://data.mendeley.com/datasets/tt3yj2pf38/1>). *Dataset* HuSHem berjumlah 216 data yang terdiri dari empat kelas. *Dataset* kedua ialah SCIAN-MorphoSpermGS (Chang et al., 2017) berjumlah 1.132 data yang terdiri dari lima kelas bentuk sperma.

3.3.2 *Preprocessing*

Proses *preprocessing* bertujuan untuk mempersiapkan data mentah agar dapat digunakan secara efektif oleh model *machine learning* atau *deep learning*. Pada tahap ini dilakukan konversi *file*, di mana semua citra dalam *dataset* dengan format yang tidak didukung dalam *tensorflow* diubah ke format (.jpeg) yang lebih umum digunakan dan kompatibel dengan berbagai alat analisis citra. Konversi *file* citra hanya dilakukan pada *dataset* SCIAN, karena *file* citra dalam *dataset* SCIAN berformat (.tif) yang tidak didukung oleh *Tensorflow*. Konversi *file* dilakukan untuk memastikan bahwa semua citra dapat diproses secara seragam tanpa masalah kompatibilitas.

Proses lainnya yaitu dengan melakukan *resizing* atau mengubah ukuran citra ke dimensi yang sama. Proses *resizing* ini membantu dalam mengurangi kompleksitas komputasi tanpa kehilangan informasi penting yang terdapat dalam citra. Selain itu juga, diterapkan normalisasi data. Normalisasi dilakukan dengan menskalakan nilai piksel dalam citra agar berada dalam rentang tertentu antara 0-1.

Untuk *dataset* HuSHem sendiri, sebelum dilakukan normalisasi dan *resizing* dilakukan proses lainnya, yaitu penyelarasan rotasi kepala sperma dan *cropping* citra. Penyelarasan citra dilakukan agar posisi

kepala sperma menghadap pada rotasi yang sama. Kemudian, proses *cropping* diterapkan agar citra lebih berfokus pada objek utamanya yaitu kepala sperma.

3.3.3 Pembagian data

Data dibagi menjadi tiga bagian utama yaitu data *training*, data *validation* dan data *testing*. Pembagian data dibuat dalam tiga skema berbeda, diantaranya adalah sebagai berikut.

- a. Data *training* 80%, data *validation* 10% dan data *testing* 10%.
- b. Data *training* 70%, data *validation* 25% dan data *testing* 5%.
- c. Data *training* 60%, data *validation* 20% dan data *testing* 20%.

3.3.4 Augmentasi Data

Menerapkan augmentasi data dalam penelitian yang berguna dalam memperbanyak jumlah variasi data. Augmentasi dalam penelitian ini digunakan karena arsitektur yang dipakai sangat kompleks sedangkan jumlah datanya sedikit sehingga proses augmentasi dibutuhkan. Ada banyak jenis augmentasi, pada penelitian ini menggunakan beberapa teknik augmentasi yaitu *rotation*, *zoom* dan *flipping*. Data citra hasil proses augmentasi tersebut lalu digabungkan dengan data citra *original*.

3.3.5 Training Arsitektur ResNet101

Proses pelatihan model menggunakan arsitektur ResNet101 yang dilatih ulang menggunakan *transfer learning* dengan penambahan *layer* model yang sesuai dengan jumlah data yang tersedia. Selain itu juga, menggunakan data yang telah diaugmentasi. Proses pelatihan menggunakan bahasa pemrograman Python yang terintegrasi di dalam Google Colab. Model dilatih dengan menggunakan beberapa *hyperparameter* yaitu *epoch*, *batch-size*, *optimizer* dan *learning rate*. Nilai atau jenis *hyperparameter* yang digunakan pada penelitian ini dapat dilihat pada Tabel 3 dan Tabel 4.

Tabel 3. *Hyperparameter Dataset HuSHem.*

<i>Hyperparameter</i>	Jenis/Nilai
<i>Epoch</i>	100
<i>Batch-Size</i>	32
<i>Optimizer</i>	Adam
<i>Learning-Rate</i>	0,001

Tabel 4. *Hyperparameter Dataset SCIAN.*

<i>Hyperparameter</i>	Jenis/Nilai
<i>Epoch</i>	100
<i>Batch-Size</i>	64
<i>Optimizer</i>	Adam
<i>Learning-Rate</i>	0,0001

3.3.6 Evaluasi

Evaluasi dilakukan dengan tujuan untuk mengukur kinerja suatu model pada penelitian dalam mengklasifikasikan sperma berdasarkan morfologi. Pada tahap evaluasi menunjukkan tingkat keberhasilan dari model yang digunakan. Metode yang digunakan dalam mengevaluasi model menggunakan *confusion matrix* dengan parameternya, yaitu *accuracy*, *precision*, *recall* dan *f1-score*.

V. SIMPULAN DAN SARAN

5.1 Simpulan

Simpulan yang didapat pada penelitian yang telah dilakukan adalah sebagai berikut:

- a. Penelitian yang telah dilakukan berhasil mengklasifikasikan sperma manusia berdasarkan morfologi menggunakan algoritme CNN dengan arsitektur ResNet101 dengan *transfer learning* serta penambahan augmentasi data. Pada *dataset* HuSHem akurasi tertinggi sebesar 97.73% pada skenario pembagian data 70:25:5 dengan penambahan augmentasi pada seluruh data, sedangkan untuk *dataset* SCIAN akurasi tertinggi sebesar 70.18% pada skenario pembagian data 70:25:5 dengan penambahan augmentasi pada seluruh data.

- b. Evaluasi menunjukkan bahwa arsitektur ResNet101 memberikan performa yang cukup baik dalam klasifikasi morfologi sperma manusia. Pada *dataset* HuSHem evaluasi metrik *recall*, dan *f1-score* masing-masing sebesar 97.73% dan *precision* 97.93% yang menunjukkan bahwa model secara signifikan sangat baik dalam mengklasifikasi citra. Hasil evaluasi metrik pada *dataset* SCIAN *precision* 69.51%, *recall* 69.17% dan *f1-score* 70.18%, menunjukkan bahwa model sudah cukup baik, namun performanya masih di bawah *Multi-model CNN fusion*.

5.2 Saran

Saran yang diberikan untuk penelitian selanjutnya adalah sebagai berikut.

1. Menggunakan berbagai arsitektur CNN lainnya, seperti Inception, YOLO, EfficientNet atau arsitektur lainnya yang memungkinkan untuk mendapatkan hasil yang optimal.
2. Menggunakan teknik augmentasi lainnya yang memungkinkan menaikkan kinerja model secara signifikan dan juga menggunakan teknik *balance* data lainnya seperti SMOTE, khususnya untuk *dataset* SCIAN yang mempunyai data yang tidak seimbang pada setiap kelas.

DAFTAR PUSTAKA

- Abdul, J. R., Arief, M. R., & Sunyoto, A. (2021). Implementation of Transfer Learning in the Convolutional Neural Network Algorithm for Identification of Potato Leaf Disease. *Procedia of Engineering and Life Science*, 1(1). <https://doi.org/10.21070/pels.v1i1.820>
- Adrianto, L. B., Wahyuddin, M. I., & Winarsih, W. (2021). Implementasi Deep Learning untuk Sistem Keamanan Data Pribadi Menggunakan Pengenalan Wajah dengan Metode Eigenface Berbasis Android. *Jurnal JTIC (Jurnal Teknologi Informasi Dan Komunikasi)*, 5(1), 89-96. <https://doi.org/10.35870/jtik.v5i1.201>
- Alin, A. Y., Kusriani, K., & Yuana, K. A. (2023). The Effect of Data Augmentation in Deep Learning with Drone Object Detection. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 17(3), 237-248. <https://doi.org/10.22146/ijccs.84785>
- Andika, L. A., Pratiwi, H., & Handajani, S. S. (2019). Klasifikasi Penyakit Pneumonia Menggunakan Metode Convolutional Neural Network Dengan Optimasi Adaptive Momentum. *Indonesian Journal of Statistics and Its Applications*, 3(3), 331–340. <https://doi.org/10.29244/ijsa.v3i3.560>
- Anhar, A., & Putra, R. A. (2023). Perancangan dan Implementasi Self-Checkout System pada Toko Ritel menggunakan Convolutional Neural Network (CNN). *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 11(2), 466-478. <https://doi.org/10.26760/elkomika.v11i2.466>
- Ani, M., Astuti, E. D., Hutabarat, N. A. J., Nardina, E. A., Sebtalesy, C. Y., Maryani, W. S., Yani, D. P., Jannah, N. B. A. R., & Mahmud, A. (2021). Biologi Reproduksi dan Mikrobiologi Mikrobiologi. Yayasan Kita Menulis.
- Aprillia, D., Rohana, T., Mudzakir, T. Al, & Wahiddin, D. (2024). Deteksi Nominal Mata Uang Rupiah Menggunakan Metode Convolutional Neural Network dan Feedforward Neural Network. *KLIK: Kajian Ilmiah Informatika Dan Komputer*, 4(4), 2068–2077.

- Aryoseto, L. (2009). Hubungan antara jumlah leukosit dengan morfologi spermatozoa pada pasien infertilitas di rumah sakit dokter kariadi. Medical faculty. Undergraduate thesis, Medical faculty.
- Babakhanzadeh, E., Nazari, M., Ghasemifar, S., & Khodadadian, A. (2020). Some of the factors involved in male infertility: A prospective review. *International Journal of General Medicine*, 13, 29–41. doi.org/10.2147/IJGM.S241099
- Boguenet, M., Bouet, P. E., Spiers, A., Reynier, P., & May-Panloup, P. (2021). Mitochondria: Their role in spermatozoa and in male infertility. *Oxford University Press on behalf of European Society of Human Reproduction and Embryology*, 27(4), 697–719. https://doi.org/10.1093/humup/dmab001
- Carrillo-López, A., & Yahia, E. M. (2019). Morphology and Anatomy. *Postharvest Physiology and Biochemistry of Fruits and Vegetables*, 113–130. https://doi.org/10.1016/B978-0-12-813278-4.00006-3
- Chang, V., Garcia, A., Hitschfeld, N., & Härtel, S. (2017). Gold-standard for computer-assisted morphological sperm analysis. *Computers in Biology and Medicine*, 83, 143–150. https://doi.org/10.1016/j.compbiomed.2017.03.004
- Choldun, M. I., & Surendro, K. (2018). Klasifikasi penelitian dalam deep learning. *Jurusan Manajemen Informatika - Politeknik Pos Indonesia*, 10(1), 25–33.
- Cholissodin, I., Sutrisno, S., Soebroto, A. A., Hasanah, U., & Febiola, Y. I. (2020). AI, Machine Learning & Deep Learning. Fakultas Ilmu Komputer (FILKOM), Universitas Brawijaya (UB), Malang.
- Chromiński, K., Benko, L., Hernández-Figueroa, Z. J., González-Domínguez, J. D., Rodríguez-del-Pino, J. C., & Přichystal, J. (2021). Python Fundamentals. Nitra : Constantine the Philosopher University in Nitra.
- Denata, I., Rismawan, T., & Ruslianto, I. (2021). Implementation of Deep Learning for Classification Type of Orange Using The Method Convolutional Neural Network. *Telematika: Jurnal Informatika Dan Teknologi Informasi*, 18(3), 297–307. https://doi.org/10.31315/telematika.v18i3.5541
- 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
- Fawwaz, M. A. A., Ramadhani, K. N., & Sthevanie, F. (2021). Klasifikasi Ras pada Kucing menggunakan Algoritma Convolutional Neural Network(CNN). *E-Proceeding of Engineering*, 8(1), 715-730.
- Wicaksono, G. W., & Andreawan, A. (2023). ResNet101 Model Performance Enhancement in Classifying Rice Diseases with Leaf Images. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 7(2), 345–352. https://doi.org/10.29207/resti.v7i2.4575

- Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). Fundamental Concepts of Convolutional Neural Network, 172, 519–567. Springer, Cham. https://doi.org/10.1007/978-3-030-32644-9_36
- Hariyani, Y. S., Hadiyoso, S., & Siadari, T. S. (2020). Deteksi Penyakit Covid-19 Berdasarkan Citra X-Ray Menggunakan Deep Residual Network. *ELKOMIKA: Jurnal Teknik Energi Elektrik, Teknik Telekomunikasi, & Teknik Elektronika*, 8(2), 443-453. <https://doi.org/10.26760/elkomika.v8i2.443>
- Hasan, M. J., Alom, Md. S., & Fatema, U. (2021). *Classification Performance Analysis of Retinal OCT Image using Handcrafted and Deep Learning Feature with Support Vector Machine*. A thesis for the degree, Hajee Mohammad Danesh Science and Technology University, Dinajpur. <https://doi.org/10.13140/RG.2.2.36346.82888/2>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.
- Herdiansah, A., Borman, R. I., Nurnaningsih, D., Sinlae, A. A. J., & Al Hakim, R. R. (2022). Klasifikasi Citra Daun Herbal Dengan Menggunakan Backpropagation Neural Networks Berdasarkan Ekstraksi Ciri Bentuk. *JURIKOM (Jurnal Riset Komputer)*, 9(2), 388-395. <https://doi.org/10.30865/jurikom.v9i2.4066>
- Hernandoko, N., Laksono, P. W., & Rosyidi, C. N. (2024). Penerapan Sistem Kontrol Kualitas dengan Menggunakan Model CNN Transfer Learning VGG 19 pada Inspeksi Kain di Industri Tekstil. *Performa: Media Ilmiah Teknik Industri*, 23(2), 166-170. <https://doi.org/10.20961/performa.23.2.86589>
- Ilahi, M. W., Apriyani, C. N., Desiani, A., Gofar, N., Andriani, Y., & Halim, M. R. (2022). Classification of Geometric Batik Motif Typical of Indonesian Using Convolutional Neural Network. *Jurnal Teknik Informatika*, 15(1), 91–100. <https://doi.org/10.15408/jti.v15i1.24968>
- Iqbal, I., Mustafa, G., & Ma, J. (2020). Deep learning-based morphological classification of human sperm heads. *Diagnostics*, 10(5), 325. <https://doi.org/10.3390/diagnostics10050325>
- Jakubik-Uljasz, J., Gill, K., Rosiak-Gill, A., & Piasecka, M. (2020). Relationship between sperm morphology and sperm DNA dispersion. *Translational Andrology and Urology*, 9(2), 405–415. <https://doi.org/10.21037/tau.2020.01.31>
- Jeba, J. A. (2021). Case study of Hyperparameter optimization framework Optuna on a Multi-column Convolutional Neural Network. [Doctoral dissertation] University of Saskatchewan.

- Jusman, Y. (2023). Comparison of Prostate Cell Image Classification Using CNN: ResNet-101 and VGG-19. *2023 IEEE 13th International Conference on Control System, Computing and Engineering (ICCSCE)*, 74–78. <https://doi.org/10.1109/ICCSCE58721.2023.10237088>
- Kalshetty, R., & Parveen, A. (2023). Abnormal event detection model using an improved ResNet101 in context aware surveillance system. *Cognitive Computation and Systems*, 5(2), 153–167. <https://doi.org/10.1049/ccs2.12084>
- Kang, C., Punjani, N., Lee, R. K., Li, P. S., & Goldstein, M. (2022). Effect of varicoceles on spermatogenesis. *Seminars in Cell and Developmental Biology*, 121, 114–124. <https://doi.org/10.1016/j.semcd.2021.04.005>
- Krichen, M. (2023). Convolutional Neural Networks: A Survey. *Computers*, 12(8), 151. <https://doi.org/10.3390/computers12080151>
- Mahardhika, A. A., Saptono, R., & Anggrainingsih, R. (2016). Sistem Klasifikasi Feedback Pelanggan Dan Rekomendasi Solusi Atas Keluhan Di UPT Puskom UNS Dengan Algoritma Naive Bayes Classifier Dan Cosine Similiarity. *ITSMART: Jurnal Teknologi Dan Informasi*, 4(1), 36–42.
- Masykur, F., & Setyawan, M. B. W. K. (2022). Optimalisasi Epoch Pada Klasifikasi Citra Daun Tanaman Padi Menggunakan Convolutional Neural Network (CNN) MobileNet. *CESS (Journal of Computing Engineering, System and Science)*, 7(2), 581–591.
- Menaouer, B., Dermene, Z., El Houda Kebir, N., & Matta, N. (2022). Diabetic Retinopathy Classification Using Hybrid Deep Learning Approach. *SN Computer Science*, 3(5), 357. <https://doi.org/10.1007/s42979-022-01240-8>
- Munantri, N. Z., Sofyan, H., & Florestiyanto, M. Y. (2019). Aplikasi Pengolahan Citra Digital Untuk Identifikasi Umur Pohon. *TELEMATIKA : Jurnal Informatika dan Teknologi Informasi*, 16(2), 97–104. <https://doi.org/10.31315/telematika.v16i2.3183>
- Nafi'iyah, N. (2015). Algoritma Kohonen dalam Mengubah Citra Graylevel Menjadi Citra Biner. *Jurnal Ilmiah Teknologi Informasi Asia*, 9(2), 49–55. <https://jurnal.stmikasia.ac.id/index.php/jitika/article/view/125>
- Okonofua, F. E., Ntoimo, L. F. C., Ayodeji, A. O. O., Olafusi, C., Unuabonah, E., & Ohenhen, V. (2022). Causes and Risk Factors for Male Infertility: A Scoping Review of Published Studies. *International Journal of General Medicine*, 15, 5985–5997. <https://doi.org/10.2147/IJGM.S363959>
- Prasetyo, N., Baihaq, K. A., Lestar, S. A. P., & Cahyana, Y. (2024). Classification Of Rice Plants Affected By Rats Using The Support Vector Machine (Svm) Algorithm. *Jurnal Teknik Informatika (JUTIF)*, 5(2), 637–643.

- Pratama, M. A., Munawaroh, M., & Pranoto, W. J. (2024). Perbandingan Performa Algoritma Linear Regresi dan Random Forest untuk Prediksi Harga Bawang Merah di Kota Samarinda. *TEKTONIK: Jurnal Ilmu Teknik*, *1*(2), 172–182.
- Pratiwi, H. A., Cahyanti, M., & Lamsani, M. (2021). Implementasi Deep Learning Flower Scanner Menggunakan Metode Convolutional Neural Network. *Sebatik*, *25*(1), 124–130. <https://doi.org/10.46984/sebatik.v25i1.1297>
- Putra, W. S. E. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101. *Jurnal Teknik ITS*, *5*(1), A65-A69. <https://doi.org/10.12962/j23373539.v5i1.15696>
- Radikto, R., Mulyana, D. I., Rofik, M. A., & Zakaria, M. O. Z. (2022). Klasifikasi Kendaraan pada Jalan Raya menggunakan Algoritma Convolutional Neural Network (CNN). *Jurnal Pendidikan Tambusai*, *6*(1), 1668–1679. <https://doi.org/10.31004/jptam.v6i1.3179>
- Rajamani, S. K., & Iyer, R. S. (2023). *Machine Learning-Based Mobile Applications Using Python and Scikit-Learn*. IGI Global Scientific Publishing. <https://doi.org/10.4018/978-1-6684-8582-8.ch016>
- Ratna, S. (2020). Pengolahan Citra Digital Dan Histogram Dengan Phyton Dan Text Editor Phycharm. *Technologia: Jurnal Ilmiah*, *11*(3), 181-186. <https://doi.org/10.31602/tji.v11i3.3294>
- Rebala, G., Ravi, A., & Churiwala, S. (2019). Learning Models. In *An Introduction to Machine Learning*. Springer International Publishing. https://doi.org/10.1007/978-3-030-15729-6_2
- Riordon, J., McCallum, C., & Sinton, D. (2019). Deep learning for the classification of human sperm. *Computers in Biology and Medicine*, *111*. <https://doi.org/10.1016/j.combiomed.2019.103342>
- Rochmawati, N., Hidayati, H. B., Yamasari, Y., Tjahyaningtijas, P. A., Yustanti, W., & Prihanto, A. (2021). Analisa Learning rate dan Batch size Pada Klasifikasi Covid Menggunakan Deep learning dengan Optimizer Adam. *JIEET (Journal Information Engineering and Educational Technology)*, *05*(02), 44-48. <https://doi.org/10.26740/jieet.v5n2.p44-48>
- Saabith, A. S., Vinothraj, T., & Fareez, M. (2020). Popular python libraries and their application domains. *International Journal of Advance Engineering and Research Development*, *7*(11), 18-26.
- Sahli, H. (2020). *An Introduction to Machine Learning*. Wiley: online library. <https://doi.org/10.1002/9781119720492.ch7>
- 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>

- Saputro, I. W., & Sari, B. W. (2020). Uji Performa Algoritma Naïve Bayes untuk Prediksi Masa Studi Mahasiswa. *Creative Information Technology Journal*, 6(1), 1-11. <https://doi.org/10.24076/citec.2019v6i1.178>
- Sen, J. (Ed.). (2021). *Machine Learning - Algorithms, Models and Applications*. IntechOpen. <https://doi.org/10.5772/intechopen.94615>
- Shaker, F., Monadjemi, S. A., Alirezaie, J., & Naghsh-Nilchi, A. R. (2017). A dictionary learning approach for human sperm heads classification. *Computers in Biology and Medicine*, 91, 181–190. <https://doi.org/10.1016/j.combiomed.2017.10.009>
- Sherwood, L. (2012). *Fisiologi manusia : dari sel ke sistem* (6th ed.). EGC.
- Shi, J., Dang, J., Cui, M., Zuo, R., Shimizu, K., Tsunoda, A., & Suzuki, Y. (2021). Improvement of Damage Segmentation Based on Pixel-Level Data Balance Using VGG-Unet. *Applied Sciences*, 11(2), 518. <https://doi.org/10.3390/app11020518>
- Sonavane, R., Ghonge, P., Patil, S. U., Sagale, K. S., & Maha, A. A. (2024). Exploring ResNet101, InceptionV3, and Xception for Modi Script Character Classification. *International Journal of Intelligent Systems and Applications in Engineering*, 12(17s), 117–124. <https://www.ijisae.org/index.php/IJISAE/article/view/4841>
- Sujatmiko, B. M., Yudaningtyas, E., & Mudji Raharjo, P. (2022). Convolution Neural Network Dengan Desain Jaringan Resnet Sebagai Metode Klasifikasi Tumor Kulit. *Jurnal Simantec*, 11(1), 53–64. <https://doi.org/10.21107/simantec.v11i1.14083>
- Suoth, S., Rumende, R. R. H., & Papu, A. (2023). Integritas Membran Spermatozoa Manusia pada Proses Sexing dengan Pemberian Kuning Telur. *JURNAL BIOS LOGOS*, 13(3), 134–140. <https://doi.org/10.35799/jbl.v13i3.52182>
- Thiodorus, G., Prasetya, A., Ardhani, L. A., & Yudistira, N. (2021). Klasifikasi citra makanan/non makanan menggunakan metode Transfer Learning dengan model Residual Network. *Teknologi*, 11(2), 74–83. <https://doi.org/10.26594/teknologi.v11i2.2402>
- Wagle, S. A., Harikrishnan, R., Sampe, J., Mohammad, F., & Md Ali, S. H. (2021). Effect of Data Augmentation in the Classification and Validation of Tomato Plant Disease with Deep Learning Methods. *Traitement Du Signal*, 38(6), 1657–1670. <https://doi.org/10.18280/ts.380609>
- Widiastuti, N. I., Rainarli, E., & Dewi, K. E. (2017). Peringkasan dan Support Vector Machine pada Klasifikasi Dokumen. *JURNAL INFOTEL*, 9(4), 416-421. <https://doi.org/10.20895/infotel.v9i4.312>
- Wijaya, A. E., Swastika, W., & Kelana, O. H. (2021). Implementasi Transfer Learning Pada Convolutional Neural Network Untuk Diagnosis Covid-19 Dan

- Pneumonia Pada Citra X-Ray. *Sainsbertek Jurnal Ilmiah Sains & Teknologi*, 2(1), 10–15. <https://doi.org/10.33479/sb.v2i1.125>
- Yanni, R. M. T., El-Ghitany, N. E.-K., Amer, K., Riad, A., & El-Bakry, H. (2021). A New Model for Image Segmentation Based on Deep Learning. *International Journal of Online and Biomedical Engineering (IJOE)*, 17(07), 28–47. <https://doi.org/10.3991/ijoe.v17i07.21241>
- Yüzkat, M., Ilhan, H. O., & Aydin, N. (2021). Multi-model CNN fusion for sperm morphology analysis. *Computers in Biology and Medicine*, 137, 104790. <https://doi.org/https://doi.org/10.1016/j.compbimed.2021.104790>
- Zegers-Hochschild, F., Adamson, G. D., Dyer, S., Racowsky, C., De Mouzon, J., Sokol, R., Rienzi, L., Sunde, A., Schmidt, L., Cooke, I. D., Simpson, J. L., & Van Der Poel, S. (2017). The international glossary on infertility and fertility care, 2017. *Human Reproduction*, 32(9), 1786–1801. <https://doi.org/10.1093/humrep/dex234>
- Zhu, J., & Song, J. (2020). An Intelligent Classification Model for Surface Defects on Cement Concrete Bridges. *Applied Sciences*, 10(3), 972. <https://doi.org/10.3390/app10030972>